

UNIVERSIDADE FEDERAL DE MINAS GERAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM SANEAMENTO,
MEIO AMBIENTE E RECURSOS HÍDRICOS

ALTERAÇÕES DE PADRÃO DE VAZÃO DECORRENTES DA
OPERAÇÃO DE PEQUENOS APROVEITAMENTOS
HIDRELÉTRICOS EM CASCATA E PREVISÃO DE SÉRIE
HORÁRIA EM AFLUENTES DO PANTANAL

Rafael Pedrollo de Paes

Belo Horizonte
2020

**ALTERAÇÕES DE PADRÃO DE VAZÃO DECORRENTES DA
OPERAÇÃO DE PEQUENOS APROVEITAMENTOS
HIDRELÉTRICOS EM CASCATA E PREVISÃO DE SÉRIE
HORÁRIA EM AFLUENTES DO PANTANAL**

Rafael Pedrollo de Paes

Rafael Pedrollo de Paes

**ALTERAÇÕES DE PADRÃO DE VAZÃO DECORRENTES DA
OPERAÇÃO DE PEQUENOS APROVEITAMENTOS
HIDRELÉTRICOS EM CASCATA E PREVISÃO DE SÉRIE
HORÁRIA EM AFLUENTES DO PANTANAL**

Tese apresentada ao Programa de Pós-graduação em Saneamento, Meio Ambiente e Recursos Hídricos da Universidade Federal de Minas Gerais, como requisito para o título de Doutor em Saneamento, Meio Ambiente e Recursos Hídricos.

Área de concentração: Hidráulica e Recursos Hídricos

Linha de pesquisa: Modelagem de Processos Hidrológicos

Orientador: Dr. Veber Afonso Figueiredo Costa

Co-orientador: Dr. Wilson dos Santos Fernandes

Belo Horizonte

Escola de Engenharia da UFMG

2020

P126a Paes, Rafael Pedrollo de.
Alterações de padrão de vazão decorrentes da operação de pequenos aproveitamentos hidrelétricos em cascata e previsão de série horária em afluentes do Pantanal [recurso eletrônico] / Rafael Pedrollo de Paes. - 2020.
1 recurso online (xi, 183 f. : il., color.) : pdf.

Orientador: Veber Afonso Figueiredo Costa.
Coorientador: Wilson dos Santos Fernandes.

Tese (doutorado) - Universidade Federal de Minas Gerais, Escola de Engenharia.

Apêndices: f. 178-183.

Bibliografia: f. 171-177.
Exigências do sistema: Adobe Acrobat Reader.

1. Engenharia sanitária - Teses. 2. Recursos hídricos - Desenvolvimento - Teses. 3. Barragens e açudes - Teses. 4. Usinas hidrelétricas - Aspectos ambientais - Teses. I. Costa, Veber Afonso Figueiredo. II. Fernandes, Wilson dos Santos. III. Universidade Federal de Minas Gerais. Escola de Engenharia. IV. Título.

CDU: 628(043)



**ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM SANEAMENTO, MEIO AMBIENTE E
RECURSOS HÍDRICOS**

ATA DA DEFESA DE TESE DE **RAFAEL PEDROLLO DE PAES**
NÚMERO DE REGISTRO: 177

Às 13:30 horas do dia 26 de junho de 2020, reuniu-se na Escola de Engenharia da UFMG a Comissão Examinadora de TESE DE DOUTORADO, indicada pelo Colegiado do PROGRAMA DE PÓS-GRADUAÇÃO EM SANEAMENTO, MEIO AMBIENTE E RECURSOS HÍDRICOS, para julgar, em exame final, o trabalho final intitulado:

"Alterações de padrão de vazão decorrentes da operação de pequenos aproveitamentos hidrelétricos em cascata e previsão de série horária em afluentes do Pantanal "

requisito parcial para a obtenção do Grau de DOUTOR em SANEAMENTO, MEIO AMBIENTE E RECURSOS HÍDRICOS, Área de Concentração: HIDRÁULICA E RECURSOS HÍDRICOS

Abrindo a sessão, o Orientador, Prof. Veber Afonso Figueiredo Costa, após dar conhecimento aos presentes o teor das Normas Regulamentares do Trabalho Final, passou a palavra ao candidato para apresentação de seu trabalho. Seguiu-se a arguição pelos examinadores com a respectiva defesa pelo candidato. Logo após, a Comissão se reuniu sem a presença do candidato e do público, para julgamento e expedição do resultado final. Foram atribuídas as seguintes indicações:

BANCA EXAMINADORA	INSTITUIÇÃO	INDICAÇÃO
Prof. Dr. Veber Afonso Figueiredo Costa - Orientador	EHR/UFMG	APROVADO
Prof. Dr. Wilson dos Santos Fernandes	EHR/UFMG	APROVADO
Prof. Dr. Luiz Rafael Palmier	EHR/UFMG	APROVADO
Prof. Dr. Francisco Eustáquio Oliveira e Silva	EHR/UFMG	APROVADO
Prof. Dr. Carlos Henrique Ribeiro Lima	UNB	APROVADO
Prof. Dr. Ibraim Fantin da Cruz	UFMT	APROVADO

Pelas indicações, o candidato foi considerado APROVADO, devendo proceder a pequenas alterações no trabalho, para a sua edição definitiva, a ser entregue no prazo de 2 meses.

O resultado final foi comunicado publicamente ao candidato pelo Presidente da Comissão. Nada mais havendo a tratar, o Presidente encerrou a reunião e lavrou a presente ATA, que será assinada por todos os membros participantes da Comissão Examinadora. Belo Horizonte, 26 de junho de 2020.

Veber Afonso Figueiredo Costa

Luiz Rafael Palmier

Carlos Henrique Ribeiro Lima

Wilson dos Santos Fernandes

Francisco Eustáquio Oliveira e Silva

Ibraim Fantin da Cruz

AGRADECIMENTOS

Tenho muito a agradecer a Deus, por me permitir participar da rede de cooperação que envolve todas as pessoas relacionadas nesta página, e que, felizmente, nos coloca em obediência construtiva aos impositivos da frente e socorro implícito às privações da retaguarda.

À minha família, Amauri, Jandira, Thais, Helton, Bianca, Lucas, tios e primos, que tão solidamente me abrigaram fraternalmente, mesmo que em sua maior parte à distância, e me dão o conforto, e me lembram do porquê e para que eu vim.

Ao professor e orientador Veber Costa, quem me permitiu partilhar um pouco de seu conhecimento, e, definitivamente, abriu caminhos e ofereceu todas as luzes necessárias ao desenvolvimento do trabalho. Gratidão imensa, Veber!

Ao professor e coorientador Wilson Fernandes, quem deu início a essa jornada desde o princípio.

A todos os professores, em especial os que me ministraram disciplinas no SMARH/UFMG: Wilson, Palmier, Márcio, Éber, Nilo, Veber, Julian, Talita e Priscilla.

A todos os amigos que compartilhei o apartamento, que me foram companhia e também ensinadores: Suedson, Thiago, Marcel, Priscila, Devid, Carol e, principalmente, Andhressa.

À Dra. Maria das Graças, psicóloga, cujo trabalho permanente foi essencial para minha saúde.

Aos professores do DESA/UFMT, que me permitiram o afastamento e cobriram minhas atividades para a qualificação docente por período integral, por três anos e meio.

Aos amigos e colegas do SMARH: Lorena, Júlia, Viviane, Dênis, Luiz, Hildelano, Sarah, Mauro, Gustavo, Fernando, Vinícius, Aline, Deyvid, Daniel, Marcel e Fábio.

Aos responsáveis pela disponibilização dos dados de vazão em curto período, por meio do sistema de informações em recursos hídricos, da ANA. Assim como aos responsáveis pela pressão para que essa disponibilidade de dados ocorresse em todo o país.

À banca avaliadora deste trabalho, pela atenção, leitura e tão bem-vindas contribuições.

RESUMO

Aproveitamentos hidrelétricos (AHs) de pequeno porte e com barragem de nível têm sido construídos em diversos países, com o argumento de promoverem pouca interferência nos sistemas hídricos. No entanto, recentes estudos questionam sua implantação de forma indiscriminada, especialmente quando esses AHs são operados em ecossistemas com frágil sensibilidade ambiental. Nesse sentido, o presente estudo se direciona para a compreensão do comportamento hídrico de curto período em um sistema de cascata de pequenos AHs.

Primeiramente, foram estudadas as alterações do padrão de vazão em estações fluviométricas intermediárias aos AHs. Foram utilizadas abordagens no domínio do tempo e técnicas de processamento de sinais no domínio multirresolução tempo-frequência, via transformada *wavelet* contínua. Em segundo momento, foram propostos modelos de regressão não-linear para previsão de séries horárias de vazão, visando a implantação de um sistema de alertas de curto período, com enfoque nas vazões mínimas. Para tanto, foram desenvolvidos modelos de redes neurais artificiais, técnica relativamente conhecida no meio científico, e de regressão por Processos Gaussianos, ainda em amplo desenvolvimento, sobretudo no emprego em recursos hídricos. Foram verificadas a viabilidade de decomposição de série temporal via transformada *wavelet* discreta e via decomposição por modos empíricos. A previsão de vazões ocorreu entre estações adjacentes, com variabilidade temporal e com variabilidade espacial na bacia.

A aplicação da metodologia foi na bacia hidrográfica do rio Jauru, Mato Grosso, região de borda de planície de inundação do Pantanal. Nessa bacia, há operação de seis AHs e monitoramento horário de vazões por meio de oito estações telemétricas. O primeiro grupo de resultados apontou indícios de distúrbios dos padrões naturais de vazão, em geral, com aumento de oscilação dos hidrogramas, intensificação dos menores ciclos e ruptura dos maiores ciclos. No que compete à previsão de vazões, os modelos híbridos de regressão por Processos Gaussianos combinados às séries decompostas por transformada *wavelet* discreta demonstraram maior robustez. Consoante à identificação das perturbações dos ciclos de vazão na primeira etapa, os modelos de previsão se mostraram aptos a reproduzir as séries, especialmente nas cinco estações de montante. Não obstante algumas limitações na previsão das três séries de jusante, os resultados podem servir de subsídio à construção de um sistema de alertas de vazões críticas, viabilizando a melhor compatibilidade dos interesses no uso dos recursos hídricos.

ABSTRACT

Run-of-river small hydropower plants (SHP) have been built in many countries, based on the argument that they exert little influence on water resources systems. Nevertheless, recent studies have questioned their indiscriminate implementation, especially when these SHP are operated in ecosystems acknowledged for being fragile environments. In this regard, the present study aims to understand the short-term behavior of the streamflow signals in a system compounded by hydropower plants in a cascade arrangement.

First, by taking into account streamgauges placed in the intermediate course of the river, one may study the effects of SHPs on the discharge cyclic patterns. For this purpose, the used approaches were the analysis of the hydrographs by the time domain and handling the signal processing technique with the multiresolution time-frequency domain, by the continuous wavelet transform. In a second moment, nonlinear regression models for forecasting hourly time series were developed, aiming at implementing a short-period warning system, focusing on minimum discharges. Therefore, the constructed models were the neural network, a relatively known technique in the scientific community, and the Gaussian Processes regression, which is still in broad development, mainly with regard to its usage in water resources problems. The viability of the time series decomposition was verified via discrete wavelet transform and via empirical mode decomposition. The univariate streamflow forecasting occurred with adjacent streamgauges, and also with the temporal and the spatial variability at the basin.

Application of the methods were conducted at the Jauru river basin, Brazilian state of Mato Grosso, in the border region of the Pantanal wetland, where there are six SHPs and eight streamgauges under operation. The first group of results evidenced disturbance in the natural discharge patterns with increasing oscillations, intensifying the smallest cycles and dissolving the largest ones. With respect to streamflow forecasting, the hybrid model combining the Gaussian Processes and the wavelet decomposition demonstrated greater robustness. According to the identification of the disrupting of streamflow cycles in the first stage, the forecasting models were, to some extent, able of reproducing the series, especially at the five upstream gauges. Despite some limitations with the three downstream series forecasting, the results may serve as a subsidy for the creation of a warning system of critical discharges at the basin, enabling a better trade-off between the interests with the use of the water resources.

SUMÁRIO

LISTA DE FIGURAS.....	VI
LISTA DE TABELAS.....	IX
LISTA DE SIGLAS E ABREVIATURAS.....	XI
1 INTRODUÇÃO	1
2 OBJETIVOS.....	8
2.1 Objetivo geral	8
2.2 Objetivos específicos	8
3 PROPOSTA METODOLÓGICA.....	9
3.1 Análise das séries temporais no domínio tempo-frequência – Transformada Wavelet.....	11
3.1.1 Transformada <i>Wavelet</i> Contínua	16
3.1.1.1 Análise univariada de séries temporais – WPS	19
3.1.1.2 Análise bivariada de séries temporais – WCS e WCO	21
3.1.1.3 Interpretações gerais da TWC em um escalograma	25
3.2 Decomposição de séries temporais para alimentação de modelos de previsão	26
3.2.1 Transformada <i>Wavelet</i> Discreta (<i>TWD</i>).....	27
3.2.2 Decomposição por modos empíricos (EMD)	33
3.3 Modelos de aprendizado de máquina para previsão de séries temporais	37
3.3.1 Redes Neurais Artificiais (RNA).....	40
3.3.1.1 Neurônio artificial	40
3.3.1.2 Topologia, arquitetura e processos de treinamento da rede neural artificial	44
3.3.1.3 Sistemas variantes no tempo.....	48
3.3.2 Regressão por Processos Gaussianos (RPG)	51
3.3.3 Medidas de desempenho de modelos de previsão.....	60
4 APLICAÇÃO DO MÉTODO.....	63
4.1 Área de estudo	63
4.1.1 Aproveitamentos hidrelétricos em operação.....	66
4.1.2 Estações telemétricas de monitoramento de vazões.....	68

4.2	Alteração nos padrões de vazão	70
4.2.1	Descrição dos dados de vazão na BHJ	71
4.2.2	Efeitos no domínio do tempo em escala horária	74
4.2.3	Efeitos nos ciclos de vazão no domínio tempo-frequência em escala diária – TWC.....	84
4.2.3.1	Potência espectral <i>wavelet</i> – WPS.....	85
4.2.3.2	Coerência <i>wavelet</i> – WCO	92
4.2.4	Comentários gerais sobre as alterações nos padrões de vazão	99
4.3	Modelos de previsão de vazão.....	103
4.3.1	Descrição, organização e processamento dos dados para aplicação nos modelos de regressão	103
4.3.2	Previsão de vazão entre séries de estações adjacentes	113
4.3.2.1	Estações ST1-ST2.....	116
4.3.2.2	Estações ST2-ST3.....	120
4.3.2.3	Estações ST3-ST4.....	123
4.3.2.4	Estações ST4-ST5.....	126
4.3.2.5	Estações ST5-ST6.....	128
4.3.2.6	Estações ST6-ST7.....	131
4.3.2.7	Estações ST7-ST8.....	135
4.3.2.8	Resumo da previsão de vazões entre séries de estações adjacentes	138
4.3.3	Previsão de vazão entre séries com variabilidade temporal	143
4.3.4	Previsão de vazão considerando variabilidade espacial	150
4.3.5	Comentários gerais sobre os modelos de previsão de vazão	161
5	CONCLUSÕES.....	164
6	RECOMENDAÇÕES.....	168
7	REFERÊNCIAS BIBLIOGRÁFICAS	171
APÊNDICE A: COMPARAÇÃO ENTRE COERÊNCIAS WAVELET COM VAZÕES DIMENSIONALIZADAS E ADIMENSIONALIZADAS PELA ÁREA DA BACIA		178
APÊNDICE B: SÉRIES TEMPORAIS DECOMPOSTAS POR TRANSFORMADA WAVELET DISCRETA (TWD) E POR DECOMPOSIÇÃO EM MODOS EMPÍRICOS (EMD)		180

LISTA DE FIGURAS

Figura 3.1: Fluxograma metodológico da pesquisa	9
Figura 3.2: Representação gráfica de: (a) transformada de Fourier, (b) transformada de Fourier de tempo curto e (c) transformada <i>wavelet</i>	13
Figura 3.3: Exemplo de função <i>wavelet</i> Morlet	18
Figura 3.4: Estrutura de decomposição dos sinais pelos filtros passa-alta e passa-baixa da transformada <i>wavelet</i> discreta	30
Figura 3.5: Diagrama esquemático de um modelo híbrido para previsão de vazões	31
Figura 3.6: Exemplo de função <i>wavelet</i> Daubechey-8	33
Figura 3.7: Processo de decomposição por modos empíricos para obter a IMF $m_1(t)$	36
Figura 3.8: Esquema de um único neurônio artificial	41
Figura 3.9: Funções de ativação aplicadas nos neurônios artificiais	43
Figura 3.10: RNA <i>Perceptron</i> com arquitetura <i>feedforward</i> e uma camada intermediária	45
Figura 3.11: Estrutura RNA <i>Perceptron</i> com arquitetura recorrente e uma camada intermediária com n_1 neurônios	46
Figura 3.12: Domínios de definição e de operação de RNA <i>Perceptron</i> de múltiplas camadas aplicado em problemas de sistemas dinâmicos	49
Figura 3.13: Topologia de uma RNA com múltiplas camadas com saídas realimentadas às entradas em sistemas dinâmicos	50
Figura 3.14: Modelo estruturado da RPG	55
Figura 3.15: Trajetórias <i>a priori</i> de funções aleatórias traçadas por Processos Gaussianos	57
Figura 3.16: Amostras de funções da distribuição <i>a posteriori</i> de um Processo Gaussiano	58
Figura 3.17: Distribuição <i>a posteriori</i> de uma RPG ajustada pela função <i>kernel</i> condicionada aos pontos observados	58
Figura 4.1: Bacia hidrográfica do rio Jauru	65
Figura 4.2: Perfil vertical e diagrama unifilar da BHJ	65
Figura 4.3: Gráficos de dispersão, histogramas e coeficientes de correlação entre as vazões horárias das oito estações telemétricas da bacia do rio Jauru	71
Figura 4.4: PACF das séries de log-vazões para as séries diárias	73
Figura 4.5: Vazões horárias e diárias nas estações fluviométricas da BHJ	76
Figura 4.6: Exemplo de série com grande amplitude em curto período (ST7)	77
Figura 4.7: Contagem de inflexões do hidrograma para recessão e ascensão	78
Figura 4.8: Quantidade e proporção de inflexões dos hidrogramas na BHJ	79
Figura 4.9: Amplitude relativa de vazões, para cada estação telemétrica (\log_2)	81

Figura 4.10: Amplitudes relativas de vazões, para cada defasagem temporal	83
Figura 4.11: Vazão e WPS – ST1	86
Figura 4.12: Vazão e WPS – ST2	86
Figura 4.13: Vazão e WPS – ST3	87
Figura 4.14: Vazão e WPS – ST5	88
Figura 4.15: Vazão e WPS – Jusante UHE Jauru	88
Figura 4.16: Vazão e WPS – ST6	89
Figura 4.17: Vazão e WPS – ST7	89
Figura 4.18: Vazão e WPS – ST8	89
Figura 4.19: Vazão e WPS da estação Porto Espiridião 1969 a 1970	91
Figura 4.20: Vazão e WPS da estação Porto Espiridião 1994 a 1995	91
Figura 4.21: Coerência <i>wavelet</i> – ST1 x ST2	93
Figura 4.22: Coerência <i>wavelet</i> – ST2 x ST3	94
Figura 4.23: Coerência <i>wavelet</i> – ST3 x ST5	95
Figura 4.24: Coerência <i>wavelet</i> – ST5 x Jusante UHE Jauru	95
Figura 4.25: Coerência <i>wavelet</i> – Jusante UHE Jauru x ST6	95
Figura 4.26: Coerência <i>wavelet</i> – ST6 x ST7	96
Figura 4.27: Coerência <i>wavelet</i> – ST7 x ST8	96
Figura 4.28: Coerência <i>wavelet</i> – ST2 x ST8	99
Figura 4.29: Séries temporais de vazão particionadas em treino e teste	105
Figura 4.30: Série de vazões da ST2 e suas componentes espectrais por meio da TWD	107
Figura 4.31: Série de vazões da ST2 e funções de modo intrínseco geradas pela EMD	108
Figura 4.32: PACF das séries de vazão horárias do trecho de treino	110
Figura 4.33: Resultados da previsão ST1-ST2 (RPG + S/D): a) Hidrogramas observado e calculados; b) Dispersão dos erros; c) Gráfico entre as vazões observadas e previstas	119
Figura 4.34: Resultados da previsão ST2-ST3 (RNA + S/D): a) Hidrogramas observado e calculados; b) Dispersão dos erros; c) Gráfico entre as vazões observadas e previstas	122
Figura 4.35: Resultados da previsão ST3-ST4 (RNA + EMD): a) Hidrogramas observado e calculados; b) Dispersão dos erros; c) Gráfico entre as vazões observadas e previstas	125
Figura 4.36: Resultados da previsão ST4-ST5 (RPG + TWD): a) Hidrogramas observado e calculados; b) Dispersão dos erros; c) Gráfico entre as vazões observadas e previstas	128
Figura 4.37: Resultados da previsão ST5-ST6 (RNA + S/D): a) Hidrogramas observado e calculados; b) Dispersão dos erros; c) Gráfico entre as vazões observadas e previstas	131
Figura 4.38: Resultados da previsão ST6-ST7 (RPG + TWD): a) Hidrogramas observado e calculados; b) Dispersão dos erros; c) Gráfico entre as vazões observadas e previstas	134

Figura 4.39: Resultados da previsão ST7-ST8 (RPG + TWD): a) Hidrogramas observado e calculados; b) Dispersão dos erros; c) Gráfico entre as vazões observadas e previstas	137
Figura 4.40: Valores de NSEiQ para previsão de vazões com variabilidade temporal	146
Figura 4.41: Valores de MAE para previsão de vazões com variabilidade temporal	147
Figura 4.42: Valores de R² para previsão de vazões com variabilidade temporal	148
Figura 4.43: Visualização gráfica de NSEiQ na previsão com variabilidade espacial	154
Figura 4.44: Visualização gráfica do MAE na previsão com variabilidade espacial	155
Figura 4.45: Visualização gráfica do R² na previsão com variabilidade espacial	157

LISTA DE TABELAS

Tabela 3.1: Funções de ativação em redes neurais artificiais	42
Tabela 3.2: Funções <i>kernel</i> para regressão em Processos Gaussianos	56
Tabela 4.1: Características do complexo de AHS em operação na bacia do rio Jauru	67
Tabela 4.2: Estações telemétricas na bacia do rio Jauru	69
Tabela 4.3: Proporção de dados horários existentes na série de 11060 horas	72
Tabela 4.4: Variâncias das vazões horárias e diárias nas estações telemétricas	76
Tabela 4.5: Estatísticas descritivas das séries horárias para os segmentos de treino e teste	106
Tabela 4.6: Modelos de regressão	109
Tabela 4.7: Conjunto de melhores ajustes e métricas de desempenho (RNA ST1-ST2)	117
Tabela 4.8: Conjunto de melhores ajustes e métricas de desempenho (RPG ST1-ST2)	118
Tabela 4.9: Conjunto de melhores ajustes e métricas de desempenho (RNA ST2-ST3)	120
Tabela 4.10: Conjunto de melhores ajustes e métricas de desempenho (RPG ST2-ST3)	121
Tabela 4.11: Conjunto de melhores ajustes e métricas de desempenho (RNA ST3-ST4)	123
Tabela 4.12: Conjunto de melhores ajustes e métricas de desempenho (RPG ST3-ST4)	124
Tabela 4.13: Conjunto de melhores ajustes e métricas de desempenho (RNA ST4-ST5)	126
Tabela 4.14: Conjunto de melhores ajustes e métricas de desempenho (RPG ST4-ST5)	127
Tabela 4.15: Conjunto de melhores ajustes e métricas de desempenho (RNA ST5-ST6)	129
Tabela 4.16: Conjunto de melhores ajustes e métricas de desempenho (RPG ST5-ST6)	129
Tabela 4.17: Conjunto de melhores ajustes e métricas de desempenho (RNA ST6-ST7)	132
Tabela 4.18: Conjunto de melhores ajustes e métricas de desempenho (RPG ST6-ST7)	133
Tabela 4.19: Conjunto de melhores ajustes e métricas de desempenho (RNA ST7-ST8)	135
Tabela 4.20: Conjunto de melhores ajustes e métricas de desempenho (RPG ST7-ST8)	136
Tabela 4.21: Resultados de NSEiQ teste	140
Tabela 4.22: Resultados de MAE teste	141
Tabela 4.23: Resultados de R^2 teste	141
Tabela 4.24: Configuração de ajuste dos modelos RPG para previsão de vazão com variabilidade temporal de 1h, 3h, 6h, 12h e 24h	144
Tabela 4.25: Valores de NSEiQ na fase de teste segundo o adiantamento temporal	145
Tabela 4.26: Valores de MAE na fase de teste segundo o adiantamento temporal	147
Tabela 4.27: Valores de R^2 na fase de teste segundo o adiantamento temporal	148
Tabela 4.28: Valores NSEiQ para previsão de vazão com variabilidade espacial	153

Tabela 4.29: Valores de MAE para previsão de vazão com variabilidade espacial	155
Tabela 4.30: Valores de R² para previsão de vazão com variabilidade espacial	156
Tabela 4.31: Desempenho dos modelos com o uso entrada das séries de montante em comparação ao uso exclusivo das séries de jusante, segundo o critério de NSEiQ	159
Tabela 4.32: Desempenho dos modelos com o uso entrada das séries de montante em comparação ao uso exclusivo das séries de jusante, segundo o critério de MAE	159
Tabela 4.33: Desempenho dos modelos com o uso entrada das séries de montante em comparação ao uso exclusivo das séries de jusante, segundo o critério de R²	160

LISTA DE SIGLAS E ABREVIATURAS

- AH** – Aproveitamento Hidrelétrico
- ANA** – Agência Nacional de Águas
- ANEEL** – Agência Nacional de Energia Elétrica
- AR[p]** – Processo autorregressivo de ordem “p”.
- ARIMA** – Autoregressive Integrated Moving Average
- BHJ** – Bacia Hidrográfica do Rio Jauru
- CGH** – Central Geradora Hidrelétrica
- COI** – Cone de influência
- EMD** – *Empirical Mode Decomposition* (Decomposição de Modos Empíricos)
- IMF** – Intrinsic Mode Functions (Funções de Modo Intrínseco)
- ONS** – Operador Nacional do Sistema
- PACF** – *Partial Autocorrelation Function* (Função de Autocorrelação Parcial)
- PCH** – Pequena Central Hidrelétrica
- RHP** – Região Hidrográfica do Rio Paraguai
- RNA** – Redes Neurais Artificiais
- RPG** – Regressão por Processos Gaussianos
- SIGEL** – Sistema de Informações Geográficas do Setor Elétrico
- ST** – Estação telemétrica de monitoramento vazões
- UHE** – Usina Hidrelétrica
- TF** – Transformada de Fourier
- TFTC** – Transformada de Fourier de tempo curto
- TW** – Transformada *Wavelet*
- TWC** – Transformada *Wavelet* Contínua
- TWD** – Transformada *Wavelet* Discreta
- WPS** – *Wavelet Power Spectrum* (Potência Espectral *Wavelet*)
- WCO** – *Wavelet Coherence* (Coerência *Wavelet*)

1 INTRODUÇÃO

A principal razão para que a produção de energia elétrica no Brasil seja majoritariamente de origem hídrica é a grande disponibilidade de água e de território. Em segunda instância, o domínio de tecnologia e a valorização da geração de energia por fontes renováveis impulsionaram essa matriz. Com tais fatores, centenas de aproveitamentos hidrelétricos (AHs) foram construídos durante o século XX, muitos deles de grande porte.

Nos últimos anos, contudo, as exigências para produção energética evoluíram para a necessidade de redução dos tempos de construção e de retorno do investimento, além de minimização de impactos sociais e ambientais. Isso deu sustentação à criação de um aparato jurídico e fiscal, que permitiram o aumento expressivo na oferta de energia, e viabilizaram a guinada para implantação de novos AHs no Brasil. Como resultado, de 2002 a 2020, o número de empreendimentos desse tipo no país passou de 433 para 1368 (ANEEL, 2002; ANEEL, 2020), grande parte deles pela operação das pequenas centrais hidrelétricas (PCHs) assegurada por barragens de nível, ou “a fio d’água”. De fato, a diversificação da matriz energética em torno de empreendimentos de menores escalas, tais como as PCHs, têm sido observada em muitos países (COUTO & ODEN, 2018).

Embora não haja definição comum internacional que conceitue uma pequena central hidrelétrica, a legislação brasileira considera PCHs os aproveitamentos hidrelétricos com produção entre 5MW e 30MW, desde que a área alagada do seu reservatório seja menor que 13 km² ou, nos casos em que maiores áreas sejam necessárias, a regularização máxima seja semanal (Resolução ANEEL 875/2020). Visto que a carga hidráulica entre montante e jusante das barragens de nível é geralmente reduzida e o tempo de residência no reservatório é curto, a operação desse tipo de AHs, em teoria, não afeta significativamente os hidrogramas a jusante. Com essa justificativa, o licenciamento ambiental tem se tornado mais fácil para essa classe de empreendimentos em muitos estados. Entretanto, estudos recentes sugerem que, em oposição a essa hipótese, os regimes de vazão natural podem ser perturbados também pelos AHs a fio d’água, quer por PCHs ou empreendimentos maiores.

Nesse contexto, são citados os efeitos de *hydropeaking*, ou seja, a alteração artificial do comportamento de vazão para garantir as operações de nível de reservatório, a fim de compatibilizar a disponibilidade de água com a demanda hidroenergética. Esses efeitos ocorrem

mesmo em empreendimentos com barragem de nível, e podem ter ciclos de pequena escala, incluindo a subdiária (HAAS *et al.* 2014; BRUDER *et al.*, 2016; HAUER *et al.*, 2016). Como exemplos de implicações promovidas pelos AHs, são citadas alterações nos picos e recessões dos hidrogramas. Por consequência, têm sido relatadas intervenções na dinâmica de transporte de sedimentos e nutrientes, bem como nas condições de desenvolvimento da fauna e flora aquáticas, o que pode reduzir a conectividade entre corpo hídrico e planície fluvial, e, com efeito, implicar a perda de serviços ecossistêmicos (LIU *et al.*, 2014; FANTIN-CRUZ *et al.*, 2015; KUMAR & KATOCH, 2015; OLIVEIRA *et al.*, 2019; CAMPOS *et al.*, 2020).

Interferências no sistema hídrico comumente são estudadas com base em registros de estações fluviométricas em grandes bacias, monitoradas durante décadas. Inapropriadamente, em muitas situações, esses dados servem de base para estudos hidrológicos que fundamentam projetos executivos de muitas obras de engenharia, mesmo para empreendimentos em bacias menores (TONGAL *et al.*, 2017). Desse modo, é comum que essas medições não compreendam escalas de discretização temporal suficientes para o estudo das alterações nas vazões de curta duração, e em cascata, visto que os pequenos AHs tendem a ser instalados em bacias pequenas, e as estações fluviométricas convencionais em bacias maiores.

Na tentativa de investigar os efeitos das barragens de nível nos regimes de vazão, técnicas distintas têm sido propostas. Há pesquisas baseadas na análise de frequência de longas séries (AYALEW *et al.*, 2017), nas alterações das curvas de permanência de vazões (FANTIN-CRUZ *et al.*, 2015) e na avaliação de índices de alteração hidrológica em escalas diárias, sazonais ou anuais (RICHTER *et al.*, 1996; KIBLER & ALIPOUR, 2017). Em geral, essas abordagens se fundamentam na comparação entre registros do período anterior à construção da barragem com o período durante a operação do AH, e utilizam séries históricas relativamente longas. Por esse motivo, autores como Fantin-Cruz *et al.*, (2015) sugerem um estudo que compare séries de estações de montante e jusante de um AH de modo pareado. Dessa forma, a variabilidade temporal é eliminada, o que permite isolar a variabilidade espacial entre as séries. Em adição ao exposto, os métodos das pesquisas mencionadas costumam se limitar à análise das séries temporais no domínio do tempo, e não informam sobre as alterações potenciais dos fenômenos cíclicos relacionados ao comportamento hídrico (WHITE *et al.*, 2005; TONGAL *et al.*, 2017; CIRIA *et al.*, 2019).

Séries de vazão em condições naturais são constituídas pela sobreposição de múltiplos componentes associados a ciclos distintos, que agregam características periódicas ou quase periódicas dos fenômenos de escoamento superficial. Esses ciclos sobrepostos desempenham importante papel nas atividades ecossistêmicas, incluindo as humanas (JUNK *et al.*, 1989; LIU *et al.*, 2014; KUMAR & KATOCH, 2015; POFF & SCHIMIDT, 2016). Sabe-se que as barragens têm o potencial de perturbar esses ciclos ou introduzir novos comportamentos não relacionados aos regimes hidrológicos naturais, o que influencia o padrão hídrico a jusante de reservatórios (WHITE *et al.*, 2005; ZHANG *et al.*, 2018, CIRIA *et al.*, 2019). Esse fato confere grande importância ao estudo das periodicidades e da previsibilidade das séries de vazão, especialmente em bacias com potencial para alteração do comportamento natural, como aquelas sob efeito de barragens.

Os impactos de grandes reservatórios nas oscilações naturais de vazão são relativamente bem conhecidos. Normalmente, a regularização está associada a alterações nas periodicidades de baixa frequência, como as anuais, ou ainda maiores (WHITE *et al.*, 2005). De maneira similar, pequenas barragens também podem modificar as características periódicas e perturbar alguns dos componentes espectrais do sinal natural. No entanto, ao contrário dos grandes empreendimentos, os pequenos reservatórios tendem a alterar componentes de alta frequência (AYALEW *et al.*, 2017; KIBLER & ALIPOUR, 2017). Isso pode ocorrer em virtude de uma combinação de fatores associados ao comportamento operacional das turbinas e à defasagem temporal da passagem de água, que é limitada pela capacidade de armazenamento. De certa maneira, tal efeito impõe considerável característica antrópica ao padrão de vazões.

Pesquisas que quantificam as implicações provocadas por pequenos reservatórios se encontram nas etapas iniciais de desenvolvimento (HAAS *et al.*, 2014; FANTIN-CRUZ *et al.*, 2015; AYALEW *et al.*, 2017, LU *et al.*, 2018; ANA; 2019; CAMPOS *et al.*, 2020). Ainda que muitos aspectos relacionados a ciclos de vazão de longo período, como as distribuições das médias anuais, sejam razoavelmente preservados na operação de usinas a fio de água, perturbações ocasionadas por pequenos reservatórios têm sido observadas em relação às oscilações de menor duração e ao desempenho de previsão.

Como exemplos de levantamentos, Fantin-Cruz *et al.* (2015) detectaram que a operação de um reservatório de pequena capacidade de regularização em uma região de transição entre planalto e planície de inundação está relacionada a fortes alterações nas vazões mínimas de curta duração

(um, três e sete dias), a vazões máximas trimestrais e ao número de inflexões. Ao pesquisar uma bacia com reservatórios ainda menores, Liu *et al.* (2014) identificaram reduções nas vazões máximas, no transporte de sedimentos e de nutrientes a jusante. Por sua vez, Zhang *et al.* (2018) encontrou alguma dificuldade para previsão de vazões diárias utilizando redes neurais artificiais em um sistema hídrico, quando comparados trechos fluviais sob influência de diversos reservatórios. Um minucioso estudo coordenado pela ANA (2019) indicou que, em escala diária, as influências dos pequenos aproveitamentos hidrelétricos nos hidrogramas frequentemente não foram expressivas. No entanto, por meio de modelos hidrológicos aplicados a séries em escala subdiária, foram identificados efeitos de *hydropeaking* com potencial de alterações no regime natural em extensão de até 100km do percurso fluvial a jusante de barragens de pequenas proporções, e maiores extensões em casos específicos. Essas observações foram encontradas em grande parte dos maiores rios da zona de transição entre planalto e planície de inundação do Pantanal.

As oscilações dos pulsos altos e baixos compõem o arranjo morfológico particular da calha fluvial. Isso cria oportunidades para a consolidação de matas ripárias e também as estratégias das vidas aquáticas ou das que dependem delas. Em condições de perturbações hídricas, essas comunidades passam a conviver com um regime hidrológico modificado (POFF & SCHIMIDT, 2016). É vastamente aceito que as planícies de inundação e as áreas marginais são particularmente vulneráveis às alterações hidrológicas (JUNK *et al.*, 1989). Esses aspectos justificam o planejamento estratégico para auxiliar escolhas sobre onde determinados empreendimentos podem ser operados e em quais condições, com vistas a mitigar danos ambientais e sociais em geral. No que concerne à minimização dessas alterações, um bom princípio é conhecer os comportamentos naturais da biota em relação aos ciclos de alimentação e reprodução, a fim de respeitar suas necessidades.

Em adição ao exposto, grande parte dos estudos sobre barragens de nível compreende uma única estrutura, ignorando possíveis perturbações cumulativas quando um conjunto de AHs é operado em série (FENCL *et al.*, 2015; KIBLER & ALIPOUR, 2017). No entanto, para aproveitar ao máximo o potencial hidrelétrico, as PCHs são frequentemente alocadas em cascata. Acrescenta-se que não existem regras gerais para definir distâncias adequadas entre dois AHs que assegurem a restauração das condições naturais do escoamento, em decorrência

da predominância das contribuições laterais (FENCL *et al.*, 2015; KUMAR & KATOCH, 2015; COUTO & ODEN, 2018).

Estudos que contemplem os fenômenos cíclicos e permitam comparar as periodicidades das séries de vazão podem ser abordados com auxílio de análise espectral, por meio de técnicas como a *wavelet* (ou ondaletas, como alternativa para o português). Essas estratégias permitem identificar a variabilidade das oscilações no tempo, a não-estacionariedade dos processos estocásticos que originam o sinal de vazão ou mesmo pontos de ruptura (*breakpoints*) sobre o hidrograma natural (WHITE *et al.*, 2005; TONGAL *et al.* 2017, CIRIA *et al.*, 2019). A abordagem espectral permite ainda decompor a série em subsinais de frequências distintas. Com efeito, tal medida auxilia a extração de características inerentes ao comportamento hidrológico da série e incorpora informações que contribuem na descrição de um modelo matemático para previsão de vazões (SHOAIB *et al.*, 2016, ZHANG *et al.*, 2018).

A proposta do planejamento de ações de um sistema qualquer é permitir desenvolver procedimentos operativos de forma que haja uma expectativa sobre as ocorrências futuras a partir de práticas executadas no momento atual, e assim reduzir implicações ocasionais. Nesse sentido, a previsão hidrológica permite antecipar a resposta do sistema hídrico quando sujeito a determinados efeitos. Isso favorece a tomada de decisões em escala de bacia hidrográfica, possibilitando, por exemplo, a criação de sistemas de alerta que previnam vazões críticas indesejáveis por meio de protocolos que regulamentem as ações efetuadas a montante.

Nesse sentido, atenção crescente tem sido dada a modelos aplicados em circunstâncias tais que a acurácia da previsão de uma série temporal é prioridade em relação à descrição particular do processo físico, sem qualquer hipótese *a priori* acerca de sua estrutura. Esses modelos são comumente denominados “modelos orientados por dados” (*data-driven models*), os quais são estudados amplamente na literatura científica (SOLOMATINE & OSTFELD, 2008; MAIER *et al.*, 2010; NOURANI *et al.*, 2014; MOSAVI *et al.* 2018; JAIN *et al.*; 2018). Dentro desse contexto, modelos de previsão de vazão de curto prazo baseados em inteligência artificial, especificamente os de aprendizado de máquina (ou *machine learning*), se destacaram nos últimos anos. Modelos como esses, sobretudo associados a técnicas de pré-processamento de sinais, como as decomposições de séries, têm sido empregados em dados cujas características contemplem eventos irregularmente distribuídos e com fenômenos locais em diferentes

frequências (TIWARI & CHATTERJEE, 2010; MAHESWARAN & KHOSA 2012; ZHANG *et al.*, 2018), o que serve como justificativa para o seu uso em sistemas com operação de AHs.

Um aspecto importante é que, na maior parte das publicações voltadas a modelos de regressão com previsão de descargas hídricas, os esforços são concentrados à modelagem sobre séries hidrológicas cujos comportamentos sejam variantes apenas em relação ao tempo (ZHANG *et al.*, 2018). De tal forma, esses trabalhos se furtam da análise com variação espacial que envolva diferentes pontos em uma bacia hidrográfica. Além disso, um número reduzido de pesquisas lida com séries históricas subdiárias, tais como a horária (MOSAVI *et al.* 2018), especialmente que considerem interferências de operações de aproveitamentos hidrelétricos em cascata em um sistema hídrico.

Tendo em vista a esperada forte estrutura de correlação entre as séries de vazão nas diversas estações de monitoramento da bacia, acredita-se a construção de modelos alimentados exclusivamente por dados vazão seja suficiente. Essa adoção permite limitar a complexidade dos modelos de previsão, ao dispensar quaisquer outras informações relativas a séries hidroclimatológicas ou sobre particularidades do processo físico que envolve os AHs, os quais normalmente não são de fácil acesso.

A aplicação dos métodos desenvolvidos foi na bacia hidrográfica do rio Jauru, localizada em Mato Grosso, a montante da planície de inundação do Pantanal, bioma com significativa sensibilidade ecossistêmica e de grande dependência das oscilações fluviais. Naturalmente, essas oscilações promovem o intercâmbio rio-planície-rio de nutrientes, sedimentos e condições de vida (JUNK *et al.*, 1989; CUNHA & JUNK, 2015). Com isso em vista, no corrente trabalho é apresentada uma contribuição metodológica associada à proposta de resolução de um problema específico de grande relevância.

Os fatores expostos no decorrer deste capítulo introdutório expõem a necessidade de trabalhos que incitem originalidade para lidar com o problema levantado. Ao apresentar resultados que apontam situações de interferências de curta duração nos ciclos de vazão em diferentes escalas, este trabalho pode ser útil na compreensão de critérios para instalação e operação de AHs com características similares. Dessa forma, os dois principais elementos de inovação da presente pesquisa estão relacionados a interferências hidrológicas ocasionadas pela operação de pequenos aproveitamentos hidrelétricos instalados em cascata com base em séries de vazão de

curto prazo. São eles: (i) identificação de alteração de padrões de escoamento; e (ii) desenvolvimento de métodos de previsão de vazões que considere uma estrutura de correlação temporal e espacial na bacia. Esses dois elementos ganham importância ao vislumbrar um futuro sistema de alerta de vazões que evite comportamentos indesejados a cada segmento fluvial no intermédio entre dois AHs e a jusante do complexo de empreendimentos, subsidiando a tomada de decisões sobre medidas operacionais na bacia. Evidentemente, as respostas esperadas com a abordagem proposta para esta tese de doutorado vão ao encontro de uma tentativa de coordenar os usos dos recursos hídricos para a produção hidroenergética e também para atender os serviços ecossistêmicos.

O texto está organizado em sete capítulos, que podem se apresentar subdivididos em tópicos, itens e subitens. Sua estrutura se mostra conforme segue:

- Capítulo 1 – Introdução: contextualiza o problema objeto da presente pesquisa e insere ao leitor as abordagens metodológicas a serem empregadas;
- Capítulo 2 – Objetivos: apresenta os objetivos gerais e específicos;
- Capítulo 3 – Proposta metodológica: explica o fluxograma metodológico da pesquisa. Além disso, explana sobre a fundamentação teórica e o desenvolvimento da metodologia empregada no estudo das alterações dos ciclos de vazão, tanto quanto nos modelos de regressão não-linear para previsão de séries temporais;
- Capítulo 4 – Aplicação do método: descreve a área de estudo e as informações dos dados utilizados. Em seguida, são apresentados os resultados referentes à identificação de alterações de vazão e à previsão de séries temporais, conforme a proposição da pesquisa;
- Capítulo 5 – Conclusões: são apresentadas as conclusões sumárias do trabalho
- Capítulo 6 – Recomendações: a partir da experiência obtida com o presente trabalho, são recomendadas algumas abordagens para desenvolvimentos em trabalhos futuros; e
- Capítulo 7 – Referências bibliográficas.

2 OBJETIVOS

2.1 *Objetivo geral*

Desenvolver um método para avaliação de alterações dos padrões de vazão e previsão de séries temporais de curta duração decorrentes da operação de pequenos aproveitamentos hidrelétricos dispostos em cascata.

2.2 *Objetivos específicos*

- Identificar alterações nos padrões de vazão entre estações a jusante dos barramentos, por meio de indicadores referentes ao domínio do tempo, para séries temporais em escala horária;
- Identificar alterações no comportamento cíclico de vazões entre estações a jusante dos barramentos, pela abordagem do domínio multirresolução tempo-frequência, para séries temporais em escala diária;
- Avaliar técnicas de regressão não-linear aplicadas a séries de vazões horárias de estações telemétricas adjacentes, considerando alternativas de decomposição de sinais nas entradas dos modelos de previsão;
- Avaliar os modelos de previsão de séries temporais considerando diferentes antecipações em escala horária entre os pares de estações; e
- Avaliar os modelos de regressão para previsão de vazões em curto período aplicados à variabilidade espacial na obtenção das relações de entrada-saída dos modelos, a partir de diferentes combinações de pares de estações na bacia.

3 PROPOSTA METODOLÓGICA

No presente capítulo, estão explanadas as técnicas desenvolvidas nas diferentes fases deste trabalho, obedecendo prioritariamente a sequência da sua implementação. Dessa forma, primeiramente, é apresentado o fluxograma da metodologia de pesquisa acompanhado de breve explanação do seu encadeamento. Em seguida, no tópico 3.1, é abordado o conteúdo relativo à análise de séries temporais no domínio tempo-frequência, com foco para a transformada *wavelet* contínua, principal ferramenta utilizada para a compreensão dos efeitos modificadores dos ciclos de vazão na bacia. No tópico 3.2 estão descritas as características principais das decomposições de séries temporais para aplicação em modelos de regressão não-linear utilizados no corrente trabalho. São elas a transformada *wavelet* discreta e a decomposição por modos empíricos. O terceiro tópico, 3.3, diz respeito aos modelos de previsão de vazão, ou seja, as redes neurais artificiais e os Processos Gaussianos. Esse último tópico é encerrado com descrição sobre as medidas de desempenho de modelos, utilizados para avaliação das previsões.

Sendo assim, na Figura 3.1 é apresentada a proposta metodológica para a obtenção dos objetivos deste trabalho. Na imagem, o acrônimo “OE” designa os objetivos específicos a serem alcançados, ordenados conforme sua numeração.

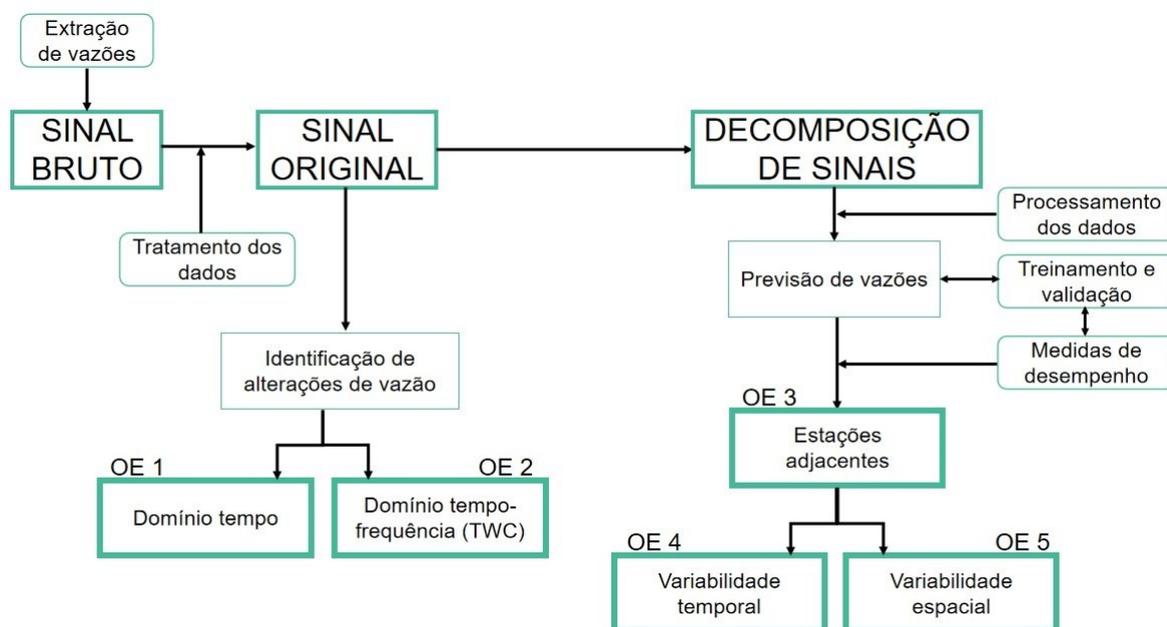


Figura 3.1: Fluxograma metodológico da pesquisa

A partir da extração e tratamento dos dados brutos horários das estações de monitoramento da bacia, a identificação de alteração dos comportamentos de vazão foi feita por duas maneiras principais. Na primeira delas foram contabilizados índices associados às inflexões e oscilações dos hidrogramas, limitados ao domínio do tempo baseadas em séries com discretização horária. Na segunda abordagem, foi feita a identificação de alteração dos espectros de vazão, por meio da transformada *wavelet* contínua (TWC), de modo que possam ser extraídas as escalas periódicas dominantes de cada hidrograma, a partir de séries diárias. Pela TWC, também são comparadas as periodicidades normalizadas entre duas estações, indicando situações de coerência entre os ciclos de dois sinais e a condição de perturbação dos hidrogramas.

Em segundo momento, foram empregadas técnicas de pré-processamento dos sinais de vazão para estudo das variáveis de entrada do modelo de regressão não-linear. Essa estratégia visou expandir as opções de variáveis regressoras a partir do princípio de que essas decomposições permitem a extração de características da série não comumente detectáveis. Nesse contexto, foi avaliada a viabilidade da decomposição de séries temporais pela transformada *wavelet* discreta (TWD) e da Transformada de Hilbert-Huang para a decomposição por modos empíricos (EMD). Além disso, outras técnicas relacionadas aos sinais de vazão foram analisadas, como as próprias estatísticas descritivas e as medidas de correlação. Ao serem associadas a ferramentas de processamento de dados para aumento de desempenho dos cálculos computacionais, comum à aplicação em todas as séries, essas informações foram utilizadas como auxílio na avaliação de modelos de regressão não-linear para previsão de vazões.

Em respeito a esses modelos, utilizados na fase seguinte, foram realizados estudos com duas técnicas distintas de aprendizado de máquina: as redes neurais artificiais e os Processos Gaussianos. No total, quatro modelos híbridos e dois modelos simples de previsão de vazão foram examinados neste trabalho. Eles consistem na combinação dessas duas técnicas de regressão com as duas ferramentas de decomposição de séries temporais, somadas ainda à verificação desses dois modelos de previsão sem a inserção das séries decompostas.

Os modelos de regressão foram ajustados por meio da validação cruzada em k -partições. Três critérios de desempenho foram utilizados para a identificação dos melhores resultados, sendo dois de ordem relativa e um de ordem absoluta. A princípio, as previsões de vazão se limitaram às séries entre pares de estações adjacentes, quando foram observados os melhores modelos e identificados padrões paramétricos. Na sequência, as previsões das séries se estenderam em

termos de variabilidade temporal entre os dados, com base em experimentos de previsão com antecipação de 1h, 3h, 6h, 12h e 24h. No último objetivo específico desta pesquisa, as previsões foram estimadas ponderando a variabilidade espacial, compondo um modelo a partir de todas as combinações par a par de estações na bacia hidrográfica. Nessas combinações par a par, foram assumidas as séries de vazão de montante como as principais alimentadoras do modelo de regressão.

3.1 Análise das séries temporais no domínio tempo-frequência – Transformada Wavelet

Transformações matemáticas podem ser aplicadas a séries temporais como uma forma de pré-processamento a fim de beneficiar a qualidade do sinal, originalmente apresentado no domínio do tempo. É comum que essas transformações sejam voltadas para a extração de características relacionadas à frequência dos sinais, e entre as formas mais conhecidas destaca-se a transformada de Fourier (TF). No entanto, essa abordagem possui limitações, especialmente por não se adequar a processos estocásticos não-estacionários, cujas características estatísticas, como média ou variância, não sejam fixas no tempo. A transformada *wavelet* (TW), por sua vez, permite observar o comportamento de frequências ao longo do tempo, e muitas vezes tem se mostrado apropriada para lidar com não-estacionariedades (SANTOS *et al.*, 2013; SHOAIIB *et al.*, 2016).

Matematicamente, a TF de uma série contínua $x(t)$ pode ser representada pela integral de $x(t)$, ao longo do tempo, multiplicada por um complexo exponencial, conforme a equação a seguir:

$$F(\omega) = \int_{-\infty}^{+\infty} x(t)e^{-i.\omega_0.t}dt \quad (3.1)$$

A TF mapeia a função de uma variável independente, como o tempo “ t ”, em uma função de outra variável independente de frequência “ ω ”. Conceitualmente, ao multiplicar cada valor de $x(t)$ por um exponencial complexo senoidal de frequência ω , são obtidos componentes baseados em somatórios de funções senos e cossenos, caracterizando uma função de comprimento infinito, na tentativa de constituir um sinal original, que normalmente é finito. Shoaib *et al.* (2016) ressaltam que um grande inconveniente nesse tratamento é que a TF converte o sinal do

domínio do tempo para o domínio da frequência gerando a perda da informação temporal, o que não é apropriado em análise de sinais oriundos de processos não-estacionários. Essa representação é mostrada na Figura 3.2a.

Ao tentar resolver a questão da perda de informação temporal, Gabor (1948) desenvolveu a técnica da transformada de Fourier de tempo curto (TFTC), ou, *Short-time Fourier Transform*, introduzindo o raciocínio de deslocamento na análise do sinal. Isso é feito em forma de janelas fixas, que se deslocam no eixo das ordenadas, percorrendo o sinal completo, e considerando o processo estacionário dentro dessa janela. Com isso são mantidas tanto a informação temporal quanto a de frequência. A TFTC é representada por:

$$F(\omega, t) = \int_{-\infty}^{+\infty} x(t)\omega(t - \tau)e^{-i.\omega.t}dt \quad (3.2)$$

O termo “ $\omega(t - \tau)$ ” denota a janela de tamanho fixo que se move sobre o sinal $x(t)$. Com efeito, a transformada de Fourier de tempo curto mapeia a função de uma variável “ t ” em uma função com duas variáveis “ ω ” e “ τ ”, e assim, tenta disponibilizar informações na frequência e também no tempo. Sua representação gráfica é mostrada na Figura 3.2b. A sua principal desvantagem é que a largura da janela que percorre os dados é fixa, podendo ignorar alterações nos sinais de vazão em intervalos variados além dessa janela, o que não é interessante, especialmente em análises de variações bruscas de curto período (SHOAIB *et al.*, 2016).

Séries temporais de variáveis aleatórias hidrológicas são frequentemente relacionadas a processos que exibem características quase periódicas, mas cujas propriedades estatísticas não são exatamente regulares, dificultando a extração de periodicidades por meio de técnicas clássicas como a transformada de Fourier. Nesse sentido, Labat *et al.* (2000) explicam que a transformada *wavelet* é considerada um desenvolvimento aprimorado na área de processamento de sinais, sendo uma análise multirresolução no domínio do tempo e da frequência simultaneamente, ou representação tempo-frequência. Essa característica torna possível analisar a periodicidade de eventos em diferentes escalas da variabilidade temporal de uma série histórica.

Na Figura 3.2 é possível comparar visualmente a transformada de Fourier (Figura 3.2a), transformada de Fourier de tempo curto (Figura 3.2b) e transformada *wavelet* (Figura 3.2c) para

dada uma série temporal, no que compete às respectivas representações de amplitude, frequência e tempo-frequência simultânea do sinal.

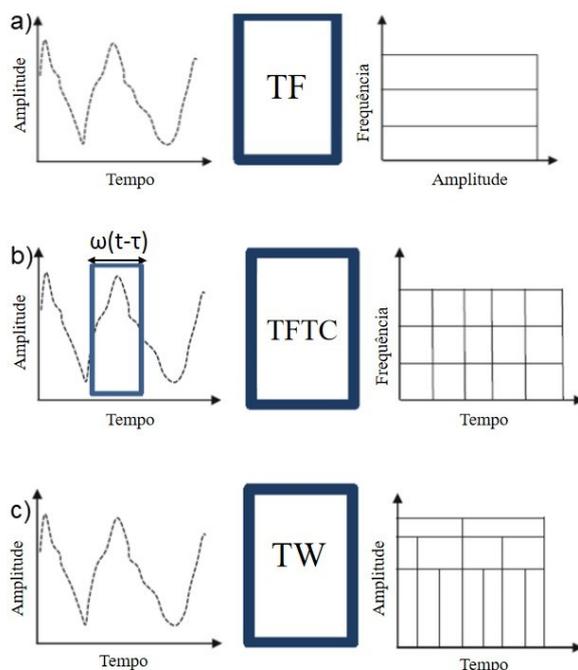


Figura 3.2: Representação gráfica de: (a) transformada de Fourier, (b) transformada de Fourier de tempo curto e (c) transformada *wavelet*

Fonte: Adaptado de Shoiaab *et al.*, 2016.

Como se nota nas representações à direita da Figura 3.2, dada uma entrada cuja relação é amplitude em função do tempo, as saídas são distintas para cada tipo de transformada. A TF converte as unidades de amplitude do sinal para unidades de frequência, provocando a perda da informação do tempo. A TFTC realiza essa conversão produzindo uma informação temporal, entretanto, limitada à largura da janela fixa. Por fim, a TW gera saídas com informações de amplitude ao longo do tempo e frequência simultaneamente, sendo, por isso, reconhecida como representação tempo-frequência.

A transformada *wavelet* atraiu considerável atenção para aplicação na grande área de ciências da terra desde sua aplicação por Grossmann & Morlet (1984), que enxergaram prosperidade na técnica originada pela matemática pura e aplicada para uso em estudos sismológicos. Atualmente, pelo caráter relativamente recente em termos de ciências exatas, trata-se de uma ferramenta em forte desenvolvimento (ADDISON, 2017).

A transformação *wavelet* analisa um sinal $x(t)$ por meio do seu produto com uma família de funções analisadoras do sinal, denominadas “funções *wavelet*”, representadas por “ $\psi(t)$ ”. Essa função *wavelet* é também chamada “*wavelet* mãe”, por originar outras funções da família a partir de operações de alteração de escala e deslocamento (MOTA, 2011). Na função *wavelet*, a largura da janela analisadora do sinal é variável, já que a transformada é calculada individualmente para cada banda espectral. Tal propriedade melhora a extração de informações sobre o tempo e a frequência da série original. Essa característica torna a TW propícia para análise de processos não-estacionários cujos sinais apresentem consideráveis variações de curto período (LABAT, *et al.*, 2000; SHOAIB *et al.*, 2016).

Na investigação de séries temporais, há diversos tipos de funções *wavelet* analisadoras, cada qual com suas características intrínsecas. Todas elas devem obedecer a determinadas condições, como possuir forma oscilante, ser regular, possuir média zero, ser de comprimento limitado, caracterizando o suporte compacto, ou, pelo menos, ter um rápido decaimento da função $\psi(t)$ em torno da origem do tempo. A primeira das condições é responsável por preservar a característica ondulatória da função $\psi(t)$, de onde provém seu nome original *ondelette*. Ela é formalizada matematicamente pela equação a seguir (LABAT *et al.*, 2000):

$$\int_{-\infty}^{+\infty} \psi(t). dt = 0 \quad (3.3)$$

A condição de energia unitária, representada pela equação abaixo, assegura que a função possua suporte compacto, ou pelo menos o rápido decaimento de amplitude (*e-folding time*), que garante localização espacial.

$$\int_{-\infty}^{+\infty} |\psi(t)|^2. dt = 1 \quad (3.4)$$

Além da normalização, condições mais restritivas devem ser impostas à função *wavelet* para possibilitar a sua reconstrução. Labat *et al.* (2000) explicam que a série temporal $x(t)$ pode ser recuperada graças aos coeficientes de decomposição *wavelet* (obtidos em etapas adiantadas), somente se os momentos de ordem mais alta da função *wavelet* (denotado por “ M ”) também forem nulos, ou, pelo menos, quase nulos. Essa terceira característica torna viável a condição de regularidade local de um sinal, formalizada por (LABAT *et al.*, 2000; ADDISON, 2017):

$$\int_{-\infty}^{+\infty} t^m \cdot \psi(t) \cdot dt = 0, \text{ para } 0 \leq m \leq M \quad (3.5)$$

Segundo Misiti *et al.* (2018), tal regularidade está relacionada à quantidade de derivações contínuas que uma função possui. Intuitivamente, uma função *wavelet* mais regular pode ser considerada mais suave.

As duas principais transformações *wavelet* são as Transformadas *Wavelet* Contínua (TWC) e Discreta (TWD). Elas se diferem segundo a forma como discretizam seus parâmetros de escala e translação. Misiti *et al.* (2018) esclarecem que as principais aplicações da TWC estão relacionadas à filtragem de componentes espectrais para análise de tempo-frequência simultaneamente, utilizados por exemplo por Torrence & Compto (1998), Grinsted *et al.* (2004) e White *et al.* (2005). Por outro lado, as principais aplicações para a TWD são a extração de sinais em sub-bandas progressivamente mais estreitas em diferentes resoluções (ADAMOWSKI & CHAN, 2011; YANG *et al.*, 2016), além de redução de ruídos (MOTA, 2011) e o processamento de sinais em imagens (SHANKAR *et al.*, 2011).

Torrence & Compo (1998), Smith *et al.* (1998) e Labat *et al.* (2000) discorrem sobre as características e aplicações de diversas funções *wavelet*. Os primeiros autores argumentam que existem determinados fatores que devem ser levados em conta durante a transformação:

- Base da função *wavelet*: Ortogonal ou não-ortogonal – Uma função *wavelet* de base ortogonal implica o uso da transformada *wavelet* discreta, ao passo que uma função *wavelet* não-ortogonal geralmente é usada com a transformada *wavelet* contínua, apesar de também ser aplicada na forma discreta. Na análise da *wavelet* discreta é gerado um espectro que contém blocos discretos de potência, o que é útil para o processamento de sinais na medida em que resulta em uma representação mais compacta. O principal inconveniente é que para análise de séries temporais, a alternância aperiódica dos dados produz diferentes espectros *wavelet*. Por outro lado, uma análise não-ortogonal gera redundância em escalas maiores, visto que o espectro em períodos adjacentes é fortemente correlacionado. A transformada não-ortogonal, de forma geral, é útil para análises de séries temporais em que são esperadas variações contínuas na amplitude das *wavelet*.

- Função *wavelet*: Complexa ou real – Uma função *wavelet* complexa retornará informação sobre a amplitude (relativa ao número real) e a fase (relativa ao número imaginário), oferecendo melhores instrumentos para interpretar comportamentos oscilatórios. Já uma função real retorna uma única componente real e pode ser usada para isolar picos ou descontinuidades.
- Largura tempo-frequência – Uma função *wavelet* bem delimitada no tempo apresenta boa resolução temporal, mas pobre resolução na frequência. Ao contrário, uma função menos precisa no tempo possui boa resolução na frequência.
- Forma – a função *wavelet* deve refletir o tipo de característica da série histórica. Para séries com mudanças abruptas e descontinuidades pontuais, são recomendadas funções do tipo Haar, ou semelhantes, enquanto para variações suaves pode ser apropriada uma função também mais suave, como a Morlet. Se o interesse principal estiver em torno da obtenção da potência espectral *wavelet*, então a escolha da função *wavelet* não é crítica, e os resultados serão semelhantes em termos qualitativos.

Pelas características descritas, a transformada *wavelet* contínua foi utilizada neste trabalho para identificação e comparação das periodicidades dominantes de vazões entre estações fluviométricas, na primeira fase do presente trabalho. Em segunda etapa, a abordagem da transformada *wavelet* discreta foi utilizada com o fim de filtrar as altas e baixas frequências das séries e avaliar a inserção dessa informação ao modelo de previsão de vazões.

3.1.1 Transformada *Wavelet* Contínua

Como já mencionado, a TWC foi formulada com o intuito de analisar janelas de tamanhos diversos da série de dados para diferentes resoluções. Matematicamente a TWC de uma série temporal é decomposta em termos dependentes da escala e do tempo. Tal decomposição é expressa por (SMITH *et al.*, 1998; SHOAIIB *et al.*, 2016):

$$W_t(s) = \frac{1}{\sqrt{s}} \int_{-\infty}^{+\infty} x(t) \psi^* \left(\frac{t-b}{s} \right) dt \quad (3.6)$$

na qual “ $\psi(t)$ ” é a função *wavelet* mãe analisadora do sinal original “ $x(t)$ ” a ser transformado, e “*” denota complexo conjugado da função. O produto da função *wavelet* $\psi(t)$ pela função $x(t)$ é integrado em toda a faixa de dados, caracterizando a convolução. O parâmetro “ s ” denota

o fator de escala (ou frequência), que é responsável pela dilatação ($s > 1$) ou contração ($s < 1$) da função *wavelet*; e “ b ” corresponde ao fator de deslocamento (ou posição), responsável pela translação da função ao longo do tempo. O deslocamento de uma função *wavelet* significa simplesmente atrasar ou avançar o início da onda ao longo do comprimento da série. O termo “ $|s|^{-1/2}$ ” é um fator de escala que garante a conservação da energia à medida em que se expande ou comprime a *wavelet* mãe. Essa transformada é chamada de contínua porque os parâmetros de escala e de deslocamento assumem valores com discretização contínua.

Conforme mencionado, além do fator de deslocamento, a TW agrega também o processo de escala, inversamente proporcional à frequência, que permite o alongamento ou encolhimento da janela na análise do sinal ao longo do tempo. Misiti *et al.* (2018) elucidam que fatores de escala maiores resultam em uma *wavelet* alongada, que por ser correspondente às baixas frequências, ajuda a capturar as características que variam lentamente, levando a uma visão aproximada do sinal, com as propriedades suavizadas. Por outro lado, um fator de escala menor resulta em uma *wavelet* encolhida, o que corresponde às altas frequências, e ajuda a analisar pequenos intervalos do sinal, capturando mudanças abruptas com detalhes. A largura da função *wavelet* varia à medida que a transformada é calculada para cada componente espectral, o que torna a TW adequada para análise de processos não-estacionários, aperiódicos que contemplam eventos irregularmente distribuídos e com fenômenos locais em diferentes frequências (LABAT *et al.*, 2000).

Desde que obedecem critérios de admissibilidade, energia unitária e regularidade de um sinal, descritos pelas equações (3.3) a (3.5), diversas funções podem ser consideradas funções *wavelet* analisadoras do sinal original. A função *wavelet* Morlet, representada na equação (3.7), é comumente usada para análise de sinais temporais que se assemelham a ondas, como o escoamento fluvial (WHITE *et al.*, 2005; SANTOS *et al.*, 2013). Addison (2017) explica que a função complexa Morlet consiste no produto de uma curva Gaussiana – terceiro termo da equação (3.7) – por uma curva senoidal complexa – segundo termo da equação (3.7) – multiplicados pelo fator de normalização – primeiro termo da equação (3.7) – para assegurar que a função *wavelet* tenha energia unitária.

$$\psi_0(\eta) = \pi^{-1/4} \cdot e^{i \cdot \omega_0 \cdot \eta} \cdot e^{-\eta^2/2} \quad (3.7)$$

Na equação acima, “ η ” denota um parâmetro adimensional proporcional ao tempo; e “ ω_0 ” (*wave number*) é um coeficiente adimensional proporcional à frequência. Usualmente, $\omega_0 = 6 (\cong 2\pi)$, o que assegura equilíbrio entre tempo e frequência e satisfaz a condição de admissibilidade de média zero da função *wavelet*. Para valores elevados de ω_0 a resolução da escala aumenta enquanto a de tempo diminui, e vice-versa. A função Morlet foi utilizada neste trabalho como função analisadora na transformada *wavelet* contínua para identificação das periodicidades dominantes e verificação de alteração dos espectros de vazão entre duas estações.

Santos *et al.* (2013) apresentam um exemplo de uma função *wavelet* Morlet comparando-a a um “pacote de onda”, de duração finita e com frequência específica. A relação dessa função Morlet com a curva Gaussiana que envolve a curva senoidal, conforme a equação (3.7), é visualizada na Figura 3.3, onde são reveladas as componentes real (linha contínua preta) e imaginária (linha tracejada laranjada).

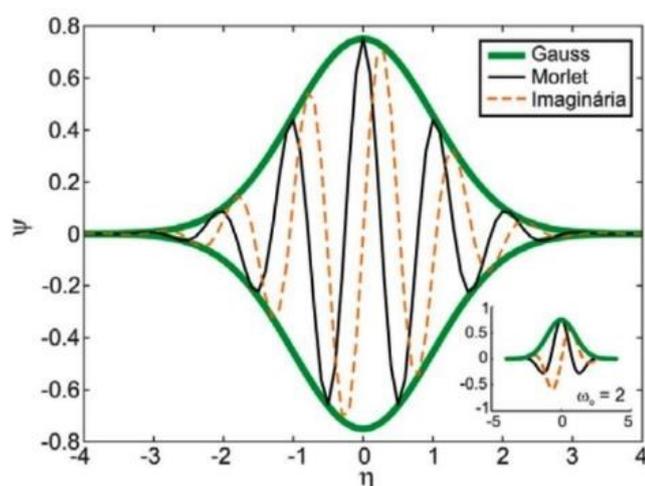


Figura 3.3: Exemplo de função *wavelet* Morlet

Fonte: Santos *et al.*, 2013.

Para explicar o funcionamento da função Morlet sobre a série temporal, Santos *et al.* (2013) oferecem um exemplo, ao supor que a largura total dessa *wavelet* seja cerca de 10 anos. Por consequência, isso possibilita encontrar a correlação, expressa em termos de potência, entre a função analisadora do sinal e os primeiros 10 anos da série. Em outras palavras, a potência espectral *wavelet* (ou *wavelet power spectrum* – WPS) representa quanto de amplitude o período de 10 anos se assemelha a uma onda senoidal que tenha essa mesma largura. Por fim, ao deslocar a função *wavelet* sobre a série temporal, uma nova série temporal da amplitude versus tempo pode ser construída. Esse deslizamento sobre a série ocorre com a mesma função

wavelet, de modo que apenas a sua escala é variável, o que é controlado por coeficientes de dilatação ou contração.

3.1.1.1 Análise univariada de séries temporais – WPS

Visto que a função *wavelet* Morlet $\psi_0(\eta)$ é um valor complexo, sua transformada *wavelet* também é complexa. Logo, a transformação da (3.6) resulta nas componentes real $Re\{W_t(s)\}$ e imaginária $Im\{W_t(s)\}$. Portanto, além da análise do módulo $|W_t(s)|$ (ou amplitude), também pode ser verificada a fase “ ϕ ”, incorporando o valor imaginário dos coeficientes resultantes (TORRENCE & COMPO, 1998; ADDISON, 2017), conforme a seguinte relação:

$$\phi = \tan^{-1} \left[\frac{Im\{W_t(s)\}}{Re\{W_t(s)\}} \right] \quad (3.8)$$

A partir da amplitude $|W_t(s)|$ da transformada *wavelet*, a potência espectral *wavelet* (WPS) pode ser expressa por:

$$WPS_t^x(s) = |W_t^x(s)|^2 \quad (3.9)$$

A WPS descreve a potência do sinal $x(t)$ em um determinado tempo “ t ” em dada escala “ s ”. A análise da potência espectral *wavelet*, permite examinar o padrão oscilatório das vazões em diversas escalas temporais, indicando a potência do sinal para cada escala.

Torrence & Compo (1998) sugeriram um teste de significância para a estimativa da potência espectral *wavelet*, que pode ser avaliada sob a hipótese nula de que o sinal seja gerado por um processo estacionário, dado um espectro de potência de fundo “ Pk ”. Nesse sentido, muitas séries geofísicas possuem características de ruído vermelho que podem ser modeladas por um processo autorregressivo de primeira ordem AR[1] (TORRENCE & COMPO, 1998; GRINSTED *et al.*, 2004; SCHAEFLI *et al.*, 2007). Assim, sendo “ k ” o índice de frequência de Fourier ($k = 0, \dots, N/2$) e “ α ” a autocorrelação *lag*-1, o espectro de potência de Fourier de um processo AR[1] é apresentado por Grinsted *et al.* (2004) conforme a seguir:

$$Pk = \frac{1 - \alpha^2}{|1 - \alpha e^{-2i\pi k}|^2} \quad (3.10)$$

Para tanto, supõe-se que a série temporal tenha um espectro de potência média, de forma que se um pico no espectro de potência da *wavelet* estiver significativamente acima desse espectro de fundo, então pode ser assumido que esta é uma característica verdadeira em um certo nível de significância α . Torrence & Compo (1998) fizeram uso de simulações de Monte Carlo com 100.000 amostras para demonstrar que a probabilidade de que a potência *wavelet* de um processo com uma dada potência espectral “ P_k ” ser maior que “ p ” pode ser expressa por:

$$P\left(\frac{|WPS_t^x(s)|^2}{\sigma_x^2} < p\right) = \frac{1}{2}Pk\chi_v^2(p) \quad (3.11)$$

na qual “ σ_x^2 ” a variância da série temporal “ $t(x)$ ”. Segundo Torrence & Compo (1998), tal probabilidade é calculada para cada escala “ s ” e em cada instante “ t ”, para assim compor a região tempo-frequência significativa segundo a distribuição qui-quadrado (χ_v^2), sendo “ v ” o número de graus de liberdade. Para aplicação com funções *wavelet* complexas, como a Morlet, são assumidos dois graus de liberdade ($v = 2$), e para funções *wavelet* reais, $v = 1$. Portanto, após encontrar um espectro de fundo apropriado e definir o nível de significância para o teste χ^2 , é possível construir os contornos representativos de confiança $(1-\alpha)$ de potência espectral, para cada escala periódica da série.

Naturalmente, a transformada *wavelet* contínua em um ponto no tempo t_0 se submete à influência de pontos vizinhos. Sobre esse aspecto, Santos *et al.* (2013) explicam que, por lidar com séries temporais finitas, erros ocorrerão no início e no fim da potência espectral *wavelet*, exigindo o preenchimento com zeros. Esse preenchimento com zeros introduz descontinuidades e diminui a amplitude próxima às bordas à medida que vai para as escalas maiores, já que mais zeros passam a ser contabilizados. Assim, é necessário introduzir um artifício para ressaltar as regiões sob efeitos de borda, representado pelo cone de influência (COI). Em síntese, o COI é a região da potência espectral *wavelet* na qual o efeito de borda se torna significativo. Visto que os picos nessas regiões foram presumidamente reduzidos em sua magnitude devido ao preenchimento com zeros, não fica explícito se a diminuição em qualquer banda de potência no COI é uma redução real na variância ou uma consequência do artifício de preenchimento. Disso decorre que as interpretações das potências nas áreas do COI devem ser feitas cautelosamente, quando não desprezadas.

Para quantificar a relação de fase da transformada *wavelet* contínua, Grinsted *et al.* (2004) sugerem o uso da média circular da fase sobre as regiões com nível de confiança > 95% localizados fora do cone de influência. Considerando “*arg*” como o argumento de um número complexo, a média circular de um conjunto de ângulos ($s_i, i = 1, \dots, n$) pode ser obtida por:

$$s_i = \arg(X, Y) \quad (3.12)$$

na qual:

$$X = \sum_{i=1}^n \cos(s_i) \quad \text{e} \quad Y = \sum_{i=1}^n \text{sen}(s_i)$$

Por meio da potência espectral da transformada *wavelet* contínua, espera-se que sejam reveladas características individuais dos dados, como periodicidades, tendências e descontinuidades que outras técnicas de análise de sinais podem não detectar. No presente trabalho, as características de periodicidades dominantes de cada série de vazões são comparadas com as características das séries de estações adjacentes, e podem indicar graus de alteração dos ciclos de vazão estatisticamente significativos, possivelmente correspondentes a aspectos físicos do sistema estudado.

Apesar de identificar ciclos dominantes simultaneamente a escalas de tempo, por meio da WPS, essa investigação é feita de maneira univariada. Por essa razão, a análise da correlação entre periodicidades de duas séries temporais e a identificação de alteração dos padrões cíclicos por meio da WPS são de difícil prospecção (GRINSTED *et al.*, 2004; MARAUN & KURTHS, 2004; SCHAEFLI *et al.*, 2007). Em contrapartida, análises bivariadas permitem reconhecer a semelhança entre duas séries temporais.

3.1.1.2 Análise bivariada de séries temporais – WCS e WCO

A relação linear entre duas séries $x(t)$ e $y(t)$ no domínio tempo-frequência pode ser revelada por meio da identificação de picos de periodicidades comuns entre os dois sinais. Exemplos de análises bivariadas são o espectro cruzado *wavelet* (*Wavelet Cross Spectrum* – WCS) e a coerência *wavelet* (*Wavelet Coherency* – WCO). Enquanto o WCS ressalta as regiões tempo-frequência de alta potência em comum, a WCO exhibe a intensidade da covariância no espaço tempo-frequência (GRINSTED *et al.*, 2004; GOUHIER *et al.*, 2019).

É possível obter o espectro cruzado WCS entre duas séries a partir do produto entre as suas transformadas *wavelet* $W_t^X(s)$ e $W_t^Y(s)$, oriundos da aplicação da equação (3.6), conforme apresentado a seguir (GRINSTED *et al.*, 2004):

$$WCS_t^{(X,Y)}(s) = W_t^X(s)W_t^Y(s)^* \quad (3.13)$$

A expressão “ $W_t^Y(s)^*$ ” denota o complexo conjugado de “ $W_t^Y(s)$ ”.

Diferentemente da WPS, o WCS é um número complexo e pode ser decomposto em amplitude (primeiro multiplicador da (3.14) e fase (segundo multiplicador), conforme a equação a seguir (MARAUN & KURTHS, 2004):

$$WCS_t^{(X,Y)} = \left| WCS_t^{(X,Y)} \right| \cdot e^{t\Phi_t(X,Y)} \quad (3.14)$$

A amplitude da WCS representa a potência da *wavelet* cruzada, enquanto a fase, analisada como um ângulo da componente complexa, descreve o atraso nas respostas dos ciclos entre dois sinais no tempo “ t ” em uma escala específica “ s ”.

A significância estatística da WCS de duas séries temporais com potências espectrais de fundo P_k^X e P_k^Y , baseadas na equação (3.10), é também estimada em relação a um processo autorregressivo de primeira ordem, expressa por (TORRENCE & COMPO, 1998; GRINSTED *et al.*, 2004):

$$P \left(\frac{|W_t^X(s) \cdot W_t^Y(s)^*|}{\sigma_X \cdot \sigma_Y} < p \right) = \frac{Z_v(p)}{v} \cdot \sqrt{P_k^X \cdot P_k^Y} \quad (3.15)$$

na qual “ $Z_v(p)$ ” equivale ao nível de confiança associado à probabilidade “ p ” de uma função densidade de probabilidade definida pela raiz quadrada do produto de duas distribuições χ^2 ; e “ σ_X ” e “ σ_Y ” são os desvios padrão das séries $t(x)$ e $t(y)$.

Apesar de ressaltar as regiões tempo-frequência em comum, picos significativos da WCS podem aparecer mesmo quando duas séries são independentes, em razão da WCS não ser normalizada (MARAUN & KURTHS, 2004; SCHAEFLI *et al.*, 2007). Por sua vez, a normalização da WCS pela WPS de cada sinal $x(t)$ e $y(t)$, em relação ao tempo e escala, leva à coerência *wavelet* (WCO), formalizada por Torrence & Webster (1999) por meio da equação:

$$WCO_t^2(s) = \frac{|S.[s^{-1}WCS_t^{XY}(s)]|^2}{S[s^{-1}|W_t^X(s)|^2].S[s^{-1}|W_t^Y(s)|^2]} \quad (3.16)$$

O termo “ s^{-1} ” converte o WCS a uma densidade de energia normalizada para cada escala; e “ S ” denota um operador de suavização relacionado ao tempo e à frequência, separadamente.

A normalização do WCS destaca os pontos dependentes entre duas séries. O valor $WCO^2 = 1$ significa que existe relação linear entre $x(t)$ e $y(t)$ em torno do tempo “ t ” em uma escala “ s ”, enquanto o valor $WCO^2 = 0$ é obtido quando a correlação é nula. Essa comparação revela áreas comuns com alta potência nas periodicidades de vazão, representando um coeficiente de correlação localizado no espaço de tempo-frequência. Torrence & Webster (1999) ressaltam que, tendo em vista que a transformada *wavelet* preserva a variância, a coerência *wavelet* é uma representação precisa da covariância normalizada entre as duas séries temporais.

As escalas de tempo e frequência sobre as quais “ S ” está suavizando definem as escalas nas quais a coerência *wavelet* mede a covariância entre as séries (TORRENCE & WEBSTER, 1999). Assim, o operador de suavização “ S ” é representado por:

$$S(W) = S_s \left(S_t(W_t(s)) \right) \quad (3.17)$$

na qual “ S_s ” denota a suavização ao longo do eixo da escala “ s ” na transformada *wavelet*, enquanto “ S_t ” denota a suavização ao longo do eixo do tempo. Para a função *wavelet* Morlet, o operador de suavização pode ser obtido por meio da equação a seguir (TORRENCE & WEBSTER, 1999; GRINSTED *et al.*, 2004):

$$S_t(W)|_s = \left(W_t(s) * c_1^{-t^2/2s^2} \right) \Big|_s, \quad (3.18)$$

$$S_s(W)|_s = (W_t(s) * c_2 \Pi(0,6s)) \Big|_s$$

nas quais “ c_1 ” e “ c_2 ” são constantes de normalização e “ Π ” é uma função retangular. O valor “0,6” é um fator determinado empiricamente por um processo iterativo, específico para a função *wavelet* Morlet. Na prática, ambas as convoluções são feitas discretamente e, portanto, os coeficientes de normalização são determinados numericamente (TORRENCE & COMPO, 1998; GRINSTED *et al.*, 2004).

A análise de WCO também requer a definição de hipóteses nulas apropriadas para testes formais de significância. Novamente, assumindo que os dados sejam temporalmente autocorrelacionados e oriundos de um processo autorregressivo de primeira ordem, a rotina para obter a WCO tem início com a extração de coeficientes do processo AR[1] da série de dados. Com a obtenção desses coeficientes, é gerada uma grande quantidade de séries temporais para realizar simulações de Monte Carlo, as quais assumem os mesmos coeficientes AR[1] extraídos da série original. Em seguida, é calculada a coerência *wavelet* entre duas séries diferentes, com os mesmos coeficientes AR[1]. Esse cálculo é realizado um elevado número de vezes (usualmente 1000), a fim de gerar a distribuição de frequência acumulada para as coerências *wavelet* em cada escala periódica e cada intervalo de tempo.

Em seguida, são comparadas as coerências *wavelet* observadas entre a série temporal original e um dado percentil da distribuição das diversas séries geradas em cada escala periódica e em cada intervalo de tempo. Por fim, se a coerência *wavelet* observada for maior que esse percentil, então essa coerência *wavelet* será admitida como significativa para um certo nível de significância “ α ”. Frequentemente, $\alpha = 0,05$, de modo que o percentil seja equivalente a 95% (GRINSTED *et al.*, 2004; GOUHIER *et al.*, 2019).

Ao discorrer sobre alguns cuidados relacionados à interpretação da análise da correlação cruzada *wavelet* e da coerência *wavelet*, Maraun & Kurths (2004) argumentam que, como a WCS descreve a potência comum de dois processos sem a normalização em cada WPS, alguns picos significativos criados por uma cooscilação aleatória podem surgir, mesmo quando as duas séries são independentes. Desse modo, esses autores concluíram que a WCS é inadequada para identificar a correspondência entre duas séries temporais. Por outro lado, a WCO é recomendada para avaliar a relação entre duas séries temporais $x(t)$ e $y(t)$, já que essa é uma medida normalizada pelas variâncias dos sinais (GRINSTED *et al.*, 2004; MARAUN & KURTHS, 2004; SCHAEFLI *et al.*, 2007). Com base nesses argumentos, neste trabalho, a comparação entre dois sinais subsequentes de vazão foi feita apenas pela WCO. Ainda assim, Schaepli *et al.* (2007) alertam que, mesmo para a WCO, pequenos contornos que indiquem coerência significativa, por si só, não apresentam necessariamente uma relação física.

Torrence & Compo (1998) desenvolveram a abordagem tradicional para testes formais de hipótese e representação gráfica da WPS. No entanto, como demonstrado por Liu *et al.* (2007), a maneira como a potência espectral era encontrada induzia a uma redução artificial e

sistemática da potência das periodicidades nos ciclos menores, o que poderia acentuar as baixas frequências (VELEDA *et al.*, 2012). O problema com a potência do espectro age principalmente na determinação da coerência *wavelet*. Portanto, no código computacional desenvolvido por Gouhier *et al.* (2019) foi realizada a correção dos desvios das potências, conforme proposto por Veleda *et al.* (2012), de forma a incluir o parâmetro de escala na potência espectral *wavelet*.

3.1.1.3 Interpretações gerais da TWC em um escalograma

Analogamente aos espectrogramas da transformada Fourier, que são representações das variações das amplitudes ou das energias dos coeficientes de Fourier em bandas de frequências fixas no tempo, os escalogramas são gráficos que permitem reproduzir a visualização bidimensional tempo-frequência dos coeficientes *wavelet*. Os escalogramas indicam a escala de periodicidades, ou ciclos, no eixo das ordenadas, em função do tempo, representado nas abscissas. As potências mais elevadas (na WPS), assim como as maiores correspondências entre duas séries (na WCO), são representadas pelas cores quentes (vermelho), enquanto as de menor representatividades têm cores frias (azul). As potências que apresentam significância estatística são circundadas por um contorno preto e espesso, e representam as periodicidades dominantes (na WPS), ou correlação (na WCO).

Conforme mencionado anteriormente, visto que a transformada *wavelet* contínua não está completamente localizada no tempo, ela submete os resultados relativos ao início e final de cada série a efeitos de borda, determinados pelo cone de influência (COI). Visualmente, nos escalogramas mostrados nos resultados, as áreas relativas a esses efeitos de borda são indicadas na região sombreada mais clara externa ao COI, o qual possui formato de “U”, e é assinalado com uma linha branca.

Na correlação cruzada ou na coerência *wavelet*, duas séries relacionadas fisicamente podem revelar atraso de ciclos periódicos, que pode ser permanente ou variar lentamente em função do tempo e da escala periódica. Evidentemente, esses efeitos devem ser relacionados com as características físicas do sistema estudado. Sendo assim, visto que a função *wavelet* Morlet é complexa, é possível extrair informações de fase associadas à componente imaginária da transformada *wavelet*, e que correspondem a essa interpretação de defasagem dos ciclos. Na transformada *wavelet* pela função Morlet, a fase varia ciclicamente entre $-\pi$ e π , ao longo da duração de determinado período (CAZELLES *et al.*, 2008; RÖSCH & SCHMIDBAUER, 2018). Para estimar a relação numérica de fase entre duas séries, é utilizada a média das fases

em relação às regiões com significância estatística que estão fora do cone de influência (TORRENCE & COMPO, 1998). Visualmente, as condições de fase e antifase costumam ser indicadas nos escalogramas por campos vetoriais, que expressam o atraso entre dois sinais no tempo após definida uma escala periódica específica. Por exemplo, setas apontando para a direita indicam que as séries $x(t)$ e $y(t)$ se movem em fase, ou seja, na mesma direção simultaneamente; apontando para a esquerda significa que elas estão em antifase, e as séries se movem na direção oposta; apontando para baixo significa que $x(t)$ está atrasada em relação a $y(t)$ por $\pi/2$ (ou um quarto de um ciclo); e apontando para cima significa que $x(t)$ está adiantada em relação a $y(t)$ por $\pi/2$ (ABDULLAH, 2016; RÖSCH & SCHMIDBAUER, 2018).

Nessas representações, Maraun & Kurths (2004) advertem sobre a possibilidade de indicações espúrias acontecerem, requerendo sua interpretação na representação para a qual se aplica o estudo. Tendo em vista a abordagem hidrológica do presente trabalho, em que a série de vazões de uma estação de montante $x(t)$ resulta diretamente na de jusante $y(t)$, não são esperadas situações de antifase, ou de adiantamentos.

3.2 Decomposição de séries temporais para alimentação de modelos de previsão

Conforme mencionado no capítulo introdutório, séries temporais originadas de processos hidrológicos costumam exibir uma variedade de padrões superpostos que não são trivialmente detectáveis. Por essa razão, muitas vezes são utilizadas transformações matemáticas para pré-processamento dos dados e assim permitir a extração de informações que possam ser melhor interpretadas.

Segundo Hyndman & Athanasopoulos (2018), para melhor conhecimento das informações contidas em uma série, é comum decompô-la em três componentes principais: a tendência, a sazonalidade e o remanescente da série, composto pelos resíduos. No entanto, essa estratégia convencional não costuma ser útil quando os dados são regidos por processos não-estacionários, ou não-lineares, ou ainda quando as oscilações cíclicas não são claramente identificadas. Como alternativa, algumas técnicas baseadas na decomposição de componentes intrínsecos à série temporal permitem extrair coeficientes que são mais regulares em comparação à série original, o que facilita a compreensão das informações contidas em processos não-estacionários.

Nesse sentido, a transformada *wavelet* discreta e a transformada de Hilbert-Huang facilitam a extração de características que melhor representam a série temporal, pois salientam o conjunto de informações mais significativas e revelam periodicidades e padrões ocultos. Ao ressaltar as propriedades mais importantes do sinal, a decomposição da série temporal por essas duas transformadas promove a redução de componentes pouco representativos da série, que podem ser associados a ruídos. O pré-processamento para alimentação de um modelo de aprendizado de máquina busca melhorar o desempenho da previsão, tanto em qualidade dos resultados quanto em diminuição do tempo de processamento computacional (NAPOLITANO *et al.*, 2011; NEVES *et al.*, 2012; NOURANI *et al.*, 2014; SHOAIIB *et al.*, 2016).

Visando melhor discorrer sobre essas estratégias na lida dos dados, nos próximos itens do presente capítulo são descritas a transformada *wavelet* discreta e a transformada de Hilbert-Huang para decomposição por modo empírico.

3.2.1 Transformada *Wavelet* Discreta (TWD)

Conforme mencionado no item 3.1.1, a respeito da transformada *wavelet* contínua, o cálculo dos coeficientes da TWC em cada escala e cada deslocamento é realizado a partir de grande quantidade de translações e escalonamentos contínuos de uma função sobre o sinal, o que resulta em grande quantidade de componentes, e comumente em redundância, especialmente nas maiores frequências. Entretanto, se a escala e a translação são realizadas em intervalos discretos, como, por exemplo, em potência de dois (característica diádica), a quantidade de componentes e a sua redundância são reduzidas consideravelmente (SHOAIIB *et al.*, 2016; MISITI *et al.*, 2018).

A transformação *wavelet* discreta pode ser realizada a partir de uma modificação da transformada contínua, formalizada conforme a seguinte equação (MALLAT, 1989):

$$\psi_{m,n}\left(\frac{t-b}{s}\right) = \frac{1}{\sqrt{s_0^m}} \int_{-\infty}^{+\infty} x(t) \psi\left(\frac{t - nb_0 s_0^m}{s_0^m}\right) dt, \text{ para } m, n \in \mathbb{Z}, a \neq 0 \quad (3.19)$$

Os parâmetros “*m*” e “*n*” são números inteiros que governam, respectivamente, a escala e a translação da *wavelet*; “*s*” é um parâmetro relativo ao passo de escala ($s_0 > 1$); e “*b*” é o parâmetro de deslocamento ($b_0 > 0$). Alguns pesquisadores sugerem como valores para esses

parâmetros que $s_0 = 2$ e $b_0 = 1$, caracterizando a amostragem diádica, sendo esse o caso mais simples e usualmente mais eficiente para propósitos práticos (ADDISON, 2017).

Em geral, processos geofísicos como o escoamento fluvial ou precipitação geram observações discretas. Com esse raciocínio, a TWD é frequentemente utilizada para decomposição e reconstrução de séries temporais para aplicação em estudos em recursos hídricos, como fizeram diversos autores (SMITH *et al.*, 1998; TIWARI & CHATTERJEE, 2010; ADAMOWSKI *et al.*, 2012; KASIVISWANATHAN *et al.*, 2016; ZHANG *et al.*, 2018). De fato, a maior parte dos trabalhos que envolvem modelos híbridos para previsão de vazões com a decomposição espectral com a transformada *wavelet* faz uso dos filtros por meio da TWD (NOURANI *et al.*, 2014; MOSAVI *et al.*, 2018).

A função TWD de uma série temporal finita discreta $x(t)$ é expressa por (SHOAIB *et al.*, 2016):

$$TWD(m, n) = 2^{-m/2} \sum_{t=0}^{N-1} \psi^*(2^{-m}t - n)x(t), \text{ para } m, n \in \mathbb{Z} \quad (3.20)$$

na qual $TWD_{(m,n)}$ denota o coeficiente *wavelet* para a transformada discreta de escala $s = 2^m$ e deslocamento $b = n \cdot 2^m$. A série temporal discreta finita é representada por $x(t)$, assumindo que $t = 1, 2, \dots, N$, sendo N um número inteiro potência de 2 (ou seja, $N = 2^M$), e M também um inteiro, com a faixa de alcance dos parâmetros “ m ” e “ n ” se limitando, respectivamente, a $0 \leq m \leq M-1$ e $0 < n \leq 2^{(M-1)}$.

Para a menor escala *wavelet* (ou seja, 2^{M-m} , sendo $m = 0$) apenas uma *wavelet* é necessária para cobrir todo o intervalo de tempo, e somente um coeficiente é produzido. Na próxima escala, com $m = 1$, e $2^{(M-m)}$, duas *wavelet* são necessárias para cobrir a série de dados, do que decorre que dois coeficientes são produzidos, e assim sucessivamente. Quando $m = M - 1$, o parâmetro de escala “ s ” é $s = 2^{(M-1)}$, logo, são produzidos $N/2$ coeficientes para descrever os dados da série temporal nessa maior escala. O número total de coeficientes *wavelet* para uma série temporal discreta de comprimento $N = 2^M$ é, portanto, $1 + 2 + 4 + 8 + \dots + 2^{(M-1)} = N - 1$. Adicionalmente, um componente suavizado do sinal “ \bar{T} ” é extraído, o qual fornece um tipo de informação da série temporal representativa da sua média. Com isso, a série temporal de comprimento N é dividida em N componentes, o que anula sua redundância. A inversa da transformada discreta de *wavelet* é representada pelas duas equações a seguir (MALLAT, 1989; SHOAIB *et al.*, 2016):

$$x(t) = \bar{T} + \sum_{m=1}^M \sum_{n=0}^{2^{(M-m)}-1} TWD_{m,n} 2^{-m/2} \psi^*(2^{-m}t - n) \quad (3.21)$$

$$x(t) = \bar{T} + \sum_{m=1}^M W_m(t) \quad (3.22)$$

A série temporal $x(t)$ pode ser entendida como a adição de um subsinal de aproximação (ou suavização) “ \bar{T} ” no nível de decomposição “ M ”, ao somatório dos subsinais de detalhe “ $W_m(t)$ ” nos níveis de decomposição $m = 1, 2, 3, \dots, M$. Essa é a base conceitual da análise multirresolução.

A consideração diádica mencionada para a TWD permite operar dois conjuntos de funções que compõem um filtro passa-faixa de localização e largura variadas. Na TWD, a série temporal original é submetida simultaneamente a esses filtros, que decompõem o sinal em componentes de aproximação “ a_M ” e de detalhes “ d_M ”. Esse processo de decomposição é iterado com sucessivas aproximações sendo separadas nível a nível, de modo que o sinal é dividido em muitos componentes de menor resolução até o seu nível M final. A essência dessa aplicação é filtrar a série temporal com diferentes filtros passa-alta e passa-baixa, e permitir extrair os componentes da transformada *wavelet* discreta, os quais podem ser utilizados para simples interpretação das altas e baixas frequências do sinal, ou ainda admitidos como variáveis de entrada em outros modelos.

Os filtros passa-alta, que produzem o subsinais de detalhe (D_M), são propícios para analisar as altas frequências, enquanto os filtros passa-baixa, responsáveis por produzir os subsinais de aproximação ($a_1, a_2, a_3, \dots, a_M$), são adequados para analisar os conteúdos de baixa frequência da série. Exemplificando, os componentes gerados pela decomposição de nível 1 produz uma aproximação (a_1) e um detalhe (D_1), a decomposição de nível dois gera uma aproximação (a_2) e dois detalhes (D_1 e D_2), a decomposição do nível três resulta em uma aproximação (a_3) e três detalhes (D_1, D_2 e D_3) e assim por diante (MALLAT, 1989; SHOAIIB *et al.*, 2016). Melhor entendimento das extrações dos componentes de alta e baixa frequência dos sinais pode ser alcançado pela observação da Figura 3.4, que representa um algoritmo piramidal de decomposição de sinais.

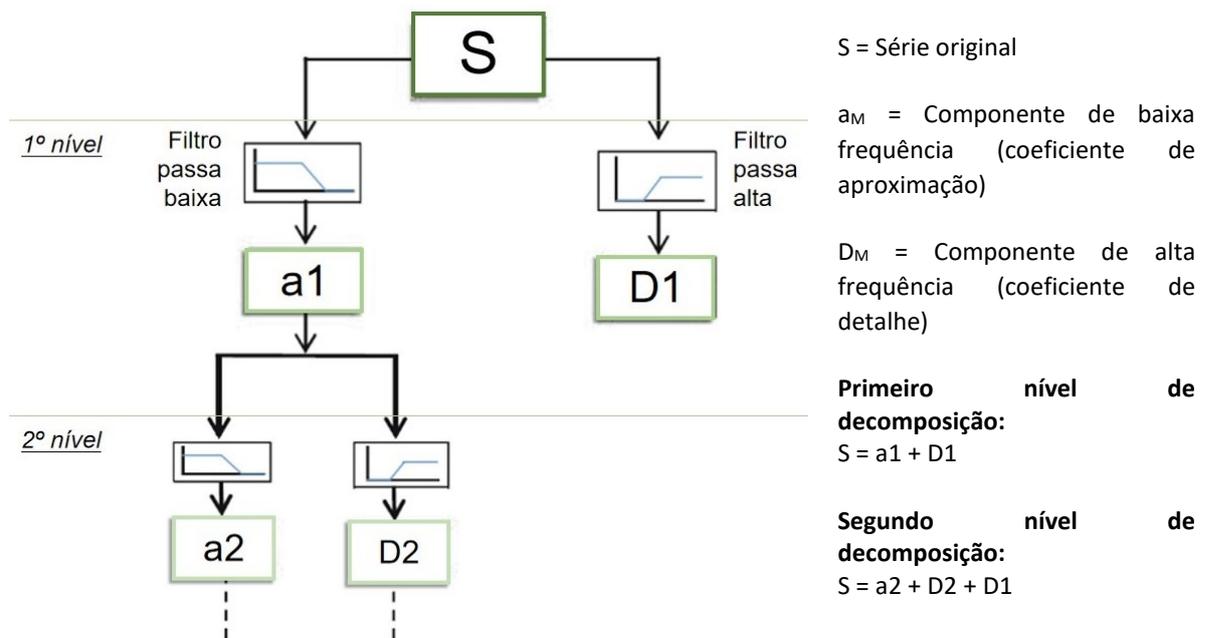


Figura 3.4: Estrutura de decomposição dos sinais pelos filtros passa-alta e passa-baixa da transformada *wavelet* discreta

Fonte: Adaptado de Shoaib *et al.*, 2016.

O filtro da TWD remove quaisquer regiões de baixa amplitude, presumivelmente comparadas a um ruído. Essa técnica tem a vantagem sobre as filtragens tradicionais por ser capaz de extrair essas baixas amplitudes do sinal em todas as frequências. Com efeito, ela pode ser usada para isolar eventos únicos com potência espectral ampla ou vários eventos que possuem periodicidade variável. A componente de baixa frequência é a informação que melhor representa o sinal isoladamente, pois fornece aproximações gerais sobre a identidade da série temporal. Por outro lado, a componente de alta frequência (detalhes) é responsável por capturar pequenas características dos dados, que podem ser decorrentes de eventos curtos e rápidos. A combinação de elementos dessa última componente é normalmente utilizada como preditores de modelos híbridos de regressão.

Em razão das possibilidades que a transformada *wavelet* oferece na extração de periodicidades relevantes de uma série temporal, bem como da robustez que modelos de aprendizado de máquina oferecem ao lidar com a natureza não-linear e dinâmica das séries temporais, a modelagem híbrida, que congrega essas duas técnicas, pode proporcionar grandes vantagens na compreensão dos processos hidroclimatológicos. De fato, nos últimos anos, muitos estudos têm sido desenvolvidos visando a decomposição do sinal original e posterior utilização em modelos

orientados por dados para previsões de séries hidrológicas a fim de melhorar a eficiência de previsão (ADAMOWSKI & CHAN, 2011; NOURANI *et al.*, 2014; SHOAIB *et al.*, 2016; ZHANG *et al.*, 2018).

Genericamente, Nourani *et al.* (2014) elucidam que, ao realizar uma previsão de série temporal, o modelo híbrido da transformada *wavelet* com técnicas de aprendizado de máquina costuma seguir um procedimento de duas etapas: (i) uso da transformada *wavelet* para pré-processar dados de entrada, fornecendo uma representação de tempo e frequência do sinal em diferentes períodos no domínio do tempo, bem como informações sobre a estrutura física dos dados; e (ii) extração de características do sinal original para servirem de entrada, e assim permitir que o modelo híbrido processe os dados. Um esquema dessa representação pode ser visualizada na Figura 3.5.

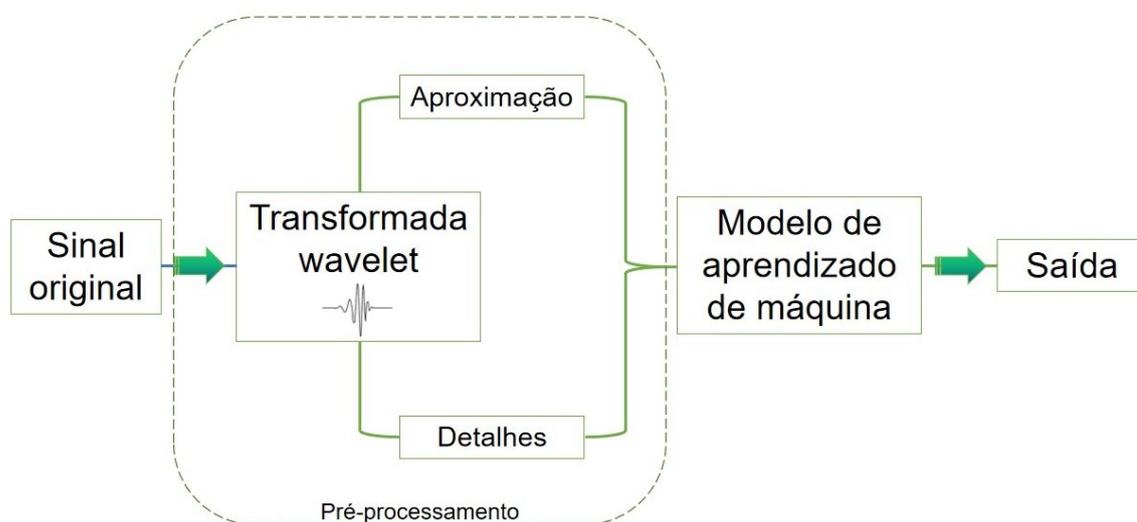


Figura 3.5: Diagrama de um modelo híbrido para previsão de vazões com base em decomposição por transformada *wavelet*

Etapa particular de cada pesquisa é a escolha da função *wavelet* a ser usada e o número de níveis de decomposição da série temporal, o que é comumente feito por tentativa e erro. Apesar da dificuldade nessa escolha, alguma sugestão para essa definição pode ser desenvolvida com base na natureza, propósitos da aplicação e em características específicas da análise, como o uso em sinais estacionários ou não, o tipo de resolução espectral, a forma dos sinais, entre outros.

Algumas pesquisas sobre comparação de funções *wavelet* para extração de características na previsão de séries hidrológicas serão aqui referenciadas. De acordo com Maheswaran & Khosa

(2012), séries temporais com transitoriedades de curta duração costumam apresentar melhor desempenho para extração de características por meio de funções *wavelet*, com forma de suporte compacto e momentos de ordem reduzida, por exemplo a Haar e a Daubechey-4. Por outro lado, as funções *wavelet* com suporte mais amplo e momentos de ordem mais alta, como as *wavelet* Daubechey-2 e Spline-B3, são recomendadas para séries temporais que possuam memória de longo prazo e maiores característica de não-linearidade.

Em estudo comparativo com 23 funções *wavelet*, Shoiab *et al.* (2014) verificaram que a função *wavelet* Daubechey-8 desempenhou a melhor performance para aplicação em modelos de regressão com redes neurais artificiais aplicadas a séries hidrológicas. Segundo esses autores, a *wavelet* Daubechey-8 indicou boa relação da largura com o decaimento em torno da origem do tempo (associado ao suporte compacto), além de ter demonstrado boas propriedades de localização no tempo-frequência. Suas características permitiram que a Daubechey-8 capturassem tanto a tendência quanto as variabilidades de curto prazo, associados respectivamente às baixas e altas frequências dos dados da série temporal.

Vale esclarecer que a *wavelet* Daubechey-8 pertence à família de funções Daubechey-n, em que “n” se refere ao número de momentos nulos que ela possui, associado à habilidade de representar polinômios de diferentes ordens, limitados ao máximo de ordem “n-1”. A família Daubechey-n foi a primeira entre as funções ortogonais, cuja formulação possibilitou a análise da transformada *wavelet* discreta (ADDISON *et al.* 2017).

Dadas essas características e o bom desempenho encontrado por Shoiab *et al.* (2014) com aplicação a séries hidrológicas, a função Daubechey-8 foi aquela verificada para a formação das séries de entrada nos modelos híbridos com decomposição por meio da transformada *wavelet* discreta, no presente trabalho. A Figura 3.6 ilustra uma representação genérica dessa função.

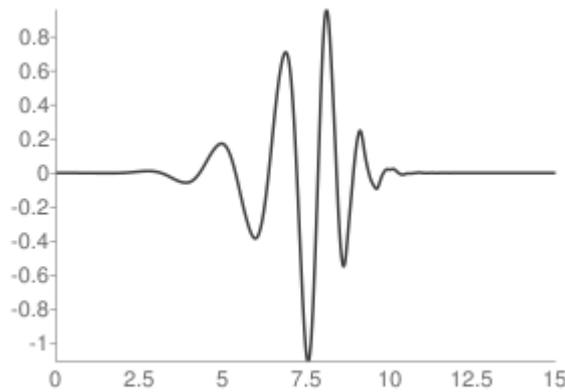


Figura 3.6: Exemplo de função *wavelet* Daubechey-8

Fonte: Misiti *et al.*, 2018.

Feita a decomposição da série histórica com uma função *wavelet*, a definição seguinte diz respeito ao número máximo de níveis de decomposição “ M ” da transformada *wavelet* discreta. Nourani *et al.* (2014) sugerem que o primeiro passo para essa escolha seja em função da extensão da série histórica “ N ”, equivalente ao número inteiro de $M = \log_2(N)$. Os autores também recomendam considerar as prováveis periodicidades inerentes aos efeitos físicos da série em estudo, como exemplo, os ciclos diários ou sazonais.

Na opção por filtros realizados por meio das transformações matemáticas com o intuito de beneficiar o pré-processamento dos sinais originais, na prática, é comum que a escolha da combinação das variáveis de entrada de um modelo de aprendizado de máquina seja pautada pelo melhor conjunto de coeficientes de detalhes. Nesse sentido, dos mais de cem trabalhos classificados e sumarizados por Nourani *et al.* (2014), foi notado que uma estratégia útil para modelagens que fazem uso da transformada *wavelet* para pré-processamento de dados na aplicação de modelos de inteligência artificial com curta resolução temporal (por exemplo horária ou diária) é utilizar subsinais que contêm maior energia, ou seja, coeficientes de detalhes com baixos níveis de decomposição *wavelet*. Por outro lado, para previsão sazonal ou modelagem de longo prazo em escalas de tempo mensais ou sazonais, um modelo híbrido que decomponha as séries temporais em níveis elevados pode ser vantajoso, uma vez que detecta a memória de longo prazo do processo.

3.2.2 Decomposição por modos empíricos (EMD)

A decomposição por modos empíricos (ou *empirical mode decomposition* – EMD) é uma técnica de decomposição de séries em tempo-frequência, cuja proposta inicial é lidar com sinais

regidos por processos não-lineares e não-estacionários, utilizando a transformada de Hilbert-Huang. Desenvolvida por Huang *et al.* (1998), a EMD decompõe a série em um número geralmente pequeno de funções com base ortogonal, denominadas “funções de modo intrínseco” (ou *intrinsic mode functions* – IMF).

As principais inovações conceituais dessa abordagem são a introdução das IMF, baseadas nas propriedades locais do sinal, o que ressalta a frequência instantânea em função do tempo; e a introdução da ideia de frequências instantâneas para um conjunto de dados complexo, o que elimina a necessidade de harmônicos espúrios para representar relações não-lineares e não-estacionárias. Por essa última razão, principalmente, a EMD parece apropriada para abordar fenômenos naturais, como as séries temporais hidrológicas, que comumente apresentam sobreposição de componentes periódicos em diversas escalas.

Ao contrário da TWD, a função base da EMD não é fixa *a priori*, e seu fundamento não é matemático, mas empírico. De forma geral, a EMD difere da transformada *wavelet* discreta por se basear em um método adaptativo de decomposição relacionado às propriedades de cada sinal, sem impor características matemáticas pré-definidas à série temporal (NAPOLITANO *et al.*, 2011; NEVES *et al.*, 2012; HUANG *et al.*, 2014).

Huang *et al.* (2009) explicam que, pela abordagem da EMD, a escala característica é definida como a distância entre dois pontos máximos (ou mínimos) sucessivos, o que confere à técnica a possibilidade de lidar com escalas explicitamente locais. Como mencionado, a decomposição empírica da EMD supõe que qualquer conjunto de dados possa ser separado em um conjunto finito de funções de modo intrínseco. Com efeito, cada IMF é uma série temporal que satisfaz duas propriedades:

- Em todo o conjunto de dados, o número de extremos (máximos e mínimos) e o número de cruzamentos na abcissa zero devem ser iguais, ou diferentes no máximo por uma unidade; e
- Em qualquer ponto da série, os valores médios das envoltórias definidas pelas curvas interpoladas que passam por todos os máximos locais e todos os mínimos locais são iguais a zero.

A primeira condição se mostra evidente e semelhante aos requisitos tradicionais de banda estreita para um processo com comportamento Gaussiano estacionário, ao passo que a segunda condição incorpora uma novidade, visto que modifica as exigências clássicas de tratamento global dos dados com base em uma caracterização local. Ela é necessária para que a frequência instantânea não adquira as flutuações indesejadas, induzidas por oscilações assimétricas. Idealmente, a segunda condição deveria ser “a média local dos dados igual a zero”. No entanto, para processos não-estacionários, a média local envolve uma escala de tempo local, o que é impossível de se obter. Como alternativa, Huang *et al.* (2009) sugerem utilizar a média local das envoltórias definidas pelos máximos e mínimos locais com o fim de forçar a simetria local.

O algoritmo da EMD decompõe uma série temporal $x(t)$ no conjunto de funções IMF, $c_i(t)$, $i = 1, \dots, L$ e uma parte restante $r(t)$ denominada “resíduo”, o qual representa um padrão monotônico e pode ser considerado como a tendência geral da série original. A soma de todos os IMF com o resíduo recompõe a série original, conforme a equação a seguir:

$$x(t) = \sum_{i=1}^L c_i(t) + r(t) \quad (3.23)$$

Dessa expressão, Napolitano *et al.* (2011) pontuam que há alguns erros numéricos inevitáveis, geralmente insignificantes. Uma característica importante das IMF é que sua transformação de Hilbert é consistente com definições que fornecem descrição de tempo-frequência-energia de uma série temporal. Com efeito, a propriedade de adaptabilidade se torna relevante na análise de processos não-lineares e não-estacionários, visto que essa adaptação às variações pontuais dos dados pode explicar alguns processos físicos associados. Huang *et al.* (1998) acrescentam que o objetivo da EMD não é fornecer uma expressão linear fisicamente significativa da série temporal, mas prover componentes individuais no sistema linear que podem ter um significado físico relacionado ao sistema não-linear, quando assumida a série completa.

As IMF são definidas por um processo iterativo denominado *sifting*, ou peneiramento, que é a base do algoritmo da EMD. Sua função é eliminar gradualmente as oscilações, suavizando os perfis das séries. A Figura 3.7 permite melhor visualização do processo de decomposição por modos empíricos, utilizando a transformada de Hilbert-Huang. Por ela, a série de dados “ $h_1(t)$ ”, é envolvida pela interpolação dos extremos máximos e mínimos, respectivamente “ $u_1(t)$ ” e “ $l_1(t)$ ”, produzindo uma IMF designada por “ $m_1(t)$ ”.

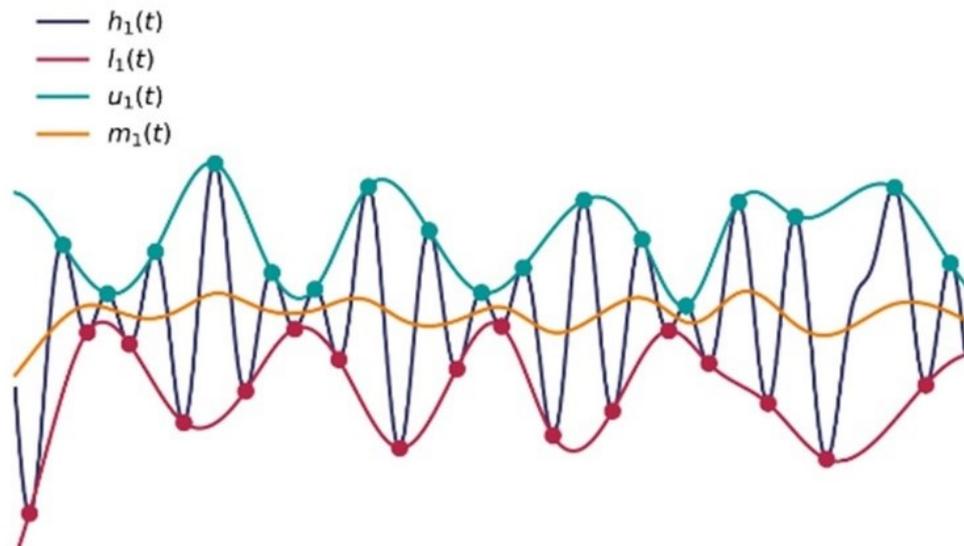


Figura 3.7: Processo de decomposição por modos empíricos para obter a IMF $m_1(t)$

Fonte: Criado por Geir Kulia, modificado por Matt Hall (Creative Commons).

O procedimento da decomposição por modos empíricos pode ser resumidamente encontrado pelos seguintes passos (NEVES *et al.*, 2012):

1. Identificar todos os pontos extremos de máximos e mínimos locais da série de dados $x(t)$;
2. Determinar a envoltória superior e_{max} e a envoltória inferior e_{min} , a partir, por exemplo, da interpolação via *spline* cúbica. Para outras interpolações, consultar Huang & Wu (2008);
3. Encontrar a média " $m(t)$ ", com $m = [e_{max}(t) + e_{min}(t)]/2$, ponto a ponto, entre as duas envoltórias;
4. Extrair o detalhe $h_1(t) = x(t) - m(t)$;
5. Se $m(t) = 0$ ou menor que um limiar fixo, o detalhe " h_1 " é armazenado como a primeira IMF, que passa a ser nomeada " c_1 ", ver Eq. (3.23);
6. Caso contrário, as etapas 1 a 3 são repetidas, agora tratando " $h_1(t)$ " como um dado da série, e assim por diante, até que $h_1(t)$ preencha as propriedades de uma IMF (número de cruzamentos igual a zero e média zero); e
7. Obter a diferença $r_1(t) = x(t) - c_1(t)$. Uma sugestão para o término do procedimento é fazê-lo quando o número de extremos de $r_1(t)$ for menor ou igual que dois; caso contrário, $r_1(t)$ deve ser tratado como uma nova série de dados $x(t)$ e repetir os passos 1 a 4 para definir a nova IMF.

Segundo Neves *et al.* (2012), a iteração que consta no passo 4 é a responsável pelo peneiramento da técnica. Atendido o critério de convergência, conforme sugerido no passo 5, o cálculo é interrompido e o resultado é um conjunto de IMF somado ao resíduo. Essa abordagem permite a modulação de frequência e de amplitude simultaneamente.

Ao trabalhar com o pré-processamento de séries de vazão para modelar uma rede neural artificial, Napolitano *et al.* (2011) mencionam que a natureza orientada por dados da EMD é sobretudo compatível com a natureza não paramétrica das RNAs. Com efeito, essa combinação fornece uma estratégia de modelagem muito flexível, a qual, dependendo das particularidades da série histórica, como trechos com maior quantidade de energia, é capaz de apresentar resultados competitivos em relação à transformada *wavelet*.

3.3 Modelos de aprendizado de máquina para previsão de séries temporais

A modelagem de processos hidrológicos procura responder questões relacionadas à compreensão do sistema, usualmente com o intuito de melhor exercer a gestão, o planejamento e outros aspectos de cunho operacional em recursos hídricos. Tal realização costuma considerar vários componentes da bacia hidrográfica, o que não é uma tarefa simples, tendo em vista suas variabilidades no espaço e no tempo, o que leva os processos hidrológicos a serem altamente não-lineares e de natureza complexa. Nesse sentido, o planejamento de ações pode ser desenvolvido com o fim de organizar uma sequência de procedimentos operativos no sistema hídrico que resulte em determinado comportamento futuro, presumivelmente esperado pelo agente responsável pela tomada de decisões.

Séries temporais de vazão são uma importante fonte de informação para diversas aplicações humanas, tais como projetos hidráulicos, gerenciamento de recursos hídricos e planejamento de reservatórios, todos realizados após algum entendimento dos processos hidrológicos envolvidos. No entanto, é comum que esses registros não sejam compreendidos em medida suficiente para estabelecer relações físicas com a bacia hidrográfica. Por outro lado, as modelagens orientadas por dados (ou *data-driven models*) oferecem uma alternativa frequentemente utilizada em muitas áreas da hidrologia, pois procuram extrair conhecimentos inerentes aos dados sem exigir necessariamente detalhes internos do sistema, como padrões de

infiltração e evapotranspiração da bacia, relações cota-volume de reservatórios ou regras operacionais de comportas. Essas modelagens envolvem equações matemáticas extraídas não prioritariamente do processo físico, mas da análise de séries de entrada, dos processos internos e das saídas simultâneas. Com efeito, sua parametrização não é fixa, e depende essencialmente do conjunto de dados (SOLOMATINE & OSTFELD, 2008).

Os métodos de aprendizado de máquina têm se mostrado promissores na modelagem e na previsão de processos hidrológicos, ao lidar com a significativa dinamicidade e quantidade de ruído do conjunto de dados. As habilidades em capturar a relação dos comportamentos envolvidos na série, mapeando sistemas não-lineares, destacam-se entre as características mais atrativas desses modelos. Maier *et al.* (2010) e Nourani *et al.* (2014) são enfáticos ao alegar que as vantagens dos modelos de inteligência artificial como esses são adequadas para aplicações em modelagem hidrológica.

Vale mencionar que no contexto do aprendizado de máquina, a palavra “aprendizado” descreve um processo de busca automática para melhores representações dos dados a serem analisados. Ao partir do conhecimento extraído unicamente das séries temporais, as técnicas de aprendizado de máquina evitam a necessidade de operadores humanos especificarem formalmente toda a informação que o computador necessita. De certa forma, a hierarquia de conceitos embutidos nos algoritmos permite o aprendizado de atributos complexos, construindo-os a partir de atributos mais simples.

Nourani *et al.* (2014) elencam três grupos principais de empregos nos campos hidroclimatológicos voltadas ao pré-processamento de dados e posterior uso em modelos de aprendizado de máquina:

- Computação evolucionária: um ramo de métodos de otimização que inclui, entre outros, os algoritmos evolucionários, de onde se destacam os algoritmos genéticos;
- Lógica Fuzzy, ou Lógica difusa: oferece uma alternativa à lógica booleana, e permite classificações em mais de um grupo com uma dada probabilidade, de acordo com os graus de pertinência assumidos;
- Métodos classificadores, de regressão e de aprendizagem estatística: empregam abordagens estatísticas e de aprendizado de máquina. Os exemplos mais comuns são as

redes neurais artificiais, métodos de *kernel* e o aprendizado profundo (*deep learning*), este último em fase mais recente de desenvolvimento.

Entre essas técnicas, as redes neurais artificiais (RNA) para a previsão de variáveis de recursos hídricos são as mais utilizadas e possuem referência bastante documentada entre a comunidade acadêmica. Desse modo, as variantes dos algoritmos das RNA predominam entre as demais abordagens em aprendizado de máquina (MAIER *et al.*, 2010; NOURANI *et al.*, 2014). Apesar disso, as tentativas de superar algumas de suas limitações têm aberto caminho para outras áreas, por exemplo, as baseadas em métodos de *kernel*, entre os quais se encontram os Processos Gaussianos (RASMUSSEN & WILLIAMS, 2006; SUN *et al.*, 2014).

De forma geral, as regressões consistem em uma técnica de construção de modelos preditivos que investigam a relação entre uma variável dependente (valor desconhecido, assumido como o alvo da regressão) e uma ou mais variáveis independentes conhecidas, denominadas “preditores”, ou ainda “regressores”. Com efeito, modelos de regressão podem ser empregados para a previsão de séries temporais, bem como para encontrar possíveis relações de efeito causal entre variáveis. Particularmente no contexto de sistemas dinâmicos para previsões, os preditores são definidos de modo que, ao interagir com o modelo, haja uma relação dinâmica entre essas variáveis regressoras e a saída. Essa relação dinâmica frequentemente aparece como consequência da diferença temporal existente entre a variável dependente e as independentes (AGUIRRE, 2015; COSTA, 2017).

A configuração da estrutura de modelos de aprendizado de máquina busca estabelecer o equilíbrio entre a capacidade de generalização e a sua complexidade. Nessa procura, a consequência de excluir um ou mais conjuntos de entradas significativas nos modelos é a redução da capacidade de capturar as analogias entrada-saída. Por outro lado, em situações em que algumas das entradas selecionadas são individualmente significativas, mas estão relacionadas entre si, pode haver a inclusão de entradas em quantidade além do apropriado, sem agregar informação adicional. Redundâncias assim tendem a ser detectadas no ajuste dos modelos, ao serem observados bons resultados na fase de treino, contudo, sem a mesma qualidade da reprodução da série na fase de teste. Essa dificuldade na generalização ocorre em razão da superestimativa do treinamento, denominada *overfitting* (CRONE & KOURENTZES, 2010; MAIER *et al.*, 2010, SNIEDER *et al.* 2019).

O procedimento de busca entre as relações entrada-saída das variáveis se estabelece em função do tipo de aprendizado de máquina, sendo objeto de muitas pesquisas. Nesse sentido, nos próximos itens do presente tópico serão apresentadas as técnicas de modelos de regressão não-linear para previsão de séries temporais a serem desenvolvidos no decorrer deste trabalho. São elas as redes neurais artificiais e os Processos Gaussianos.

3.3.1 Redes Neurais Artificiais (RNA)

A estrutura das redes neurais artificiais foi desenvolvida a partir de modelos de sistemas nervosos biológicos do cérebro humano. Os elementos computacionais, denominados neurônios artificiais, são modelos simplificados dos neurônios biológicos. Uma RNA pode ser entendida como um conjunto de interconexões paralelas de nós representadas por vetores de pesos sinápticos e que trabalham como um sistema coletivo, cujo objetivo é aprender as analogias entre entrada e saída das variáveis para então reproduzi-las (ADAMOWSKI & CHAN, 2011).

Silva *et al.* (2016) explicam que a estratégia de funcionamento das RNA para fornecer saídas contínuas é feita com base em rotinas que envolvem um sistema com a coleta dos sinais existentes em suas entradas, agregando-as segundo sua função operacional, para então produzir uma resposta levando em conta uma função de ativação. Esse sistema é subdividido em no mínimo três camadas: a camada de entrada, uma ou mais camadas intermediárias (também denominadas camadas ocultas) e a camada de saída. Todo esse procedimento envolve diversas estratégias de operacionalização, o que demanda decisões práticas sobre a configuração dos dados de entrada, arquitetura, topologia e forma de treinamento da rede, entre outros fatores, que podem ser associados a um ajuste de “hiperparâmetros”.

Esses assuntos serão percorridos nos subitens seguintes do presente item. Primeiramente, é importante ressaltar que uma complexa rede neural artificial é composta por um conjunto de elementos mais simples, que é o neurônio artificial. Portanto, a essência do funcionamento de um neurônio artificial é explicada a seguir, e nos subitens subsequentes serão abordados os demais aspectos de uma RNA.

3.3.1.1 Neurônio artificial

Na representação mais simples do modelo de um neurônio artificial (ou “nó”), ilustrado na Figura 3.8, os diversos sinais de entrada $\{x_1, x_2, \dots, x_n\}$ são ponderados por seus respectivos

vetores de pesos sinápticos $\{w_1, w_2, \dots, w_n\}$, os quais, após subtraídos por um limiar de ativação “ θ ”, resultam no potencial de ativação denotado por “ u ”. Por sua vez, esse potencial de ativação é submetido a uma função de ativação “ $g(\cdot)$ ”, resultando finalmente em um valor de saída “ y ”.

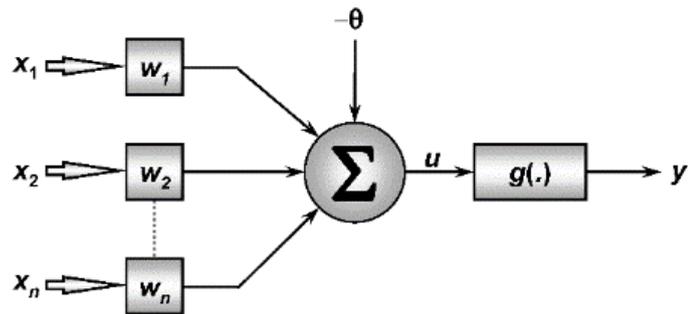


Figura 3.8: Esquema de um único neurônio artificial

Fonte: Silva *et al.*, 2016.

Por essa representação, sete elementos básicos de um neurônio artificial podem ser elencados:

- Sinais de entrada $\{x_1, x_2, \dots, x_n\}$: têm origem nos dados observados, como, por exemplo a vazão em diferentes defasagens temporais significativas, ou ainda coeficientes de decomposição de sinal que as representem;
- Pesos sinápticos $\{w_1, w_2, \dots, w_n\}$: são multiplicadores dos sinais de entrada, os quais tendem a indicar a importância de cada nó de entrada conforme seu valor for mais alto. Podem ser comparados a parâmetros que devem ser bem ajustados para o bom desempenho do modelo;
- Combinador linear $\{\Sigma\}$: agrega todos os sinais de entrada que foram ponderados pelos respectivos pesos sinápticos, a fim de produzir um valor de potencial de ativação;
- Limiar de ativação $\{\theta\}$: especifica o patamar apropriado para que o resultado produzido por $\{\Sigma\}$ possa gerar um valor de disparo em direção à saída do neurônio. A funcionalidade de $\{\theta\}$ lembra o intercepto do modelo de uma função, e está associada ao desvio (*bias*) inicial;
- Potencial de ativação $\{u\}$: é o resultado obtido pela diferença do valor produzido entre o combinador linear e o limiar de ativação. Se $u \geq \theta$, então o neurônio produz um potencial excitatório e o cálculo é efetuado; caso contrário, o potencial será inibitório;

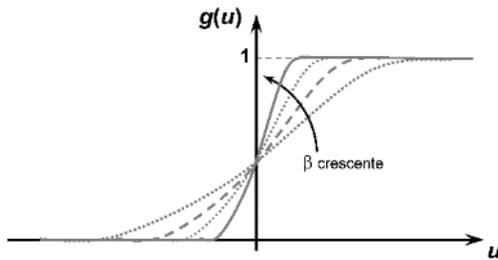
- Função de ativação $\{g\}$: seu objetivo é limitar a saída do neurônio dentro de um intervalo de valores razoáveis a serem assumidos pela imagem da função (algumas funções de ativação serão descritas adiante); e
- Sinal de saída $\{y\}$: consiste no valor final produzido pelo neurônio em relação a um determinado conjunto de sinais de entrada. Conforme a arquitetura da rede, esse valor $\{y\}$ poderá servir como sinal de entrada para outros neurônios.

Existem diversas funções de ativação para serem empregadas em um neurônio artificial. As funções logística, tangente hiperbólica, Gaussiana e linear, que se caracterizam por serem totalmente diferenciáveis, estão formalizadas, respectivamente, pelas equações expostas na Tabela 3.1. As representações gráficas desses quatro tipos de funções de ativação aplicadas a neurônios artificiais são ilustradas na Figura 3.9.

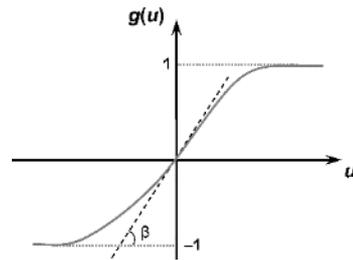
Tabela 3.1: Funções de ativação em redes neurais artificiais

Funções de ativação em RNA	Expressão matemática	Número da equação
Logística	$g(u) = \frac{1}{1 + e^{-\beta u}}$	(3.24)
Tangente hiperbólica	$g(u) = \frac{1 - e^{-\beta u}}{1 + e^{-\beta u}}$	(3.25)
Gaussiana	$g(u) = e^{-\frac{(u-c)^2}{2\sigma^2}}$	(3.26)
Linear	$g(u) = u$	(3.27)

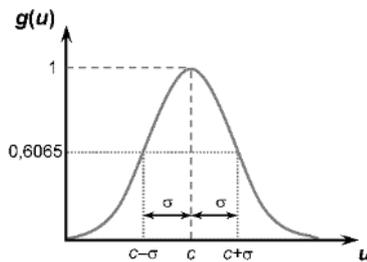
a) Função logística



b) Função tangente hiperbólica



c) Função Gaussiana



d) Função linear

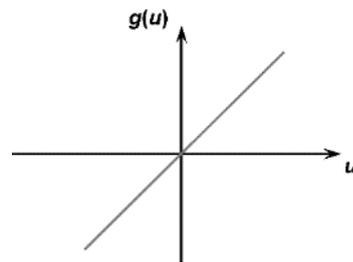


Figura 3.9: Funções de ativação aplicadas nos neurônios artificiais

Fonte: Silva *et al.*, 2016.

Embora também haja funções de ativação parcialmente diferenciáveis (como as funções degrau e a de rampa simétrica), todas aquelas exibidas na Figura 3.9 possuem derivadas de primeira ordem e são conhecidas em quaisquer pontos do seu domínio.

O coeficiente β das funções sigmóides (logística e tangente hiperbólica) é uma constante real associada ao nível de inclinação da função frente ao seu ponto de inflexão, de forma que, quando seu valor tende ao infinito, essas funções se aproximam de uma função degrau. Matematicamente, a principal diferença entre as funções sigmóides é que a função logística possui como imagem números reais entre 0 e 1, ao passo que a função tangente hiperbólica possui imagem entre -1 e 1. Visto que neurônios biológicos funcionam de forma binária (comando ativar ou não ativar), a função logística costuma ser uma alternativa para modelar processos não-lineares, já que assume valores apenas entre 0 (não ativação) e 1 (ativação). No entanto, nas regiões de saturação da função, onde essas derivadas tendem a zero, a propagação do gradiente é reduzida, causando dificuldades no treinamento. Nesse sentido, as funções

sigmóides melhor se aproximam da identidade e possuem menor região de saturação. Por isso, elas são as mais empregadas nas camadas intermediárias das RNA (SILVA *et al.*, 2016).

Em relação aos coeficientes da função de ativação Gaussiana, apresentada na equação (3.26) **Erro! Fonte de referência não encontrada.**, o parâmetro “ c ” é responsável por definir o centro da função, enquanto “ σ ” indica o seu desvio padrão, cujo valor está diretamente associado ao ponto de inflexão da função. Segundo Braga *et al.* (2007), esta função de ativação é bastante útil em redes multicamadas, como por exemplo as redes RBF (*Radial Basis Function*), uma variação das redes neurais artificiais. Nelas, a ativação de um neurônio pode ser função da distância entre seus vetores de entrada e de peso.

A função de ativação linear, ou função identidade, produz resultados de saída idênticos aos valores do potencial de ativação $\{u\}$. Uma das aplicabilidades dessa função está na utilização de redes neurais artificiais como aproximadores universais de funções, a fim de mapear o comportamento entre variáveis de entrada e saída. Evidentemente, a aplicação indiscriminada de funções puramente lineares resulta em uma rede neural com uma única transformação linear. Para eliminar essa possibilidade, ao menos uma das camadas intermediárias de uma RNA deverá conter funções de ativação não-lineares. Sendo assim, é comum que as funções lineares sejam utilizadas na camada de saída, e outras funções, como as sigmóides, sejam utilizadas nas camadas intermediárias (BRAGA *et al.*, 2007).

3.3.1.2 Topologia, arquitetura e processos de treinamento da rede neural artificial

Apesar de neurônios individuais possuírem capacidade computacional limitada, um conjunto de neurônios artificiais conectados na forma de uma rede é capaz de resolver problemas de elevada complexidade. Conforme já mencionado, para compor essa rede, os neurônios são organizados em no mínimo três camadas principais. A camada de entrada é usada para alimentar dados para as redes; a camada de saída é usada para produzir uma resposta às entradas fornecidas; e uma ou mais camadas intermediárias são usadas para atuar como uma coleção de detectores de recursos, e permitem representar o processo não-linear, após serem ajustados os pesos a serem ponderados pelos dados de entrada. Com efeito, a topologia da RNA consiste na disposição dos nós nas camadas da RNA, organizados, por exemplo, em função do número de neurônios em cada camada, além da quantidade de camadas intermediárias, ou ainda do tipo de função de ativação configurada para cada nó. Todas as características na definição da topologia devem levar em conta o objetivo da aplicação da rede. Nesse sentido, em muitas situações, uma

única camada intermediária é suficiente para resolver modelos de regressão, o que não acontece com problemas relacionados à classificação (BRAGA *et al.*, 2007; ADAMOWSKI *et al.*, 2012; KASIVISWANATHAN *et al.*, 2016).

Enquanto a topologia de uma RNA diz respeito ao número e organização dos nós, camadas intermediárias e funções de ativação, a arquitetura de uma rede neural define a estrutura como os diversos neurônios estão interligados em função do fluxo de cálculo. Duas das principais arquiteturas RNA são as redes *feedforward* (com alimentação à frente) de camadas múltiplas e as redes recorrentes.

Em uma arquitetura *feedforward* o fluxo dos cálculos segue uma única direção, ou seja, cada neurônio está conectado apenas com neurônios em camadas contíguas, sem retroalimentação. De fato, a arquitetura de rede neural artificial mais comum é a *Perceptron feedforward* multicamadas (ADAMOWSKI *et al.*, 2012). Uma rede *Perceptron* multicamadas típica composta por três camadas com função de ativação sigmoideal na camada intermediária é mostrada na Figura 3.10.

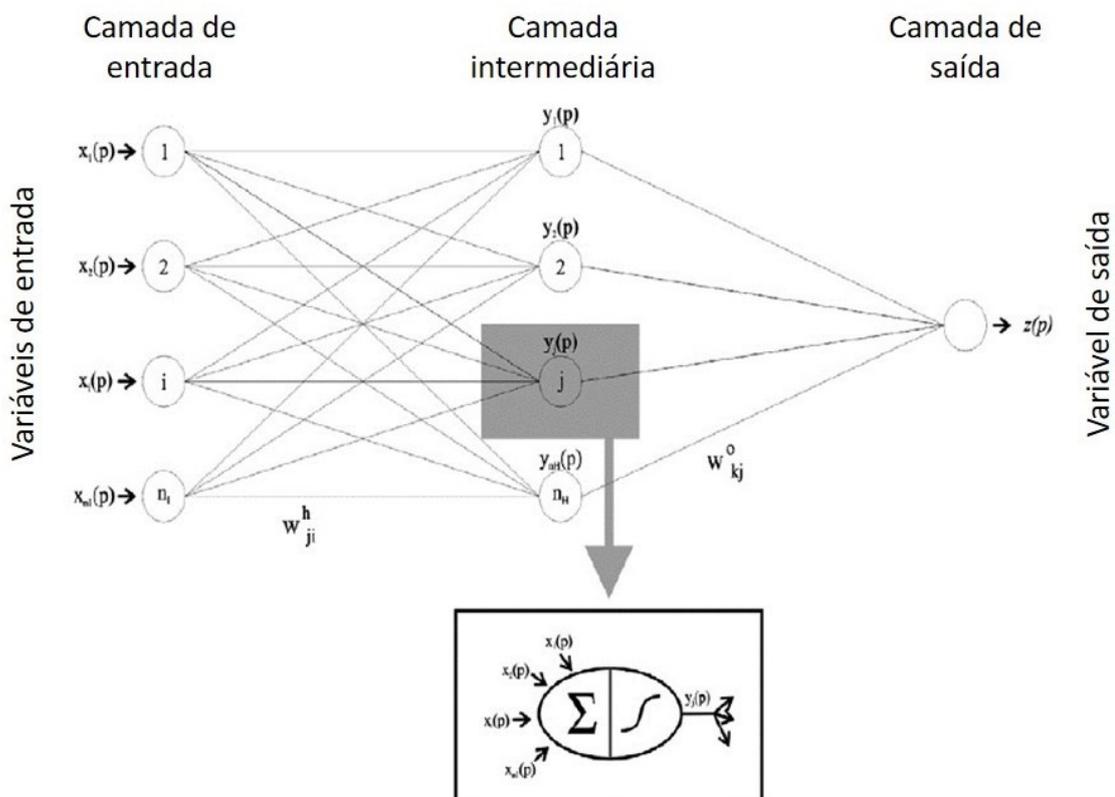


Figura 3.10: RNA *Perceptron* com arquitetura *feedforward* e uma camada intermediária

Fonte: Adaptado de Adamowski & Chan, 2011.

Nessa ilustração, dois conjuntos de pesos ajustáveis estão presentes: o w_{ji} controla a força da conexão entre o nó intermediário j e o nó de entrada i ; enquanto w_{kj} controla a força da conexão entre o nó de saída k e o nó intermediário j . Cada neurônio recebe uma matriz de entrada e produz uma única saída. A saída de um neurônio na camada de entrada é conduzida ao neurônio na camada intermediária. Da mesma forma, a saída do neurônio na camada intermediária é a entrada para o neurônio da camada de saída. Cada neurônio intermediário e de saída processa sua entrada pela função de ativação, conforme representado no detalhe inferior da Figura 3.10. Nessa arquitetura, como se nota, não há conexão direta entre o neurônio na camada de entrada com aqueles neurônios da camada de saída (ADAMOWSKI & CHAN, 2011).

A principal diferença entre a arquitetura RNA *feedforward* para a RNA recorrente é que nesta última há retroalimentação da informação de saída para alimentar outros neurônios da rede. A propriedade de retroalimentação qualifica as redes recorrentes para processamento dinâmico de informações, sendo bastante empregadas em análises de sistemas variantes em relação ao tempo, como a previsão de séries temporais e otimização de processos (SILVA *et al.*, 2016).

A Figura 3.11 representa uma rede *Perceptron* com arquitetura recorrente, cuja informação de saída realimenta os neurônios da camada intermediária.

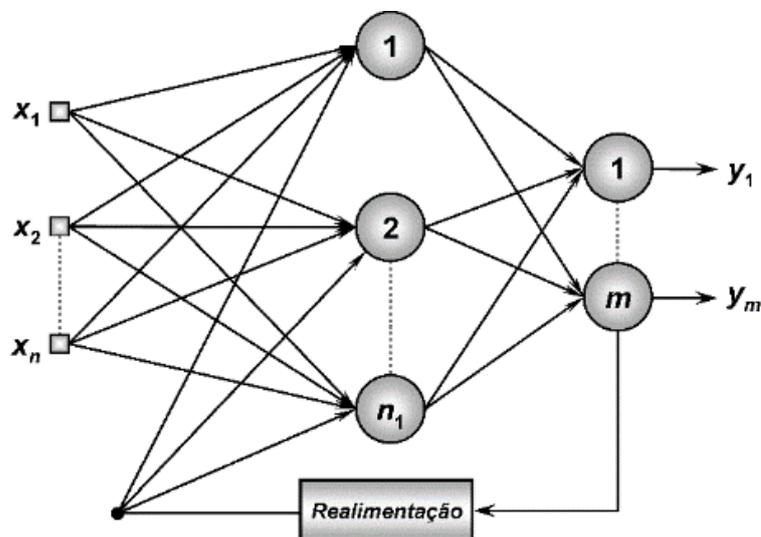


Figura 3.11: Estrutura RNA *Perceptron* com arquitetura recorrente e uma camada intermediária com n_1 neurônios

Fonte: Silva *et al.*, 2016.

Para qualquer arquitetura, a cada conexão entre nós é atribuído um peso, que é uma estimativa numérica proporcional à força de conexão com a entrada. O processo de treinamento da RNA

consiste da aplicação de passos ordenados para o ajuste ideal desses pesos sinápticos e limiares de seus neurônios, objetivando a generalização de soluções a serem produzidas pelas suas saídas, cujas respostas são representativas do sistema físico.

Nas RNA *Perceptron*, os algoritmos de aprendizado utilizados nos processos de treinamento para ajuste dos pesos sinápticos $\{w\}$ e dos limiares de ativação $\{\theta\}$ são geralmente variantes da regra delta generalizada. Essa regra estabelece um comparativo entre a saída produzida y_p e a saída desejada y_d , de forma que enquanto houver diferenças entre elas acima de um limiar especificado, os pesos sinápticos e limiares da rede serão incrementados (condição excitatória) proporcionalmente aos valores de seus desvios. Quando houver proximidade entre y_p e y_d , os pesos e limiares se mantêm inalterados (condição inibitória). Esse processo é repetido sequencialmente para todas as amostras de treinamento, até que a saída produzida seja similar à desejada de cada amostra, conforme expresso na seguinte iteração:

$$w_t = w_{t-1} + \eta \cdot \Delta y \cdot x_k \quad (3.28)$$

Nessa representação, “ w_t ” e “ w_{t-1} ” denotam o vetor de pesos $\{w\}$ e limiar de ativação $\{\theta\}$ nos passos atual e anterior, respectivamente ($w = [\theta \ w_1 \ w_2 \ \dots \ w_n]^T$). O segundo termo da equação (3.28) **Erro! Fonte de referência não encontrada.** denota o ajuste aplicado aos pesos, de modo que “ x_k ” é a k -ésima amostra de treinamento ($x_k = [-1 \ x_1^k \ x_2^k \ \dots \ x_n^k]^T$); “ Δy ” é a diferença entre as saídas produzida e esperadas para a k -ésima amostra de treinamento ($\Delta y = y_d^k - y_p$); e “ η ” é uma constante que define a taxa de aprendizagem da rede. A taxa de aprendizagem “ η ” exprime o quão rápido o treinamento da rede é conduzido à sua convergência. Sua escolha deve ser realizada com cautela para evitar instabilidades durante o treinamento, normalmente $0 > \eta > 1$ (SILVA *et al.*, 2016). A taxa de aprendizagem é alterada conforme o processo computacional, e as técnicas de ajuste dessa alteração são função do algoritmo de convergência.

Os algoritmos de aprendizado das RNA diferem, basicamente, na forma como o ajuste aplicado aos pesos (segundo termo da equação (3.28)) é calculado. Há vários algoritmos diferentes para treinamento de redes neurais, os quais costumam ser agrupados em dois tipos principais: aprendizado supervisionado e aprendizado não-supervisionado.

O treinamento supervisionado, usualmente praticado em regressões, se fundamenta na existência de amostras correspondentes de saída desejada para cada entrada, organizadas, por

exemplo, em forma de tabela de atributos, com campos de entrada e saída associadas $[(x_1, y_1), (x_2, y_2), \dots, (x_i, y_i)]$. Visto que a resposta da rede é função dos valores atuais do seu conjunto de pesos, estes são ajustados de forma a aproximar a saída da rede com a saída desejada contida na tabela de atributos, por meio de minimização da diferença incremental. Dessa forma, são realizados ajustes nos vetores de pesos e limiares, com atualização a cada época de treinamento dos dados. A rede será considerada treinada quando a defasagem entre as saídas produzidas e desejadas atingir um limite aceitável.

No treinamento não-supervisionado o pareamento entre informações de entrada e saída da rede neural não existe. Durante o processo de aprendizagem, os padrões de entrada são revelados continuamente à rede, que tenta identificar as regularidades existentes, agrupando em subconjuntos com características semelhantes. Portanto, os pesos sinápticos e limiares dos neurônios são ajustados conforme a capacidade de auto-organização da rede, de modo a refletir essa representação internamente.

3.3.1.3 Sistemas variantes no tempo

Até a presente etapa do texto, a conceituação sobre redes neurais artificiais foi generalizada, aplicáveis normalmente em problemas de ordem estática, ou seja, os dados de entrada são sempre os mesmos durante o processamento. Exemplos de sistemas assim são aqueles voltados para aproximação de funções e classificação ou reconhecimento de padrões. Contrariamente, os problemas de ordem dinâmica possuem saídas que dependem dos valores anteriores de saída e de entrada, ao assumir determinado instante de tempo, sendo, portanto, variantes no tempo. Uma das principais aplicações de sistemas dinâmicos é na previsão de séries temporais.

Segundo Silva *et al.* (2016), em sistemas estáticos, após ter sido treinada uma RNA de múltiplas camadas, os domínios de definição e de operação são os mesmos. Por outro lado, em sistemas dinâmicos, ambos os domínios de definição e de operação são regidos pelo tempo, não sendo coincidentes nesse eixo, conforme mostrado na Figura 3.12. Dessa forma, visto que nos sistemas dinâmicos a saída atual depende das saídas e entradas anteriores, utilizam-se os dados de treinamento e teste para ajustar os pesos sinápticos internos da rede. Em seguida, essa rede estará apta a estimar valores futuros que pertencem ao seu domínio de operação.

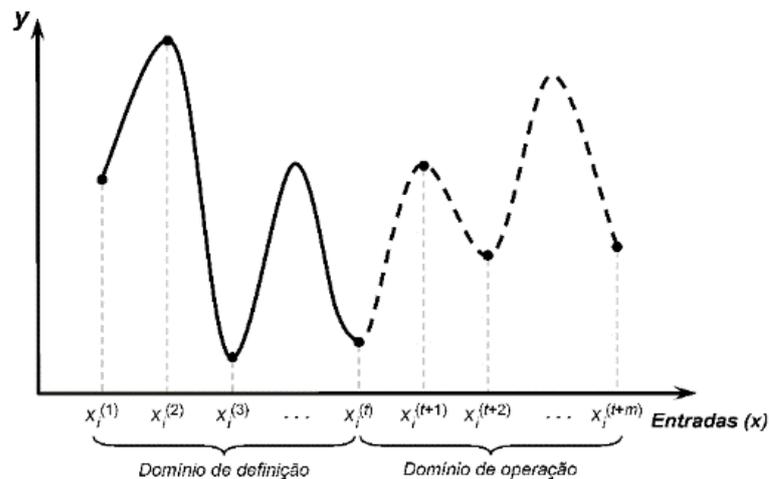


Figura 3.12: Domínios de definição e de operação de RNA *Perceptron* de múltiplas camadas aplicado em problemas de sistemas dinâmicos

Fonte: Silva *et al.*, 2016.

Ao incorporar um termo de memória na estrutura da rede neural (convencionalmente estática, como um *Perceptron* de múltiplas camadas), a sua saída se torna uma função do tempo, agregando características dinâmicas ao procedimento. Com efeito, a rede estática lida com a não-linearidade, enquanto a memória é responsável pela variação dos dados a cada passo temporal. Sucintamente, há duas maneiras principais de promover memória a uma RNA: (i) introduzindo atraso no tempo; e (ii) utilizando redes recorrentes, cujas conexões de entrada são realimentadas pelas saídas do próprio modelo.

Nas redes neurais com atraso no tempo, a previsão de valores posteriores a partir do instante “ t ” é computada a partir do conhecimento dos valores anteriores em relação ao tempo, de modo semelhante a um modelo autorregressivo. A equação abaixo expressa a relação do atraso temporal, considerando “ n_p ” a ordem da memória do preditor, ou seja, a quantidade de amostras anteriores necessárias para estimar o valor de $x(t)$.

$$x(t) = f(x(t-1), x(t-2), \dots, x(t-n_p)) \quad (3.29)$$

No processamento computacional, a rede recebe as n_p entradas e prediz como resposta o respectivo valor esperado para $x(t)$, cujo resultado é fornecido pelo seu neurônio de saída. Assim, a rede tentará ajustar as matrizes de pesos visando minimizar o erro produzido pela diferença entre $x(t)$, que é função das entradas anteriores, e a saída. Portanto, é utilizado o

algoritmo de treinamento supervisionado. De forma geral, a operação ocorre continuamente como uma janela deslizante de largura n_p em cada interação de tempo ao longo da série.

Conforme mencionado, a memória também pode ser inserida à RNA ao promover saídas recorrentes às entradas, o que possibilita a recuperação de respostas passadas a partir de realimentação de sinais produzidos em instantes anteriores. A predição de valores futuros associados ao comportamento do processo, a partir do instante “ t ”, será também baseada nos valores anteriores que foram produzidos por suas saídas, conforme expresso a seguir:

$$x(t) = f(x(t-1), x(t-2), \dots, x(t-n_p), y(t-1), x(t-2), x(t-n_p)) \quad (3.30)$$

Novamente, “ n_p ” denota a ordem equivalente à memória do preditor para estimar adequadamente o valor da entrada $x(t)$. Nas redes recorrentes de sistemas dinâmicos, o papel desempenhado pela rede após o seu treinamento é o de representar de forma indireta a função responsável por identificar o relacionamento entre as entradas e saídas. O arranjo topológico de uma RNA de múltiplas camadas com recorrência dos dados é ilustrado na Figura 3.13.

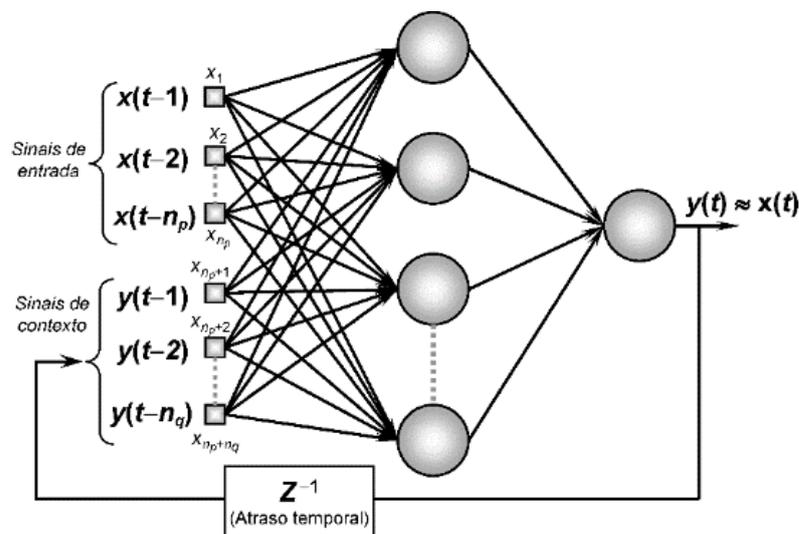


Figura 3.13: Topologia de uma RNA com múltiplas camadas com saídas realimentadas às entradas em sistemas dinâmicos

Fonte: Silva *et al.*, 2016.

Por essa configuração, a rede recebe as n_p entradas $\{x(t-1), x(t-2), \dots, x(t-n_p)\}$ capazes de representar o comportamento do sistema, gerando estimativas de entradas no tempo atual $x(t)$, as quais são comparadas com as saídas $y(t)$ do modelo. Particularmente nas redes recorrentes para processos dinâmicos, os sinais de contexto realimentam os neurônios da primeira camada,

utilizando todas as n_q respostas passadas que foram produzidas pelo neurônio de saída em seus instantes anteriores. Com efeito, o mapeamento entre entradas e saídas é executado de maneira implícita, ou seja, sem o controle do ajuste dos pesos ao longo do procedimento.

3.3.2 Regressão por Processos Gaussianos (RPG)

No início do presente tópico 3.3, sobre modelos de aprendizado de máquina para previsão de séries temporais, foram descritos conceitos iniciais que competem a modelos de regressão. Como exemplo de emprego, é citada a previsão de séries baseada no aprendizado supervisionado, ou seja, em modelos que se utilizam da relação entrada-saída dos dados. A regressão por Processos Gaussianos (RPG) é um modelo estatístico não paramétrico que tira proveito do aprendizado supervisionado para extrair uma medida da semelhança entre dois pontos a fim de prever um valor de um ponto desconhecido dos dados de treinamento, bem como trazer informação quanto à distribuição marginal sobre esse valor. Tal medida de semelhança é estimada por meio das funções *kernel* (também chamadas de “cerne”, ou “núcleo”, em português).

Em condições reais, é comum que as relações não-lineares do sinal original dificultem a captura de informações para a boa associação dos dados. Nesse contexto, de acordo com o teorema de Cover, as informações de entrada podem ser mapeadas para um espaço de características de dimensão superior por meio de funções não-lineares, como as referidas funções *kernel*. Seu principal benefício é que, ao invés de identificar uma série de associações das entradas do modelo, basta que seja definida uma única função capaz de calcular a semelhança entre os pontos. Com efeito, as funções *kernel* mapeiam implicitamente os dados para um espaço dimensional maior S , tal que $S = \{1, \dots, d\}$, admitindo, matematicamente, que “ S ” possua dimensão infinita. No entanto, para fins práticos, é usual limitar um conjunto finito de valores nesse espaço dimensional “ S ”, a fim de permitir a generalização necessária para que o modelo resolva uma variedade de problemas hidrológicos (RASOULI *et al.*, 2012; SUN *et al.*, 2014).

A associação entrada-saída de um modelo pode ser interpretada ao considerar “ n ” variáveis independentes de treinamento num espaço vetorial “ \mathbf{X} ”¹, sendo $\mathbf{X} = [x_1, \dots, x_n]$, de modo que a i -ésima entrada “ x_i ” influencia diretamente a saída “ y_i ”. Essa associação é regida por uma

¹ Todas as representações em negrito denotam um vetor.

função “ f_i ” desconhecida, sendo $f_i = f(x_i)$, geradora do vetor de variáveis dependentes $\mathbf{y} = [y_1, \dots, y_n]$. Em observações de séries naturais, como em sistemas de recursos hídricos, é comum adicionar ainda um ruído Gaussiano independente “ ε_i ”, com distribuição do tipo $\varepsilon_i \sim N(0, \sigma^2)$. Essa descrição é matematicamente expressa por:

$$y_i = f_i + \varepsilon_i \quad (3.31)$$

Admite-se que as n variáveis aleatórias em um vetor $\mathbf{f} = [f_1, \dots, f_n]^T$ estejam relacionadas com o vetor \mathbf{X} de entrada. Além disso, considera-se que qualquer combinação linear dos n componentes possua distribuição Gaussiana univariada. Portanto, sua função densidade de probabilidade “ $p(\mathbf{f})$ ” é expressa por:

$$p(\mathbf{f}) = \left(\sqrt{2\pi^n |\Sigma|}\right)^{-1} \exp\left(-\frac{1}{2} (\mathbf{f} - \mu)^T \frac{1}{\Sigma} (\mathbf{f} - \mu)\right) \quad (3.32)$$

Nota-se que “ $|\Sigma|$ ” é um escalar, visto ser o determinante da matriz de covariância Σ .

Rasmussen & Williams (2006) sintetizam toda a representação *a priori* da regressão por Processos Gaussianos por meio da expressão da função “ f ”, formalizada por:

$$f(\mathbf{x}) \sim PG(m(\mathbf{x}), k(x, x')) \quad (3.33)$$

A notação “ $m(\mathbf{x})$ ” denota a função de média; e “ $k(x, x')$ ” é a função *kernel*, a qual expressa a covariância esperada entre o valor da função nos pontos x e x' e determina a característica da função que se deseja prever.

A consideração de o vetor de funções \mathbf{f} possuir *a priori* distribuição Gaussiana multivariada é um dos conceitos essenciais da RPG. A partir de então, a definição das funções de média e covariância com os dados observados \mathbf{X} e \mathbf{y} no treino implicam uma distribuição *a posteriori* sobre essa função. Isso ocorre mediante a especificação da função de verossimilhança dos resíduos da regressão, a qual, em geral, é também assumida como Gaussiana, com erros independentes e identicamente distribuídos.

Pela definição teórica explanada por Rasmussen & Williams (2006), um Processo Gaussiano é um conjunto de variáveis aleatórias, sendo que, *a priori*, qualquer subconjunto finito oriundo

desse conjunto possui uma distribuição Gaussiana multivariada. Com efeito, a distribuição Gaussiana multivariada sobre o vetor de funções \mathbf{f} é dada conforme a seguir:

$$\mathbf{f} | \mathbf{X}, \boldsymbol{\theta} \sim N(\mathbf{0}, \mathbf{K}) \quad (3.34)$$

Por essa interpretação, o vetor de funções “ \mathbf{f} ” está sujeito à probabilidade condicional de entradas “ \mathbf{X} ” e parâmetros “ $\boldsymbol{\theta}$ ”. Eles são regidos por uma distribuição Gaussiana multivariada com média composta por um vetor de tamanho “ n ” e valor constante, normalmente igual a zero, para simplificar o equacionamento; e matriz de covariância “ \mathbf{K} ”, de dimensão $n \times n$.

Assumindo a simbologia da função de covariância como “ $k(\cdot, \cdot)$ ”, a entrada (i, j) da matriz “ \mathbf{K} ” é expressa por “ $k(x_i, x_j)$ ”, a qual apresenta característica simétrica positiva semidefinida. Quando essa condição ocorre, a função de covariância é denominada “função *kernel*”. Em termos gerais, isso significa que seus autovalores são não-negativos para que, ao executar o cálculo da matriz de covariância sobre um número finito de variáveis, o resultado seja não-negativo. Melhor descrição sobre as propriedades das funções de covariância é explicada por Rasmussen & Williams (2006).

Genericamente, a função *kernel* é expressa por:

$$\text{cov}(f(x), f(x')) = k(x, x') \quad (3.35)$$

A partir dos dados de entrada “ \mathbf{X} ”, “ \mathbf{y} ” e “ $k(x, x')$ ”, a predição por meio dos Processos Gaussianos é de fato realizada ao ser considerado um ponto de teste “ \mathbf{x}^* ” e seu valor latente associado a “ f^* ”. Dessa forma, o conceito fundamental da RPG permite adequar a equação (3.34) de modo que a distribuição conjunta do vetor “ \mathbf{f} ” e da nova variável aleatória “ f^* ” seja Gaussiana multivariada, conforme a seguir:

$$\begin{bmatrix} \mathbf{f} \\ f^* \end{bmatrix} | \mathbf{X}, \boldsymbol{\theta} \sim N\left(\mathbf{0}, \begin{bmatrix} \mathbf{K} & \mathbf{k} \\ \mathbf{k}^T & \kappa \end{bmatrix}\right) \quad (3.36)$$

Nessa expressão, $\mathbf{k} = [k(x^*, x_1), \dots, k(x^*, x_n)]^T$ designa o vetor $n \times 1$ formado a partir da covariância entre o ponto de teste “ \mathbf{x}^* ” e o vetor de entradas “ \mathbf{X} ” da série de treino. O valor escalar “ κ ” corresponde à medida de semelhança entre os pontos de teste, ou seja, $k(\mathbf{x}^*, \mathbf{x}^*)$.

Ao assumir que “ \mathbf{I} ” é a matriz identidade, a interpretação da distribuição conjunta sobre os valores observados “ \mathbf{y} ” da série de treino e os valores não observados “ \mathbf{y}^* ”, com a adição do ruído Gaussiano independente e identicamente distribuído, com variância “ σ^2 ”, é dada por:

$$\begin{bmatrix} \mathbf{y} \\ \mathbf{y}^* \end{bmatrix} | \mathbf{X}, \boldsymbol{\theta} \sim N \left(\mathbf{0}, \begin{bmatrix} \mathbf{K} + \sigma^2 \mathbf{I} & \mathbf{k} \\ \mathbf{k}^T & \kappa + \sigma^2 \end{bmatrix} \right) \quad (3.37)$$

A partir da função *kernel* “ \mathbf{k} ”, definida por parâmetros “ $\boldsymbol{\theta}$ ”, é possível realizar uma predição da distribuição Gaussiana para um dado ponto de teste “ \mathbf{x}^* ” qualquer. Para tanto, condicionando a distribuição Gaussiana multivariada ao vetor de valores observados “ \mathbf{y} ”, a representação se arranja na seguinte forma:

$$y^* | \mathbf{y}, \mathbf{X}, \mathbf{X}^*, \boldsymbol{\theta}, \sigma^2 \sim N(m(\mathbf{x}^*), v(\mathbf{x}^*)) \quad (3.38)$$

A média $m(\mathbf{x}^*)$ e a variância $v(\mathbf{x}^*)$ dessa distribuição são respectivamente obtidas por:

$$m(\mathbf{x}^*) = \mathbf{k}^T (\mathbf{K} + \sigma^2 \mathbf{I})^{-1} \mathbf{y} \quad (3.39)$$

$$v(\mathbf{x}^*) = \kappa + \sigma^2 - \mathbf{k}^T (\mathbf{K} + \sigma^2 \mathbf{I})^{-1} \mathbf{k} \quad (3.40)$$

Para dado conjunto qualquer de m pontos da série $\mathbf{X}^* = [x_{1^*}, \dots, x_{m^*}]$, a distribuição preditiva Gaussiana multivariada pode ser encontrada utilizando as seguintes expressões:

$$m(\mathbf{X}^*) = \mathbf{K}^{*T} (\mathbf{K} + \sigma^2 \mathbf{I})^{-1} \mathbf{y} \quad (3.41)$$

$$v(\mathbf{X}^*) = \mathbf{K}^{**} + \sigma^2 \mathbf{I} - \mathbf{K}^{*T} (\mathbf{K} + \sigma^2 \mathbf{I})^{-1} \mathbf{K}^* \quad (3.42)$$

Nessas equações, “ \mathbf{K}^* ”, com dimensão $n \times m$, é uma matriz de covariâncias entre as variáveis independentes de treino “ \mathbf{X} ” e os pontos de teste “ \mathbf{X}^* ”. Ao passo que a matriz “ \mathbf{K}^{**} ” consiste nas covariâncias entre os pontos de teste, com dimensão $m \times m$.

Uma distinção essencial da RPG em comparação a outros modelos de regressão é que ela pode ser implementada com base nas suas estatísticas de segunda ordem. De tal modo, ao estipular a média e uma função de covariância a partir de um par finito de variáveis aleatórias, especifica-se uma distribuição Gaussiana multivariada para esses valores. Isso ocorre porque a função de

covariância procura representar as suposições acerca da função para a qual se intenciona realizar o aprendizado, o que dispensa a necessidade de definição formal do conjunto de funções envolvidas (RASMUSSEN & WILLIAMS, 2006).

Uma representação gráfica genérica da estimativa de variáveis por meio da regressão por Processos Gaussianos é ilustrada na Figura 3.14.

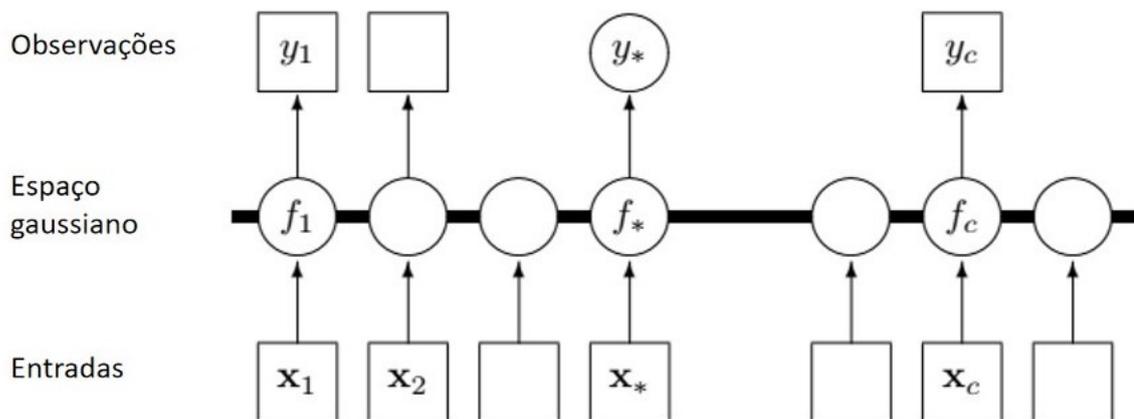


Figura 3.14: Modelo estruturado da RPG

Fonte: Adaptado de Rasmussen & Williams, 2006.

Nessa ilustração é mostrada a estrutura de dependências condicionais probabilísticas entre as variáveis aleatórias. Os ícones quadrados denotam as variáveis observadas, os círculos são os elementos desconhecidos e a linha horizontal espessa indica um conjunto de nós totalmente interconectados. Assim, uma observação y_i é independente de todos os outros nós, condicionada à variável latente correspondente à função f_i . Devido à propriedade de marginalização dos Processos Gaussianos, a adição de outras entradas x_* , variáveis latentes f e valores não observados a serem estimados y_* não altera a distribuição das outras variáveis do modelo.

A noção de similaridade entre os pontos de dados é fundamental para o aprendizado supervisionado. É evidente que um vetor de entrada “ x ” com valores próximos uns dos outros aumenta a possibilidade das variáveis independentes “ y ” serem semelhantes. Logo, se uma amostra cujos pontos de treinamento estejam próximos a um ponto de teste, é provável que ela seja suficientemente informativa para a previsão naquele ponto em específico. Com efeito, sob o ponto de vista dos Processos Gaussianos, a informação embutida na função *kernel* é a responsável pela medida de semelhança entre dois pontos.

A fim de realizar o mapeamento dos dados, existem diversas funções *kernel*, as quais são verificadas para encontrar aquelas melhor representam as variáveis submetidas à regressão. Algumas dessas formalizações estão expostas na Tabela 3.2.

Tabela 3.2: Funções *kernel* para regressão em Processos Gaussianos

Tipo da funções <i>kernel</i>	Expressão matemática $k(x, x') = \exp(-\sigma\ x - x'\ ^2)$	Número da equação
Linear	$\langle x^T \cdot x' \rangle$	(3.43)
Laplaciana	$\exp(-\sigma\ x - x'\)$	(3.44)
Exponencial quadrática	$\exp(-\sigma\ x - x'\ ^2)$	(3.45)
Matérn	$\frac{2^{1-\nu}}{\Gamma(\nu)} \left(\frac{\sqrt{2\nu}\ x - x'\ }{\ell} \right)^\nu K_\nu \left(\frac{\sqrt{2\nu}\ x - x'\ }{\ell} \right)$	(3.46)

Fonte: Rasmussen & Williams, 2006; Karatzoglou *et al.*, 2019.

Nas expressões matemáticas, os termos x e x' indicam as covariâncias no espaço de entrada; σ é um parâmetro positivo relacionado à largura da função Gaussiana (a qual exerce influência vertical na função); ℓ é um parâmetro de valor positivo relacionado à escala de comprimento da função (influência horizontal); ν é um parâmetro positivo de ajuste; K_ν é uma função de Bessel modificada; e “ $\| \ \|$ ” denota a distância euclidiana.

A função *kernel* exponencial quadrática é também denominada função *kernel* de base radial, ou ainda, função *kernel* Gaussiana. Ela é infinitamente diferenciável, o que significa que uma RPG com essa função possui derivadas quadráticas médias para todas as ordens estatísticas. Sua disposição ocorre de modo que, quando os pontos x e x' estão próximos, naturalmente, apresentam distância euclidiana curta, e a covariância entre esses pontos é elevada, tendendo à unidade. Isso é ressaltado pelo exponencial negativo, visto que $\sigma > 0$. Por outro lado, caso os pontos x e x' estejam afastados, a distância euclidiana será elevada, e a covariância entre esses pontos será reduzida.

Rasmussen & Williams (2006) explicam que em razão dessa propriedade, para valores x e x' vizinhos, há elevada correlação entre os pontos. Essa característica converge com diversas observações geoestatísticas, por comumente possuírem relações de dependência entre pontos próximos. Com efeito, a imagem da função se apresenta com notável suavidade. No entanto, existem indícios de que as suposições de suavidade desse tipo de função *kernel* não são realistas

para modelar muitos processos físicos, quando comparada, por exemplo, com a classe de funções Matérn. Apesar desse fato, a função exponencial quadrática é provavelmente a mais utilizada em problemas com regressão, possivelmente pelo pragmatismo no ajuste (RASOULI *et al.* 2012; SUN *et al.*, 2014)

Tal como expresso pela equação (3.33) assumir uma *priori* cuja função f seja descrita por uma distribuição Gaussiana com média zero e covariância obtida a partir da especificação de uma função *kernel*, implica uma distribuição *a posteriori* sobre f . Um exemplo dessa condição *a priori* é ilustrada na Figura 3.15. Utilizando a função *kernel* do tipo exponencial quadrática, foram traçadas cinco amostras de trajetórias aleatórias das funções f_i , sendo $i = \{1, \dots, 5\}$, avaliadas nos pontos “ x_i ”. Nessa representação não há dados observados, visto que as trajetórias amostradas são arbitrárias. Além da suavidade comum entre essas amostras, destaca-se a equivalência do comprimento horizontal das oscilações nesses traçados, relativo ao parâmetro de escala ℓ .

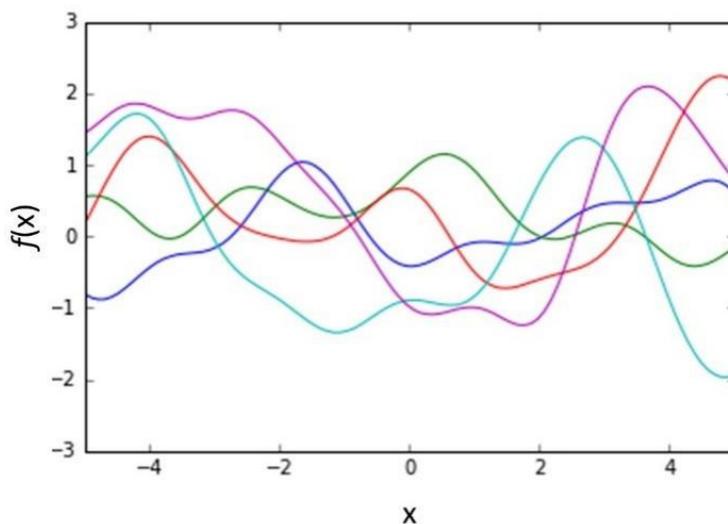


Figura 3.15: Trajetórias *a priori* de funções aleatórias traçadas por Processos Gaussianos

Fonte: Adaptado de CAIXETA, 2016.

Conforme mencionado, ao inserir informações dos dados observados, é possível gerar trajetórias por meio de distribuições condicionadas a esses dados, o que está matematicamente formalizado pelas equações (3.38), (3.39) e (3.40). Assim, para cada ponto x_i^* (oriundo do vetor de entradas \mathbf{X}^* para teste), é obtida uma distribuição Gaussiana univariada em que a média é dada por $m(\mathbf{x}^*)$ e a variância por $v(\mathbf{x}^*)$.

Com base nesse princípio, na Figura 3.16 são mostradas as trajetórias *a posteriori* dessas funções, com atualização da média e concentração da variância próximo aos valores observados.

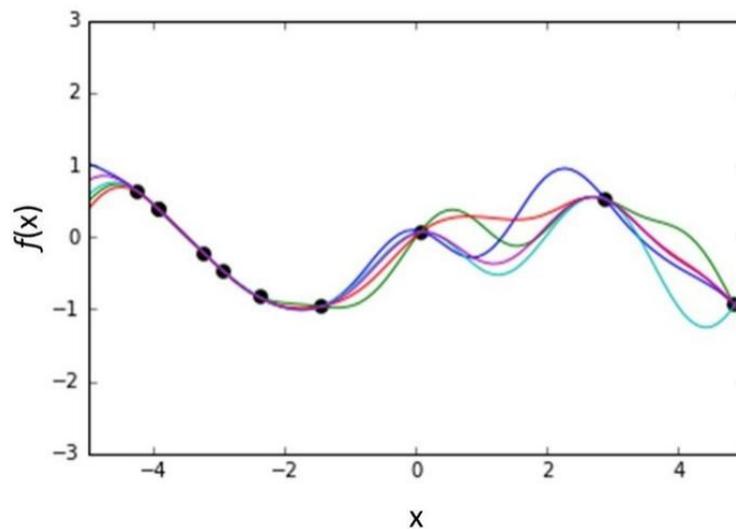


Figura 3.16: Amostras de funções da distribuição *a posteriori* de um Processo Gaussiano

Fonte: Adaptado de CAIXETA, 2016.

Na Figura 3.17, são ilustradas essa mesma amostra de pontos observados e a distribuição preditiva para uma função exponencial quadrática.

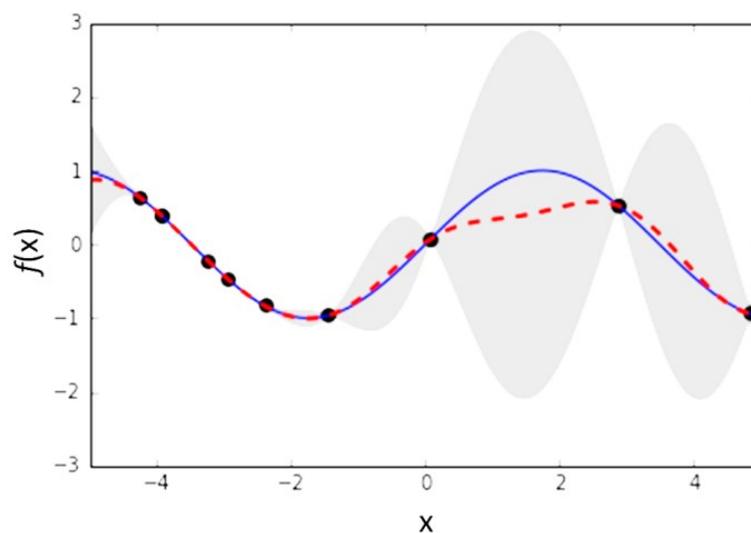


Figura 3.17: Distribuição *a posteriori* de uma RPG ajustada pela função *kernel* condicionada aos pontos observados

Fonte: Adaptado de CAIXETA, 2016.

Pela imagem, é notado que a média da distribuição probabilística *a posteriori* (traços em cor vermelha) efetua uma interpolação sobre os valores conhecidos da função *kernel* exponencial quadrática (linha contínua azul), condicionada aos pontos observados. Por sua vez, a variância permite estimar a incerteza preditiva em relação às estimativas. Em suma, se a estimativa ocorre entre pontos afastados um do outro, a sua variância é maior e, portanto, a sua incerteza preditiva também é maior, quando comparado com a predição para dois pontos próximos.

Evidentemente, bons resultados das previsões dependem do ajuste dos parâmetros da função *kernel*. Para tanto, uma possibilidade é introduzir hiperparâmetros às funções *kernel* original. Com esse intuito, por exemplo, a função *kernel* exponencial quadrática passa a receber os hiperparâmetros “ s_f ” e “ l ”, e se reapresenta da seguinte maneira:

$$k(x, x') = s_f^2 \exp\left(-\frac{1}{2l^2} \|x - x'\|^2\right) \quad (3.47)$$

Com essa consideração, “ s_f ” e “ l ”, permitem exclusivamente definir propriedades da distribuição preditiva, e por isso são chamados de hiperparâmetros.

A implementação do modelo requer o ajuste dos hiperparâmetros da função *kernel*, os quais são desconhecidos e necessitam ser inferidos a partir dos dados. Para tanto, existem diversas técnicas, e uma das mais utilizadas é pela maximização da log-verossimilhança (SCHULZ *et al.*, 2018). Sua expressão matemática é dada por:

$$\log p(\mathbf{y}|X) = -\frac{1}{2} \mathbf{y}^T (\mathbf{K} + \sigma^2_n \mathbf{I})^{-1} \mathbf{y} - \frac{1}{2} \log(|\mathbf{K} + \sigma^2_n \mathbf{I}|) - \frac{n}{2} \log 2\pi \quad (3.48)$$

na qual “ n ” é o número de pontos observados. Como se observa, a maximização da log-verossimilhança é obtida a partir de três termos matemáticos. O primeiro deles é responsável pela medida do ajuste dos dados, indicando quão bem a parametrização da função *kernel* explica as variáveis dependentes. O segundo termo da equação trata da penalização da complexidade do ajuste. Por fim, o terceiro termo é uma constante de normalização.

Dessa forma, ocorre a generalização do modelo de Processos Gaussianos para a obtenção da melhor combinação de hiperparâmetros da função *kernel* exponencial quadrática. Pondera-se que essa estratégia permite realizar o ajuste para modelos de regressão não-linear que considera apenas uma única saída de série temporal.

3.3.3 Medidas de desempenho de modelos de previsão

O desenvolvimento de modelos de regressão e a obtenção dos resultados, expressos, por exemplo, na forma de série temporal, requerem a avaliação do próprio resultado, relativo ao desempenho do modelo. Dawson *et al.* (2007) explicam que o processo de avaliação do desempenho de um modelo hidrológico pode incluir tanto características subjetivas, como a simples visualização das séries observada e calculada, quanto estimativas numéricas objetivas. No que concerne às inspeções visuais, os resultados podem ser formulados acerca do comportamento geral dos hidrogramas, trazendo informações de ordem sistemática (como o sub ou o superdimensionamento) e dinâmicas (características relacionadas aos intervalos temporais, ascensões e recessões, reprodução dos valores máximos e mínimos). No entanto, incorporar objetividade à avaliação dos modelos ao atribuir índices quantitativos aos seus resultados garante algumas vantagens, tais como: (i) oferecer um indicador numérico associado à habilidade do modelo reproduzir o comportamento da bacia hidrográfica; (ii) possibilitar a comparação do modelo com ele mesmo, permitindo avaliar tanto a sua melhora quanto a do método empregado a cada nova implementação; e (iii) dispor de um mecanismo de comparação dos resultados entre diferentes tipos de modelos.

Em razão das vantagens elencadas, avaliar um modelo hidrológico por meio de critérios numéricos é uma abordagem amplamente empregada pelos pesquisadores (GUPTA *et al.* 1998; DAWSON *et al.*, 2007; PUSHPALATHA *et al.*, 2012). Entretanto, a quantidade de métricas disponíveis é extremamente numerosa, de modo que sua escolha deve ser função das necessidades particulares para cada aplicação. Com efeito, o conjunto de critérios de desempenho deve ser definido de modo a evitar a sua redundância, além de ser sensível aos diferentes tipos de erros. Normalmente, a sugestão de qual dos modelos verificados melhor atinge os objetivos é feita a partir da comparação dos índices encontrados para determinados critérios, seguida da ordenação desses resultados.

Para avaliação dos modelos de previsão no presente trabalho, três métricas de desempenho foram utilizadas, expostas na seguinte ordem de importância: (i) Coeficiente de Nash-Sutcliffe calculado com vazões invertidas (NSEiQ); (ii) erro absoluto médio (MAE); e (iii) coeficiente de determinação (R^2). Suas expressões matemáticas são:

$$NSEiQ = 1 - \frac{\sum_{i=1}^n \left(\frac{1}{Q_i} - \frac{1}{\bar{Q}_i} \right)}{\sum_{i=1}^n \left(\frac{1}{Q_i} - \frac{1}{\bar{Q}_i} \right)} \quad (3.49)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Q_i - \hat{Q}_i| \quad (3.50)$$

$$R^2 = \left[\frac{\sum_{i=1}^n (Q_i - \bar{Q})(\hat{Q}_i - \bar{\tilde{Q}})}{\sqrt{\sum_{i=1}^n (Q_i - \bar{Q})^2 \sum_{i=1}^n (\hat{Q}_i - \bar{\tilde{Q}})^2}} \right]^2 \quad (3.51)$$

nas quais “ n ” é o número de dados da série; “ Q_i ” é a vazão observada; “ \hat{Q}_i ” é a vazão calculada pelo modelo; “ \bar{Q} ” é a média das vazões observadas; e “ $\bar{\tilde{Q}}$ ” é a média das vazões calculadas.

O NSEiQ é derivado direto da função de eficiência Nash-Sutcliffe, a qual é uma das métricas mais comuns para avaliação de desempenho de modelos como um todo. No entanto, sua expressão na forma de vazões invertidas ($1/Q_i$) aumenta a sensibilidade das vazões mínimas da série, quando comparados os valores observados e estimados. Visto que o NSEiQ não possui limite inferior, há possibilidade de serem encontrados valores negativos nas piores modelagens. Por outro lado, os modelos de previsão melhor avaliados resultam em NSEiQ próximos à unidade. Essa métrica se apresenta no contexto de um levantamento realizado por Pushpalatha *et al.* (2012), que estudaram nove critérios de desempenho de modelos com foco para vazões mínimas, aplicando o estudo em 940 bacias. Os autores encontraram melhores resultados com a aplicação do NSEiQ, o qual se destacou dos outros critérios testados por não demonstrar sensibilidade às vazões máximas. O resultado dessa métrica é adimensional, o que possibilita estabelecer índices padrão que dizem respeito a qualidades intermediárias da reprodução dos valores observados. Além disso, por ser um critério que expressa resultados relativos, o NSEiQ permite comparar modelos entre si, bem como eventos de diferentes ordens.

O erro absoluto médio, ou *mean absolut error* (MAE), informa o nível de concordância geral entre os conjuntos de dados observados e modelados. Trata-se de uma métrica absoluta, com unidades reais não-negativas, sem limites superiores, cujos melhores modelos de MAE se aproximam de zero. Uma desvantagem no emprego do MAE é sua insensibilidade a erros sistemáticos, podendo expressar reduzidos valores mesmo quando há sub ou superestimação.

Essa métrica não pondera eventos de maior ou menor magnitude, mas avalia todos os desvios dos dados observados de maneira igual independentemente se o erro é negativo ou positivo. Por essa razão, o uso do MAE é recomendado para avaliação de modelos aplicados em eventos isolados, por exemplo, para uma mesma série histórica, de modo que não traz informação útil quando comparados modelos que utilizam diferentes eventos. Em estudo com séries hipotéticas, Dawson *et al.* (2007) destacaram o MAE entre as medidas de desempenho que melhor representaram séries cujos hidrogramas possuem reduzidas magnitudes.

O coeficiente de determinação R^2 descreve a variabilidade nos dados que é explicada pelo modelo de regressão, visto que relaciona, em razão quadrática, a dispersão dos valores observados com a dispersão dos valores estimados pelo modelo. O R^2 é de ordem relativa, cuja faixa de alcance é entre zero e um, sendo que as melhores previsões indicam a unidade. Apesar de medir o nível de concordância geral entre duas séries, o coeficiente de determinação parte do pressuposto que há relação linear entre elas. Ao padronizar alguns momentos estatísticos, como médias e variâncias das séries observada e modelada, a função se mostra tendenciosa à consideração de eventos extremos, demonstrando grande sensibilidade a *outliers*. Além disso, tendo em vista que o cálculo do R^2 é restrito à diferença da dispersão entre os dois conjuntos de dados, essa métrica é incapaz de detectar erros de ordem sistemática, com efeitos de sub ou superestimação, podendo indicar bons resultados mesmo quando as séries calculadas não expressam adequadamente os valores observados. Por essas razões, o coeficiente de determinação deve ser usado com cautela e em conjunto com outros critérios. Uma vantagem de utilizar essa medida de desempenho é que seu resultado, adimensional, permite comparar a performance de diferentes modelos e eventos, balizando a comparação por padrões pré-determinados.

4 APLICAÇÃO DO MÉTODO

Neste capítulo, disposto em três tópicos, serão apresentados os resultados da aplicação dos métodos desenvolvidos no decorrer da presente pesquisa. Para tanto, primeiramente, será delineado o contexto em que se situa a área onde serão implementados os métodos, seguido de informações relativas aos aproveitamentos hidrelétricos e as estações telemétricas que geraram os dados. O segundo tópico é introduzido com uma breve descrição das séries de vazão empregadas no estudo dos efeitos nos padrões de descarga hídrica, acompanhado dos resultados que dizem respeito à identificação de alterações de comportamento de vazões no domínio do tempo e no do tempo-frequência. No último tópico, após breve descrição dos dados utilizados no estudo de previsão de vazões, a pesquisa evoluirá para a apresentação dos resultados concernentes à aplicação dos seis modelos de regressão, acoplados ou não com as séries decompostas. Nessa fase, são explorados três grupos de previsão das séries, sendo eles as previsões entre estações adjacentes, com variabilidade temporal e entre as combinações dos pares de estações na bacia, caracterizando a variabilidade espacial.

4.1 Área de estudo

Justificada pela ascensão agroindustrial, os estados da região centro-oeste do Brasil passam por grande crescimento do número de aproveitamentos hidrelétricos (AHs) licenciados e construídos, de modo que muitos têm se concentrado na Região Hidrográfica do Rio Paraguai (RHP). Definida pela Resolução CNRH n° 109/2010, a RHP se limita à porção brasileira da bacia hidrográfica do rio Paraguai, a qual possui área de 362.376 km². Além da RHP, a bacia do rio Paraguai se estende pela Bolívia, Paraguai e Argentina, o que lhe confere importância internacional (ANA/GEF/PNUMA/OEA, 2004; GAP, 2015; ANA, 2019).

Uma particularidade da RHP é abranger uma das maiores áreas inundáveis do mundo, a planície pantaneira, com cerca de 150.000 km². Na RHP estão abrigados três sítios Ramsar, o que, por meio do tratado intergovernamental de Ramsar, fornece estrutura para ação nacional e cooperação internacional para a conservação e uso racional dos recursos naturais dessas zonas úmidas (RAMSAR, 2019). O Pantanal está submetido a ciclos de escoamento laterais aos cursos d'água. Esses ciclos possuem baixa amplitude e longa duração (3 a 4 meses), os quais são descritos pelo conceito de “pulso de inundação” (JUNK *et al.*, 1989), que provocam alternância anual de características terrestre e aquática. A estrutura formada pelos ambientes lóticos nos corpos hídricos e ambientes lênticos alternados com terrestres, conforme a época do

ano, é a principal força responsável pela existência, produtividade e interações da biota em sistemas entre o rio e a planície de inundação adjacente. Em áreas úmidas como essas, há grande dependência dos ciclos naturais que promovem as trocas laterais de nutrientes e sedimentos para consolidar a conectividade biótica. Os pulsos de inundação coincidem com a estação das chuvas ao norte da bacia e apresenta defasagem de aproximadamente três meses na parte sul (CUNHA & JUNK, 2015; FANTIN-CRUZ *et al.*, 2015).

Inserida na RHP, a bacia hidrográfica do rio Jauru (BHJ) possui seis AHs em operação. Na BHJ também estão instaladas oito estações telemétricas de monitoramento com frequência horária ou maior, nomeadas de montante para jusante de ST1 a ST8. Especialmente na área a montante da bacia, onde estão instalados os AHs e as estações telemétricas, a BHJ possui formato alongado, o que implica reduzida contribuição lateral entre as estações. A área aproximada da BHJ é de 15.800 km² e o comprimento do talvegue principal é de 390 km. Apesar disso, o trecho utilizado para experimentação metodológica se limita à estação telemétrica ST8 (PCH Figueirópolis Jusante), com área de drenagem de 3.093 km². As altitudes da BHJ variam entre 700 m na região da Chapada dos Parecis, ao norte, e 116 m, na confluência com a margem direita do rio Paraguai, já considerada região de Pantanal Mato-grossense.

Na Figura 4.1 é possível visualizar a bacia do rio Jauru, localizada em região de transição entre planalto e planície de inundação, assim como o posicionamento dos AHs e STs. Logo em seguida, na Figura 4.2, são mostrados o perfil vertical e o diagrama unifilar da BHJ, com destaque para os quilômetros entre 120 e 185 do percurso fluvial, onde são representados a topografia local e o posicionamento dos aproveitamentos hidrelétricos e estações de monitoramento. Pelas imagens, é possível notar a declividade relativamente elevada da calha do rio Jauru, até o quilômetro 160, aproximadamente. A partir da barragem da PCH Salto, é notada a redução drástica da declividade média do perfil, a qual assume características de planície.

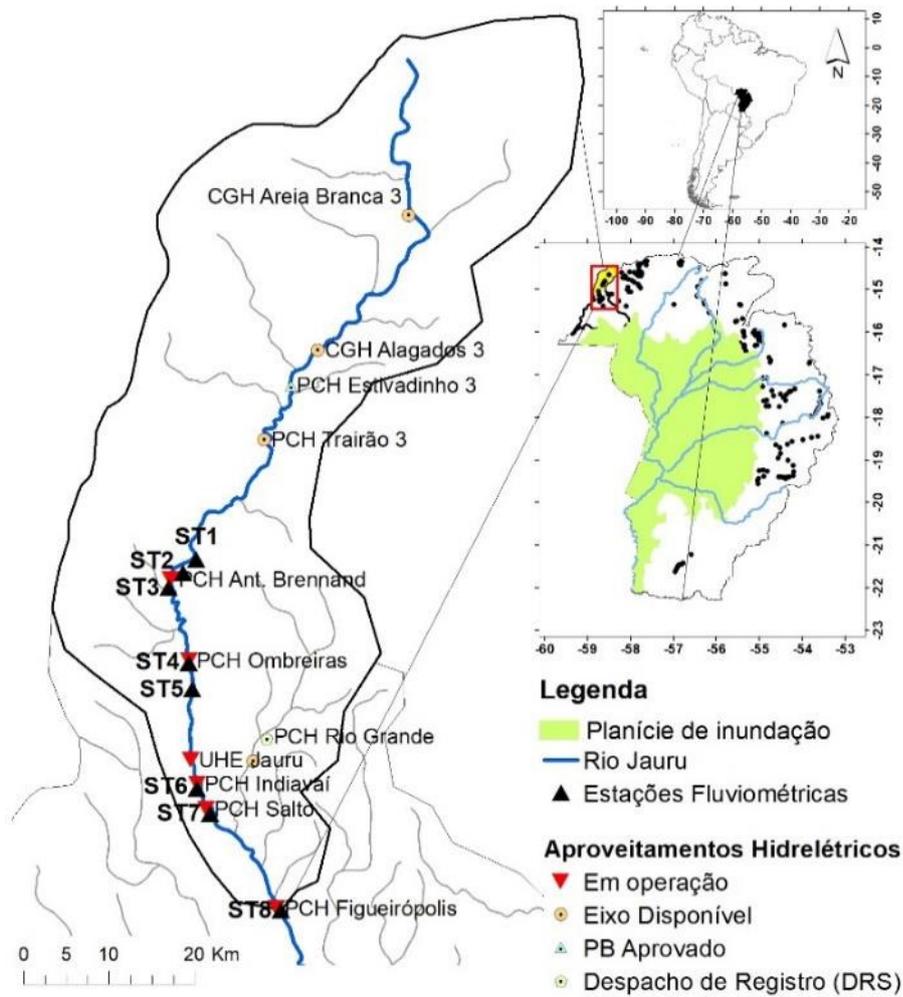
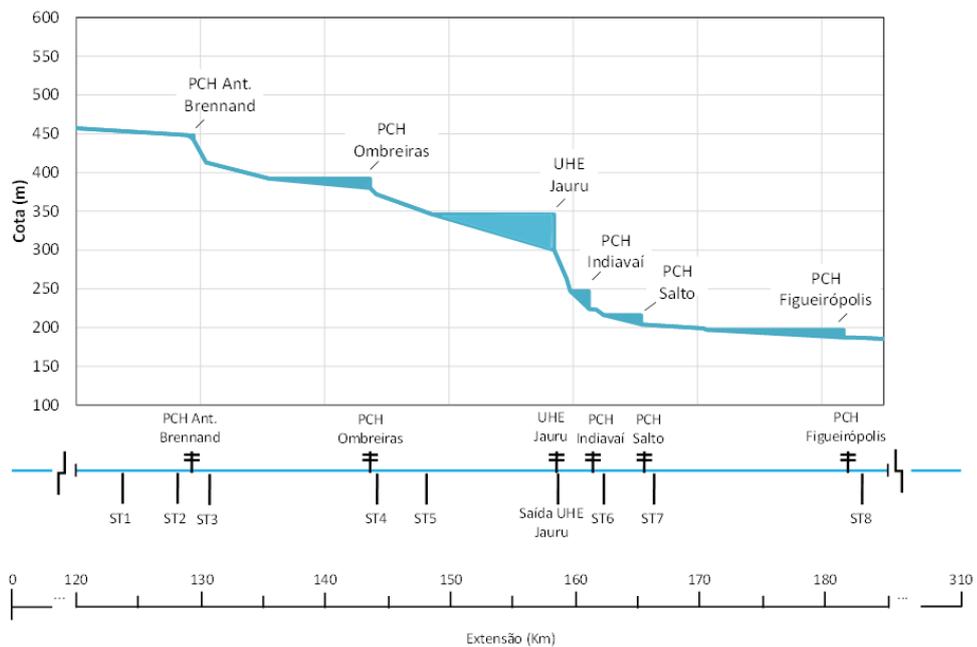


Figura 4.1: Bacia hidrográfica do rio Jauru



Os sistemas atmosféricos que atuam na região são caracteristicamente tropicais, com precipitação anual média em torno de 1250 mm/ano. A estação chuvosa compreende o período entre outubro e março, quando normalmente mais de 70% das precipitações são registradas (REBOITA *et al.*, 2010; PERTUSSATTI, 2013). A pluviometria na região da BHJ, interpretada pela estação de código ANA 1558004, apresenta veranicos com período médio de 25 dias e máximo de 33 dias (PERTUSSATTI, 2013). Um veranico pode ser definido como uma sequência de dias secos (ou com altura de precipitação abaixo de determinado limite), durante a estação chuvosa, e que, por isso, podem responder pelas periodicidades observadas nos corpos hídricos da região no período chuvoso (ÖZGER *et al.*, 2010). Sob o enfoque sinótico, Vera *et al.* (2006) explicam que o veranico é causado por um padrão de grande escala na pressão atmosférica, bloqueando efetivamente o fluxo atmosférico úmido. A circulação anticiclônica em grande escala da Alta da Bolívia e uma depressão próxima à costa nordeste do Brasil são os fenômenos mais evidentes associados à circulação de alta velocidade na estação úmida na região do Centro-Oeste brasileiro, o que provavelmente são as principais responsáveis pela ocorrência dos veranicos (ASSAD *et al.* 1993). Os fenômenos de veranico são comumente descritos por suas durações e magnitudes e constituem um fator influente para a produção agrícola na no Centro-Oeste do Brasil. Esse fato tem motivado muitas pesquisas sobre veranicos na região (ASSAD *et al.*, 1993; CARVALHO *et al.*, 2013; PERTUSSATTI *et al.*, 2013).

4.1.1 Aproveitamentos hidrelétricos em operação

Em consulta ao banco de dados do Sistema de Informações Georreferenciadas do Setor Elétrico (SIGEL/ANEEL, 2017), cinco PCHs e uma usina hidrelétrica (UHE) são operadas na BHJ (Tabela 4.1). Além desses empreendimentos, estão previstos outros seis pequenos AHs na bacia, sendo quatro no rio Jauru, localizados a montante dos AHs em operação, e dois no córrego do Sangue, um dos principais afluentes do rio Jauru, cujo exutório está localizado 5 km a jusante da PCH Salto.

Tabela 4.1: Características do complexo de AHs em operação na bacia do rio Jauru

AH / Característica	PCH Antônio Brennand	PCH Ombreiras	UHE Jauru	PCH Indiavaí	PCH Salto	PCH Figueirópolis
Proprietário	Brennand Energia	Brennand Energia	Queiroz Galvão	Brennand Energia	Brookfield Power	Desa Dobrevè
Início da operação	Jul, 2003	Jul, 2005	Jun, 2003	Ago, 2003	Fev, 2008	Out, 2010
Potência instalada (MW)	22	26	121	28	19	19
Tipo de turbina	Francis Horizontal	Kaplan Horizontal	Francis Vertical	Francis Horizontal	Kaplan Horizontal	Kaplan Horizontal
Área de drenagem (km²)	2062	2352	2470	2493	2523	3087
Alagamento do reservatório (km²)	0,03	1,21	1,93	0,27	0,79	7,26
MW gerado / km² alagado	733,33	21,49	62,69	103,70	24,05	2,62
Distância do AH de montante (km)	-	14,2	14,8	2,8	4,2	16,3
TRH (hora)⁽¹⁾	1,4	132	96	11	11	163

(1) TRH: Tempo de retenção hidráulica

Fonte: Silva, 2015; SIGEL/ANEEL, 2017; Brennand Energia; Queiroz Galvão Energia; Engecon Engenharia; Google Earth®.

A maioria dos empreendimentos opera a fio d'água e sem comportas. Não obstante, o operador dos AHs possui considerável influência sobre a descarga que passa pela turbina por meio das pás móveis no rotor e das palhetas que direcionam seu fluxo no distribuidor. A esse respeito, Silva (2015), que realizou uma busca dos licenciamentos no órgão ambiental estadual, descreve que a UHE Jauru atua a fio d'água, mas que as operações de nível preveem a oscilação diária de 1,0m no reservatório. Isso possibilita gerar a totalidade da capacidade instalada durante as três horas por dia de maior demanda de energia elétrica. Informações sobre as operações de nível dos demais reservatórios não foram encontradas.

Na tentativa de minimizar grandes impactos relativos às vazões regularizadas por barragens, o Operador Nacional de Sistema Elétrico (ONS, 2017) publicou em seu “Manual de procedimento e operação” algumas restrições para defluência dos reservatórios. Pelo

documento, a UHE Jauru é a única entre os AHs operados na bacia do rio Jauru que possui restrição de vazão sanitária de jusante, com valor mínimo de 3m³/s. Vale salientar que as vazões médias mínimas anuais de jusante da UHE Jauru são da ordem de 70m³/s. Não há qualquer alusão a restrições quanto aos máximos ou sobre limites de variabilidade ao longo do ano, assim como não há menção sobre restrições de oscilações de descarga hídrica.

Outras particularidades sobre os demais empreendimentos na BHJ são citadas. A PCH Ombreiras não possui trecho de vazão reduzida, assim, sua vazão defluente decorre exclusivamente da passagem da água pelas turbinas, ou, nas situações máximas, pelo vertedouro. Concernente às demais propriedades dos AHs na bacia, aqueles situados a jusante da UHE Jauru (PCH Indiavaí, PCH Salto e PCH Figueirópolis) possuem características semelhantes entre si: interrompem o rio e trabalham com vazão máxima, possuem trecho de vazão reduzida e vertedouro com soleira livre. A principal diferença entre elas é que a PCH Figueirópolis está localizada no segmento com menor declividade fluvial. Essa característica potencializou a grande extensão longitudinal do seu reservatório, bem como o reduzido coeficiente entre a produção de energia em relação à área alagada.

Ao verificar as magnitudes das potências instaladas, é observado que, por esse critério, a maioria dos empreendimentos se enquadra como PCH. Além disso, é interessante notar que o somatório das potências instaladas das cinco PCHs equivale a 114MW, e não supera a potência instalada da única usina hidrelétrica em operação na BHJ. Por fim, outra observação importante está relacionada ao acúmulo dos tempos de retenção hidráulica promovidos pelos seis reservatórios, equivalente a 414,4 horas, ou 17,3 dias. Esse intervalo no escoamento da água é bastante representativo, face ao tempo de concentração da bacia até a estação ST8, que, pelo método de Kirpich (SILVEIRA, 2005), foi estimado em 60,4 horas.

4.1.2 Estações telemétricas de monitoramento de vazões

Os dados horários de vazão das oito estações telemétricas em monitoramento na BHJ foram extraídos do sítio eletrônico “Sala de Situação”, alimentado pela Agência Nacional de Águas (ANA)². As informações das estações ST1 a ST8, que forneceram os dados para esta pesquisa, são apresentadas na Tabela 4.2.

² Disponível em: <<http://gestorpcd.ana.gov.br/Mapa.aspx>>. Acesso em 18 jan 2019.

Tabela 4.2: Estações telemétricas na bacia do rio Jauru

ST / Característica	Data de instalação	Coordenada geográfica	Área de drenagem (km²)	Altitude (m)	Distância da ST de montante (km)
PCH Antônio Brennand Mont2 66071353 (ST1)	30/04/2012	Lat: -15:1:23 Long: -58:43:18	2046	452	-
PCH Antônio Brennand Mont1 66071355 (ST2)	07/12/2012	Lat: -15:2:13 Long: -58:44:9	2054	449	4,6
PCH Antônio Brennand Jus 66071363 (ST3)	07/12/2012	Lat: -15:3:10 Long: -58:45:3	2140	413	2,6
PCH Ombreiras Jus 66071380 (ST4)	23/04/2015	Lat: -15:7:56 Long: -58:43:47	2355	375	13,0
UHE Jauru Mont 66071382 (ST5)	21/06/2014	Lat: -15:9:37 Long: -58:43:33	2405	362	4,0
PCH Indiavaí Jus 66071392 (ST6)	10/12/2012	Lat: -15:15:55 Long: -58:43:17	2495	224	14,3
PCH Salto Jus 66071397 (ST7)	26/04/2012	Lat: -15:17:31 Long: -58:42:27	2528	204	4,0
PCH Figueirópolis Jus 66071470 (ST8)	26/03/2012	Lat: -15:23:39 Long: -58:37:58	3093	187	16,5

Fonte: Sala de Situação/ANA; SIGEL/ANEEL, 2017; Google Earth®.

As vazões das estações telemétricas são estimadas com base em curvas-chave construídas e monitoradas por empresas de consultoria contratadas pelas produtoras de energia. Algumas dessas curvas-chave foram disponibilizadas por meio da Lei de Acesso à Informação, via solicitação à Superintendência de Gestão da Rede Hidrometeorológica da ANA. Essas curvas-chave são de responsabilidade das entidades operadoras dos AHs e até então não foram avaliadas pela ANA. Os dados de vazão das estações localizadas a jusante dos AHs são de defluência total (vazão turbinada + vazão vertida + trecho de vazão reduzida, quando houver).

É importante salientar que duas dessas estações telemétricas estão posicionadas a montante do primeiro AH, ou seja, sem efeito de qualquer barramento. Elas serão utilizadas como controle no decorrer da pesquisa. A maioria das demais estações é operada imediatamente a jusante dos AHs, com exceção da ST5 (UHE Jauru Montante). Como não há estação telemétrica intermediária entre a UHE Jauru e a PCH Indiavaí, o controle dos sinais de vazão para obtenção dos resultados relacionados ao padrão cíclico, por meio da TWD, foi feito por meio dos dados de defluência da UHE Jauru. Sua série possui discretização diária e foi denominada neste trabalho como “Jusante UHE Jauru”. Essa informação foi obtida pelo Sistema de Acompanhamento de Reservatórios (SAR³), também operado pela ANA.

Da série bruta de vazões, foram observadas muitas falhas sem padrões evidentes de variação temporal, o que exigiu seleção do período de registros em comum com menos lacunas nas oito estações. Dessa forma, o início do período com menos falhas na BHJ foi limitado pela estação ST3, com observações regulares a partir de 06 de maio de 2016.

Diversos aspectos foram considerados para proporcionar a consistência dos dados. Além da exclusão de valores espúrios, houve o preenchimento de lacunas pelas seguintes maneiras: (i) ajuste e aplicação de curva-chave em situações de medição de nível de água; (ii) utilização de curvas-chave, quando seus coeficientes foram disponibilizados pela Superintendência de Gestão da Rede Hidrometeorológica da ANA; (iii) interpolação linear das vazões horárias quando as falhas se limitavam a 12 horas, quando eram observadas situações de constância nos níveis de água de intervalos adjacente e estações contíguas; e (iv) preenchimento de lacunas entre as estações ST1 e ST2 por meio de regressão linear, após verificar que o coeficiente de determinação entre as vazões dessas duas estações equivale a 0,99. Para continuidade nesta pesquisa, o conjunto dos dados tratados passou a ser denominado “sinal original”.

4.2 Alteração nos padrões de vazão

O presente tópico 4.2 – Alteração nos padrões de vazão, é constituído por três itens. O primeiro deles, 4.2.1 – Descrição dos dados de vazão na BHJ, aborda características gerais das séries originais de vazão extraídas nas estações da bacia e utilizadas no contexto da alteração dos padrões de vazão. Os dois outros itens são relativos aos dois primeiros objetivos específicos

³ Disponível em: <<http://sar.ana.gov.br>>. Acesso em 02 fev 2018.

desta pesquisa. Assim, o item 4.2.2 –Efeitos no domínio do tempo em escala horária está relacionado à identificação das alterações das vazões no domínio do tempo entre estações adjacentes e em diferentes defasagens temporais. Já o segundo objetivo específico, cujos resultados estão no item 4.2.3 – Efeitos nos ciclos de vazão no domínio tempo-frequência em escala diária – TWC, está relacionado à identificação das alterações das oscilações e amplitudes das vazões no domínio tempo-frequência. Esses dois resultados dizem respeito à compreensão no âmbito geral das alterações que a descarga hídrica na bacia está sujeita.

4.2.1 Descrição dos dados de vazão na BHJ

Após a extração e tratamento dos dados, em primeiro momento, foram obtidas séries de vazões perfazendo 11.060 horas para as oito estações, entre 06 de maio de 2016 às 15h e 10 de agosto de 2017 às 10h, com algumas lacunas, o que compôs aproximadamente 15 meses de registros horários, com um ciclo completo de período úmido e período seco. A fim de compreender a relação entre as vazões extraídas no rio Jauru, a dispersão desses dados foi avaliada, exibida em gráficos na Figura 4.3. Nessa mesma figura, também são apresentados os histogramas das séries, na diagonal, e os coeficientes de correlação entre os dados, na sua porção superior direita.

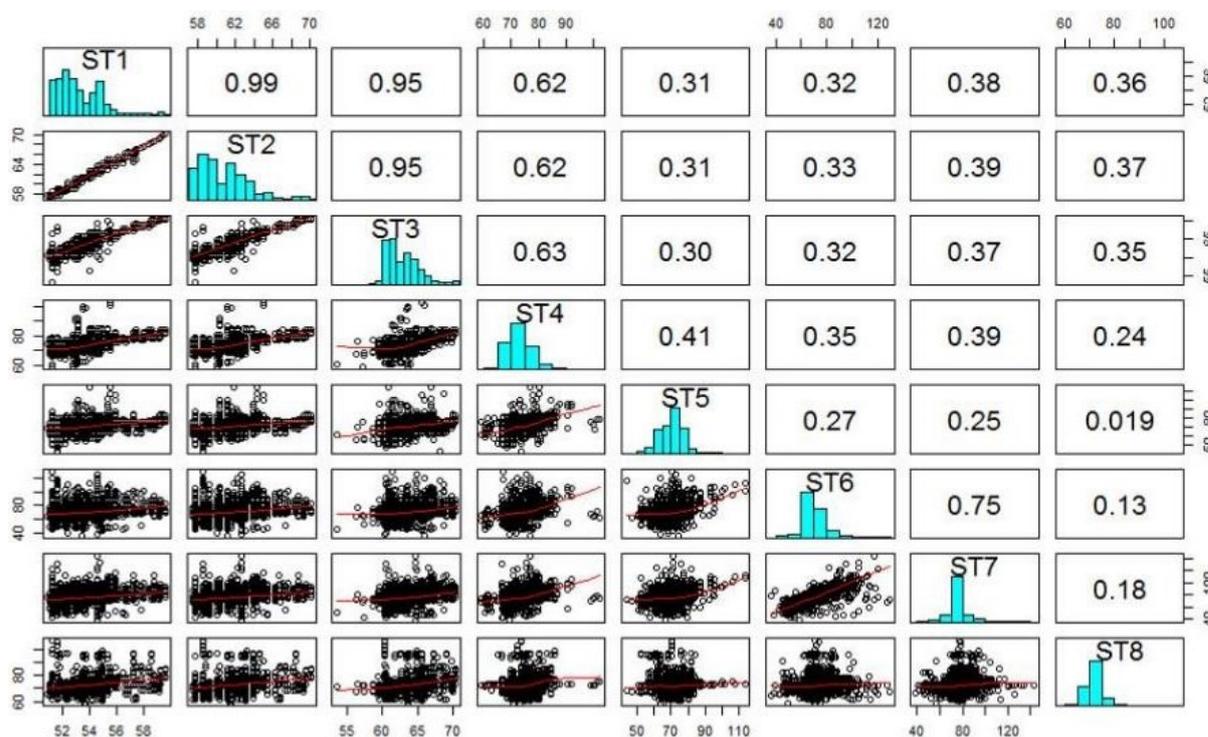


Figura 4.3: Gráficos de dispersão, histogramas e coeficientes de correlação entre as vazões horárias das oito estações telemétricas da bacia do rio Jauru

Entre os aspectos mais notáveis dessa figura destaca-se o fato de as maiores correlações se restringem às vazões das três estações de montante, especialmente ST1 e ST2, anteriores ao primeiro barramento. Além disso, pela observação dos histogramas, é perceptível que as estações de montante possuem forma platicúrtica, portanto, com caudas leves; ao passo que as séries de jusante tendem a concentrar seus valores em torno da média, com forma leptocúrtica e caudas pesadas. Principalmente essa última observação é congruente com a afirmativa de Teräsvirta *et al.* (1993), ao mencionar que séries temporais com intervalos de curto período costumam exibir características de alta curtose. Outra característica pontuada por esse mesmo autor a respeito de séries com discretização temporal de alta frequência é a tendência à não-linearidade positiva, o que de fato foi verificado por meio do teste de hipótese de Teräsvirta. Sucintamente, o teste de Teräsvirta usa a expansão da série de Taylor para atingir uma estatística de teste, a qual rejeita a hipótese nula de que um modelo linear represente adequadamente a série de dados (TERÄSVIRTA *et al.*, 1993; TRAPLETTI *et al.*, 2018).

Mesmo após realizada a consistência dos dados, algumas falhas sem padrões evidentes continuaram sendo observadas. Todavia, em grande parte dos registros há maior número (74,04%) de estações com informações concomitantemente nas oito estações. A Tabela 4.3 mostra das proporções de dados na série de 11.060 pontos por cada estação. Adicionalmente, 22,35% e 3,61% dos dados de vazão se fazem presentes respectivamente em sete e seis estações em simultâneo, não havendo lacunas em quatro ou mais estações ao mesmo tempo.

Tabela 4.3: Proporção de dados horários existentes na série de 11060 horas

	ST1	ST2	ST3	ST4	ST5	ST6	ST7	ST8	Períodos completos
Nº dados	11054	11054	10639	10768	10914	11051	8790	10940	8189
% Dados	99,95%	99,95%	96,19%	97,36%	98,68%	99,92%	79,48%	98,92%	74,04%

Entre diversas formas de reconhecimento dos dados, a função de autocorrelação se faz importante por descrever a medida da correlação entre as observações dessa série e os seus próprios valores, defasados por um *lag* com “*k*” unidades de tempo (y_t e y_{t-k}). Uma particularidade da função de autocorrelação parcial (PACF – *Partial Autocorrelation Function*) é que essa representação é feita controlando os valores da série temporal em diversas defasagens temporais medindo a relação entre y_t e y_{t-k} após remover os efeitos de atrasos temporais iguais

a 1, 2, 3, ..., $k-1$ (HYNDMAN & ATHANASOPOULOS, 2018). Por essa razão, a PACF é capaz de indicar a dependência entre os dados pertencentes à mesma série, o que é requisito para diversas análises estatísticas, como testes de significância para a potência espectral *wavelet* (GRINSTED *et al.*, 2004). Além disso, essas análises também servem de indicador inicial na definição de variáveis regressoras em modelos de previsão de séries temporais (MAIER *et al.*, 2010; NOURANI *et al.*, 2014).

Na Figura 4.4 são ilustradas as PACF das vazões logaritmizadas relativas às séries das estações ST1 à ST8, adicionada aos dados de efluência da UHE Jauru, considerando discretização diária. Nessa representação, a discretização diária foi assumida por ser essa a adotada para a identificação de efeitos nos ciclos de vazão no domínio tempo-frequência, constante no item 4.2.3. As linhas tracejadas na horizontal representam os limites dos intervalos de confiança equivalentes a 95% para as diferentes defasagens temporais (*lags*).

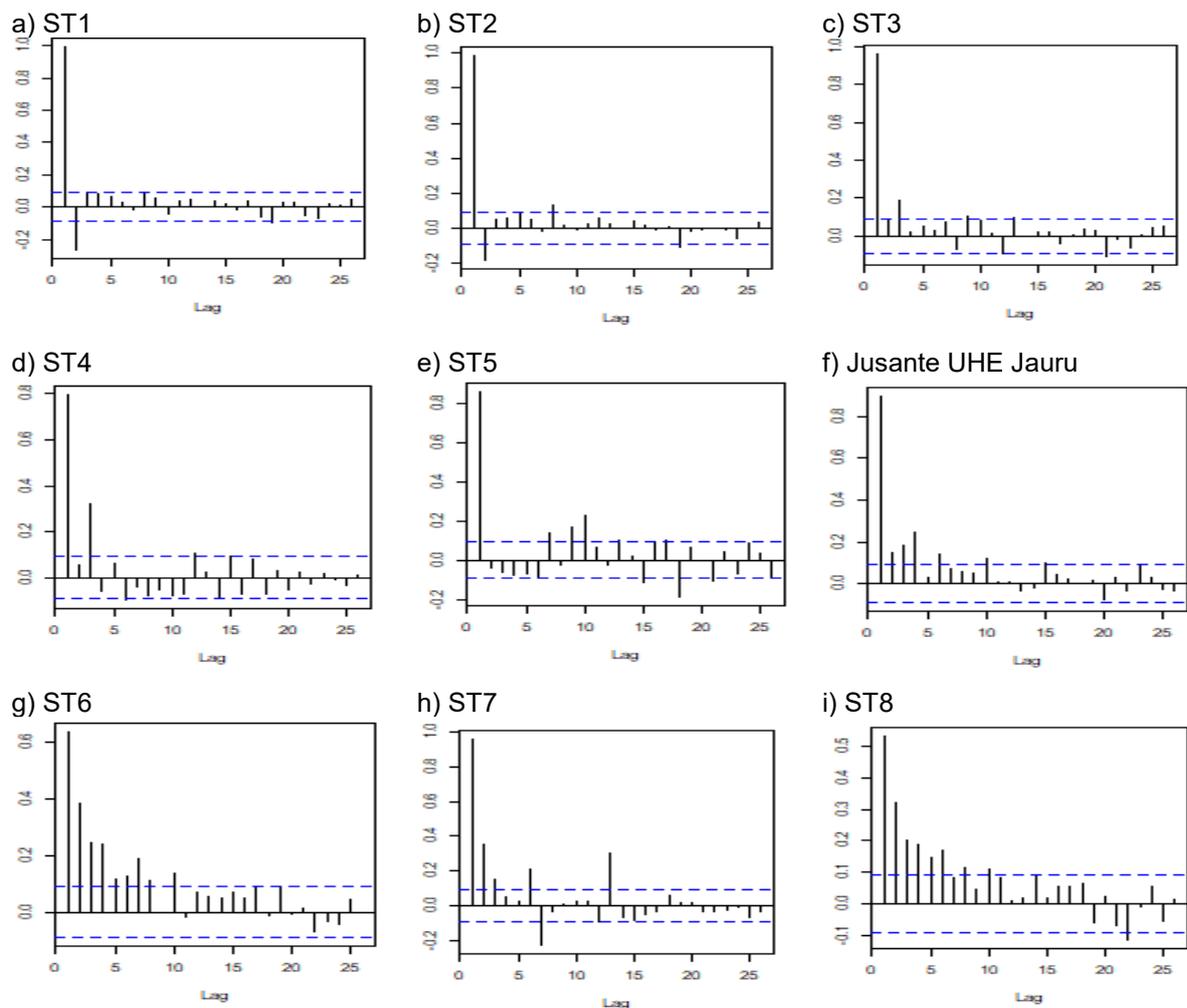


Figura 4.4: Funções de autocorrelação parcial das séries de log-vazões diárias

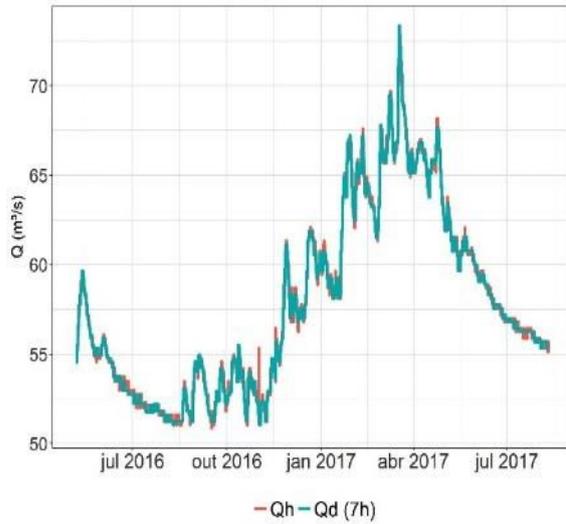
Pela análise das PACF da série de log-vazões diárias, é verificado que as autocorrelações parciais passam a não ser estatisticamente significativas a partir das defasagens temporais de pequena ordem, especialmente nas estações de montante. Entretanto, nas séries de jusante, com destaque para ST6 e ST8, foi observado um comportamento que descreve o processo autorregressivo de maior ordem, com caimento gradual dos coeficientes. Em razão das características inerentes à série histórica, as correlações negativas foram interpretadas como isentas de significado estatístico.

4.2.2 Efeitos no domínio do tempo em escala horária

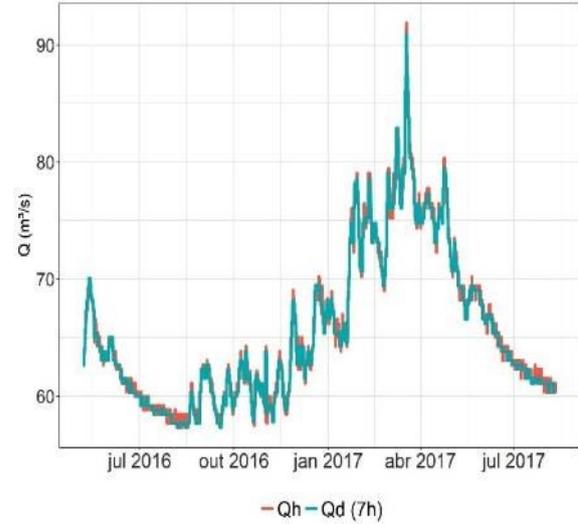
Recentemente, algumas pesquisas têm abordado o tema denominando *hydropeaking* como a alteração artificial nos hidrogramas com base na operação dos AHs por meio do armazenamento de água em determinadas situações para gerar eletricidade em função da demanda de energia (HAAS *et al.* 2014; HAUER *et al.*, 2016). Com vistas a identificar efeitos semelhantes na BHJ, algumas observações que descrevem essas ocorrências foram realizadas. A primeira delas foi contrastar os registros horários de vazão com as medições diárias às 7h. Para comparar essas duas informações em uma mesma escala temporal, esse registro diário às 7h foi replicado para todas as demais horas do dia, com interpretação idêntica às medições de estações fluviométricas convencionais no Brasil. Com isso, objetiva-se verificar possíveis efeitos visuais de vazão de curto período em decorrência do manejo operativo dos aproveitamentos hidrelétricos entre estações de montante e jusante, bem como variações subdiárias não registradas em estações convencionais.

Para tanto, os valores horários foram plotados em paralelo com os registros pontuais diários medidos às 7h, conforme é mostrado na Figura 4.5. Os rótulos de a) a h) se referem às séries das estações ST1 a ST8.

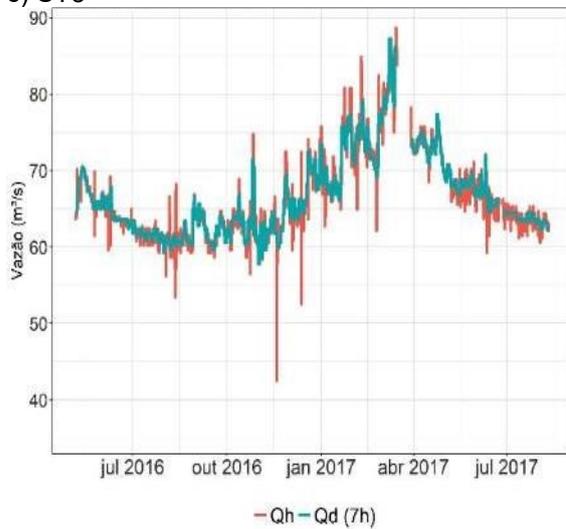
a) ST1



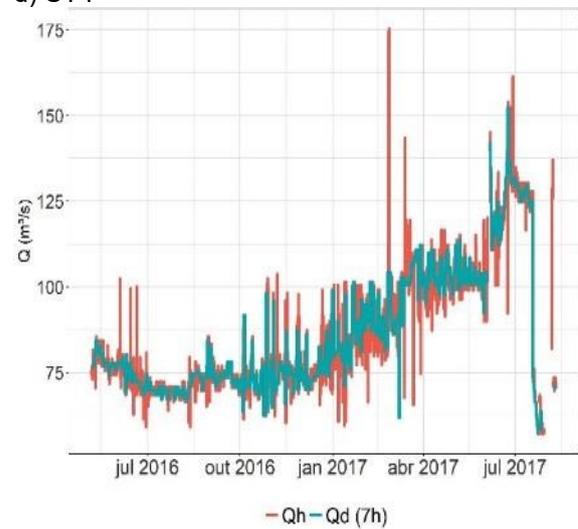
b) ST2



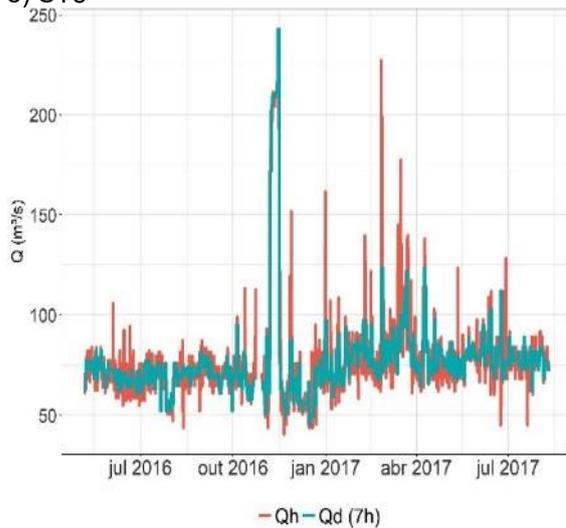
c) ST3



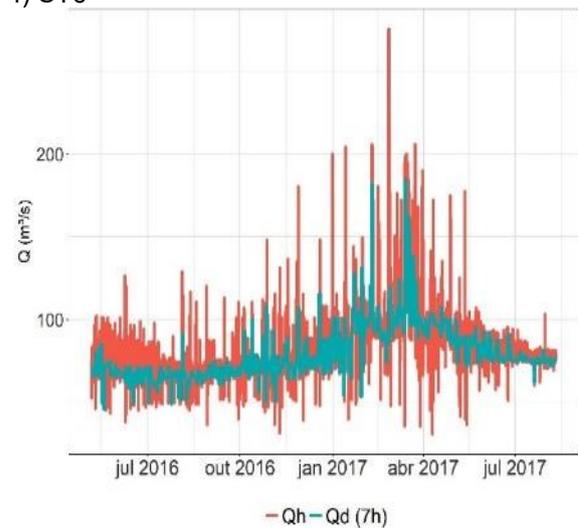
d) ST4



e) ST5



f) ST6



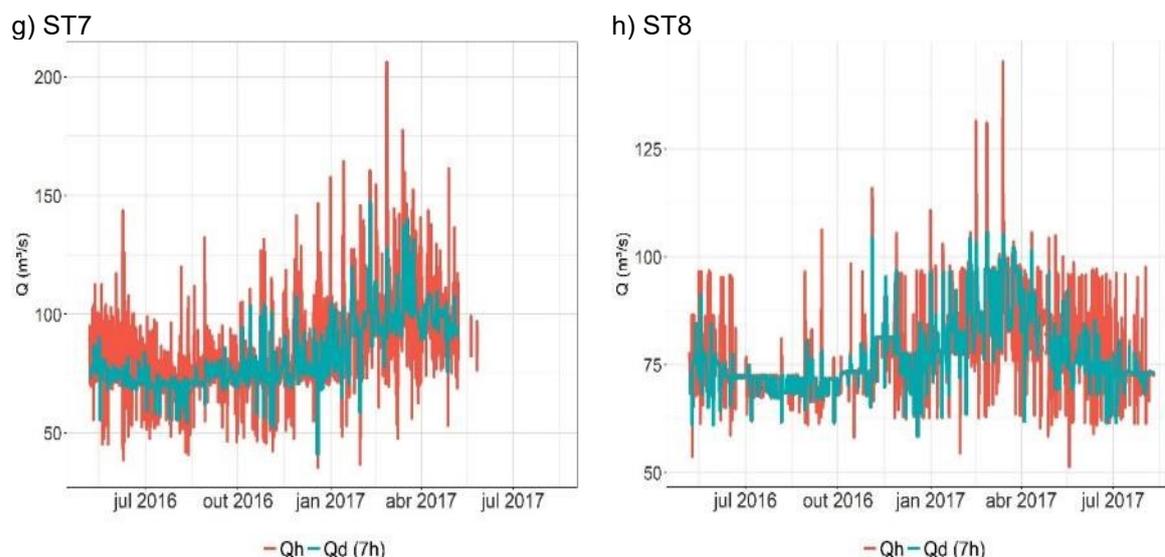


Figura 4.5: Vazões horárias e diárias nas estações fluviométricas da BHJ

Ao rememorar que as duas primeiras estações se situam a montante do primeiro aproveitamento hidrelétrico, portanto, sem influência de qualquer barramento, e comparando com os registros das 7h, é notável a brusca diferença no comportamento de vazões de jusante no que tange ao aumento das oscilações de curto período. Um aspecto notável dessa observação diz respeito à variância das vazões horárias em relação às vazões diárias, quando comparadas pareadamente a cada uma das estações em direção a jusante da bacia (Tabela 4.4).

Tabela 4.4: Variâncias das vazões horárias e diárias nas estações telemétricas

	ST1	ST2	ST3	ST4	ST5	ST6	ST7	ST8
Variância vazão horária (m ³ /s) ²	26,29	42,95	28,26	334,52	472,41	395,64	287,76	77,32
Variância vazão diária (m ³ /s) ²	26,37	43,05	33,34	335,62	119,12	288,24	235,68	75,33

Nas operações a fio d'água as defluências dos AHs são definidas de forma a corresponderem diretamente com a afluência ao reservatório, porém, limitadas pelo atraso temporal relativo ao seu volume e ao seu tempo de residência hidráulico. Assim, o grau que os AHs podem acomodar as operações das usinas a fio d'água depende das características físicas do reservatório, por menor que seja, e que afetam descargas naturais na subida e descida dos hidrogramas. A esse fator é acrescentado o manejo com as turbinas desses empreendimentos, o qual tende a descaracterizar os hidrogramas, conforme pode ser avaliado. Com efeito, as operações a fio

d'água geralmente não produzem condições de descarga que realmente coincidem com as condições pré-barragem, embora ações mitigadoras possam ser efetuadas, como discorrem Bruder *et al.* (2016).

Outras resultantes atribuídas à ocorrência de *hydropeaking*, como os valores médios de vazão entre horas de menor e maior demanda energética, foram sumariamente investigados. Por exemplo, em determinados trechos, especialmente nas estações ST5, ST6 e ST7, foi verificado que as vazões de escoamento às 19h foram ligeiramente superiores às vazões registradas às 7h. Esse efeito é comumente observado a jusante de AHs, função da maior demanda de produção de energia nos horários de final da tarde. Além disso, foi notado que nas três últimas estações houve aumento da variância das vazões das 19h em relação à das 7h, com destaque para a ST6, superior a 55%.

Considerando que os *hydropeakings* estão associados às variações artificiais diárias ou subdiárias na defluência de um AH, operações de nível no reservatório da UHE Jauru, que preveem oscilações diárias de 1,0m (elucidado no item 4.1.1), podem ser suficientes para explicar alguns desses fenômenos. Entretanto, conforme mencionado anteriormente, não foram encontradas regras de operações de nível para os reservatórios dos demais aproveitamentos hidrelétricos na BHJ.

Ainda sobre a oscilação das vazões, em alguns períodos foram notadas bruscas variações em pequeno intervalo, cuja proporção dos picos e vales pode se aproximar de 80% em intervalo de 1h. Como simples exemplo onde pode ser visualizada essa observação, na Figura 4.6 é exibido um extrato da série de vazões horárias entre os dias 7 e 19 de junho de 2016 da estação ST7 (PCH Salto Jusante).

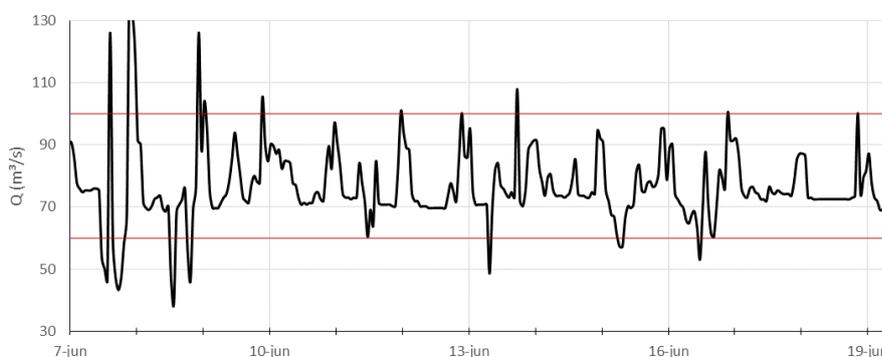


Figura 4.6: Exemplo de série com grande amplitude em curto período (ST7)

O número de inflexões (ou reversões) nas séries de vazão tem sido utilizado por alguns autores (RICHTER *et al.*, 1996) como um indicador útil para mensurar a frequência de alteração do comportamento da descarga hídrica. Desse modo, com o intuito de aumentar a percepção a respeito das oscilações de vazão no decorrer do percurso fluvial, foram calculados indicadores relativos ao número de inflexões para cada estação, ao levar em conta a possibilidade de as operações dos AHs modificarem o comportamento quantitativo das oscilações. Para tanto, foi considerado que uma inflexão ocorre quando, após uma sequência de ascensão do hidrograma, a vazão pontual é reduzida, e passa por uma recessão, ou vice-versa. Sendo assim, foi contabilizado o número de inflexões do hidrograma (ascensões e recessões) entre intervalos de 1h, 12h e 24h, conforme mostrado na Figura 4.7. Essas escalas temporais foram assumidas por entender serem representativas de ciclos operacionais.

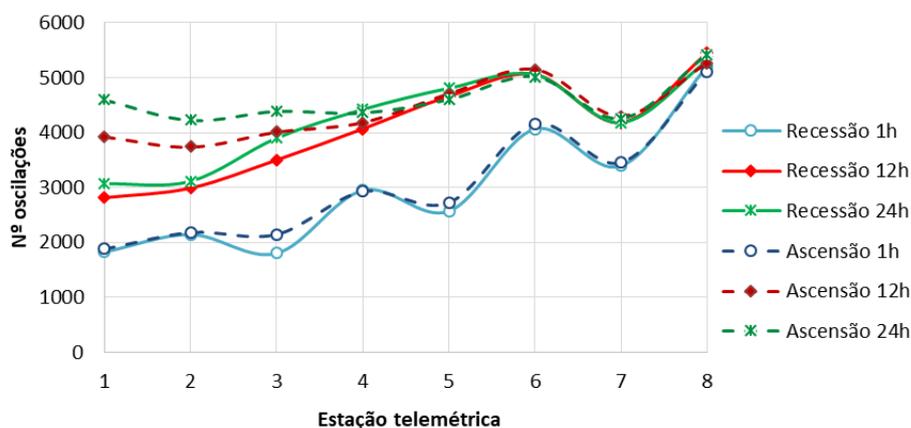


Figura 4.7: Contagem de inflexões do hidrograma para recessão e ascensão

O crescimento do número de inflexões para uma mesma defasagem temporal entre diferentes estações, tanto da recessão quanto da ascensão, evidencia aumento das oscilações de vazão. Esse aumento é demonstrado na Figura 4.7, ao comparar as estações de jusante com as de montante, indicando alguma modificação das condições de escoamento natural. Uma segunda característica, já esperada, é em relação às maiores defasagens temporais tenderem a maiores oscilações.

Outro indicador concernente ao comportamento oscilatório de vazões está associado às proporções de inflexão para ascensão (Figura 4.8a) e para recessão (Figura 4.8b) dos hidrogramas, quando comparadas duas estações adjacentes. É dado um exemplo para auxiliar essa interpretação: nas abcissas, a interestação 1-2 (trecho que compara inversões das estações

ST1 e ST2) indica que houve aumento de 17% no número de ascensões (Figura 4.8a) e de 16% no de recessões (Figura 4.8b) para a defasagem temporal de 1h (*lag* de maior sensibilidade). Percentagens igual a zero significam estabilidade do número de inflexões, porcentagens positivas significam elevação, e negativas a redução.

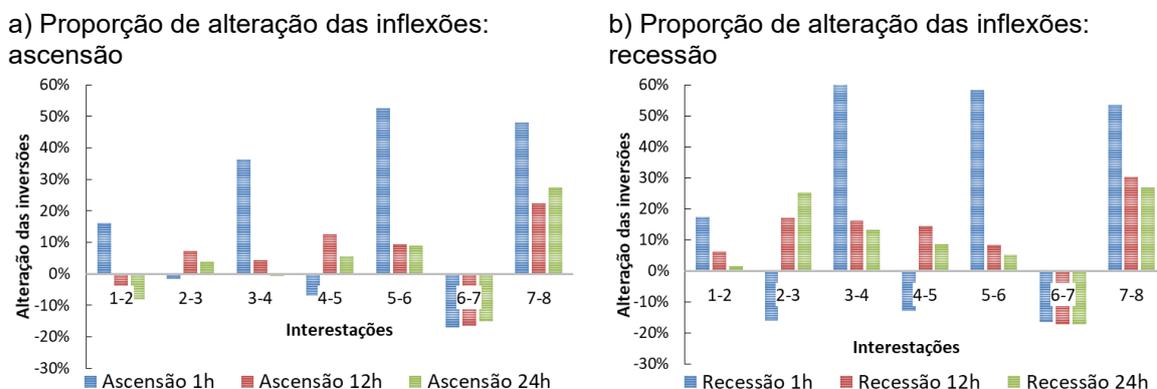


Figura 4.8: Quantidade e proporção de inflexões dos hidrogramas na BHJ

A primeira observação das alterações nas inflexões na passagem entre uma estação para outra, pela Figura 4.8a e Figura 4.8b, diz respeito à maior sensibilidade nos *lags* horários. Além disso, as comparações entre as estações ST1-ST2, ST2-ST3 e ST4-ST5 apresentaram proporções de inflexões em escalas de mesma grandeza. Vale salientar que, desses três pares, apenas o ST2-ST3 possui um aproveitamento hidrelétrico em operação em trecho intermediário, a propósito, o de menor área de reservatório. Por outro lado, as maiores magnitudes de alterações nas passagens de vazões foram verificadas nas estações ST3-ST4, ST5-ST6 e ST7-ST8 (em cujos segmentos fluviais estão a PCH Ombreiras, a UHE Jauru, a PCH Indiavaí e a PCH Figueirópolis). Essas alterações são quase sempre crescentes, tanto para a ascensão quanto para a recessão nos hidrogramas.

As inflexões de vazão, assim como as modificações nas ascensões e recessões do hidrograma, estão diretamente relacionados a fenômenos de turbulência e desestabilização das condições aquáticas, o que pode influenciar o ecossistema ao provocar estresse em plantas e organismos de baixa mobilidade, ou em fase de reprodução (RICHTER *et al.*, 1996; POFF & SCHIMIDT, 2016). No que concerne ao número de inflexões, é interessante notar que a oscilação aumentou conforme a área de drenagem da bacia. Por possuir menor tempo de resposta das precipitações, entre outras razões, o mais comum é que bacias menores sejam mais suscetíveis às variações

de vazão, resultando em maior número de inflexões (SILVA & TUCCI, 1998). Entretanto, o observado no rio Jauru foi o inverso, ou seja, nas séries das estações que controlam menores áreas da bacia as variações de vazão foram menores que as séries de jusante.

No próximo grupo de indicadores, para cada uma das oito estações telemétricas foram calculadas as amplitudes de vazões em termos percentuais nas seguintes defasagens temporais: 1h, 2h, 3h, 6h, 12h e 24h. Em seguida, as amplitudes foram ordenadas e os maiores valores foram plotados, a fim de comparar os resultados entre as estações. Visto que a ST5 e a ST8 possuem leituras sub-horárias de 15 minutos e 30 minutos, respectivamente, esses intervalos foram adicionados. Esse direcionamento assume por princípio que, em condições naturais, bacias menores estejam mais suscetíveis a oscilações de pequena escala. Logo, em um corpo hídrico sem perturbações, espera-se que essas inflexões de vazão sejam proporcionalmente reduzidas conforme o percurso a jusante. O resultado é mostrado na Figura 4.9. Para a melhor visualização, as ordenadas foram representadas em escala \log_2 .

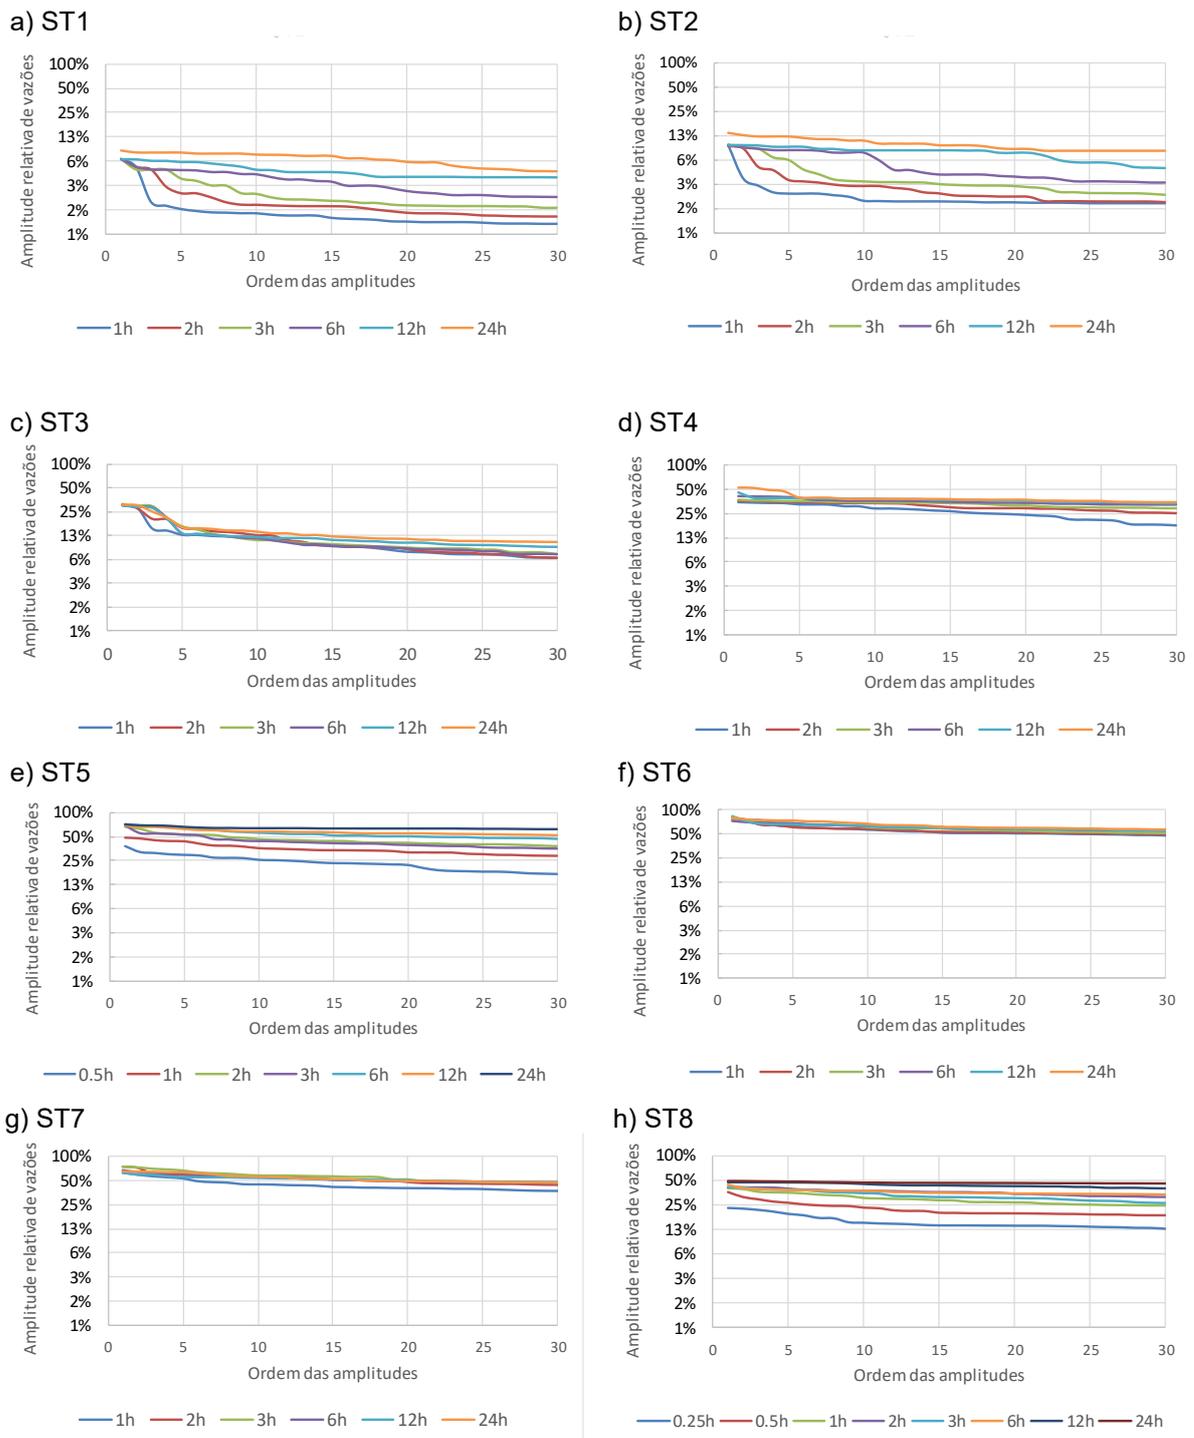


Figura 4.9: Amplitude relativa de vazões, para cada estação telemétrica (\log_2)

As estações ST1, ST2 (ambas a montante do primeiro barramento), ST5 (UHE Jauru Montante) e ST8 (PCH Figueirópolis Jusante) apresentaram distribuição de amplitudes porcentuais de vazão mais bem definidas que as demais estações. Regra geral, os menores intervalos de tempo permaneceram com as menores proporções entre vazões, função da dependência entre um

intervalo de tempo e outro, conforme esperado. Entretanto, o aspecto mais relevante dessa análise é verificar não haver variação em grau absurdo nas menores escalas da amostra de vazões, especialmente entre os intervalos sub-horários das estações ST5 e ST8.

Uma das maiores importâncias nessa última observação tem origem na concepção geral de projetos dos AHs, em que há desvio de parcela da água do corpo hídrico por um canal de captação, que conduz a água ao duto forçado que alimenta as turbinas, enquanto a outra parte da água segue o leito natural, no trecho de vazão reduzida, até que encontre novamente a parcela da água desviada para a turbina. Tendo em vista que o operador tem relativo controle sobre a vazão turbinada, a qual é operada de acordo com as demandas horárias e diárias, o problema desse controle está no tempo de resposta entre mudança da vazão na turbina e seu escoamento pelo trecho de vazão reduzida, que em função da rejeição de carga pode causar transiente, e, por consequência, o sistema hídrico se sujeitar a ondas de cheia ou de rebaixamento de curta duração com brusca intensidade. Com efeito, impactos de alta magnitude poderiam ocorrer em situações de paralisação completa das turbinas, com possibilidades de redução abrupta de água do rio por alguns instantes, o que não foi observado nas séries estudadas.

Adicionalmente, merece atenção a proporção das amplitudes quando são comparadas as estações telemétricas adjacentes. Enquanto as duas primeiras estações se mantiveram inferiores a 15%, as demais séries indicaram desvios iniciais acima dos 30%. Maiores proporções foram observadas nas estações ST6 e ST7, nas quais, mesmo após a trigésima maior amplitude, quase todos os desvios se conservaram superiores a 40%.

Outra forma de analisar as amplitudes percentuais de vazão é ordenando-as e expondo os valores para cada estação em paralelo, com o intuito de confrontar os efeitos entre as séries das estações, de modo a isolar cada defasagem temporal. Dessa forma, na Figura 4.10 estão ilustradas as referidas amplitudes relativas em função das defasagens temporais de 1h, 2h, 3h, 6h, 12h e 24h.

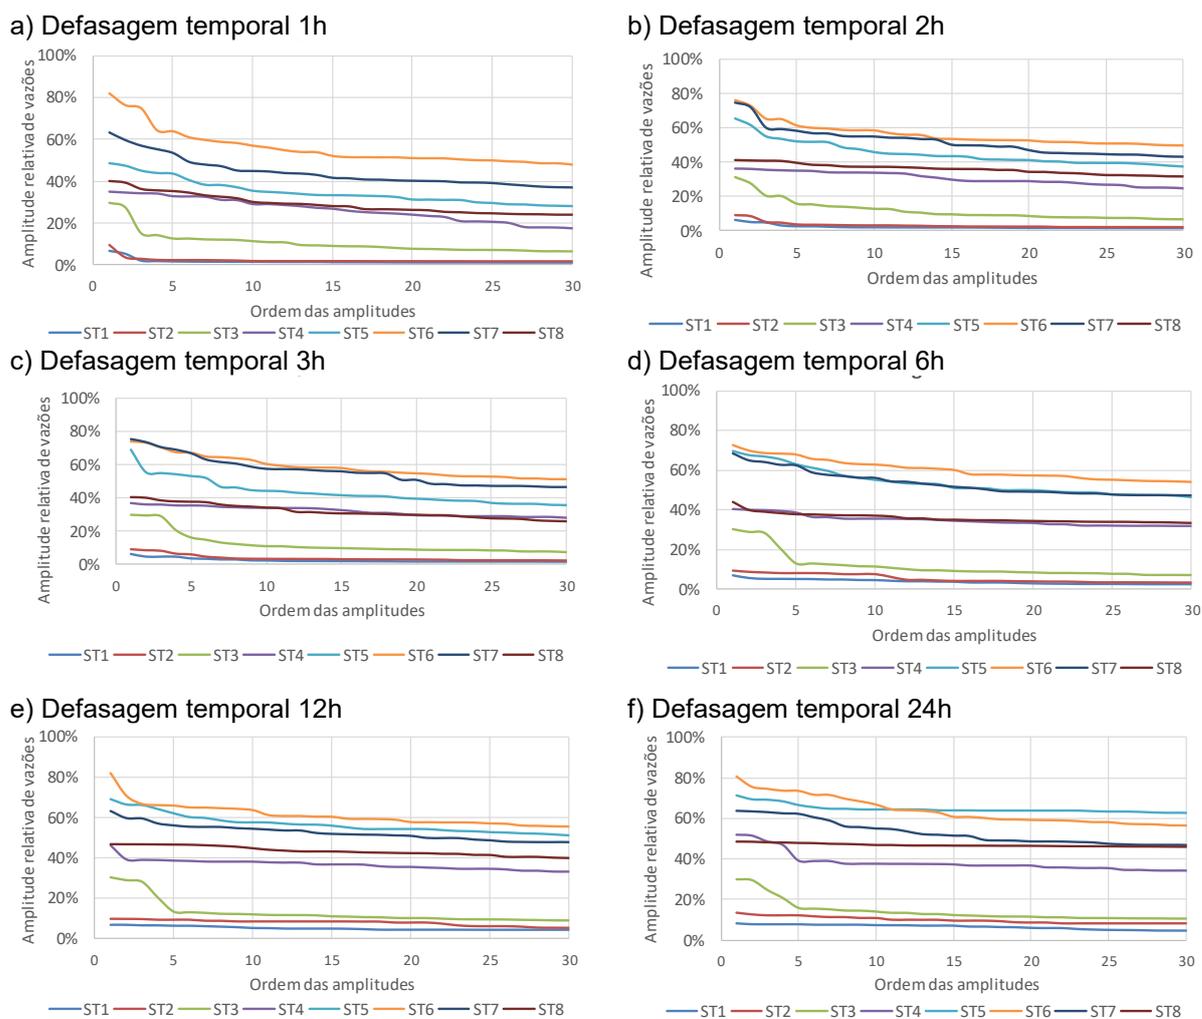


Figura 4.10: Amplitudes relativas de vazões, para cada defasagem temporal

Fica evidente que as duas estações de montante na bacia do rio Jauru possuem amplitudes relativas máximas muito semelhantes entre si, as quais são consideravelmente reduzidas. O trecho onde se situa a estação PCH Antônio Brennand Jusante (ST3) indicou diferenças de vazões próximas a essas duas primeiras. Diferentemente, para todas as demais estações houve expressivo aumento de diferença de vazões para todos os *lags* temporais. Além disso, o segmento fluvial relativo à estação PCH Indiavaí (ST6) registrou por diversas vezes as maiores variações de vazão. Interessante notar que nessa estação, mesmo para o *lag* horário (o qual em teoria deveria apresentar as menores amplitudes), a trigésima maior amplitude ainda se manteve acima de 50%.

De modo geral, pela análise das séries de vazões limitada ao domínio do tempo, foi demonstrado algum efeito perturbador nas descargas defluentes aos empreendimentos

hidrelétricos conforme o percurso a jusante da bacia. Inicialmente, essa implicação foi notada pelo aspecto visual da plotagem dos hidrogramas comparando vazões horárias e diárias, onde é mostrado o aumento da oscilação de vazão em intervalos subdiários nos segmentos fluviais a jusante dos barramentos. Na sequência, os cálculos das amplitudes percentuais de vazões entre as estações telemétricas e entre as diferentes defasagens temporais evidenciaram que houve, em certo grau, aumento expressivo das amplitudes percentuais de vazão. Apesar disso, interrupções de vazão de curto prazo não foram observadas.

Tendo em vista a necessidade de aprofundar os estudos a respeito das oscilações de vazão, a continuidade da presente pesquisa se deu com enfoque na análise simultânea das escalas periódicas e da extensão temporal das oscilações dominantes.

4.2.3 Efeitos nos ciclos de vazão no domínio tempo-frequência em escala diária – TWC

A técnica da transformada *wavelet* contínua permitiu estudar as alterações nas frequências dos sinais de vazão. Para tanto, a partir da série histórica original horária, foram selecionados dados de vazões diárias compreendidas entre 06 de maio de 2016 e 10 de agosto de 2017, com 462 dias, ou 15 meses. Nessa análise, a série da ST5 está limitada a partir de 16 de novembro de 2016 e a série ST7 está limitada até maio de 2017, ambas devido a lacunas que não puderam ser preenchidas. Além disso, conforme mencionado, as medições da ST4 não foram utilizadas, e a defluência do reservatório da UHE Jauru, denominada “Jusante UHE Jauru”, foi adicionada ao registro de vazões.

Após efetuado o tratamento dos dados (conforme explanado no item 4.1.2), esta etapa foi finalizada com a transformação logarítmica das vazões. O intuito dessa realização foi aproximar as distribuições de probabilidade da série a um modelo Gaussiano e estabilizar a variância das séries temporais (HYNDMAN & ATHANASOPOULOS, 2018). O recurso de logaritmizar os dados de vazão foi necessário tendo em vista que os testes de significância da potência espectral, a serem executados nos passos seguintes, assumem pressupostos de normalidade da série, com autocorrelação temporal oriunda de um processo AR[1] (GRINSTED *et al.*, 2004).

Em decorrência dessas considerações, foi realizada a análise da função de autocorrelação parcial (PACF) de log-vazões diárias para verificar a medida da correlação entre as observações da série e os seus próprios valores defasados (conforme Figura 4.4, item 4.2.1). Com isso, foi constatado que apesar de haver correlações significativas além do *lag-1*, os valores dos

coeficientes de autocorrelação são reduzidos, e, por consequência, o viés introduzido nas estimativas de vazão provenientes do modelo AR[1] é minimizado (COSTA & FERNANDES, 2017). Disso se supõe que as interpretações da análise de padrões cíclicos de vazão pela TWC não serão comprometidas.

O principal aspecto do primeiro grupo de resultados do presente item 4.2.3 é observar se ao longo do curso do rio os padrões cíclicos de vazão de curta duração se mantêm ou se são modificados. Desse modo, a observação da potência espectral *wavelet* (*wavelet power spectrum* – *WPS*), cujos resultados estão no subitem 4.2.3.1, permite identificar os componentes periódicos dominantes de uma série temporal e seu comportamento ao longo do tempo. Em segundo momento, no subitem 4.2.3.2, é apresentada a análise por meio da coerência *wavelet* (*wavelet coherence* – *WCO*), que correlaciona as periodicidades de vazão dominantes entre duas estações de maneira escalonada.

4.2.3.1 Potência espectral *wavelet* – WPS

Na Figura 4.11 e na Figura 4.12, referentes aos sinais de ST1 e ST2, são exibidos o hidrograma e o respectivo escalograma que representa a potência espectral *wavelet* (WPS). Para interpretação dos escalogramas, regiões dentro das áreas delimitadas por um contorno espesso de cor preta indicam padrão de oscilação dominante (eixo das ordenadas) durante determinado tempo (eixo das abcissas), em um nível de confiança de 95%. A graduação entre cores quentes (vermelhas) e frias (azuis) está relacionada à potência dessa periodicidade. A região curva em forma de “U” representa o cone de influência (COI), cuja área interna resguarda as potências *wavelet* do efeito de borda.

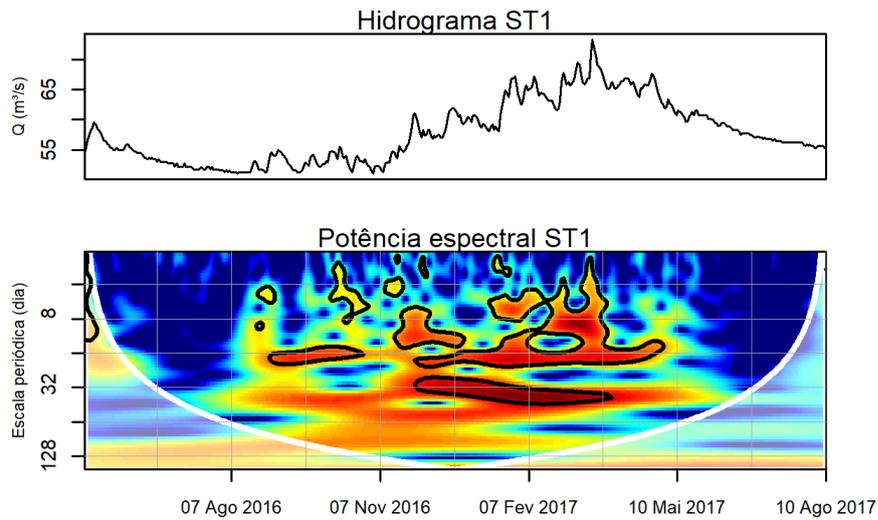


Figura 4.11: Vazão e WPS – ST1

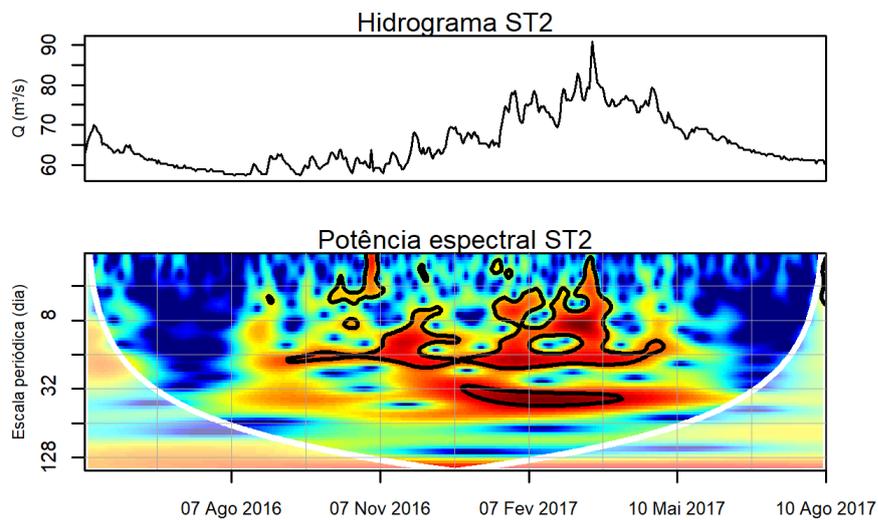


Figura 4.12: Vazão e WPS – ST2

A similaridade entre as periodicidades dominantes entre ST1 e ST2 é notável. A semelhança mais duradoura é identificada nos ciclos de vazão em torno de 16 dias, entre setembro de 2016 e abril de 2017, com uma ligeira interrupção em novembro de 2016 na ST1. Apesar disso, a potência mais forte em ambos os sinais, identificada pela intensidade do vermelho, está situada entre 30 e 40 dias, entre meados de dezembro de 2016 e final de março de 2017. Outros ciclos mais curtos com potência significativa têm alguma semelhança entre ST1 e ST2, por exemplo, nas oscilações próximas de 8 dias entre fevereiro e março de 2017; e de 12 dias entre meados

de novembro de 2016 e meados de março de 2017, com algumas interrupções. Um ponto importante sobre a distribuição de ciclos dominantes ao longo do tempo é o seu limite, que abrange de setembro de 2016 a abril de 2017, compreendendo a estação chuvosa. Essas periodicidades significativas são visíveis dentro desse intervalo de tempo nas análises de todas as outras séries de vazão.

Em continuação das observações das periodicidades nas demais estações da bacia, o hidrograma e a WPS da ST3 são apresentados na Figura 4.13.

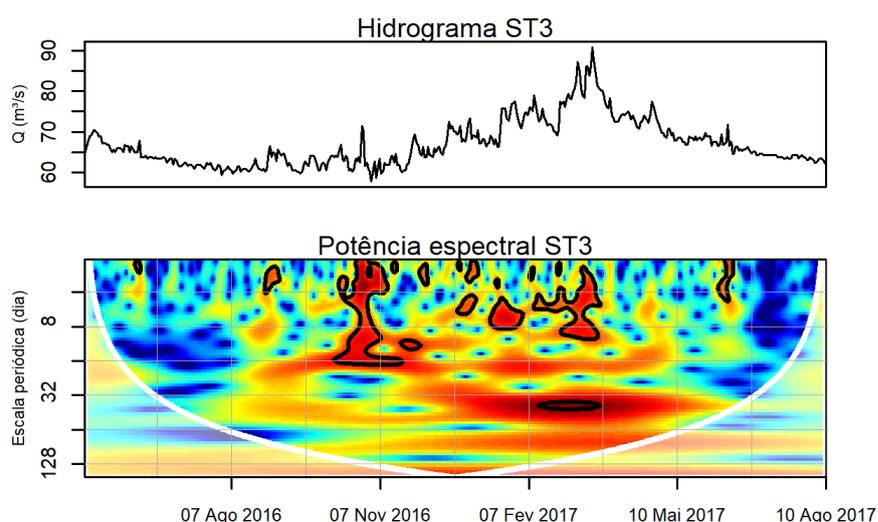


Figura 4.13: Vazão e WPS – ST3

A respeito da estação ST3, é notado um ciclo dominante em torno de 35 dias entre o início de fevereiro e meados de maio de 2017, centralizado no escalograma em relação às potências mais fortes exibidas em ST1 e ST2. Além disso, há um período significativo do final de outubro ao início de novembro de 2016 para ciclos inferiores a 16 dias. Apesar de algumas áreas significativas serem destacadas em escalas menores em alguns períodos curtos na estação seca, principalmente aquelas menores que 16 dias, o aparecimento por curto prazo dessas potências significativas é percebido como uma observação não constante, por exemplo, no começo de novembro. Comparando o escalograma da ST3 com os das duas estações anteriores, ainda é notada alguma semelhança entre as periodicidades dominantes, embora muitas frequências tenham deixado de ser significativas ou estejam com as potências enfraquecidas.

Os hidrogramas e as potências espectrais *wavelet* das demais estações da bacia (ST5, Jusante UHE Jauru, ST6, ST7 e ST8) são apresentadas nas imagens da Figura 4.14 até a Figura 4.18. A série da ST5 é limitada a partir de 16 de novembro de 2016 e a série da ST7 está limitada até o dia 07 de maio de 2017, ambas as situações devido a lacunas que não puderam ser preenchidas.

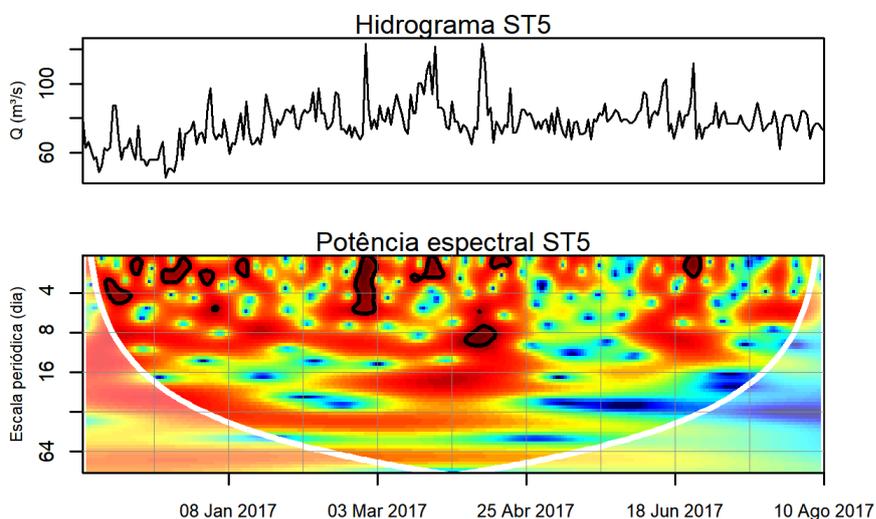


Figura 4.14: Vazão e WPS – ST5

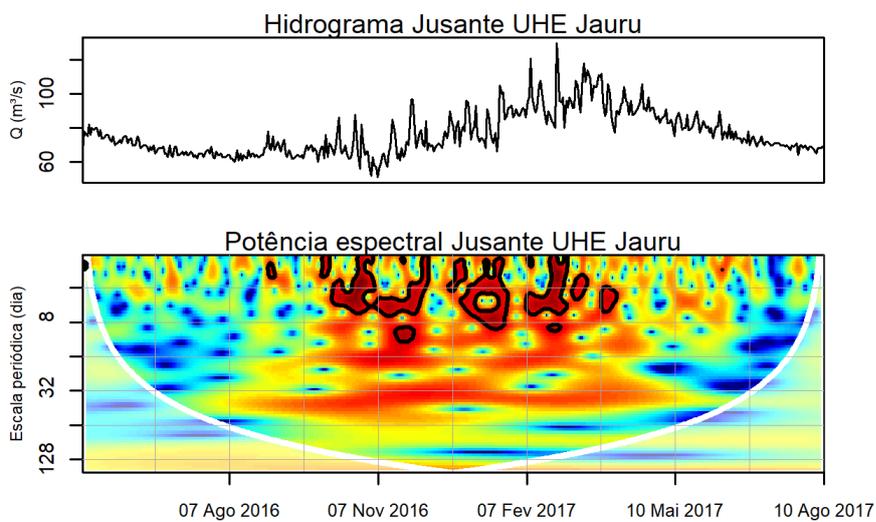


Figura 4.15: Vazão e WPS – Jusante UHE Jauru

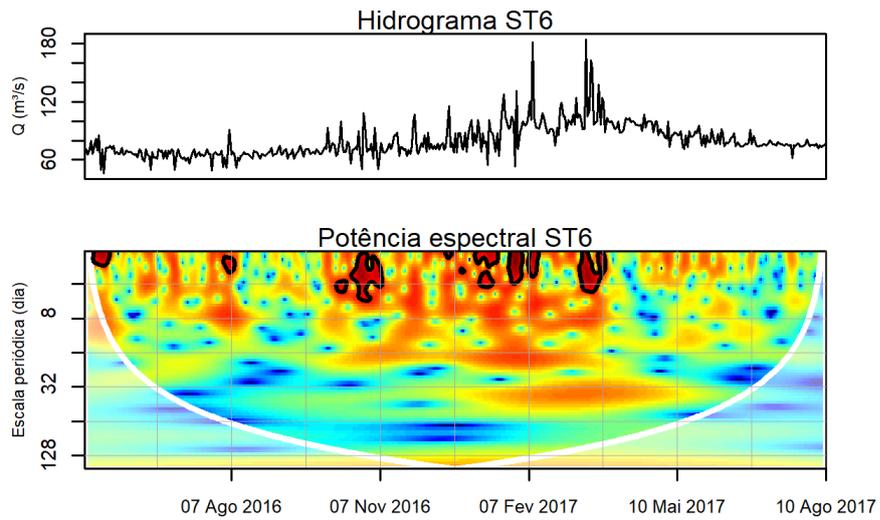


Figura 4.16: Vazão e WPS – ST6

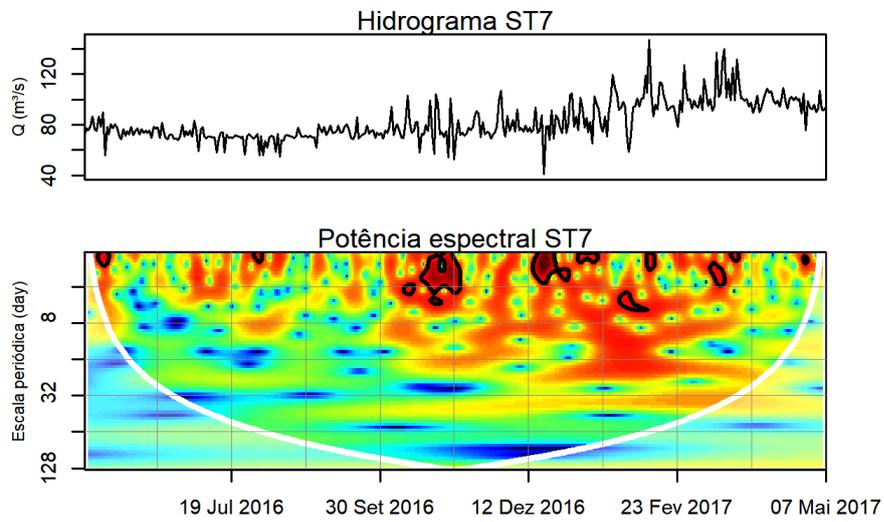


Figura 4.17: Vazão e WPS – ST7

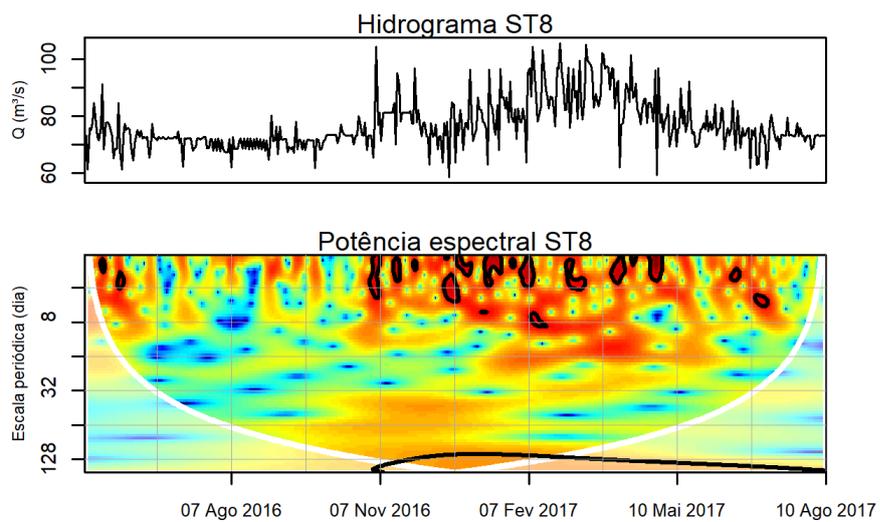


Figura 4.18: Vazão e WPS – ST8

A redução dos ciclos dominantes foi observada gradualmente entre as WPS das estações a jusante, não sendo identificados em qualquer intervalo de tempo na maioria das séries. Esse comportamento decrescente nos padrões oscilatórios é observado a partir da ST2, principalmente nas escalas mais elevadas (baixas frequências). Por outro lado, a potência espectral nas menores escalas periódicas (altas frequências) se tornou mais forte, evidenciando o aumento da importância das oscilações de curto período. O enfraquecimento das potências nos maiores ciclos e o aumento das potências nas menores escalas dão sustentação para a hipótese inicial de modificação das distribuições marginais de vazão. É possível que essa observação seja devido à grande flutuação dos picos e vales dos hidrogramas, o que inclui também o aumento da variância da série, ratificando alguns resultados apresentados no item “4.2.2 – Efeitos no domínio do tempo em escala horária”. Essas observações levam a crer que, de fato, há uma interrupção dos padrões cíclicos de vazões iniciais à medida que a água passa pelos barramentos, e, até a saída do sistema estudado, o comportamento original não é recuperado.

Com atenção à discretização temporal dos dados, White *et al.* (2005) compararam a WPS de um sinal de vazão em escala horária e diária, de uma série de 72 anos, que abrangia período anterior e posterior à construção de uma grande barragem (*Glen Canyon Dam*) de uma usina hidrelétrica no rio Colorado, Estados Unidos. Eles verificaram que a WPS do período pré-barragem, quando criada a partir dos dados de descarga horária, é quase idêntica à WPS criada usando a vazão média diária. Por outro lado, a WPS gerada no período pós-barragem, apresentou notáveis diferenças entre os padrões oscilatórios contrastando as vazões horárias e diárias. Para a investigação na bacia do rio Jauru, a análise da WPS com vazões horárias não evidenciou padrões cíclicos dominantes, possivelmente por redundância de observações, de modo que tal semelhança não aconteceu, mesmo nas estações a montante. Uma explicação para isso pode ser o curto período de registros disponíveis, 15 meses no Rio Jauru, ante 72 anos no rio Colorado, ou a qualidade dos dados horários de vazão.

Além das estações telemétricas ST1 a ST8, foi possível estimar as potências espectrais da série de vazões diárias da estação fluviométrica Porto Espiridião (66072000). Essa estação foi operada no rio Jauru entre 1965 e 2007, portanto, não compreendeu o período de pós-construção de todas as barragens na BHJ. Sua área de drenagem é de 5660 km², ou seja, muito superior aos 3093 km² da ST8, vide Tabela 4.2. O intuito de verificar o comportamento cíclico de vazões no

rio Jauru em período anterior à construção dos barramentos na bacia é por entender esta ser uma indicação das condições naturais do hidrograma. Para facilitar a interpretação das escalas periódicas em função do tempo, foram selecionados intervalos temporais da série histórica de vazões diárias com extensão compatível com as séries históricas das estações telemétricas (entre 06 de maio e 10 de agosto de cada ano, contemplando também 462 dias). Dois exemplos são apresentados na Figura 4.19 e na Figura 4.20.

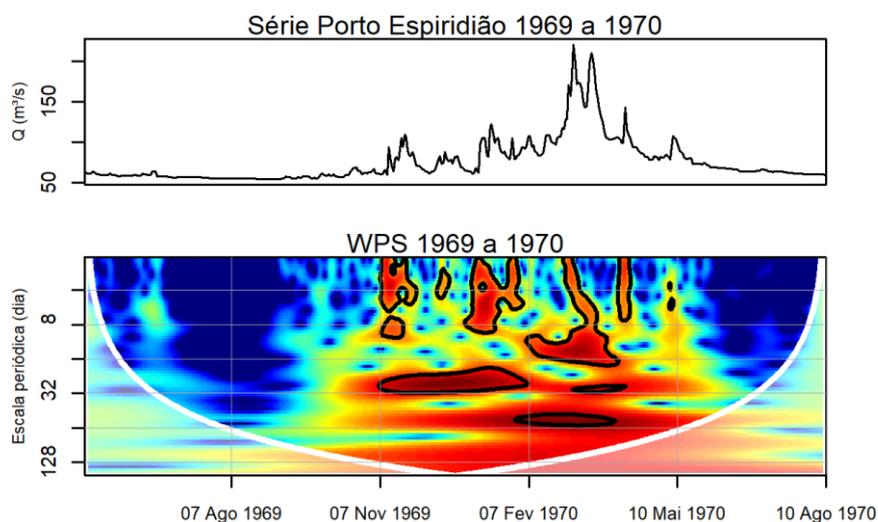


Figura 4.19: Vazão e WPS da estação Porto Espiridião 1969 a 1970

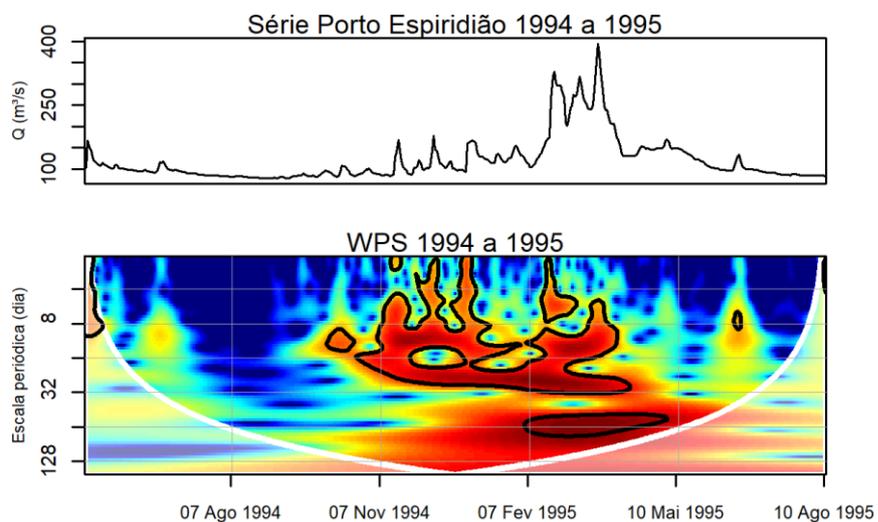


Figura 4.20: Vazão e WPS da estação Porto Espiridião 1994 a 1995

Por essa observação, fica evidente que o padrão de oscilações de vazão nos anos anteriores aos barramentos na estação Porto Espiridião, posicionado em trecho bem a jusante da ST8, é semelhante ao observado na Figura 4.11 (WPS ST1) e na Figura 4.12 (WPS ST2). Essa observação reforça o raciocínio de que, apesar da variabilidade espacial, as estações intermediárias na bacia do rio Jauru (ST3 a ST8) permaneceriam com esse mesmo comportamento caso não houvessem efeitos perturbadores decorrentes das operações dos AHs.

Buscando relações físicas para os padrões oscilatórios observados a montante, é retomado que a existência de veranicos na região Centro-Oeste do Brasil (PERTUSSATTI *et al.*, 2013; CARVALHO *et al.*, 2013) oferece uma explicação plausível para a ocorrência de potências espectrais significativas nas três estações a montante e nas séries da estação Porto Espiridião, conforme foi discorrido no tópico 4.1 – Área de estudo. De fato, alguns dos ciclos dominantes do rio Jauru a montante das barragens, especialmente o de 35 dias, foram compatíveis com os veranicos médios e máximos predominantes na bacia identificado por Pertussatti (2013). Ademais, era esperado que as potências significativas nas escalas menores pudessem estar relacionadas ao tempo de concentração das sub-bacias, devido à resposta da precipitação. Porém, isso não foi verificado pela análise de descargas diárias, possivelmente pela discretização temporal.

4.2.3.2 Coerência *wavelet* – WCO

Como já foi mencionado, existe certa subjetividade na análise da correlação entre padrões de duas séries temporais por meio da WPS. Por outro lado, a análise da coerência e da fase *wavelet* permitem conhecer o grau de relação linear entre duas séries no domínio tempo-frequência. A principal questão na corrente investigação é que, mesmo sem uma periodicidade dominante para um sinal de vazão, a comparação entre séries contíguas permite identificar as compatibilidades e mudanças no comportamento dos hidrogramas.

As bandas de maior frequência de vazão estão mais sujeitas às interferências de precipitações de curto prazo, aos desvios de captação ou mesmo à manobras de operação das turbinas. Por isso, acredita-se na menor representatividade entre duas séries nos ciclos menores. Adicionalmente, é esperado o aumento entre as correspondências dessas menores escalas conforme o percurso a jusante, visto que as interferências nas vazões tendem a ser

proporcionalmente menores entre estações adjacentes, em função do aumento da área da bacia. Essa expectativa também ocorre sobretudo em bacias sem expressivas ações antrópicas, pois, naturalmente, as variações bruscas que causam oscilações significativas tendem a diminuir com o aumento da área, assim como a ocorrência de eventuais variações de curto período.

Na Figura 4.21 é mostrada a correspondência entre as potências espectrais *wavelet* das vazões das estações ST1 e ST2, por meio da análise da WCO.

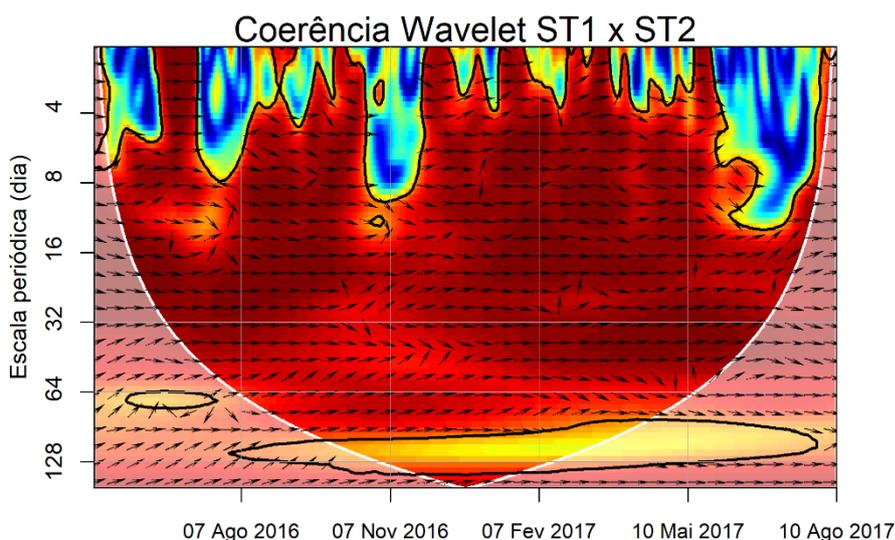


Figura 4.21: Coerência *wavelet* – ST1 x ST2

Para a interpretação dos escalogramas da WCO, vale recordar que seus valores variam de 0 (cores frias) a 1 (cores quentes). Os valores mais altos estão inscritos pelo contorno preto e espesso, que indicam a região tempo-frequência com potência comum significativa ao nível de 5% entre as duas séries históricas. As áreas internas a esse contorno indicam grande inter-relação entre as duas estações, ao passo que regiões tempo-frequência não significativas, ou seja, sem dependência entre as séries, estão apresentadas fora desse contorno.

Em razão da função Morlet ser uma *wavelet* complexa e prover valores real e imaginário, é possível usar a componente imaginária para estimar a relação de diferença de fases entre as séries. Essa representação é feita pelas setas nas regiões com alta coerência, indicando a relação de tempo entre adiantamento (ou atraso) de duas séries, ao fixar uma escala periódica particular. Uma diferença de fase zero (setas apontando para a direita) significa que as duas séries se movem juntas e estão em fase e sem adiantamento ou atraso temporal de uma estação para outra

(ABDULLAH, 2016). Esse caso é o mais esperado, quando se trata de análise de vazões de estações contíguas e sem grandes intervalos de tempo para o trânsito de cheia entre elas.

A Figura 4.21 indica correlações elevadas entre as séries de vazão entre ST1 e ST2 nas escalas de frequência entre 8 e 96 dias, excluindo áreas sob efeitos de borda, ou seja, fora do COI. Além disso, na maior parte do tempo, principalmente durante a estação chuvosa, as escalas de frequência com menores coerências se estendem para 4 dias ou menos. Tal similaridade era esperada, uma vez que as estações ST1 e ST2 são adjacentes, não possuem barramentos em trecho intermediário e não há confluência fluvial relevante. Além disso, na maior parte dos períodos, principalmente entre o início de novembro de 2016 e meados de maio de 2017, durante quase toda a estação chuvosa, as escalas menores de coerência se estendem a valores inferiores a 4 dias. Essa grande correspondência já havia sido identificada ao comparar WPS ST1 e WPS ST2 no subitem anterior (Figura 4.11 e Figura 4.12). A característica de fase (setas para a direita) é predominante em todas as escalas significativas, e demonstra que as séries de ST1 e ST2 manifestam relação direta no que tange às variações de tempo-frequência, também conforme esperado.

Pelas imagens da Figura 4.22 até a Figura 4.27 são apresentados os escalogramas de WCO entre vazões das estações ST2 x ST3, ST3 x ST5, ST5 x Jusante UHE Jauru, Jusante UHE Jauru x ST6, ST6 x ST7 e ST7 x ST8. Há uma PCH operando entre todos esses pares, com exceção da comparação Jusante UHE Jauru x ST6, onde o reservatório da usina hidrelétrica de Jauru está em operação.

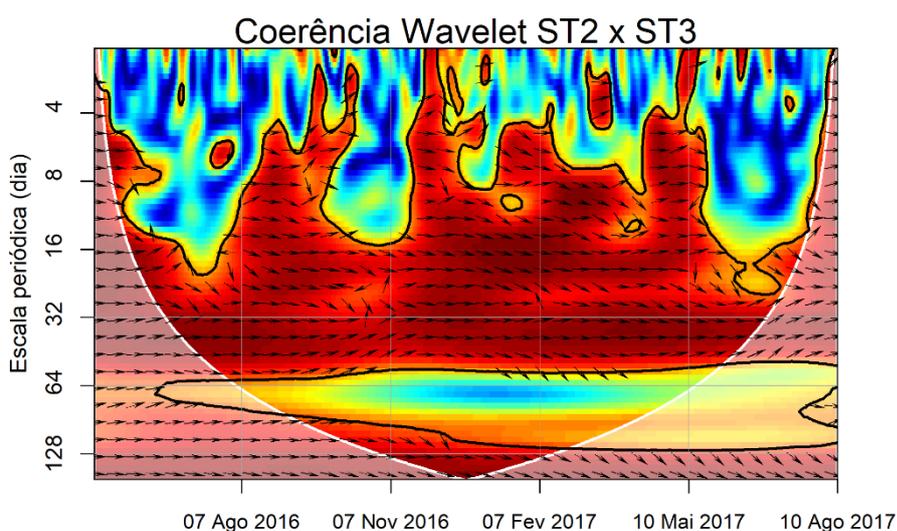
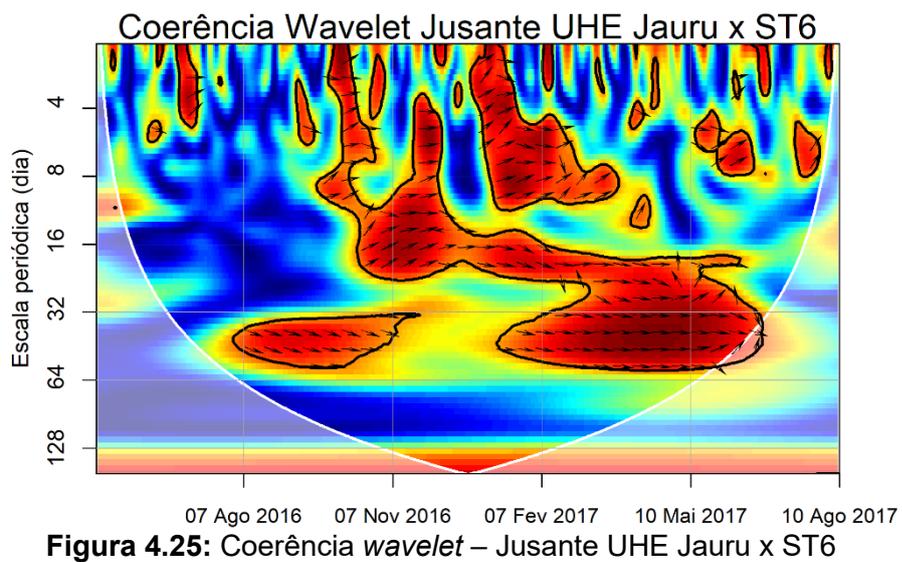
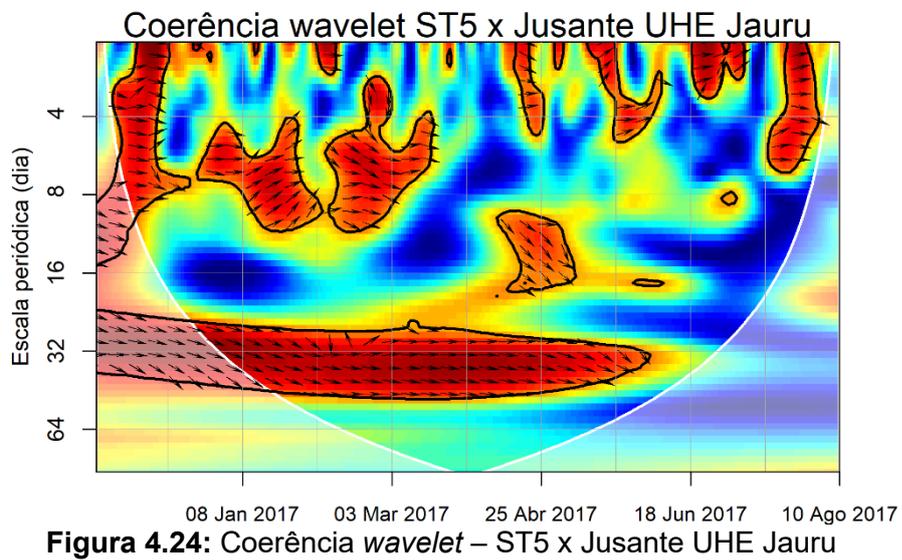
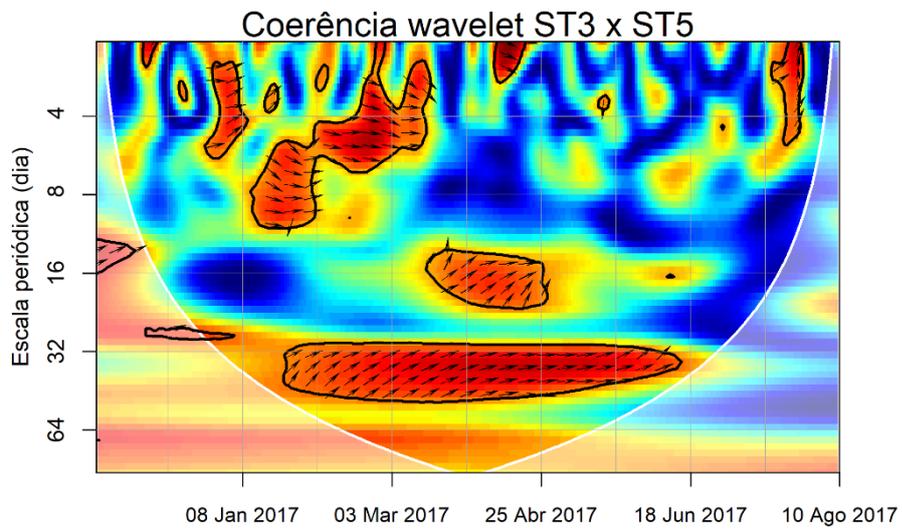
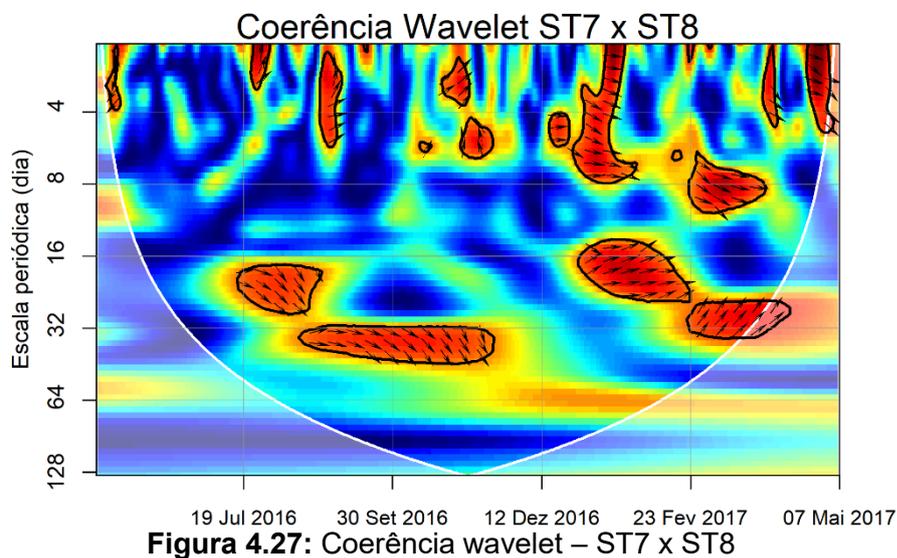
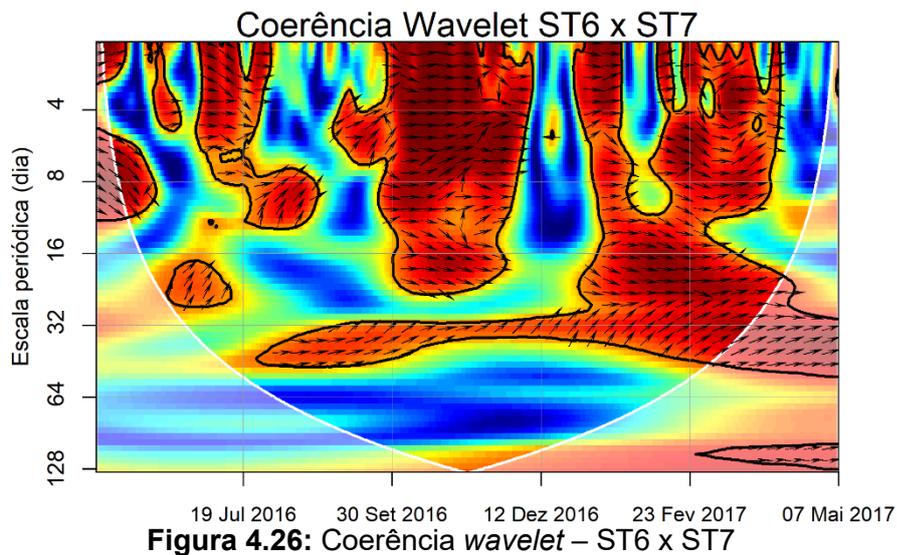


Figura 4.22: Coerência *wavelet* – ST2 x ST3





Pela Figura 4.22 (WCO ST2 x ST3), as oscilações de ST2 se manifestam em ST3 em comprimentos de onda que variam entre cerca de 24 dias a pouco menos de 64 dias, durante longo intervalo de tempo. Em relação à comparação anterior (WCO ST1 x ST2), além dos coeficientes terem reduzido (tonalidade do vermelho escuro), a escala de correspondências também diminuiu, ainda que de maneira sutil. A não coerência em torno de 128 dias se expandiu para 64 dias, com aumento das variações aleatórias nas menores escalas. Portanto, deduz-se que a PCH Antônio Brennand cause distúrbios no sistema, porém, em grau leve. Essa perturbação, ainda que reduzida, sugere um princípio de regularização de vazão. Nesse sentido, é importante lembrar que o reservatório da PCH Antônio Brennand é o menor entre os demais em

operação na bacia hidrográfica (vide Tabela 4.1), o que provavelmente é a principal razão para o menor grau de perturbação.

O contraste com a WCO ST3 x ST5 (Figura 4.23), por outro lado, não permite conjectura similar. Diferentemente das duas análises anteriores, não foi identificada periodicidade permanente entre as séries de vazões, embora haja um ciclo predominante entre 32 e 48 dias de janeiro a junho de 2017, e outras correlações significativas apareçam em períodos mais curtos nas menores escalas. Ao focar os ciclos de vazão entre 4 e 8 dias, os padrões de descarga não foram afetados de forma substancial durante o período de chuvas. No entanto, as correspondências entre essas duas séries desaparecem durante os meses de estiagem. Essa comparação indica uma perturbação moderada/forte na periodicidade dos sinais, causada provavelmente pela operação da PCH Ombreiras e pela contribuição incremental (266 km²). Entre as características conceituais do projeto da PCH Ombreiras que se diferencia das demais, é lembrado que esse AH não possui trecho de vazão reduzida para escoamento da vazão sanitária, cuja função primordial é manter o escoamento em condições parcialmente naturais. Disso resulta que toda a vazão defluente é oriunda da passagem de água pela turbina (ou pelo vertimento, em situações máximas) o que aumenta a susceptibilidade do corpo hídrico às oscilações, especialmente durante a estiagem.

Pela Figura 4.24, a análise da WCO entre as vazões da estação ST5 (assumida como afluência do reservatório da UHE Jauru) e da série de Jusante UHE Jauru também indica alteração nas periodicidades, em escalas semelhantes às da última análise. No entanto, em geral, as correspondências têm larguras maiores no tempo e nos comprimentos de onda, indicando alguma repetição de comportamento de ordem mensal. Vale ressaltar que a UHE Jauru possui o segundo maior reservatório da bacia em área alagada (em escala proporcional à da PCH Ombreiras), o terceiro maior tempo de residência hidráulica e que sua operação é a fio d'água. A sub-bacia incremental em relação à estação ST5 é de 65 km². A perturbação nesse trecho foi classificada como de grau moderado/forte.

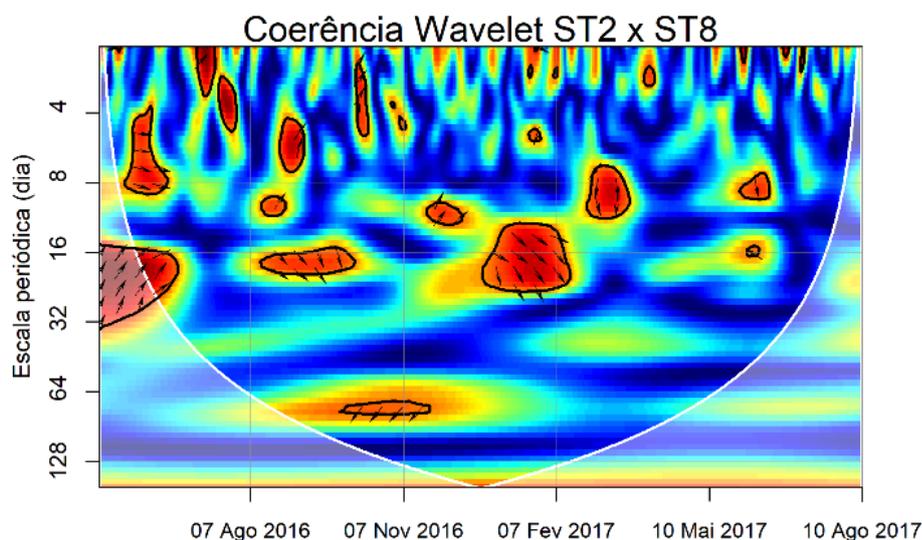
A comparação entre sinais antes e depois da PCH Indiavaí (Figura 4.25) também demonstra mudança nas periodicidades, dessa vez assumindo formas diferentes das últimas análises. Embora não tenha sido significativa, foi identificada forte coerência próximo da escala de 128 dias, o que não havia sido apontado na análise da WPS. Além disso, foi observada menor coerência nos períodos anteriores a outubro em todas as frequências. As correlações foram mais

comuns nas bandas de 16 dias e em torno de 48 dias, de novembro de 2016 a maio de 2017. Usando as mesmas considerações anteriores, é sugerido que a PCH Indiavaí cause uma perturbação de grau moderado/forte, mesmo com a reduzida contribuição lateral de 25 km².

Na WCO ST6 x ST7 (Figura 4.26), há o aumento da área com potência significativa no período chuvoso entre o final de setembro de 2016 e o final de março de 2017, evidentemente, excluindo uma área muito fraca durante cerca de um mês e meio, entre dezembro e janeiro, quando se entende que houve grande perturbação nos ciclos antes e após a PCH Salto. Apesar dessas correlações, pode-se supor como grau moderado de perturbação na periodicidade de vazões, mesmo com reduzida área incremental entre as bacias, equivalente a 33 km².

Pela Figura 4.27, a WCO ST7 x ST8 possui a menor área com periodicidades significativas em comum, além de não revelar correlação permanente ao longo do tempo e escala. Deve ser lembrado que no curso intermediário dessas estações há afluência de um tributário, cuja contribuição lateral (565 km²) é a maior entre todas as outras sub-bacias. Essa área extensa poderia alterar o comportamento de jusante da PCH Salto, tendendo a recompor os ciclos de vazões ao padrão natural, assemelhando-se ao observado em ST1 e ST2. Outra particularidade em relação às demais barragens pode ser observada, do que se pode aduzir a maior perturbação dos ciclos de vazão entre os trechos estudados. Por exemplo, pelo perfil vertical da BHJ (Figura 4.2) é notado que a PCH Figueirópolis está localizada no segmento fluvial com a menor declividade fluvial. Além disso, seu reservatório é o de maior área, o mais longo e o de maior tempo de retenção hidráulica (Tabela 4.1). Pela análise da WCO, houve o aparecimento de correlações em contornos pontuais, os quais podem ser assumidos como coincidência e sem significado físico, o que foi discutido por Maraun & Kurths (2004). Portanto, visto que as séries das vazões de montante e jusante tomaram aspecto de independência entre os sinais, o distúrbio de WCO ST7 x ST8 está classificado como de alto grau.

Apesar de não haver monitoramento hidrológico ao longo do rio Sangue, com deságue entre as estações ST7 e ST8, há um pressuposto natural que sua considerável contribuição lateral possui comportamento padrões de vazão semelhante às estações de montante da BHJ. Com base nessa hipótese, foi analisada a possibilidade de recuperação, ao menos parcialmente, das periodicidades naturais em função da bacia incremental, por meio da WCO ST2 x ST8 (Figura 4.28).



Como se verifica, a suposição de recuperação dos ciclos de montante da BHJ, com base na naturalização de vazões proporcionada pela bacia incremental do rio Sangue não se confirmou, tendo em vista a pequena área de coerência *wavelet* entre os dados de ST2 e ST8. Sendo assim, a defluência do sistema de cascatas na BHJ não possui comportamento semelhante às condições naturais, observadas a montante.

4.2.4 Comentários gerais sobre as alterações nos padrões de vazão

De maneira geral, foram encontrados resultados expressivos no que concerne ao estudo de alterações nos padrões de vazão na bacia do rio Jauru. No entanto, houve limitações acerca da qualidade da série histórica e, por consequência, do potencial de generalização das análises realizadas. Por exemplo, com base na curta extensão de séries horárias disponíveis concomitantemente a todas as estações, totalizando 15 meses, para alguns estudos, houve necessidade de eliminar seis meses da série ST5, três meses da ST7 e exclusão integral da ST4. Além disso, o intervalo disponível abrangeu apenas um ciclo completo do ano hidrológico, contendo um período de estiagem e um período de chuvas, com alguma margem antes e após esses períodos.

As análises realizadas pelo domínio do tempo evidenciaram efeitos de *hydropeaking* que descaracterizam os ciclos naturais da bacia, especialmente no que diz respeito ao aumento de

oscilações nas estações a jusante. Por um lado, houve pouco aumento de oscilações no trecho fluvial ST2-ST3, onde se localiza o primeiro barramento, de alguma maneira se aproximando do comportamento observado a montante. Por outro lado, os segmentos fluviais intermediários às estações ST3-ST4, ST5-ST6 e ST7-ST8 se destacaram em relação ao número de inflexões do hidrograma. Ainda assim, mesmo para as demais estações a jusante das barragens, outras análises permitiram constatar que as amplitudes de vazões aumentaram consideravelmente quando comparadas com as observações das duas estações a montante na bacia.

No que tange às análises das séries pelo ponto de vista do comportamento cíclico de vazões, na maior parte da análise com a transformada *wavelet* contínua na BHJ, foi possível identificar a resposta dos coeficientes de potência espectral e de coerência *wavelet* contrastando as estações chuvosa e de estiagem. Em geral, a estação chuvosa apresenta correspondências maiores do que durante a estiagem, possivelmente em razão da maior capacidade de retenção de água no reservatório durante o período seco, enfatizando o seu efeito de regularização. Essa observação sugere maior sensibilidade a alterações do comportamento hídrico no período de estiagem, quando comparado com o período úmido.

Conforme Grinsted *et al.* (2004), a medida da WCO pode detectar coerência significativa mesmo que a potência comum entre as séries seja reduzida. Portanto, espera-se que as comparações entre séries adjacentes permitam reconhecer padrões cíclicos (ou variações aleatórias) também com base em comportamentos remanescentes em cada par, o que inclui a possibilidade de observar a restauração de uma periodicidade natural. Por essa razão, após a perturbação em um par de dados, presume-se que na próxima comparação das séries os padrões cíclicos possam ser identificados, caso existam. Contudo, essa característica não foi observada com os experimentos realizados na BHJ. Isso significa que, alterado um comportamento periódico após a passagem de água por um barramento, esse mesmo comportamento periódico não se manteve após a passagem pelo próximo barramento em nenhuma das verificações.

A respeito da análise da componente complexa das coerências *wavelet*, capaz de indicar as relações de atraso da resposta a padrões oscilatórios dos sinais de uma estação para outra, em geral, os ângulos das setas são relativamente constantes e na posição em fase, com algumas variações de ângulos sem significado físico ao longo de todas as escalas com periodicidades significativas. Dessa observação deduz-se, como esperado, a relação direta e constante entre as medições a montante e a jusante. Uma explicação para o predomínio da posição em fase sem

identificação de defasagens temporais são os pequenos valores das estimativas do tempo de resposta entre as sub-bacias, o que não permitiu indicar o atraso da propagação de ciclos de uma estação para outra, dada a discretização de vazões em escala diária.

Tendo em vista as análises realizadas até este momento, há fortes indícios de que as perturbações nos padrões cíclicos dos hidrogramas estejam associadas às operações de reservatório como um todo. Tais operações englobam o funcionamento das turbinas e as regularizações naturais de vazão, mesmo dos pequenos reservatórios. Salienta-se que esses fatores são normalmente ignorados nos procedimentos de licenciamento.

As observações capazes de identificar efeitos significativos entre os ciclos de vazão em diferentes estações levaram em conta principalmente o estudo dos hidrogramas. Contudo, sabe-se que características específicas – como o tamanho da bacia, a distribuição espacial da precipitação, do solo e da formação geológica – podem afetar os regimes naturais de vazão. Dessa forma, a fim de avaliar a componente “área da bacia” e identificar possíveis distúrbios em função da sua variação, foram realizadas análises de WPS e WCO com valores de vazões adimensionalizadas, ou seja, a partir de séries de vazões divididas pela área de drenagem de cada estação. Os resultados das WCO, apresentados no APÊNDICE A deste trabalho, apontaram que os padrões de WPS e WCO se mostraram quase idênticos, sugerindo que, pelo menos para este estudo, as perturbações no escoamento são insensíveis à variação da área da bacia. Além disso, outros possíveis fatores, como a distribuição das precipitações na BHJ e os componentes pedológicos e geológicos, não puderam ser profundamente analisados. No entanto, ao levar em conta a pequena dimensão da bacia em estudo, admite-se considerável grau de homogeneidade climatológica e fisiográfica, o que reduz a possibilidade de que os distúrbios nos hidrogramas sejam decorrentes dessas particularidades.

As observações das WPS mostrando a compatibilidade de padrões oscilatórios entre amostras de séries da estação fluviométrica Porto Espiridião em período anterior à construção dos AHs e amostras de séries da ST1 e da ST2, demonstrados no subitem 4.2.3.1, corroboram o argumento de que não são as propriedades fisiográficas da bacia as principais responsáveis pela modificação do comportamento dos ciclos de vazões.

De modo geral, o efeito perturbador nas vazões a jusante dos aproveitamentos hidrelétricos foi diagnosticado na maior parte dos estudos. Essa característica foi notada no domínio do tempo

e, mais acentuadamente, no domínio tempo-frequência por meio dos escalogramas. Resumidamente, as comparações da WCO permitiram identificar a seguinte escala de perturbação, na sequência da mais coerente para a menos coerente: ST1 x ST2 (inexistente); ST2 x ST3 (grau leve); ST6 x ST7 (grau moderado), ST5 x Jusante UHE Jauru (grau moderado/forte), Jusante UHE Jauru x ST6 (grau moderado/forte), ST3 x ST5 (grau moderado/forte) e ST7 x ST8 (grau forte). As propriedades dos AHs mais compatíveis com essa graduação de perturbações foram o tempo de residência, a área superficial do reservatório e o quociente entre a potência instalada e a área de superfície (MW/km²). Se tais observações forem confirmadas por estudos subsequentes, esses parecem ser importantes fatores a serem ponderados para outros licenciamentos ambientais e para o projeto de construções futuras.

Por fim, a capacidade instalada dos AHs aparentemente não atua de maneira direta no grau de alteração das periodicidades das vazões, já que a UHE Jauru não é o empreendimento que mais afeta os padrões cíclicos, e as PCH Salto e PCH Figueirópolis (as de menor potência instalada) não são as que menos perturbam. Vale pontuar que nos processos de licenciamento em geral, a potência instalada é o fator fundamental para estimar o grau de impacto do empreendimento, sendo essa a principal característica para classificação entre centrais geradoras hidrelétricas (CGH), PCHs e UHEs, e, portanto, definir o roteiro e a complexidade do licenciamento.

Tendo em vista os resultados obtidos na BHJ a respeito dos efeitos no comportamento de descarga em escala horária e diária, nos domínios do tempo e do tempo-frequência, fica premente a necessidade de maior conhecimento sobre o padrão de vazões de modo a evitar situações críticas não desejadas. Nesse contexto, na próxima fase do presente trabalho serão avaliadas técnicas de previsão de vazão com discretização horária registradas entre estações adjacentes, com variabilidades temporal e espacial, com vistas à construção de um sistema de alerta na bacia. Nesse processo, foi avaliada a possibilidade da decomposição de séries temporais integradas a esses modelos para auxiliar a interpretação dos ciclos observados. Conforme mencionado, foi dada maior importância às vazões mínimas, por ser assumida como uma das condições mais sensíveis na dinâmica da bacia.

4.3 Modelos de previsão de vazão

O presente tópico contém os resultados associados aos três últimos objetivos específicos desta pesquisa, os quais estão relacionados ao desenvolvimento de modelos de regressão para a previsão de séries temporais de vazões. Introdutoriamente, no item 4.3.1, são esclarecidas características específicas e genéricas sobre os dados utilizados nos modelos de regressão relacionadas à descrição, organização e processamento prévio à sua utilização. Além disso, serão mostrados os resultados das estatísticas descritivas e dos componentes gerados pela decomposição de sinais. Na sequência, os resultados são expostos em três itens distintos. No item 4.3.2, sobre a previsão de vazões entre séries de estações adjacentes, foi apresentado o desempenho dos melhores ajustes para os seis modelos de regressão (considerando os híbridos e os não híbridos), assumindo que a previsão tenha antecedência de uma hora. Ainda no item 4.3.2, maior enfoque foi dado a diversas características relacionadas aos ajustes dos modelos, abrangendo avaliações preliminares, adoções dos hiperparâmetros, métricas de desempenho para as fases de treino e teste e discussões acerca das melhores variáveis regressoras. Em seguida, ao adotar determinada configuração correspondente aos melhores ajustes para cada par de estações naquela primeira fase de previsões, tal padrão foi utilizado como orientação para o item seguinte (4.3.3), na aplicação do modelo de regressão visando a previsão entre séries considerando a variabilidade temporal. Por fim, essa experiência foi também aproveitada para o desenvolvimento de previsão de vazões sob a consideração da variabilidade espacial das estações telemétricas na bacia hidrográfica, disposto no item 4.3.4.

4.3.1 Descrição, organização e processamento dos dados para aplicação nos modelos de regressão

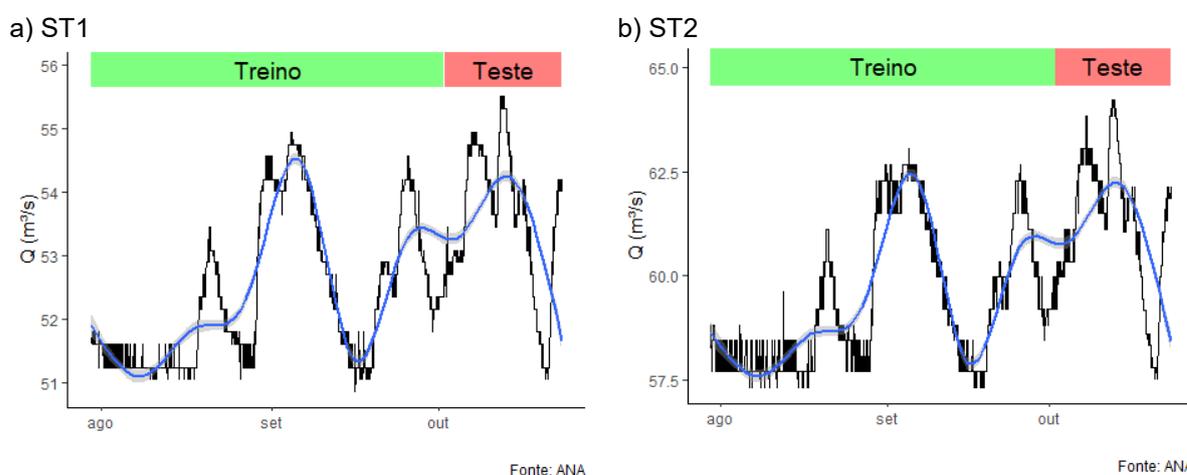
A série temporal horária extraída para verificação de previsão de vazões é a mesma em todos os modelos de regressão. Ela totaliza 2048 horas e está compreendida entre 30 jul 2016 às 04h e 23 out 2016 às 11h. Esses dados foram escolhidos pela limitação do período disponível de modo que fossem concomitantes entre as oito estações telemétricas da bacia hidrográfica.

Conforme descrito no item 4.2.1 – Descrição dos dados de vazão na BHJ, até janeiro de 2019, quando houve a conclusão da fase de levantamento de dados hidrológicos, tal período compreende uma das mais extensas séries horárias simultâneas entre as estações da BHJ. Além disso, como parte dos próprios argumentos para o desenvolvimento da atual pesquisa, essa série abrange o período de estiagem, compreendida como a de maior sensibilidade ecossistêmica no

que diz respeito à perturbação hídrica e aos efeitos de amortecimento do conjunto de reservatórios e turbinas.

A extensão da série, equivalente a 2048h, foi definida pelas condições da decomposição espectral via transformada *wavelet*, a qual exige que o número de dados seja potência de dois. Nessa circunstância: $2^{11} = 2048$, ou seja, a TWD gerará 11 séries de detalhes e uma série de aproximação no décimo primeiro nível, totalizando 12 subsinais. Por outro lado, a decomposição via EMD não possui limitação numérica de dados. Com efeito, dependendo das características das séries originais de vazão, a decomposição por EMD resultou em número de funções de modo intrínseco (*intrinsic mode function* - imf) entre seis e dez séries decompostas (imf1, imf2, ... , imf10). Outros detalhes a esse respeito serão discorridos nos itens seguintes.

Etapa semelhante a todos os modelos de previsão de séries temporais neste trabalho diz respeito ao processamento inicial da série de dados original, ou das suas combinações com sinais decompostos, para só então alimentar os modelos de regressão. O ajuste dos modelos foi baseado em uma variação da técnica de validação cruzada, com separação da série em dois segmentos, treino (75%) e teste (25%). Na Figura 4.29, para as estações de ST1 a ST8, os blocos verde e rosa são as delimitações dos trechos de treino e teste, a linha preta indica os dados horários e a linha azul revela suas suavizações por um modelo aditivo generalizado. Em síntese, o modelo aditivo generalizado consiste no ajuste empírico de um modelo linear cujos coeficientes de cada variável explicativa são substituídos por funções não-lineares, o que permite expressar as relações não-lineares entre as variáveis explicativa e resposta, demonstrando a série original de maneira suavizada.



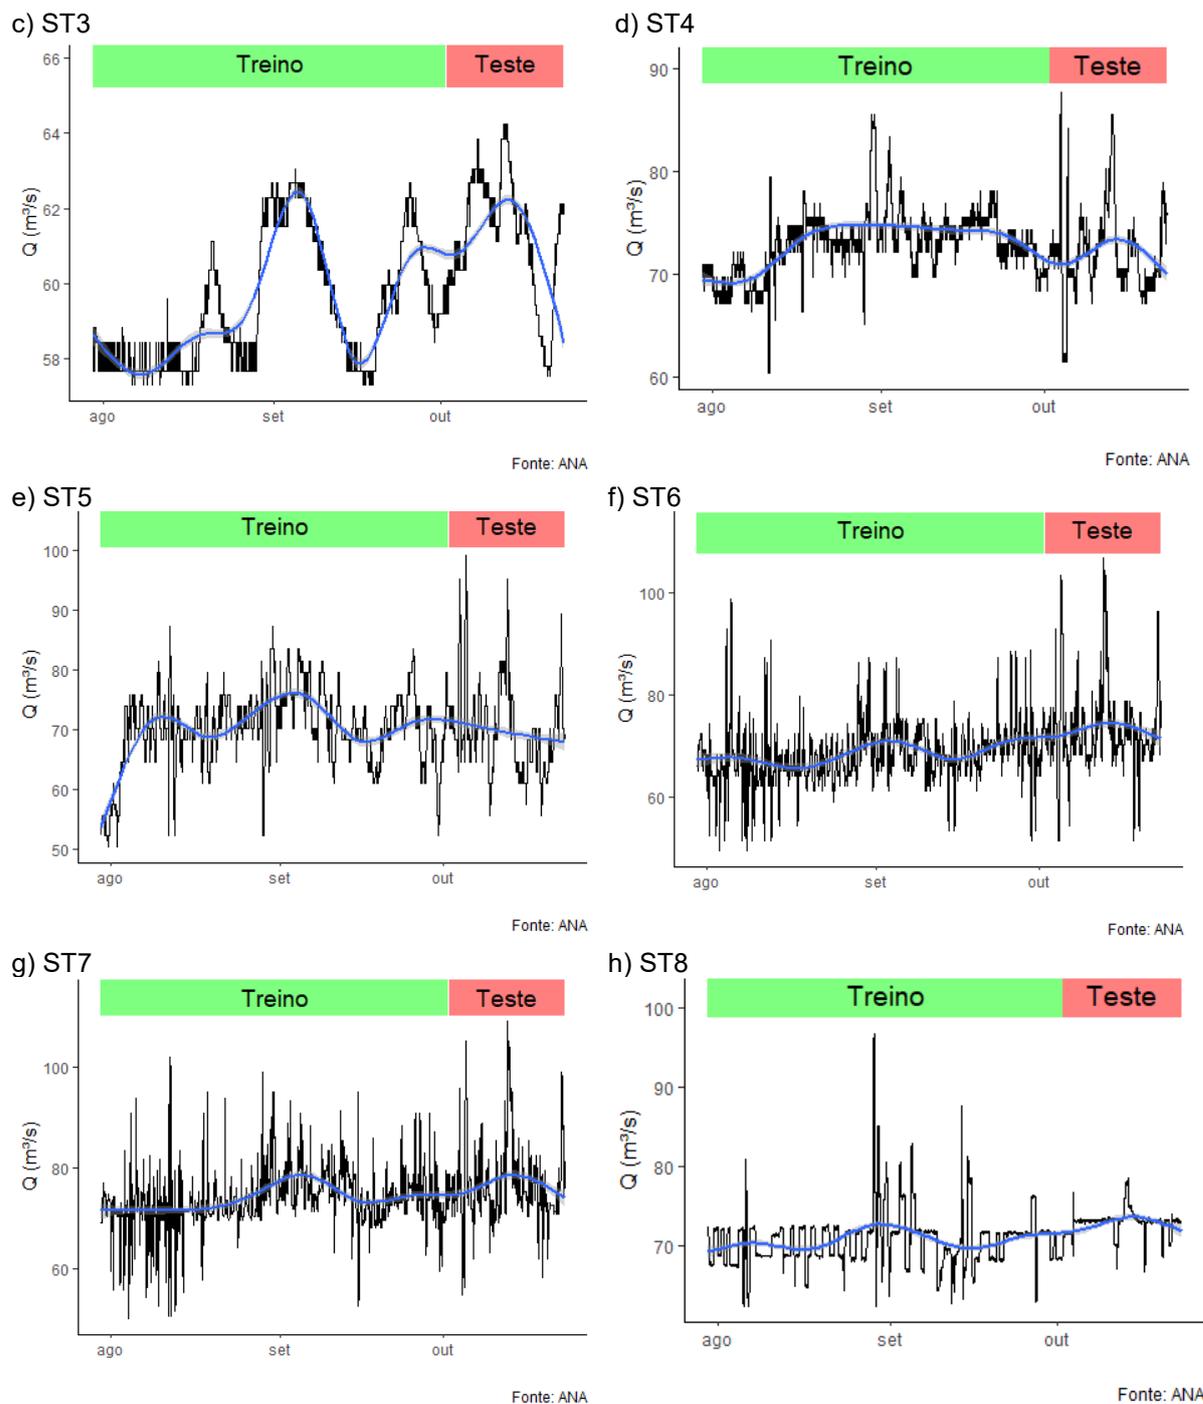


Figura 4.29: Séries temporais de vazão particionadas em treino e teste

Após realizada a segmentação das séries horárias em treino e teste, os quais comportaram, respectivamente, 1533h e 511h, algumas estatísticas descritivas para cada trecho puderam ser extraídas. Os resultados estão na Tabela 4.5.

Tabela 4.5: Estatísticas descritivas das séries horárias para os segmentos de treino e teste

Estação telemétrica	Série de treino			Série de teste		
	Média	Variância	Coefficiente de assimetria	Média	Variância	Coefficiente de assimetria
ST1	52,39	1,31	0,69	53,63	1,24	-0,43
ST2	59,36	2,74	0,65	61,24	2,65	-0,43
ST3	61,81	2,53	0,86	62,97	2,92	0,05
ST4	73,01	9,98	0,40	72,14	18,89	0,71
ST5	70,29	41,50	-0,58	70,11	56,06	1,10
ST6	68,55	34,58	0,83	73,45	68,43	1,23
ST7	73,81	33,01	0,36	76,80	64,73	1,16
ST8	70,70	13,67	2,98	73,04	2,05	-0,36

Como se verifica, regra geral, os valores possuem escalas proporcionais, quando contrastadas as séries de treino e teste no tocante às médias. Dois aspectos principais são mencionados: o primeiro é em relação à variância, que se manteve equivalente nas estações ST1, ST2, ST3 e ST5; mas foi aproximadamente dobrada nas estações ST4, ST6 e ST7; por fim, foi reduzida bruscamente na última estação. O último aspecto comparando os trechos de treino e teste é em relação ao coeficiente de assimetria, que indicou deslocamento da cauda do histograma da direita para a esquerda nas estações ST1, ST2 e ST8; e deslocamento da esquerda para a direita na ST5. Vale lembrar que, por mais que sejam aflúências e defluências de operações a fio d'água, esses dados estão sujeitos a intervenções do nível de reservatório, por meio de operações das pás móveis do rotor e das palhetas direcionadoras de escoamento nas turbinas. De fato, maiores diferenças ocorrem nas comparações entre as estações, o que evidencia que algumas séries, como ST5, ST6 e ST7, possuem variâncias muito maiores que as das demais estações. Entretanto, essa última questão foi abordada com ênfase no item 4.2.2 – Efeitos no domínio do tempo em escala horária.

Certamente, um modelo de previsão ajustado com séries de treino e teste cujas características estatísticas sejam semelhantes possui tendência a desempenhar melhores resultados. No entanto, em situações reais, como em séries com variabilidades sem compreensão exata do processo físico e com certa aleatoriedade em relação às operações de reservatório, de turbina e ocorrências climatológicas, tal prática não é sempre possível. Assim, capturar informações necessárias para realizar a regressão não-linear passa a ser um desafio do modelo de previsão.

A decomposição de séries temporais gerou diferentes componentes pelas técnicas da transformada *wavelet* discreta e decomposição por modos empíricos. Conforme mencionado, o número de subsinais gerados pela TWD é constante, e depende do número de dados. Dessa forma, visto que o sinal original possui 2048h, a TWD produziu 11 (2^{11}) séries de detalhe (D1, D2, ..., D10, D11) e uma série de aproximação (S11). A título de compreensão dessas componentes, que tendem à redução da frequência (suavização) conforme o nível de decomposição, a série original da estação ST2 e seus subsinais gerados pela TWD estão expostos na Figura 4.30.

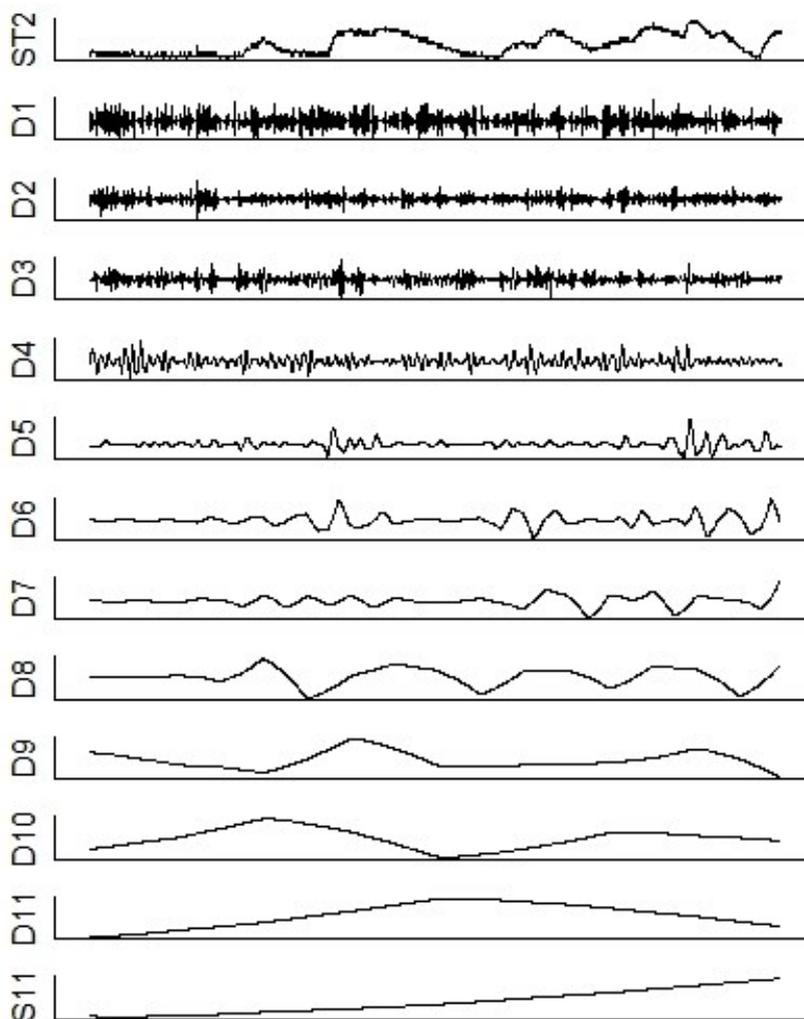


Figura 4.30: Série de vazões da ST2 e suas componentes espectrais por meio da TWD

O número de séries produzidas pela decomposição por EMD é variável, não sendo função direta do comprimento da série de dados original. Há maior dependência das características próprias dessas séries na geração das funções de modo intrínseco, produtos da EMD. Na Figura 4.31 são

mostrados a mesma série ST2 acompanhada pelas funções de modo intrínseco, que, nesse caso, somam 10 (imf1, imf2, ..., imf10). Assim como a TWD, quanto maior o número de decomposições na EMD, maior a sua suavização, resultando em sinais com menores frequências. As decomposições temporais promovidas pela TWD e pela EMD das séries ST1 a ST8 estão apresentadas no APÊNDICE B: Séries temporais decompostas por transformada *wavelet* discreta (TWD) e por decomposição em modos empíricos.

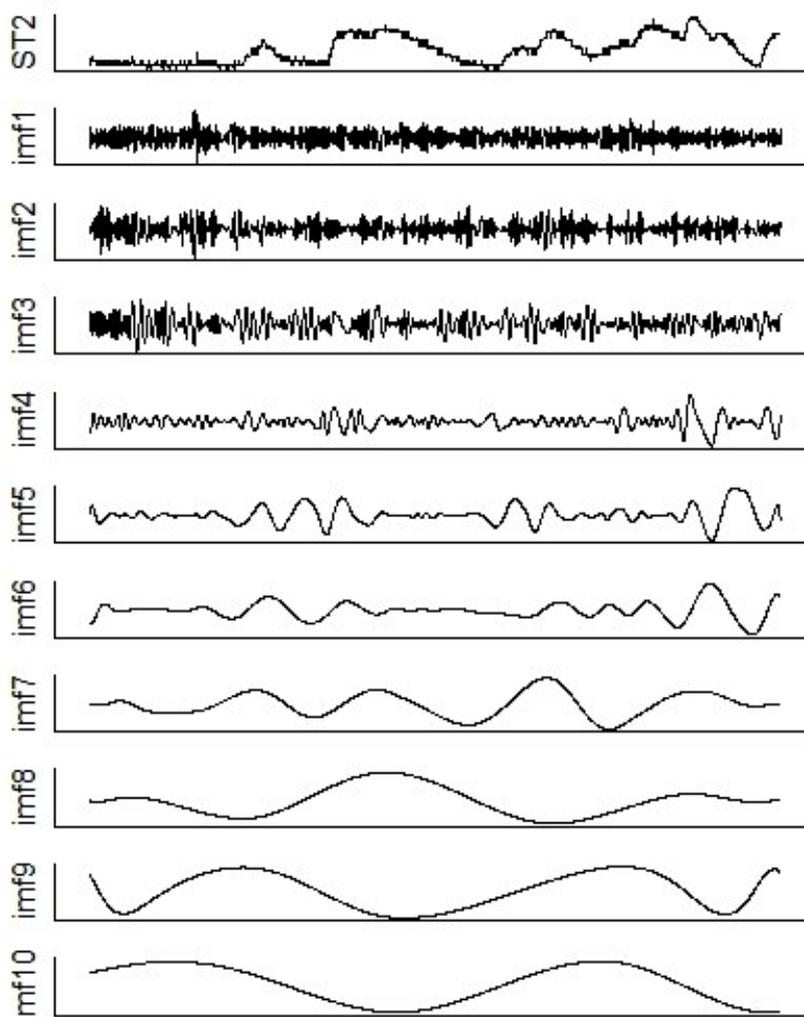


Figura 4.31: Série de vazões da ST2 e funções de modo intrínseco geradas pela EMD

Conforme explicado em assuntos específicos do tópico 3.2 – Decomposição de séries temporais para alimentação de modelos de previsão, as decomposições permitem o acesso a características não facilmente detectadas, como por exemplo a existência de periodicidades. Isso justifica as tentativas de pré-processamento usando as decomposições, de forma que sinais originais e subsinais possam ser combinados entre si para a alimentação do modelo de regressão.

As componentes geradas pelas decomposições (TWD e EMD) das séries de montante combinadas às séries originais com defasagem temporal das estações de jusante, portanto, sem decomposição (S/D), possibilitam vasta gama de entradas a serem avaliadas, de modo que suas combinações com as técnicas de aprendizado de máquina (RNA e RPG) torna possível a verificação de seis modelos de regressão não-lineares, conforme disposto na Tabela 4.6.

Tabela 4.6: Modelos de regressão

Modelo de regressão	Característica do modelo
TWD + RNA	Híbrido
EMD + RNA	Híbrido
S/D + RNA	Simples
TWD + RPG	Híbrido
EMD + RPG	Híbrido
S/D + RPG	Simples

Para a composição dos conjuntos das variáveis de entrada dos modelos de regressão, foram verificadas diversas combinações unicamente a partir de outras séries históricas de vazão, inclusive suas decomposições, caracterizando a previsão univariada. Como vantagem dessa prática, o modelo não requer qualquer outra informação sobre fatores relacionados ao processo físico dos AHs ou ainda séries hidroclimatológicas. Os conjuntos de preditores avaliados são compostos pelas combinações dos seguintes grupos:

- (i) série original de montante de cada par de estações, sem decomposição (S/D);
- (ii) decomposições TWD e EMD das séries de montante de cada par de estações;
- (iii) defasagens horárias das séries originais de jusante de cada par, relacionadas com a sua dependência, indicada pela função de autocorrelação parcial (PACF).

Face à grande quantidade de sinais disponíveis, três estratégias principais foram empregadas para orientar a seleção do melhor conjunto de preditores. A primeira delas foi a análise da PACF das séries originais de vazão, a qual auxiliou na identificação de defasagens horárias significativas. A segunda técnica foi a avaliação do grau de importância dos preditores utilizados na regressão, segundo Gevrey *et al.* (2003). A terceira estratégia foi utilizar os

resultados das métricas de avaliação nas fases de treino e teste para filtrar aquelas combinações que revelaram melhores desempenhos por meio de tentativa e erro.

No que tange ao primeiro item desses critérios, a Figura 4.32 ilustra as autocorrelações parciais, as quais indicam a relação de dependência horária das séries de treino. O intuito principal desse estudo é dar orientações para a inserção de variáveis predictoras com defasagem temporal das séries de jusante em cada par de estações.

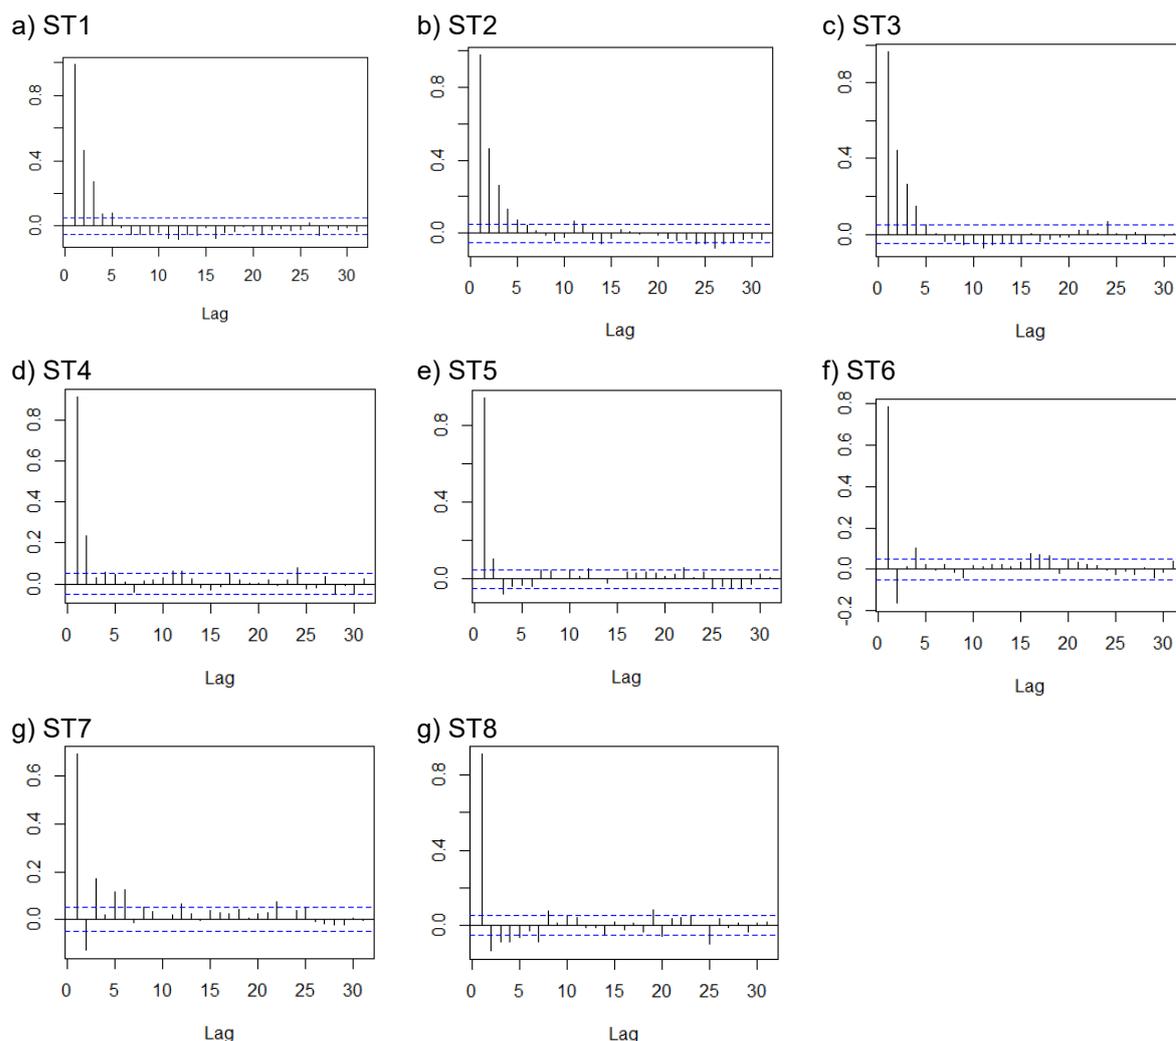


Figura 4.32: PACF das séries de vazão horárias do trecho de treino

A apreciação dos gráficos de PACF das séries de vazões horárias indica expressiva modificação no comportamento das relações de dependência quando comparadas as três primeiras séries de montante com as demais. Enquanto nas estações ST1, ST2 e ST3 as autocorrelações parciais se

mantém estatisticamente significativas até a defasagem temporal de quarta ordem, as dependências temporais são reduzidas para uma ou duas horas da estação ST4 em diante.

Para o aprimoramento do ajuste dos modelos de aprendizado de máquina, foi efetuada a validação cruzada em k -partições (ou *k-fold cross validation*), aplicada exclusivamente à série de treino. Essa prática permite melhor avaliar a capacidade de generalização do ajuste para um subconjunto de dados de maneira independente. Para tanto, o trecho de treino é subdividido em “ k ” subconjuntos, os quais são submetidos a um método de avaliação por k vezes. A cada validação, um desses k subconjuntos é avaliado, enquanto os demais “ $k-1$ ” subconjuntos são reunidos para compor a série de “subtreino” dessa validação. Logo, uma única repetição desse algoritmo permite que cada dado seja utilizado apenas uma vez para teste e $k-1$ vezes para validação. A critério do modelador, esse procedimento pode se repetir “ n ” vezes, multiplicando o número de subtreinos, o que reduz a variância dos resultados do treino.

A validação cruzada em k partições minimiza a influência de possíveis comportamentos atípicos da série de treino que possam prejudicar o ajuste inicial dos modelos. Ela também reduz possibilidades de superestimativas do treinamento (*overfitting*). No entanto, sua maior desvantagem é que, na fase de treino, a validação é executada um grande número ($k \times n$) de vezes, o que aumenta proporcionalmente o tempo de processamento computacional (SILVA *et al.*, 2016; ORD *et al.*, 2017; CHOLLET & ALLAIRE, 2018).

Na aplicação dos modelos neste trabalho, o ajuste foi realizado utilizando a validação cruzada com cinco partições ($k = 5$) e dez repetições ($n = 10$), totalizando 50 validações. Logo, são 50 conjuntos de hiperparâmetros e pesos. A definição de qual desses conjuntos será utilizado para a fase de teste é realizada por uma métrica matemática associada aos erros das “ $k \times n$ ” validações. Visto que o escopo da presente pesquisa está relacionado à previsão de vazões com enfoque para os valores mínimos, o critério de ajuste dessas $k \times n$ realizações foi o erro absoluto médio (*mean absolut error* – MAE), descrito no item 3.3.3 – Medidas de desempenho de modelos de previsão.

Dentro do contexto de processamento de dados, alguns modelos de aprendizado de máquina podem enfrentar problemas na assimilação de sua alimentação, especialmente se as séries abrangem ampla gama de valores, independentemente da existência de oscilações predominantes. Chollet & Allaire (2018) explanam que, frente a esses casos de comportamento

heterogêneo dos dados, o modelo pode capturar as informações necessárias com alguma eficiência, no entanto, fica suscetível a certas dificuldades durante a fase de treinamento. Portanto, uma prática comum em processamento de dados é a sua normalização. Ou seja, para cada valor dos dados de entrada, é realizada a sua subtração pela média desses valores, e seu resultado é ainda dividido pelo desvio padrão desses dados de entrada. Dessa forma, a série fica centrada em zero e possui desvio padrão unitário.

Alguns pesquisadores na área de modelagem de recursos hídricos que utilizam aprendizado de máquina têm observado a influência da padronização dos valores iniciais na sua implementação e suas consequências na obtenção dos resultados. Como exemplo, Napolitano *et al.* (2011) identificaram que as incertezas devido à aleatoriedade dos pesos iniciais aplicados a modelos híbridos de RNA + EMD pode atingir porcentagens médias entre 15% e 35%. Para evitar esse tipo de variação a fim de permitir comparação entre quaisquer modelos de previsão de vazão no presente trabalho, todos os valores necessários para inicialização dos modelos matemáticos foram fixados.

Tendo em vista a grande quantidade de possíveis combinações entre variáveis de entrada e as definições paramétricas, o processo iterativo para a obtenção da melhor combinação é relevante. Isso requer condições de parada de processo iterativo de forma adequada. Portanto, todos os modelos possuem critérios de parada configurados para que ela ocorra assim que o erro de treinamento alcance um valor suficientemente pequeno. Quando não for o caso, a condição de parada foi configurada para ocorrer após 1000 iterações.

Sabe-se que programas computacionais são desenvolvidos em geral para serem executados de modo que uma instrução seja realizada na sequência da outra. Como alternativa, existe a possibilidade de execução paralela desses cálculos, o que consiste na divisão das tarefas de uma aplicação entre os vários núcleos (*cores*) do processador. Com o objetivo de reduzir o tempo de processamento computacional em razão do esforço exigido para o cálculo dos modelos, optou-se por uma ferramenta que permitisse realizar a computação paralela durante o cálculo. Visto que processadores de uso doméstico possuem normalmente de quatro a seis núcleos, para a implementação dos modelos de previsão utilizados no presente trabalho, o código computacional foi configurado para que sejam executados três núcleos em simultâneo.

No tocante às medidas de performance utilizadas nos modelos de previsão, durante a fase de avaliação, maior importância foi dada aos valores mínimos, uma vez que o efeito amortecedor dos reservatórios tende a ser mais expressivo durante a estiagem. Por esse motivo, a ordem de prioridade entre os critérios de desempenho para a escolha dos melhores modelos neste trabalho foi a seguinte: i) Coeficiente de Nash-Sutcliffe calculado com vazões invertidas (NSEiQ); ii) erro absoluto médio (MAE); e iii) coeficiente de determinação (R^2). O NSEiQ e o MAE receberam maior destaque nessa sequência por conferirem sensibilidade aos valores de menor magnitude do hidrograma, conforme verificado por Dawson *et al.* (2007) e Pushpalatha *et al.* (2012). Além disso, o NSEiQ se mostra insensível a valores máximos das séries, concentrando, de fato, sua avaliação sobre os mínimos.

A fim de referenciar o modelador, alguns índices padrão podem ser assumidos para as métricas de dimensões relativas, como o NSEiQ e o R^2 . Desse modo, na presente pesquisa, foi admitido que um modelo cujos índices apresentem valores de NSEiQ e R^2 entre 0,8 e 1,0 a previsão temporal é de boa qualidade; enquanto valores abaixo de 0,8 até 0,5 significam previsão de razoável qualidade; e valores abaixo de 0,5 indicam que os modelos avaliados não foram capazes de reproduzir os dados observados com satisfação.

4.3.2 Previsão de vazão entre séries de estações adjacentes

Anteriormente à aplicação aos modelos de máquinas de aprendizado propostos neste trabalho, foi verificada a viabilidade da previsão de vazão por meio de técnicas reconhecidas como *baseline* na previsão de séries temporais, em especial os modelos ARIMA, acrônimo de *Autoregressive Integrated Moving Average* (BOX & JENKINS, 1970). De forma sucinta, esses modelos se baseiam em obtenção relativamente simples de coeficientes que respondem pela regressão das variáveis sobre ela mesma (componente autorregressivo); erros de regressão a partir de informações cujos valores ocorreram no momento presente e em outros momentos de passos anteriores (componente de média móvel); e um processo que indica a diferença entre seus valores e os valores anteriores (componente integrado). No entanto, o emprego desses modelos *baseline*, retornou métricas de desempenho muito ruins em todas as verificações. Além disso, em quase todas as simulações, os valores dos resíduos permaneceram com algum grau de dependência entre si, o que não é adequado.

Foram identificados três fatores principais que contribuíram para esses resultados. O primeiro deles é a característica não-estacionária dos dados de vazão, pressuposto frequentemente desejado para aplicação dos modelos ARIMA (ORD *et al.*, 2017; HYNDMAN & ATHANASOPOULOS, 2018). O segundo fator está relacionado à longa extensão a ser prevista (512h), equivalente à série de teste, ou seja, 25% do total dos dados extraídos. Nesse sentido, as previsões com modelo ARIMA são comumente realizadas com adiantamento temporal para curto prazo de previsão, limitado a algumas dezenas de passos adiante. Assim, os primeiros passos da previsão se aproximam dos dados observados, no entanto, essa característica não é mantida, e os dados previstos tendem a se estabilizar em torno da média (HYNDMAN & ATHANASOPOULOS, 2018). Um terceiro fator para o mal desempenho dos modelos ARIMA está relacionado à discretização temporal horária das séries de vazão. Esses modelos possuem dificuldade para reproduzir séries com elevado grau de oscilação, parte em função da estabilização das respostas em torno da média. Acrescenta-se que a possibilidade de inexistência de fortes periodicidades de curto prazo, como a diária, tenha prejudicado as detecções dos melhores parâmetros do modelo. Os motivos expostos justificam o emprego de técnicas mais complexas para previsão de séries temporais, tais como os modelos de aprendizado de máquina utilizados no presente trabalho.

Anteriormente à implementação dos modelos RNA e RPG, foram necessárias avaliações preliminares para determinar suas configurações gerais e definitivas. No caso da RNA, essas definições dizem respeito às funções de ativação nas camadas intermediárias e de saída, arquitetura e topologia da rede. Na RPG, as principais avaliações preliminares estão relacionadas à função *kernel*. As definições para a aplicação dos modelos estão mostradas na Tabela 4.7.

Tabela 4.7: Configurações gerais dos modelos de regressão

Modelos RNA	
Função de ativação na camada intermediária	Logística
Função de ativação na camada	Linear
Arquitetura	<i>Feedforward</i> com camadas múltiplas
Topologia	Uma camada de entrada, uma intermediária e uma de saída
Modelos RPG	
Função <i>kernel</i>	Exponencial quadrática

Particularmente às RNA, as funções de ativação mais aplicadas são a função logística na camada intermediária e a linear na camada de saída. Essa foi a conformação utilizada no presente trabalho, após realizados testes com as seguintes funções de ativação na camada intermediária: logística, tangente hiperbólica, Gaussiana e linear (descritas na Tabela 3.1).

A arquitetura implementada para as RNA foi a do tipo *feedforward* (com alimentação à frente) de camadas múltiplas. Essa estrutura é a mais utilizada para modelos de regressão não-linear, e tem sido comumente aplicada a séries geofísicas (NAPOLITANO *et al.*, 2011; ADAMOWSKI *et al.*, 2012; ZHANG *et al.*, 2018).

Ainda na fase de avaliação preliminar do modelo de RNA, foram verificadas diversas topologias, com o fim principal de analisar a influência da inserção de uma ou mais camadas intermediárias. Com esse exercício, foi constatado que adicionar algumas camadas intermediárias, mesmo que com um ou poucos nós nessas camadas, resultou no efeito de *overfitting*, visto serem observadas diversas situações com aparente bom ajuste na fase de treino e não correspondência na fase de teste. Além disso, a adição de mais de uma camada intermediária ocasionou aumento expressivo no tempo do processamento computacional. Por essa razão, apenas uma camada intermediária foi utilizada.

Em relação à fase de treinamento da RNA, fixadas as condições explanadas acima, os hiperparâmetros buscados a cada simulação se resumiram a dois: número adequado de nós na camada intermediária e coeficiente de decaimento dos pesos sinápticos, denominado “*decay*”. Os dois objetivos principais do *decay* são auxiliar o processo de otimização dos pesos sinápticos e reduzir o efeito de *overfitting*. Essa busca foi realizada por um algoritmo capaz de ler e avaliar uma grade de valores combinados de nós intermediários e de coeficientes *decay*. Inicialmente, a grade de hiperparâmetros foi composta pela combinação de um vetor com os seguintes valores de números de nós na camada intermediária: 1, 2, 3 e 4; e outro vetor com eventuais valores de *decay*: $5 \cdot 10^{-4}$, $1 \cdot 10^{-3}$, $5 \cdot 10^{-3}$, $1 \cdot 10^{-2}$, $5 \cdot 10^{-2}$, $1 \cdot 10^{-1}$, $2 \cdot 10^{-1}$, $5 \cdot 10^{-1}$. Isso resultou em 28 diferentes pares de hiperparâmetros.

No que compete exclusivamente à implementação da RPG, uma das suas características básicas está relacionada à definição de qual função *kernel* melhor representa as variáveis submetidas à regressão. Com efeito, foram realizadas verificações preliminares com as seguintes funções *kernel* (dispostas na Tabela 3.2): linear, Laplaciana, exponencial quadrática e Matérn. Essa

análise permitiu constatar que a função *kernel* exponencial quadrática é a mais adequada para ajuste dos modelos de previsão de vazão na BHJ. Além de algumas aplicações que associam essa função *kernel* com modelos de previsão para séries em recursos hídricos (RASOULI *et al.*, 2012; SUN *et al.*, 2014), a função exponencial quadrática é tipicamente utilizada quando não há muito conhecimento prévio a respeito do comportamento dos dados (KARATZOGLOU *et al.*, 2019).

Também denominada “função de base radial”, a função exponencial quadrática, requer o ajuste do hiperparâmetro “ σ ”, ou *sigma*, associado à largura da função Gaussiana. Para tanto, foi construída uma grade de hiperparâmetros com possíveis valores a serem ajustados na fase de treinamento. Visto que a função *kernel* exponencial quadrática exige somente esse ajuste de σ , a grade foi composta por um único vetor com eventuais valores: 1.10^{-3} ; 5.10^{-3} ; 1.10^{-2} ; 5.10^{-2} ; 1.10^{-1} e 5.10^{-1} .

Conforme mencionado, em todos os casos verificados no presente item, a regressão foi implementada considerando como meta a ser atingida o adiantamento de uma hora dos dados de vazão. Logo, todas as variáveis de entrada, incluindo as séries decompostas, possuem defasagem de uma hora, exceto aquelas séries das estações de jusante com *lags* horários maiores. Esse prazo horário foi assim admitido por ser a menor escala da série temporal disponível. Outras antecipações temporais foram avaliadas em item específico.

As tabelas e gráficos seguintes consistem nos resultados das melhores combinações paramétricas com o conjunto das variáveis regressoras mais representativas. As informações indicam os valores das métricas de desempenho para cada caso e suas representações visuais por meio de hidrogramas observado e calculados, bem como informações sobre a dispersão dos erros. Para tanto, foi obedecida a sequência do posicionamento das estações no percurso fluvial. A hierarquia de importância para definição dos melhores resultados foi a seguinte: i) maior NSEiQ; ii) menor MAE; iii) maior coeficiente de determinação R^2 ; iv) menor número de preditores; e v) menor número de nós na camada intermediária (exclusivo para a RNA).

4.3.2.1 Estações ST1-ST2

O interstício entre as estações ST1-ST2 não possui qualquer interferência de aproveitamentos hidrelétricos. A distância desse percurso é de apenas 4,6km e a área incremental é de 8km² (vide Tabela 4.2). Pela grande proximidade espacial e também pela minimização das interferências

antrópicas e hidroclimatológicas, é esperado que esse par de estações apresente o melhor desempenho de previsão em relação aos demais pares.

Na Tabela 4.8 estão os resultados do melhor ajuste de cada modelo RNA para a previsão da série da estação ST2 com base primordialmente na alimentação da série ST1, representado por “ST1-ST2”. Nessa tabela, as colunas TWD, EMD e S/D se referem aos três modelos verificados, dois com decomposição temporal (modelos híbridos) e um sem decomposição. A topologia expressa a configuração dos nós nas camadas neurais. Por exemplo, a topologia “3.1.1” denota que o melhor ajuste ocorreu ao inserir três séries como preditores, com um nó na camada intermediária e um nó na camada de saída. Por fim, *decay* indica o valor do coeficiente de decaimento obtido com esse melhor ajuste. Os pesos sinápticos de cada neurônio não são mostrados, por não trazerem contribuição interpretativa.

Tabela 4.8: Conjunto de melhores ajustes e métricas de desempenho (RNA ST1-ST2)

(RNA) ST1-ST2						
Decomposição	TWD		EMD		S/D	
Fase	Treino	Teste	Treino	Teste	Treino	Teste
NSEiQ	0.97	0.96	0.97	0.96	0.97	0.96
MAE	0.22	0.24	0.22	0.24	0.22	0.24
R ²	0.97	0.97	0.97	0.97	0.97	0.97
Topologia	3.1.1		5.1.1		3.1.1	
Decay	0.01		0.005		0.01	
Entradas	ST1 + ST2_lag1 + D1		ST1 + ST2_lag1 + ST2_lag2 + imf1 + imf2		ST1 + ST2_lag1 + ST2_lag2	

Como se nota, os valores das métricas foram idênticos para os três modelos, expressando bom desempenho tanto na série de treino quanto na de teste. Entende-se que as condições favoráveis para a previsão das séries tenham promovido esse efeito. No entanto, para tal realização, foram obtidas diferentes configurações paramétricas. Especialmente no modelo RNA + EMD, além de maior número de variáveis de entrada, o valor do *decay* foi diferente dos demais modelos. Além disso, os três modelos RNA apresentaram o melhor ajuste com apenas um nó na camada intermediária. Foram observados efeitos de *overfitting* quando acrescentados outros nós. No que compete à seleção das variáveis regressoras, para os dois modelos híbridos, as componentes que resultaram em melhor ajuste foram aquelas de maior frequência, ou seja, D1 para o modelo RNA + TWD, e imf1 + imf2 para o modelo RNA + EMD. Outra observação é que os três

modelos tiraram proveito do sinal original da estação de montante (ST1). Por fim, também os três modelos revelaram boas correspondências com as defasagens temporais, sendo de uma hora, para o RNA + TWD e de duas horas para o RNA + EMD e o RNA + S/D.

Na Tabela 4.9 estão as informações referentes aos melhores ajustes para cada um dos modelos RPG para o par de estações ST1-ST2.

Tabela 4.9: Conjunto de melhores ajustes e métricas de desempenho (RPG ST1-ST2)

(RPG) ST1-ST2						
Decomposição	TWD		EMD		S/D	
Fase	Treino	Teste	Treino	Teste	Treino	Teste
NSEiQ	0.96	0.96	0.96	0.96	0.96	0.96
MAE	0.24	0.25	0.24	0.25	0.24	0.26
R²	0.96	0.97	0.96	0.97	0.96	0.97
<i>Sigma</i>	0.005		0.005		0.005	
Entradas	ST1 + ST2_lag1 + ST2_lag2 + D1		ST1 + ST2_lag1 + ST2_lag2 + imf1 + imf2		ST1 + ST2_lag1 + ST2_lag2	

Assim como os modelos RNA, as métricas de desempenho na aplicação com os modelos RPG retornaram praticamente os mesmos valores entre si e com elevada performance na previsão de vazões. De alguma maneira, essa semelhança de valores com bons resultados nos seis modelos indica uma saturação na realização dessas previsões. Aparentemente, qualquer das aplicações utilizadas traria boas reproduções da série de teste. De maneira geral, foi notado que mesmo os ajustes com outras configurações para *sigma* e variáveis de entrada (não apresentados neste trabalho), os valores de NSEiQ foram quase sempre superiores a 0,90. Interessante notar que o valor de *sigma* admitido para os três modelos RPG foi o mesmo, equivalente a 0,005. Além disso, os sinais decompostos resultarem nos melhores ajustes tanto para RPG quanto para RNA sugere coerência para a importância das menores frequências. Ou seja, ambos fizeram uso da componente D1 para os modelos com TWD e das componentes imf1 + imf2 para os modelos com EMD.

Visto que a performance dos seis modelos foi muito semelhante no que diz respeito às métricas, o RPG + S/D foi considerado o de melhor ajuste por duas razões: dispensa o uso de sinais decompostos, o que significa maior simplicidade na sua implementação; e padronização do único ajuste paramétrico ($\sigma = 0,005$).

Desse modo, na Figura 4.33 é visualizado o resultado do modelo RPG + S/D para a previsão de ST2. No painel superior estão as séries de vazões originais ST2 (linha preta), acompanhadas das séries de treino (linha verde) e teste (pontos vermelhos). No painel inferior à esquerda está o gráfico de dispersão dos erros da previsão, enquanto no painel inferior à direita está o gráfico de pontos que compara as séries de vazões observadas e previstas no trecho de teste.

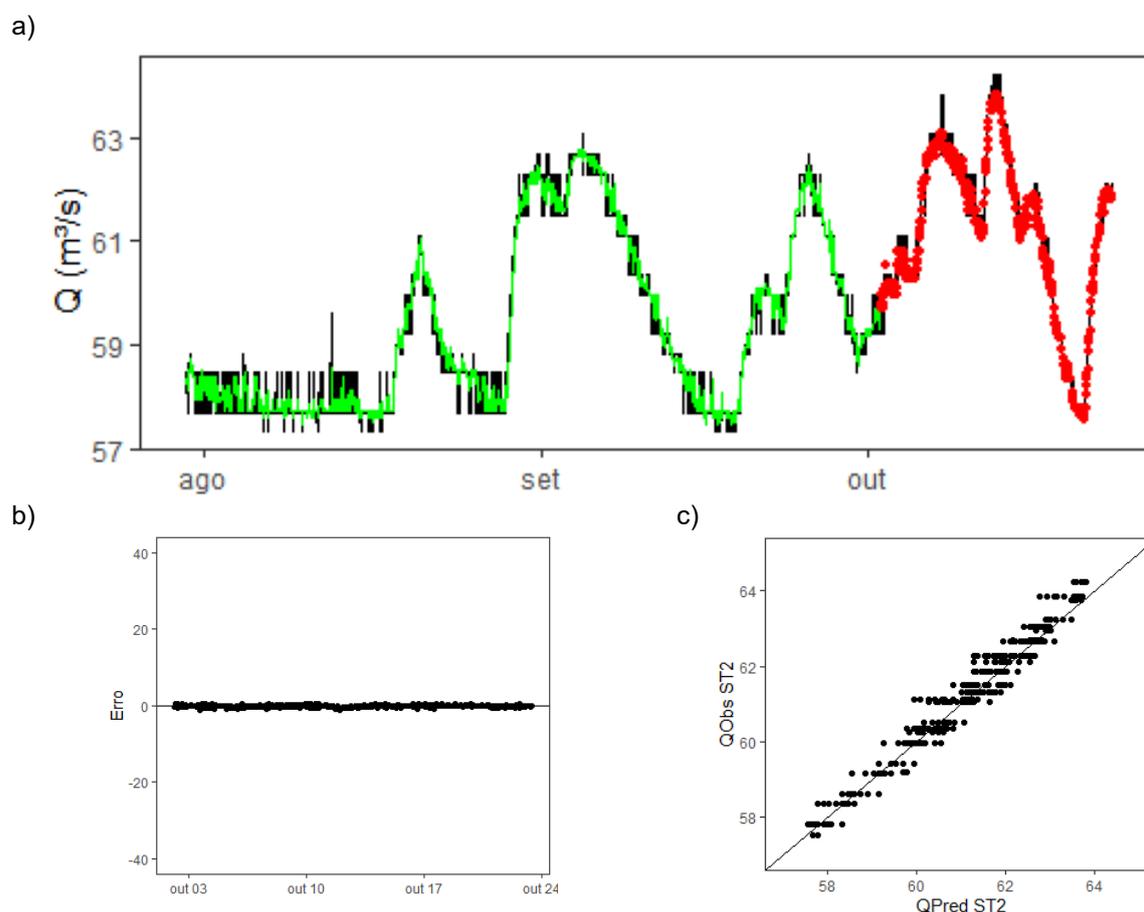


Figura 4.33: Resultados da previsão ST1-ST2 (RPG + S/D): a) Hidrogramas observado e calculados; b) Dispersão dos erros; c) Gráfico entre as vazões observadas e previstas

As imagens mostram, como esperado, boa correspondência entre os valores observados e calculados, com alguma dificuldade para capturar as oscilações na série de treino, no início de agosto, e em dois picos máximos na série de teste. Por outro lado, os valores mínimos foram bem representados. O desvio do primeiro quartil entre as vazões observada e calculada foi de 0,10 m³/s, enquanto diferença entre o valor mínimo observado e estimado foi de 0,13m³/s, o que representa erro de 0,22%.

4.3.2.2 Estações ST2-ST3

A Tabela 4.10 apresenta os resultados numéricos da previsão ST2-ST3 para os modelos RNA, onde no segmento fluvial intermediário está em operação a PCH Antônio Brennand. A distância entre essas estações é a menor entre todos os pares estudados (2,6km), com bacia de contribuição lateral de 86km².

Tabela 4.10: Conjunto de melhores ajustes e métricas de desempenho (RNA ST2-ST3)

(RNA) ST2-ST3						
Decomposição	TWD		EMD		S/D	
Fase	Treino	Teste	Treino	Teste	Treino	Teste
NSEiQ	0.94	0.94	0.94	0.94	0.94	0.95
MAE	0.24	0.25	0.25	0.25	0.25	0.25
R²	0.95	0.95	0.94	0.95	0.94	0.95
Topologia	5.3.1		5.1.1		3.1.1	
Decay	0.005		0.005		0.005	
Entradas	ST2 + ST3_lag1 + ST3_lag2 + D6 + D9		ST2 + ST3_lag1 + ST3_lag2 + imf9 + imf10		ST2 + ST3_lag1 + ST3_lag2	

Semelhante ao caso anterior, os resultados das métricas de desempenho indicam bom desempenho de previsão dos três modelos, com ligeira melhor estimativa com RNA + S/D. Ainda assim, na previsão de ST3, não foram encontradas diferenças expressivas quando são adicionadas decomposições das vazões. Os melhores coeficientes de decaimento tiveram o mesmo valor para os três modelos RNA, igual a 0,005. Diferentemente do par de estações anterior, o melhor ajuste para o modelo RNA + TWD exigiu o uso de três nós na camada intermediária, ao passo que nos outros dois modelos isso ocorreu com apenas um nó. No que tange às variáveis regressoras utilizadas para o ajuste, é notado que, dessa vez, os componentes que melhor representaram a previsão possuem de média a baixa frequência, no caso da RNA + TWD foram os subsinais D6 + D9; enquanto na RNA + EMD foram os subsinais imf9 + imf10. Essa observação diverge com a do par ST1-ST2, cuja melhor representação foi aquela com as maiores frequências. Isso sugere a ocorrência de alguma alteração nos comportamentos da frequência dos sinais de vazão, quando comparado com a série natural, registrada a extremo montante da bacia. Apesar dessa característica, ao longo do ajuste, foi notado que mesmo a inserção de outras componentes, incluindo as de maior frequência, em geral, os valores das métricas de desempenho se mantiveram elevados.

Na Tabela 4.11 estão os resultados numéricos da previsão do mesmo par de estações ST2-ST3, agora para os modelos RPG.

Tabela 4.11: Conjunto de melhores ajustes e métricas de desempenho (RPG ST2-ST3)

(RPG) ST2-ST3						
Decomposição	TWD		EMD		S/D	
Fase	Treino	Teste	Treino	Teste	Treino	Teste
NSEiQ	0.93	0.93	0.93	0.93	0.93	0.93
MAE	0.29	0.30	0.29	0.29	0.29	0.30
R²	0.94	0.93	0.94	0.93	0.93	0.93
<i>Sigma</i>	0.005		0.005		0.005	
Entradas	ST2 + ST3_lag1 + ST3_lag2 + D1		ST2 + ST3_lag1 + ST3_lag2 + imf4		ST2 + ST3_lag1 + ST3_lag2	

As métricas de desempenho obtidas nos três modelos RPG indicaram condições adequadas de reprodução da série de teste. Seus valores foram semelhantes entre si, não representando melhora relevante com o acréscimo de subsinais de vazão. O modelo RNA apresentou discreta melhor condição de reprodução das vazões em comparação com o RPG, visto que suas diferenças são observadas na escala centesimal de cada métrica. Esse padrão inclui o MAE, que possui maior sensibilidade, por possuir dimensões absolutas, ao invés de relativas. Todos os valores de *sigma* repetiram o padrão identificado na previsão do par de estações anterior, equivalente a 0,005. Em relação às variáveis regressoras, os melhores ajustes fizeram uso, além das séries da estação de montante e das defasagens temporais com até duas horas da estação de jusante, de componentes de média a alta frequência, diferentemente da previsão por RNA. Esse padrão é padrão similar ao detectado na previsão do par de estações ST1-ST2 com os modelos híbridos RPG.

Visto que o RNA + S/D atingiu valor de NSEiQ pouco melhor que os demais modelos, na Figura 4.34 são mostradas as séries observada e calculada, bem como a dispersão dos erros das estimativas, considerando sua melhor configuração. Por ela, é notado que apesar de haver alguma dificuldade para a previsão dos extremos máximos e mínimos, o modelo conseguiu reproduzir o comportamento do hidrograma observado. Vale pontuar que a diferença entre o primeiro quartil das vazões observada e calculada foi nulo, e que a subtração entre as duas vazões mínimas é de 1,00m³/s, equivalente a 1,69%.

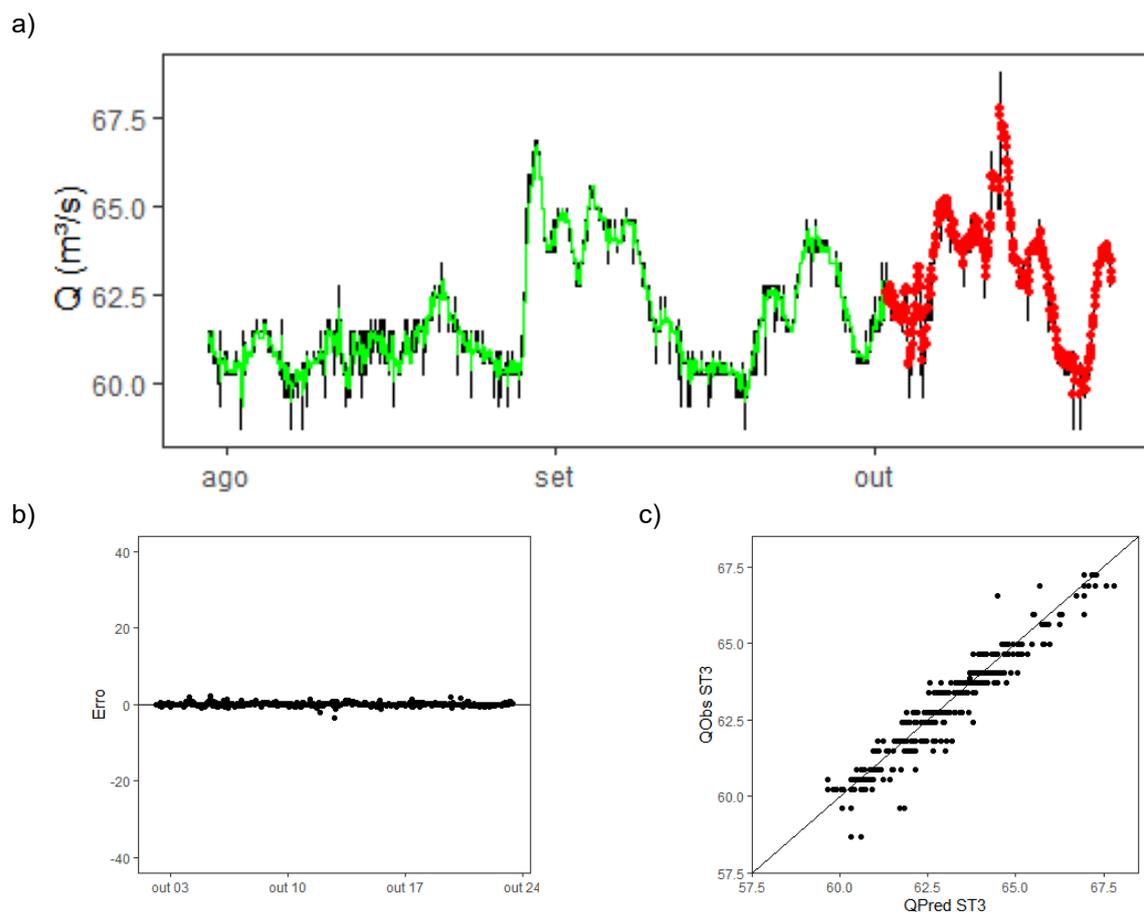


Figura 4.34: Resultados da previsão ST2-ST3 (RNA + S/D): a) Hidrogramas observado e calculados; b) Dispersão dos erros; c) Gráfico entre as vazões observadas e previstas

Nos pares de estações de montante da bacia, ST1-ST2 e ST2-ST3, não houve grande diferença na melhora dos ajustes com ou sem decomposição das séries temporais, de modo que valores de NSEiQ, MAE e R^2 foram muito semelhantes. Por um lado, era esperado que os ciclos naturais fossem ser de fácil identificação na modelagem, o que seria ratificado com o emprego das decomposições, resultando em melhores ajustes. Por outro lado, nesses dois pares, acredita-se que se torna quase indiferente melhorar as métricas de desempenho dos ajustes elevados (por exemplo, com $NSEiQ > 0,90$, erros do primeiro quartil nulos e erros mínimos absolutos na ordem de $1\text{m}^3/\text{s}$), ao serem ou não empregadas técnicas de decomposição.

4.3.2.3 Estações ST3-ST4

No trecho entre as estações ST3-ST4 é operada a PCH Ombreiras, que possui reservatório com a terceira maior área de alagamento. A distância entre essas estações é de 13km e a área incremental é de 215km². A Tabela 4.12 mostra os valores das métricas de desempenho referentes ao melhor conjunto paramétrico e de variáveis regressoras obtidos para a previsão desse par de séries, com o uso dos modelos RNA.

Tabela 4.12: Conjunto de melhores ajustes e métricas de desempenho (RNA ST3-ST4)

(RNA) ST3-ST4						
Decomposição	TWD		EMD		S/D	
	Treino	Teste	Treino	Teste	Treino	Teste
NSEiQ	0.81	0.80	0.82	0.81	0.89	0.78
MAE	0.98	1.31	0.89	1.34	0.85	1.32
R ²	0.83	0.81	0.83	0.81	0.83	0.79
Topologia	4.1.1		3.1.1		2.1.1	
Decay	0.5		0.5		0.2	
Entradas	ST3 + ST4_lag1 + D10 + D11		ST3 + ST4_lag1 + imf3 + imf10		ST3 + ST4_lag1	

Como se nota por meio das métricas de desempenho do modelo, a qualidade da previsão no trecho ST3-ST4 esteve no limiar entre bom e regular. Pelos índices estabelecidos para este trabalho, os modelos RNA híbridos se mantiveram com métricas relativas acima de 0,80, portanto, com boa reprodução das vazões observadas, o que não ocorreu com o modelo simples. Nesse par de estações, houve diferença entre os valores de *decay* entre os modelos com decomposição (0,5) e sem decomposição (0,2). Esses valores foram bem maiores que nos pares anteriores. Nas três situações, os melhores ajustes ocorreram com um nó na camada intermediária. Houve diferença no padrão dos subsinais, visto que no RNA + TWD, além da série de vazões de montante e da série de jusante com defasagem temporal horária, o melhor ajuste requereu a inserção de dois componentes espectrais de baixa frequência (D10 + D11); enquanto no modelo RNA + EMD, essas componentes foram uma de alta e uma de baixa frequência (imf3 + imf10). Pela análise das métricas de desempenho, o RNA + EMD indicou ser o melhor modelo, em razão, principalmente, do valor obtido com o NSEiQ.

A Tabela 4.13 mostra a configuração do ajuste para ST3-ST4 com os modelos RPG.

Tabela 4.13: Conjunto de melhores ajustes e métricas de desempenho (RPG ST3-ST4)

(RPG) ST3-ST4						
Decomposição	TWD		EMD		S/D	
Fase	Treino	Teste	Treino	Teste	Treino	Teste
NSEiQ	0.75	0.80	0.75	0.79	0.74	0.78
MAE	1.06	1.32	1.06	1.33	1.05	1.34
R ²	0.77	0.82	0.77	0.82	0.76	0.80
<i>Sigma</i>	0.005		0.005		0.005	
Entradas	ST3 + ST4_lag1 + D3 + D4		ST3 + ST4_lag1 + imf3 + imf4		ST3 + ST4_lag1	

Semelhante ao ajuste com RNA, os melhores modelos RPG se mantiveram na fronteira do índice que considera a boa e a regular qualidade da previsão de vazões. No entanto, dessa vez, a melhor performance utilizando a TWD foi mais evidente, quando comparado ao conjunto das métricas. Os valores de *sigma* repetiram o melhor ajuste com 0,005. Quanto às entradas dos modelos híbridos, os subsinais de maior frequência foram novamente os mais representativos na reprodução da série temporal. Essa observação se mostra interessante, quando a intenção é estabelecer padrões gerais para a reprodução dos modelos de regressão não-lineares. Comparando o desempenho dos modelos RNA + EMD e RPG + TWD, foi notado que apesar dos melhores valores de NSEiQ serem atingidos com as redes neurais artificiais, os Processos Gaussianos foram capazes reproduzir as vazões extremas mínimas e máximas com ténue melhor qualidade. Esse fato põe em questão qual modelo realmente melhor reproduziu as séries de teste. É possível que tal aspecto seja explicado pela compensação das métricas MAE e R² de RPG +TWD terem melhor performance.

Na Figura 4.35 estão os hidrogramas observado e calculados do modelo RNA + EMD, expostos em paralelo com a plotagem das informações sobre a dispersão dos resultados da série de teste, relativos à previsão das estações ST3-ST4.

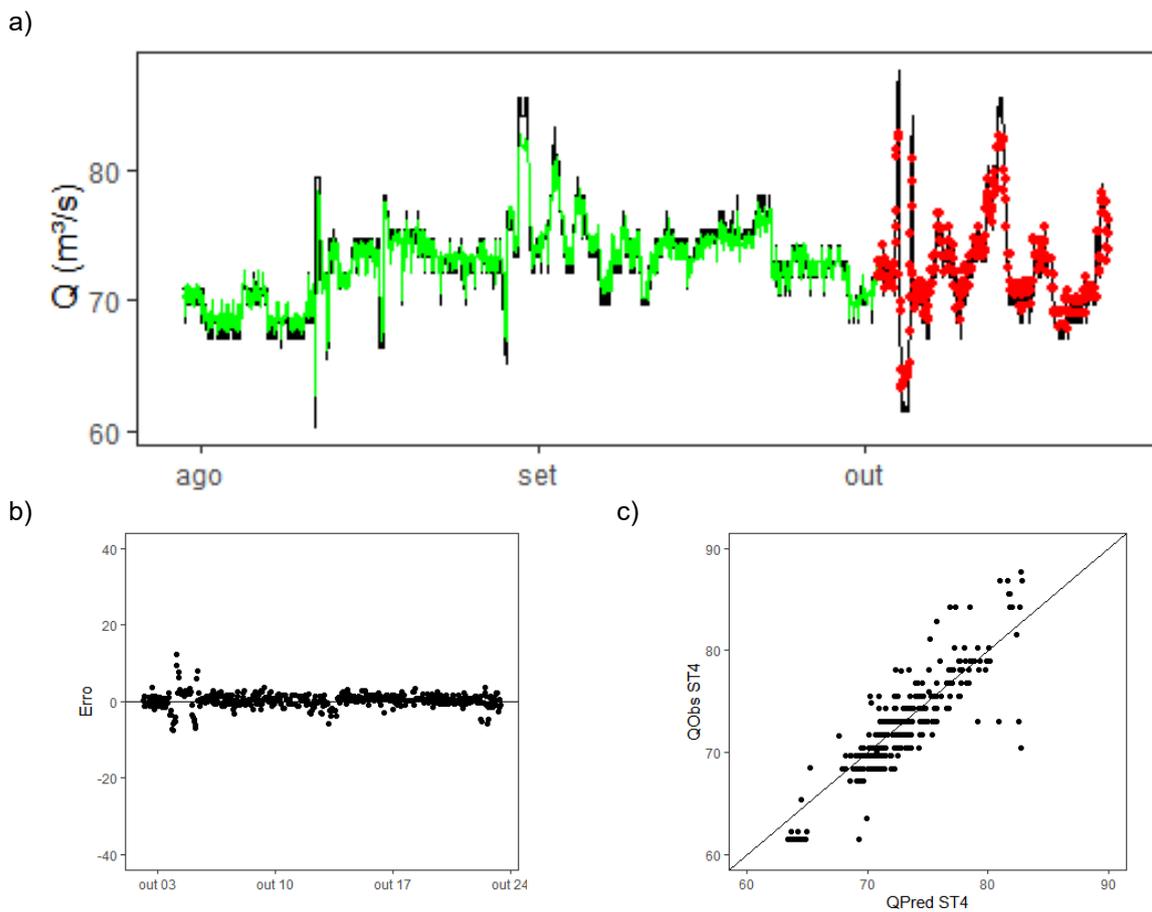


Figura 4.35: Resultados da previsão ST3-ST4 (RNA + EMD): a) Hidrogramas observado e calculados; b) Dispersão dos erros; c) Gráfico entre as vazões observadas e previstas

Pelas imagens, são verificadas algumas oscilações bruscas nos dois trechos da série observada e que, nesses curtos momentos, houve certa dificuldade na representação da previsão. Além disso, é também enfatizado o aprendizado geral do modelo no que se refere ao comportamento das curvas de ascensão e recessão do hidrograma. Diferentemente dos dois pares de estações anteriores, no ST3-ST4 o ajuste da melhor combinação paramétrica e do melhor conjunto de variáveis de entrada logrou efeito frente às tentativas de ajuste (não apresentadas neste trabalho), as quais, muitas vezes, revelaram capacidade de previsão razoavelmente inferior que a exibida aqui. No que compete ao alcance dos mínimos, o desvio absoluto dessas vazões foi de $1,85\text{m}^3/\text{s}$, com erro na estimativa do valor mínimo correspondente a $2,92\%$. A diferença entre o primeiro quartil entre as vazões observada e calculada foi de $0,60\text{m}^3/\text{s}$.

4.3.2.4 Estações ST4-ST5

No segmento fluvial entre as estações ST4 e ST5 não existe aproveitamento hidrelétrico em operação. Esse trecho consiste em uma estação de monitoramento de jusante da PCH Ombreiras e de outra estação para monitoramento da afluição do reservatório da UHE Jauru. Conforme mencionado, embora seja uma usina a fio d'água, há mecanização nas operações de nível com periodicidade diária no reservatório, que é o de segunda maior área alagada na bacia. Esse fato possivelmente influencia o padrão de vazões da ST5, visto que o comportamento desse hidrograma é consideravelmente distinto da ST4. A extensão entre as estações é de 4km e a bacia incremental é de 50km². Expostas essas observações, a Tabela 4.14 mostra os conjuntos que indicaram os melhores ajustes para o par ST4-ST5 com o uso do modelo RNA.

Tabela 4.14: Conjunto de melhores ajustes e métricas de desempenho (RNA ST4-ST5)

(RNA) ST4-ST5						
Decomposição	TWD		EMD		S/D	
	Treino	Teste	Treino	Teste	Treino	Teste
NSEiQ	0.90	0.82	0.90	0.82	0.90	0.82
MAE	1.45	2.18	1.49	2.15	1.48	2.17
R ²	0.90	0.80	0.89	0.82	0.90	0.81
Topologia	4.1.1		4.1.1		4.1.1	
Decay	0.05		0.005		0.05	
Entradas	ST4 + ST5_lag1 + ST5_lag2 + D3		ST4 + ST5_lag1 + imf2 + imf3		ST4 + ST5_lag1 + ST5_lag2 + ST5_lag3	

Os resultados das métricas apontam desempenho muito parecido entre os três modelos, visto que todos eles reproduziram as séries de vazão com boa qualidade. O valor do hiperparâmetro *decay* do modelo RNA + EMD (igual a 0,005) foi diferente dos outros dois (equivalente a 0,05). Os três modelos requisitaram apenas um nó na camada intermediária. Para esse ajuste, tanto RNA + TWD quanto RNA + EMD utilizaram subsinais de elevada frequência. Ao comparar os valores das métricas das séries de treino e teste para os três modelos, há indícios de *overfitting*, pois, entre uma e outra fase, houve considerável queda de NSEiQ e R², assim como elevação do MAE.

Na Tabela 4.15 estão expostos os conjuntos que indicaram os melhores ajustes do par ST4-ST5 com modelos RPG.

Tabela 4.15: Conjunto de melhores ajustes e métricas de desempenho (RPG ST4-ST5)

(RPG) ST4-ST5						
Decomposição	TWD		EMD		S/D	
Fase	Treino	Teste	Treino	Teste	Treino	Teste
NSEiQ	0.84	0.83	0.90	0.83	0.90	0.83
MAE	1.87	2.14	1.13	2.20	1.13	2.20
R ²	0.85	0.82	0.89	0.81	0.89	0.81
<i>Sigma</i>	0.005		0.005		0.005	
Entradas	ST4 + ST5_lag1 + D3 + D4		ST4 + ST5_lag1 + imf2 + imf3		ST4 + ST5_lag1	

De maneira geral, as métricas obtidas com RPG apresentaram leve melhor desempenho que os modelos RNA, especialmente se o enfoque for no NSEiQ. Exclusivamente entre os modelos híbridos, os subsinais utilizados para os melhores ajustes foram compatíveis com os utilizados no RNA, ou seja, aqueles de baixa frequência. Novamente, os melhores ajustes para todos os modelos RPG ocorreram com a admissão de *sigma* equivalente a 0,005. Ao comparar a performance dos três modelos RPG, é pontuada a grande semelhança na capacidade de reprodução da série de teste, com destaque para os menores valores obtidos com o MAE no modelo RPG + TWD. Com efeito, esse foi o modelo interpretado como o de melhor qualidade para ser exposto na Figura 4.36. A visualização desses gráficos permite constatar a boa reprodução das vazões observadas, especialmente no atendimento aos valores mínimos, em detrimento da boa interpretação dos valores máximos. Ainda com enfoque nas mínimas, a subtração entre o primeiro quartil das vazões observada e calculada é equivalente a 0,40m³/s, e a diferença das mínimas é de 1,11m³/s, ou seja, erro de 1,95%.

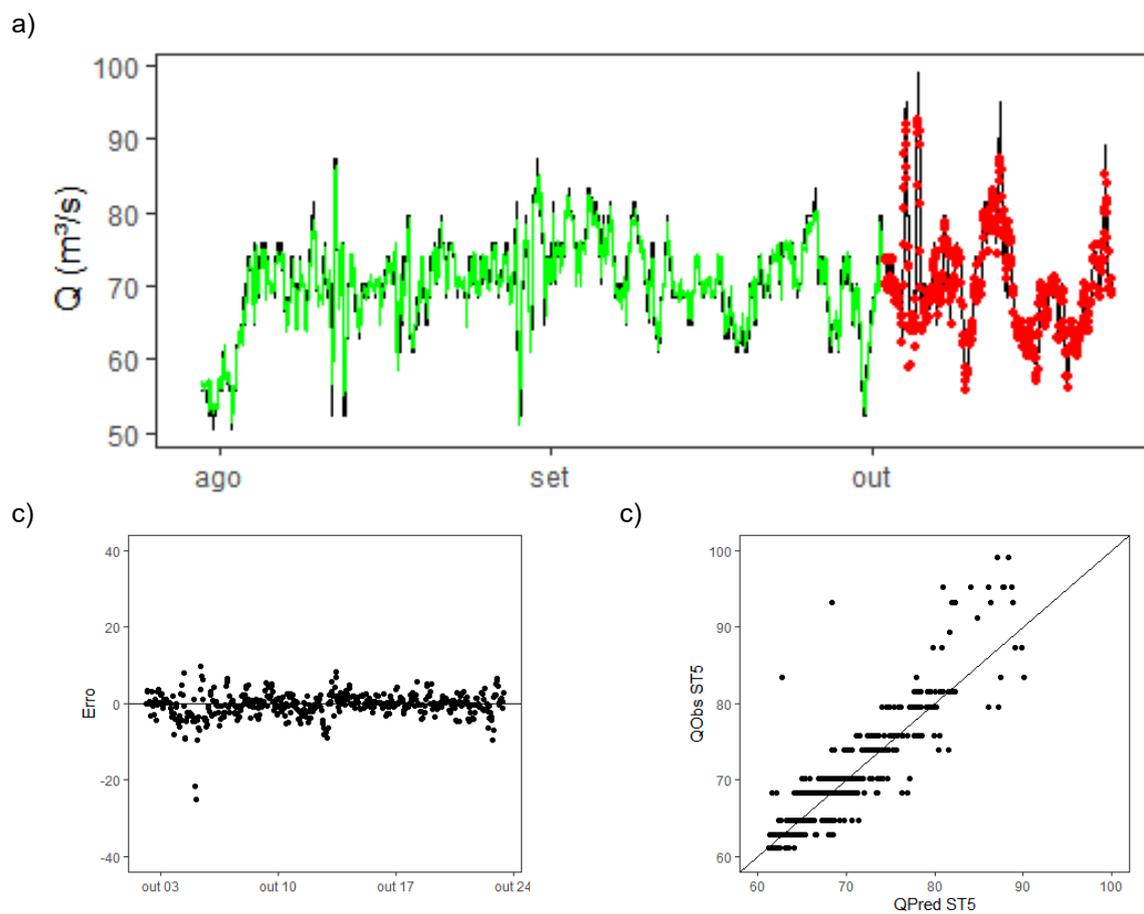


Figura 4.36: Resultados da previsão ST4-ST5 (RPG + TWD): a) Hidrogramas observado e calculados; b) Dispersão dos erros; c) Gráfico entre as vazões observadas e previstas

4.3.2.5 Estações ST5-ST6

Entre o percurso fluvial ST5-ST6, há dois aproveitamentos hidrelétricos em operação: a UHE Jauru e a PCH Indiavaí, não havendo estação telemétrica com registros horários cujos dados estejam disponíveis nesse trecho intermediário. A distância entre ST5-ST6 é de 14,3km, e sua contribuição lateral é de 90km². Na Tabela 4.16 estão expostos os valores das métricas de desempenho e as condições de ajuste para o par ST5-ST6, com modelos RNA.

Tabela 4.16: Conjunto de melhores ajustes e métricas de desempenho (RNA ST5-ST6)

(RNA) ST5-ST6						
Decomposição	TWD		EMD		S/D	
Fase	Treino	Teste	Treino	Teste	Treino	Teste
NSEiQ	0.51	0.50	0.52	0.51	0.54	0.52
MAE	2.60	3.81	2.54	3.83	2.50	3.72
R²	0.57	0.59	0.60	0.61	0.61	0.61
Topologia	5.3.1		4.3.1		3.4.1	
Decay	0.05		0.05		0.5	
Entradas	ST5 + ST6_lag1 + D3 + D4 + D5		ST5 + ST6_lag1 + imf6		ST5 + ST6_lag1	

No segmento ST5-ST6 os modelos de previsão de vazão apresentaram o pior desempenho entre as simulações realizadas. Particularmente em relação à métrica NSEiQ, seu valor esteve no limiar entre a incapacidade de reprodução dos valores observados e a reprodução com qualidade regular, conforme os índices estabelecidos neste trabalho. É interessante notar que no melhor ajuste entre as tentativas, foi necessária maior quantidade de nós na camada intermediária quando comparada com as previsões de outras séries, sendo três nós intermediários nos modelos híbridos e quatro nós no modelo simples. Já os valores de *decay* se mostraram entre 0,05 para os modelos híbridos e 0,5 para o modelo simples. Diferentemente das outras previsões, as entradas dos modelos híbridos fizeram uso de subsinais de baixa a média frequência, sendo o D3 + D4 + D5 no modelo RNA + TWD e o imf6 no modelo RNA + EMD.

No que diz respeito aos modelos RPG, na Tabela 4.17 estão expostos os valores das métricas de desempenho e as condições de ajuste para o par de estações ST5-ST6.

Tabela 4.17: Conjunto de melhores ajustes e métricas de desempenho (RPG ST5-ST6)

(RPG) ST5-ST6						
Decomposição	TWD		EMD		S/D	
Fase	Treino	Teste	Treino	Teste	Treino	Teste
NSEiQ	0.30	0.49	0.31	0.49	0.29	0.48
MAE	3.24	4.00	3.24	4.04	3.26	4.08
R²	0.34	0.64	0.35	0.64	0.34	0.63
Sigma	0.005		0.005		0.005	
Entradas	ST5 + ST6_lag1 + D7 + D10		ST5 + ST6_lag1 + imf6		ST5 + ST6_lag1	

Os resultados dos três modelos RPG se mostraram ligeiramente inferiores aos ajustes dos modelos RNA, o que, com base no NSEiQ, foi suficiente para defini-los como incapazes de reprodução das vazões da estação ST6. Essa definição não se enquadra caso a análise seja feita por meio do R^2 , relacionado à dispersão dos valores, visto que os três modelos RPG retornaram coeficientes de determinação superiores aos modelos RNA. Em relação ao *sigma*, outra vez seus valores permaneceram iguais a 0,005, sugerindo algum padrão para o ajuste. Assim como nos modelos híbridos RNA, as variáveis regressoras dos modelos híbridos RPG tenderam a ser de média a alta frequência, sendo o D7 + D10 no RPG + TWD e, novamente, o imf6 no modelo RPG + EMD.

No que tange à má qualidade da reprodução de vazões da série de teste, vale retomar que, de acordo com estudos anteriores a respeito dos padrões de vazão na BHJ, a série ST6 está entre aquelas que indicaram maior alteração no seu comportamento, demonstrando aumento expressivo de oscilações (item 4.2.2), reduzida coerência nas periodicidades em relação à estação de montante (item 4.2.3) e baixa relação de dependência com a própria série, conforme análise das PACF.

Ainda que apresentando regular desempenho na previsão do par ST5-ST6, a qual se concentrou em atingir os valores médios do hidrograma e com considerável dispersão dos erros, o modelo RNA + S/D foi o que melhor se ajustou. Sua representação visual está na Figura 4.37.

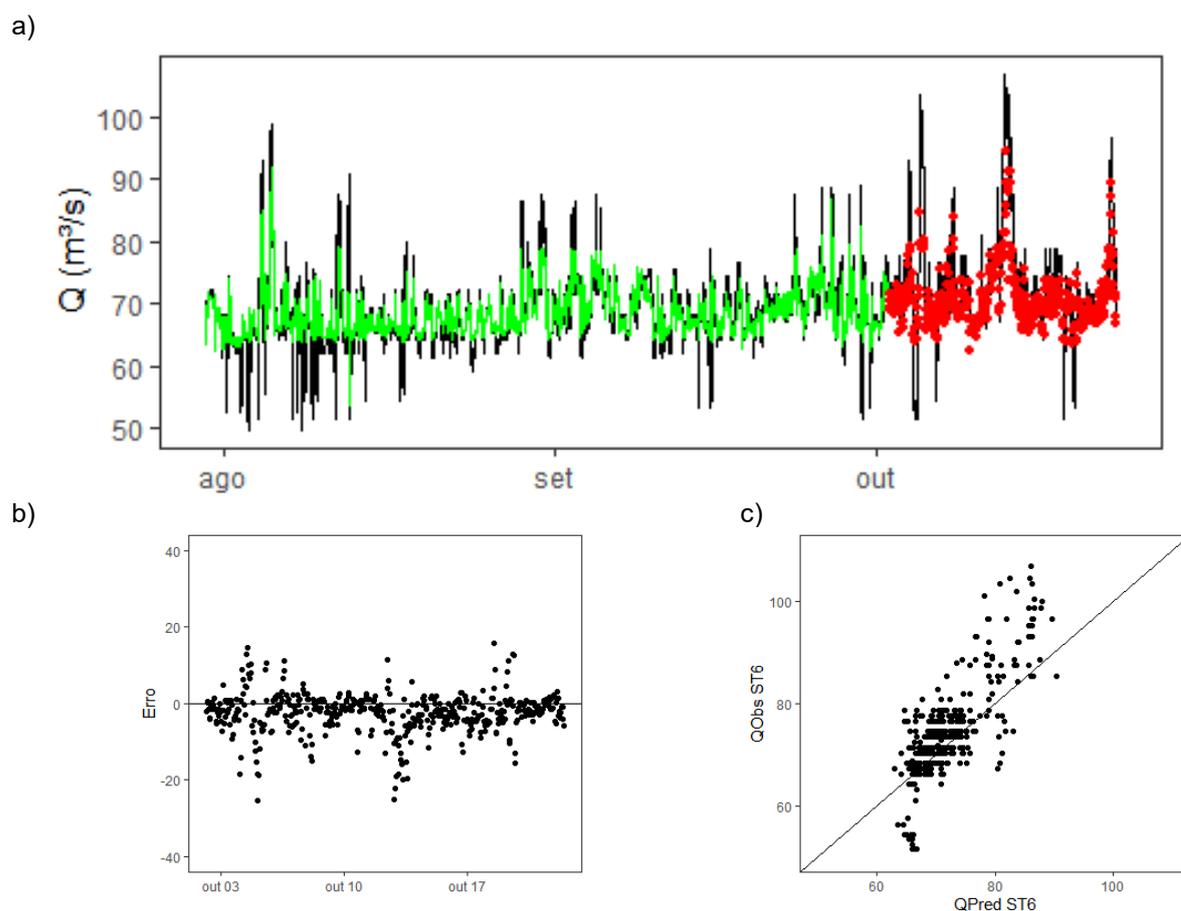


Figura 4.37: Resultados da previsão ST5-ST6 (RNA + S/D): a) Hidrogramas observado e calculados; b) Dispersão dos erros; c) Gráfico entre as vazões observadas e previstas

Com esse modelo RNA + S/D, o primeiro quartil da vazão observada subtraído do primeiro quartil da vazão estimada foi de $0,10\text{m}^3/\text{s}$; enquanto a diferença dos extremos mínimos foi de $11,53\text{m}^3/\text{s}$, o que representa erro de 18,29%. O desvio entre os primeiros quartis em relação aos valores mínimos denota a baixa qualidade da reprodução dos menores valores, com concentração da previsão no entorno dos valores médios.

4.3.2.6 Estações ST6-ST7

No trecho intermediário às estações ST6-ST7 é operada a PCH Salto. A distância entre essas estações é de 4km e a bacia de contribuição lateral tem área de 33km^2 . Na Tabela 4.18 constam as informações do conjunto paramétrico, variáveis regressoras e as métricas de desempenho para a previsão dos melhores ajustes dos modelos RNA.

Tabela 4.18: Conjunto de melhores ajustes e métricas de desempenho (RNA ST6-ST7)

(RNA) ST6-ST7						
Decomposição	TWD		EMD		S/D	
Fase	Treino	Teste	Treino	Teste	Treino	Teste
NSEiQ	0.50	0.64	0.49	0.62	0.48	0.64
MAE	2.76	3.12	2.78	3.22	2.48	3.00
R ²	0.51	0.72	0.50	0.70	0.52	0.73
Topologia	5.1.1		5.1.1		4.4.1	
Decay	0.005		0.05		0.5	
Entradas	ST6 + ST7_lag1 + ST7_lag2 + D2 + D10		ST6 + ST7_lag1 + ST7_lag2 + imf2 + imf4 + imf7		ST6 + ST7_lag1 + ST7_lag2 + ST7_lag3	

De acordo com os índices assumidos para as métricas no presente trabalho, esses três modelos de previsão representaram as vazões observadas com razoável qualidade, expressando-as melhor que a previsão do par de estações anterior. Comparando as métricas de desempenho entre os modelos, seus valores se encontram na mesma escala, sendo que o RNA + S/D foi tenuamente superior em relação aos modelos híbridos. O coeficiente de decaimento para cada ajuste retornou três valores diferentes, ou seja, 0,005 no RNA + TWD, 0,05 no RNA + EMD e 0,5 no RNA + S/D. Em relação ao número de nós intermediários, os modelos híbridos tiveram seus melhores ajustes quando a topologia é composta por um único nó na camada intermediária, ao passo que o modelo simples necessitou de maior complexidade, com 4 nós intermediários. Em relação ao melhor conjunto de variáveis regressoras dos modelos híbridos, não foi identificado um padrão correspondente à frequência dos subsinais utilizados, pois houve uso de séries decompostas de alta, média e baixa frequência. Foi notado ainda que em todos os modelos o uso de séries com defasagem temporal da estação de jusante se demonstrou importante, com até duas horas nos modelos híbridos e até 3h no modelo simples. De forma geral, tendo como base o número de nós envolvidos, os modelos RNA para o par de estações ST5-ST6 e ST6-ST7 são os que exigiram maior complexidade estrutural, visto que necessitaram de maiores quantidades de nós intermediários e de variáveis regressoras. Esse aspecto pode estar relacionado à dificuldade na captura e reprodução das informações da série.

Os resultados referentes aos ajustes dos modelos RPG estão na Tabela 4.19.

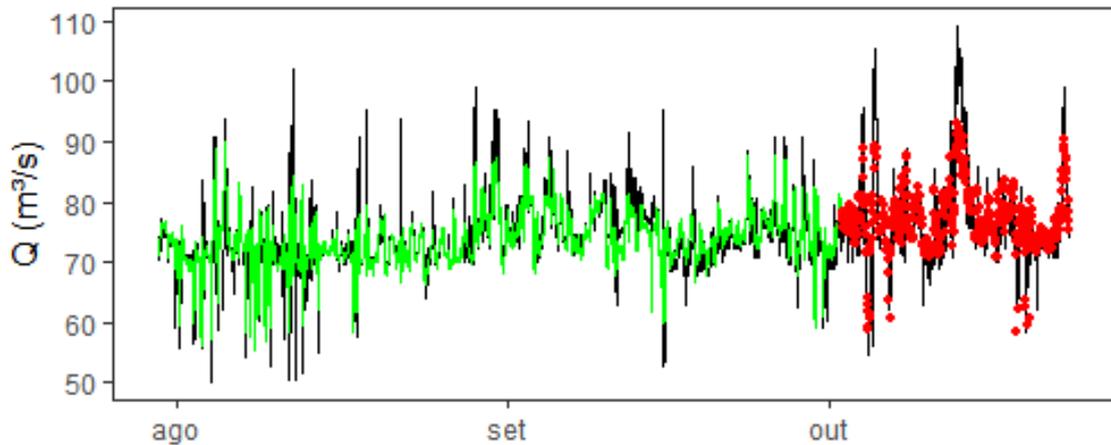
Tabela 4.19: Conjunto de melhores ajustes e métricas de desempenho (RPG ST6-ST7)

(RPG) ST6-ST7						
Decomposição	TWD		EMD		S/D	
	Treino	Teste	Treino	Teste	Treino	Teste
NSEiQ	0.55	0.66	0.51	0.65	0.57	0.65
MAE	2.55	2.99	2.58	3.00	2.47	2.99
R ²	0.55	0.75	0.53	0.74	0.58	0.75
<i>Sigma</i>	0.005		0.005		0.005	
Entradas	ST6 + ST7_lag1 + D1 + D3		ST6 + ST7_lag1 + imfl		ST6 + ST7_lag1	

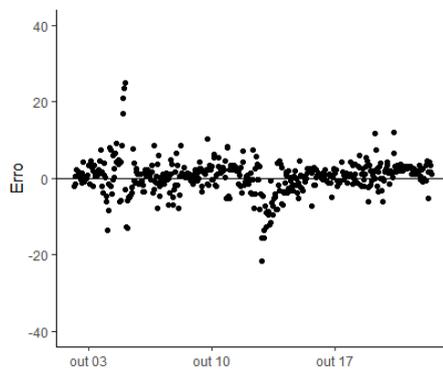
Os resultados alcançados com os modelos RPG foram um pouco superiores aos com os modelos RNA em quase todas as métricas analisadas, no entanto, o desempenho dessa previsão também se manteve com qualidade regular. A comparação entre esses três modelos RPG fez constatar que o RPG + TWD e o RPG + S/D apresentaram performance praticamente idêntica, com exceção de uma casa centesimal na métrica NSEiQ, favorável ao RPG + TWD, o que torna discutível qual desses modelos é mais adequado, tendo em vista que o modelo simples não requer decomposição de sinais. Concernente ao hiperparâmetro *sigma*, todos os modelos foram melhor ajustados quando seu valor é 0,005, repetindo o padrão analisado até esse ponto. Em relação às variáveis regressoras, ao contrário do ajuste com os modelos RNA, além de serem utilizadas séries com menores defasagens temporais, houve alguma identificação com os subsinais de alta frequência, com o D1 + D3 no RPG + TWD e o imfl no RPG + EMD.

A visualização do ajuste do modelo RPG + TWD com os hidrogramas observado e calculados e a plotagem contendo essa comparação para a série de testes estão na Figura 4.38.

a)



b)



c)

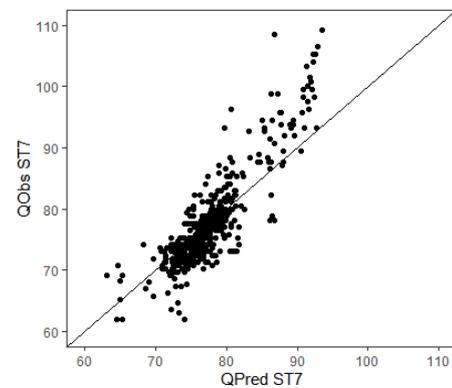


Figura 4.38: Resultados da previsão ST6-ST7 (RPG + TWD): a) Hidrogramas observado e calculados; b) Dispersão dos erros; c) Gráfico entre as vazões observadas e previstas

Mesmo que a qualidade da previsão da série de vazões tenha sido classificada como regular com base nas métricas de desempenho, de maneira geral, a análise das imagens permite constatar que o modelo foi capaz de responder relativamente bem com relação aos mínimos do hidrograma observado. No entanto, isso não foi verificado com os valores máximos. A diferença dos primeiros quartis entre as vazões observada e calculada é de $1,60\text{m}^3/\text{s}$, enquanto a diferença de valores mínimos absolutos é de $3,93\text{m}^3/\text{s}$, o que representa $6,71\%$.

A análise do gráfico de dispersão de vazões, juntamente com essas informações numéricas sobre os valores mínimos sugere que a principal condicionante para que a previsão não atinja os critérios de desempenho com boa qualidade seja a má representação das vazões máximas. Esse fato sugere que, mesmo em algumas condições em que as métricas de desempenho dos modelos de aprendizado de máquina não logrem boa simulação para a previsão, as situações

críticas de valores mínimos ainda podem ser respaldados por um sistema de alerta de vazões mínimas elaborado para a bacia hidrográfica.

4.3.2.7 Estações ST7-ST8

O último interstício é o de maior área de contribuição lateral entre os pares de estações estudados, são 565km², com distância de 16,5km entre as estações. Imediatamente a montante da ST8 é operada a PCH Figueirópolis, cujo reservatório possui a maior área alagada na bacia. As informações relativas aos melhores ajustes de cada modelo RNA estão na Tabela 4.20.

Tabela 4.20: Conjunto de melhores ajustes e métricas de desempenho (RNA ST7-ST8)

(RNA) ST7-ST8						
Decomposição	TWD		EMD		S/D	
	Treino	Teste	Treino	Teste	Treino	Teste
NSEiQ	0.81	0.58	0.81	0.54	0.81	0.57
MAE	0.75	0.52	0.75	0.59	0.75	0.54
R ²	0.81	0.64	0.81	0.63	0.81	0.63
Topologia	3.1.1		3.1.1		2.1.1	
Decay	0.5		0.5		0.5	
Entradas	ST7 + ST8_lag1 + D9		ST7 + ST8_lag1 + imf6		ST7 + ST8_lag1	

A previsão de vazões no par ST7-ST8 com os modelos RNA não reproduziu com boa qualidade a série observada, visto que as métricas relativas se mantiveram abaixo de 0,8 na fase de teste. Outra observação importante é que, entre as séries analisadas na bacia, esse par de estações apresentou maior efeito de *overfitting*. Em relação aos hiperparâmetros de ajuste, dessa vez os três modelos utilizaram apenas um nó na camada intermediária, assim como o mesmo valor para o *decay*, igual a 0,5. As variáveis regressoras utilizadas nos melhores modelos híbridos contém, além das séries da estação de montante e da defasagem temporal horária, uma componente de média frequência, sendo o D9 para o modelo RNA + TWD e o imf6 para o RNA + EMD.

Os resultados referentes aos ajustes com RPG estão expostos na Tabela 4.21.

Tabela 4.21: Conjunto de melhores ajustes e métricas de desempenho (RPG ST7-ST8)

(RPG) ST7-ST8						
Decomposição	TWD		EMD		S/D	
Fase	Treino	Teste	Treino	Teste	Treino	Teste
NSEiQ	0.61	0.64	0.64	0.52	0.64	0.52
MAE	1.13	0.44	1.1	0.69	1.09	0.68
R ²	0.62	0.66	0.64	0.62	0.64	0.63
<i>Sigma</i>	0.005		0.005		0.005	
Entradas	ST8_lag1 + ST8_lag2 + D9 + D10		ST7 + ST8_lag1 + ST8_lag2 + imf8 + imf9		ST7 + ST8_lag1 + ST8_lag2	

Assim como nos modelo RNA, o RPG também não foi capaz de prever as vazões da série de teste com boa qualidade, restringindo-se à faixa que denota uma reprodução razoável, se os critérios utilizados forem as métricas relativas (NSEiQ e R²). Entre os seis modelos de previsão no par de estações ST7-ST8, o modelo RPG + TWD foi o que logrou melhor resultado, com diferença expressiva frente aos demais. É válido notar que o RPG + TWD foi o único que não apresentou efeitos de *overfitting*. Mesmo nos modelos RPG + EMD e RPG + S/D houve supertreinamento em menor grau que a previsão por RNA. Igualmente a todos os ajustes dos modelos RPG, o valor de *decay* se manteve 0,005. No que tange aos preditores dos modelos híbridos, os componentes utilizados foram os de baixa frequência, ou seja, D9 + D10 para o RPG + TWD e imf8 + imf9 para o RPG + EMD. Uma singularidade do RPG + TWD para o par de estações ST7-ST8 é que esse foi o único ajuste cujo uso da série original de vazões da estação de montante (ST7) produziu efeitos de *overfitting*, de modo que sua exclusão gerou melhores resultados. Portanto, apenas os subsinais de baixa frequência da série de montante (D9 + D10) foram utilizados junto com as defasagens temporais da série de jusante.

Um aspecto notável diz respeito aos valores obtidos com o MAE em todos os modelos aplicados ao par de estações ST7-ST8. Ao contrastar a média do MAE na fase de testes para esses seis modelos ($\overline{MAE} = 0,58$), com a média dos outros pares de estações, a qualidade desta previsão é comparável aos melhores desempenhos na bacia. Ou seja, se a análise for realizada somente por essa métrica, a performance da previsão do par ST7-ST8 se encontra intermediária entre as previsões dos pares ST2-ST3 ($\overline{MAE} = 0,27$) e ST3-ST4 ($\overline{MAE} = 1,33$). A compreensão desse efeito fica nítida ao analisar a Figura 4.39, que contém os gráficos dos hidrogramas observado e calculados, bem como as informações de dispersão dos resultados das séries ST7-ST8, extraídos com o modelo RPG + TWD.

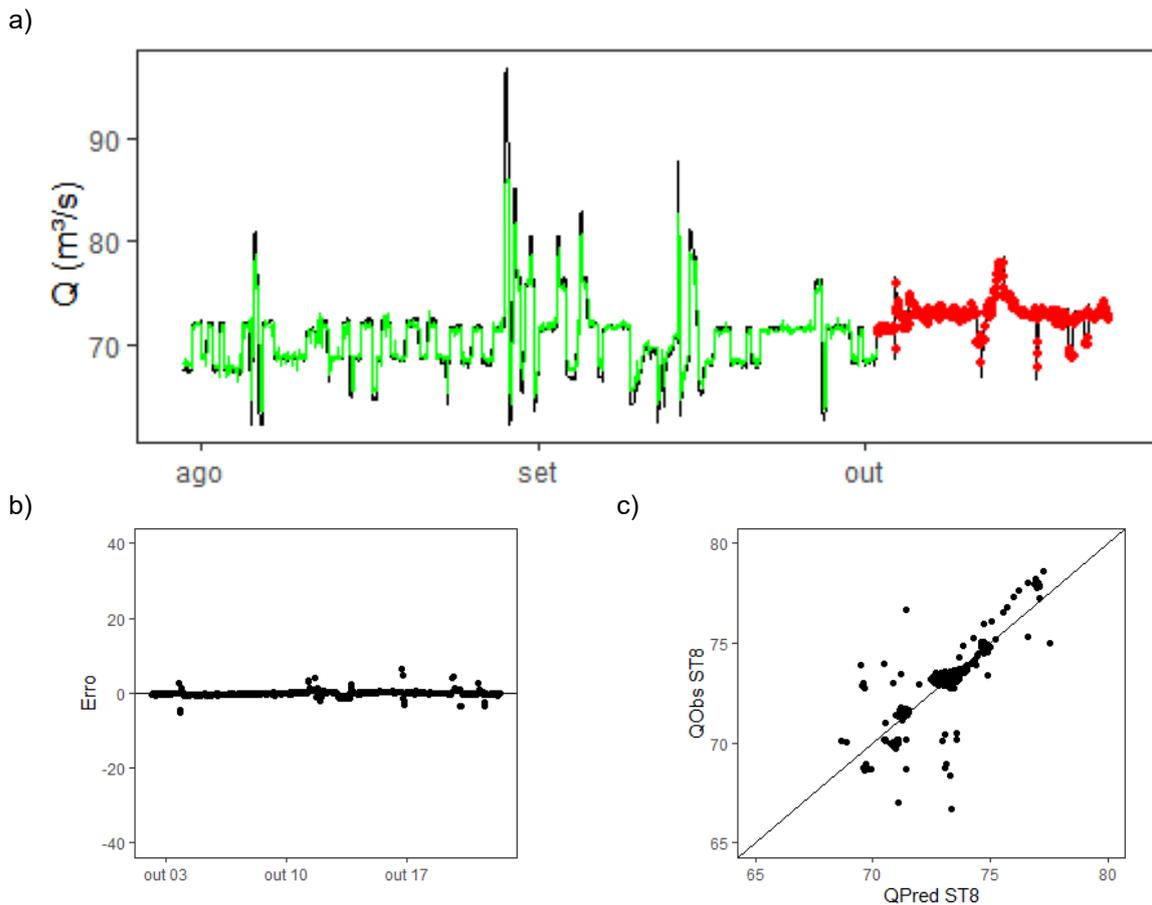


Figura 4.39: Resultados da previsão ST7-ST8 (RPG + TWD): a) Hidrogramas observado e calculados; b) Dispersão dos erros; c) Gráfico entre as vazões observadas e previstas

Como é possível observar, houve alguma dificuldade na reprodução da série de teste especialmente em algumas faixas de menores escalas. A oscilação dos valores previstos em torno dos valores observados, que se mostraram notadamente estáveis ao longo da série, indicando a existência de comporta, não prejudicou as estimativas de MAE, métrica relacionada aos erros absolutos, todavia o fez com as métricas relativas quadráticas NSEiQ e R^2 . De alguma forma, visto que os maiores desvios estão nas faixas de vazões baixas a médias, essa característica pode ter influenciado o relativo bom desempenho no que diz respeito aos valores de MAE, já que esses desvios tendem a ser menores em termos absolutos. Adicionalmente, vale lembrar que uma característica inerente à formulação do MAE é a sua insensibilidade a erros sistemáticos, podendo resultar em valores reduzidos, mesmo quando as estimativas não são bem calculadas. Com enfoque nos valores mínimos, o erro entre o primeiro quartil da vazão observada em relação ao da vazão estimada é de $0,80\text{m}^3/\text{s}$. Já o desvio entre os valores mínimos é de $1,95\text{m}^3/\text{s}$, o que equivale a 2,83%. Isso sugere que, assim como na previsão do par de estações ST6-ST7, apesar de as métricas de desempenho não indicarem essencialmente bons

resultados, os valores mínimos têm condições de serem relativamente bem atendidos por um modelo de previsão, reforçando a proposta do desenvolvimento de um sistema de alerta de vazões mínimas na bacia pautado nessas previsões.

4.3.2.8 Resumo da previsão de vazões entre séries de estações adjacentes

Ao realizar uma leitura genérica do comportamento dos modelos de previsão, algumas observações gerais podem ser extraídas. Em consonância com a coerência *wavelet* entre as séries de estações adjacentes, conferida na primeira parte dos resultados da corrente pesquisa, aqueles pares de séries com maiores correspondências entre si tenderam também a lograr melhor previsibilidade de vazões, com destaque para as estações de montante. Esse fato era esperado, visto que o modelo de aprendizado de máquina busca extrair analogias entre as informações das séries e reproduzi-las com base em padrões. Nas situações de pequenas correspondências, há dificuldade para a captura das informações.

Em alusão aos hiperparâmetros de ajuste dos modelos RNA, embora haja variação no número de nós na camada intermediária, boa parte dos modelos foi melhor ajustada com apenas um nó. Uma observação comum ao longo das diversas tentativas é a tendência a *overfitting* conforme a complexidade aumenta, o que vai ao encontro de algumas ponderações relacionadas às redes neurais artificiais (SILVA *et al.*, 2016; ISMAIL *et al.*, 2018). Regra geral, os pares de estações com os melhores desempenhos de previsão foram também os mais simples no que diz respeito à topologia das redes neurais, tanto que em quase todos os melhores modelos RNA foi utilizado apenas um nó na camada intermediária. Por outro lado, os ajustes para previsão dos pares ST5-ST6 e ST6-ST7, com razoável reprodutibilidade das séries de teste, exigiram três e quatro nós na camada intermediária, ambos sem inserção de séries decompostas (RNA + S/D). Esses dois pares de previsões foram também os que apresentaram maior complexidade dos modelos RNA, por requisitarem, também, grande quantidade de variáveis de entrada no modelo. Além disso, o hiperparâmetro *decay* se mostrou muito variável, sem identificação de um padrão regular que apontasse melhores ou piores ajustes, ou que indicasse relação direta evidente com efeitos de *overfitting*, já que uma das funções do *decay* é atuar na sua redução.

Ao comparar as métricas de desempenho de treino e teste dos modelos RNA, foi recorrente a observação de supertreinamento. Segundo Maier *et al.* (2010), isso ocorre porque a maior complexidade de um sistema a ser modelado tende a aumentar o tamanho da rede, e, portanto, o número de pesos a serem ajustados. Como resultado, o efeito de *overfitting* provoca a perda

de generalização das estimativas do modelo, retornando resultados aparentemente muito positivos durante a etapa de treinamento, entretanto com perda de qualidade na fase de teste. Essa característica é ainda compatível com diversas constatações levantadas por Jain *et al.* (2018) e Snieder *et al.* (2019). Desse modo, a inclusão de entradas redundantes introduz mínimos locais adicionais à superfície de erro no espaço de busca de pesos. Com efeito, a presença de mínimos locais nesse espaço de busca compromete a obtenção de um conjunto ideal de pesos sinápticos, aumentando, por exemplo, as chances de ocorrerem efeitos de equifinalidade, o que dificulta a extração de informações para o ajuste do modelo. Portanto, para evitar o treinamento excessivo nessa etapa do trabalho, muitas vezes a complexidade do modelo RNA foi reduzida compulsoriamente, por exemplo, com a diminuição do número de nós na camada intermediária. É interessante pontuar que tal condição de supertreinamento não foi observada nos ajustes do modelo RPG, exceto no par de estações ST4-ST5, restrito às métricas MAE e R^2 .

Particularmente aos modelos RNA, os valores do número de nós intermediários e do coeficiente de decaimento ressaltaram a importância do uso da grade de parâmetros no algoritmo de busca para seus ajustes. No entanto, uma considerável desvantagem de grades com muitos parâmetros é o aumento do tempo de processamento computacional. Utilizando as configurações médias para a execução de um modelo RNA com uma grade contendo quatro combinações paramétricas (por exemplo, um vetor com dois valores de nós intermediários e outro vetor com dois valores de *decay*), o tempo médio de processamento é inferior a três minutos. Para essa mesma configuração e uma grade de parâmetros com 30 combinações diferentes, o tempo de uma única simulação se aproxima de 30 minutos. Os cálculos foram realizados em um computador Intel core i7, 8Gb de memória RAM, com operação de 3 *cores* em paralelo.

Ainda no tocante à grade de parâmetros ajustados na fase de treinamento, a RPG possui muito menos combinações que as RNA. Enquanto a RNA requer o ajuste do número de nós na camada intermediária e do *decay*, a RPG necessita ajustar unicamente o hiperparâmetro *sigma* da função *kernel* exponencial quadrática. A essa conveniência, acrescenta-se que na previsão dos três modelos RPG para os sete pares de estações, o valor de *sigma* que melhor se adequa aos ajustes permaneceu constante ($\sigma = 0,005$). Portanto, nesse aspecto de ajuste de hiperparâmetros reside uma das principais vantagens na aplicação da regressão por Processos Gaussianos.

Quanto às variáveis regressoras, foi consenso o uso de séries da estação de jusante com suas defasagens temporais. Em todos os melhores ajustes para as previsões das séries de montante (ST1-ST2 e ST2-ST3) foram empregadas defasagens temporais *lag1h* e *lag2h*. Com algumas exceções, as estações de jusante (pares ST3-ST4 até ST7-ST8) retornaram melhores resultados com defasagem temporal horária (*lag1h*). Aparentemente, esse fato ocorreu independentemente das combinações com séries decompostas. Tal observação é coerente com os resultados das autocorrelações parciais, discutidas no item 4.3.1, indicando redução da dependência da série em relação a ela mesma conforme o percurso a jusante na bacia. Essa característica ratifica as sugestões de Maier *et al.* (2010) e Silva *et al.* (2016), que destacam a importância de estudo preliminar dos dados no que compete à sua memória, ao adotar variáveis de entrada em modelos de aprendizado de máquina com sistemas variantes no tempo.

De modo geral, houve relativa vantagem na inclusão de séries decompostas para a previsão de vazão. Isso ocorre ainda que com a consideração de que nas situações em que as métricas de desempenho sejam parecidas, o melhor modelo passa a ser aquele com o menor número de variáveis regressoras; ou ainda, sem decomposição de sinais, a fim de priorizar as estruturas mais simples. Para visualizar o desempenho das previsões do presente trabalho, a Tabela 4.22 mostra a súmula dos valores de NSEiQ obtidos na fase de teste. As marcações com asterisco indicam os melhores ajustes ao ponderar sua avaliação seguindo a hierarquia prioritária de NSEiQ, MAE, R² e menor número de variáveis de entrada. As marcações em negrito indicam os melhores resultados para cada par de estações em cada modelo de aprendizado de máquina. Na sequência, a Tabela 4.23 contém os valores de MAE e a Tabela 4.24 os valores de R².

Tabela 4.22: Resultados de NSEiQ teste

Estação	RNA			RPG		
	TWD	EMD	S/D	TWD	EMD	S/D
ST1-ST2	0.96	0.96	0.96*	0.96	0.96	0.96*
ST2-ST3	0.94	0.94	0.95*	0.93	0.93	0.93*
ST3-ST4	0.80	0.81*	0.78	0.80*	0.79	0.78
ST4-ST5	0.82	0.82*	0.82	0.83*	0.83	0.83
ST5-ST6	0.50	0.51	0.52*	0.49*	0.49	0.48
ST6-ST7	0.64	0.62	0.64*	0.66*	0.65	0.65
ST7-ST8	0.58*	0.54	0.57	0.64*	0.52	0.52

Tabela 4.23: Resultados de MAE teste

Estação	RNA			RPG		
	TWD	EMD	S/D	TWD	EMD	S/D
ST1-ST2	0.25	0.24	0.24	0.25	0.25	0.26
ST2-ST3	0.25	0.25	0.25	0.30	0.29	0.30
ST3-ST4	1.31	1.34	1.32	1.32	1.33	1.34
ST4-ST5	2.18	2.15	2.17	2.14	2.20	2.20
ST5-ST6	3.81	3.83	3.72	4.00	4.04	4.08
ST6-ST7	3.12	3.22	3.00	2.99	3.00	2.99
ST7-ST8	0.52	0.59	0.54	0.44	0.69	0.68

Tabela 4.24: Resultados de R² teste

Estação	RNA			RPG		
	TWD	EMD	S/D	TWD	EMD	S/D
ST1-ST2	0.97	0.97	0.97	0.97	0.97	0.97
ST2-ST3	0.95	0.95	0.95	0.93	0.93	0.93
ST3-ST4	0.81	0.81	0.79	0.82	0.82	0.80
ST4-ST5	0.80	0.82	0.81	0.82	0.81	0.81
ST5-ST6	0.59	0.61	0.61	0.64	0.64	0.63
ST6-ST7	0.72	0.70	0.73	0.75	0.74	0.75
ST7-ST8	0.64	0.63	0.63	0.66	0.62	0.63

Pela Tabela 4.22, é possível constatar que nos modelos RNA, para os sete pares de vazões analisados, quatro dos melhores ajustes foram com o RNA + S/D, dois com o RNA + EMD e um com o RNA + TWD. Os ajustes com o RPG foram diferentes nesse quesito, visto que não houve melhores previsões com o modelo RPG + EMD. No entanto, cinco ajustes foram efetuados com o RPG + TWD, os quais se destacaram das demais tentativas de inserção de séries decompostas. Outros dois ajustes foram realizados com o modelo RPG + S/D. Vale salientar que esses dois últimos casos foram grifados por atender o critério de menor número de variáveis de entrada, e não por expressarem métricas com melhores desempenhos. De modo geral, os modelos se distribuíram entre previsões boas, regulares e ruins, não sendo identificada clara associação entre a qualidade da previsão e o tipo do modelo com o melhor ajuste.

Particularmente nos modelos híbridos, uma análise da relação entre o nível de detalhe de decomposição das séries e a performance da previsão de vazões evidenciou que os pares de estações com os cinco melhores resultados dos modelos RPG fizeram uso de componentes de alta frequência, com decomposições de no máximo até a quarta ordem. Tal característica representa certa segurança ao usuário que utiliza o RPG. Nos modelos com EMD, o detalhamento dessa decomposição não possui significado físico direto; no entanto, nas decomposições por TWD os subsinais de alta frequência apontam relação com comportamentos cíclicos em escala diádica, ou seja, de $2^1 = 2$ h a $2^4 = 16$ h. Essa observação da construção de modelos alimentados com subsinais de alta frequência condiz com algumas pesquisas que abordam o uso de decomposição de sinais associados ao nível de detalhe (MAHESWARAN & KHOSA, 2012; NOURANI *et al.*, 2014). Por outro lado, os ajustes que obtiveram os dois piores resultados com o RPG (ST5-ST6 e ST7-ST8) utilizaram subsinais de baixa frequência.

Nas previsões com o RNA, contrariamente, o padrão entre o nível de decomposição da série e os melhores ajustes dos modelos não foi detectado. Mesmo entre os melhores resultados, ora as maiores frequências foram utilizadas, por exemplo em ST1-ST2 e ST4-ST5, ora as menores frequências foram utilizadas, como na previsão ST3-ST4 e ST7-ST8. Para a previsão das séries, ST2-ST3 e ST5-ST6, foram necessárias combinações de subsinais com médias e baixas frequências. Por fim, para a previsão de ST6-ST7, foram utilizadas componentes de alta e baixa frequência em simultâneo. Esse aspecto dificulta um eventual ajuste de modelos RNA em que as séries não sejam bem conhecidas. Uma análise pelo ponto de vista da busca por uma padronização dos sinais decompostos utilizados para alimentação dos modelos de previsão, no que diz respeito às suas frequências, aponta certa similaridade dos subsinais, entre os modelos RNA e RPG nas previsões das séries de montante, e não similaridade nas previsões das séries de jusante. Isso sugere modificação do comportamento geral das frequências dos sinais de vazão de jusante, quando comparados com as séries naturais a montante da bacia, o que refletiu na necessidade ou não do modelo utilizar subsinais de maiores ou menores frequências, dependendo o caso.

Em alusão aos desvios entre as vazões mínimas observadas e as calculadas pelos modelos com seus melhores ajustes, é possível verificar que suas proporções variaram de $0,13\text{m}^3/\text{s}$ (erro de 0,22%) na previsão de ST1-ST2 a $11,53\text{m}^3/\text{s}$ (erro de 18,29%) em ST5-ST6. Apesar do relativo elevado valor do desvio na previsão de ST5-ST6, as previsões de todos os demais pares de

estações tiveram erros consideravelmente pequenos frente à proporção das vazões a serem previstas. Por exemplo, o par de estações com segundo maior desvio entre as vazões mínimas é o ST6-ST7, com diferença de 3,93m³/s, equivalente a 6,71%. Vale destacar que em todas as demais previsões, o erro absoluto de vazões mínimas foi inferior a 2m³/s. Padrão semelhante foi verificado no que diz respeito à diferença entre o primeiro quartil das séries observadas e estimadas.

Ao longo das diversas tentativas de ajuste dos modelos, o que incluía a diversidade de variáveis regressoras disponíveis para essas aplicações, foi notado que o RNA se mostrou com maior variação dos valores das métricas de desempenho, quando comparado com o RPG. Com isso, foi constatado que o modelo RPG se mostrou mais estável durante o ajuste como um todo. Essa característica confere segurança ao modelador, por entender que, mesmo quando um hiperparâmetro ou um conjunto de entradas não seja exatamente aquele capaz de atingir o ajuste de mínimo erro, resultados próximos a ele se mostraram mais facilmente encontrados, o que corresponde à sua robustez.

4.3.3 Previsão de vazão entre séries com variabilidade temporal

Conforme mencionado, todas as previsões de séries temporais realizadas no item anterior consideraram apenas a antecipação horária da previsão. Naquela ocasião, além da implementação dos métodos e aplicação das técnicas em si, um dos objetivos foi encontrar configurações padrão a partir dos seus ajustes, a fim de ampliar tal emprego para verificar a possibilidade de desenvolvimento de modelos com variabilidade temporal e espacial.

No que compete à variabilidade temporal para a previsão de séries de vazão entre estações contíguas, principal enfoque do presente item, as antecipações são as seguintes: 1h, 3h, 6h, 12h e 24h. Essas escalas foram assim assumidas por significarem valores representativos à tomada de decisão por parte dos operadores dos aproveitamentos hidrelétricos. Desse modo, o modelo compreende intervalos desde a menor discretização da série temporal, inclui turnos de trabalho dos operadores e se estende até o período de um dia, o qual envolve ciclos diários de operações de nível de reservatório e de consumo de energia.

Para tanto, será utilizado exclusivamente o aprendizado de máquina de regressão por Processos Gaussianos de forma a respeitar o melhor ajuste alcançado para cada par de estações no item anterior, permitindo pequenas adequações na composição desse modelo. Além de o RPG

requerer calibração de apenas um hiperparâmetro durante a fase de treino, a experiência com o uso dos modelos permitiu identificar a constância do hiperparâmetro σ , definido a partir de um vetor com eventuais valores, validados dezenas de vezes a cada treinamento. Com essa definição, a grade de parâmetros para o ajuste dos modelos foi descartada, reduzindo sobremaneira o tempo de processamento computacional. Além disso, menciona-se a maior robustez dos modelos RPG, quando comparados ao RNA, na obtenção dos melhores resultados de previsão mesmo quando as variáveis regressoras não são as mais representativas. Esse aspecto se faz importante, visto que o foco no presente item está relacionado à verificação prática de previsão de vazão com variabilidades temporais, sem necessidade de investigações dos ajustes em si, o que solicitaria muitas simulações para identificar o melhor conjunto paramétrico e as variáveis de entrada. Por fim, deve ser lembrada a maior tendência a efeitos de *overfitting* observados em alguns casos em que foram utilizadas as RNA, o que oferece respaldo ao uso do RPG.

Com o intuito de analisar a possibilidade dos ajustes obtidos na fase anterior não serem os mais adequados para a previsão de vazões com variabilidade temporal, foram realizadas algumas verificações preliminares com pequenas variações das variáveis regressoras. No entanto, isso só fez confirmar tal configuração como apropriada. Evidentemente, a mesma função *kernel* exponencial quadrática foi assumida para essa fase da pesquisa. Sendo assim, na Tabela 4.25 estão tabuladas as informações referentes à combinação que consistiu nos melhores ajustes dos modelos RPG, os quais compreendem os valores do hiperparâmetro σ da função *kernel*, bem como as variáveis de entrada dos modelos para cada par de estações.

Tabela 4.25: Configuração de ajuste dos modelos RPG para previsão de vazão com variabilidade temporal de 1h, 3h, 6h, 12h e 24h

Série a ser prevista	σ	Variáveis de entrada
ST2	0.005	ST1 + ST2_lag1 + ST2_lag2
ST3	0.005	ST2 + ST3_lag1 + ST3_lag2
ST4	0.005	ST3 + ST4_lag1 + D3 + D4
ST5	0.005	ST4 + ST5_lag1 + D3 + D4
ST6	0.005	ST5 + ST6_lag1 + D7 + D10
ST7	0.005	ST6 + ST7_lag1 + D1 + D3
ST8	0.005	ST8_lag1 + ST8_lag2 + D9 + D10

Ao serem estabelecidas essas formas para a alimentação do modelo, todas as outras configurações necessárias foram conforme explanado no item anterior. Isso inclui, por exemplo, o procedimento da validação cruzada, com divisão da série em 75% para treino e 25% para teste, sendo o treino realizado com 5-partições, cujas simulações sejam avaliadas pelos erros absolutos médios (MAE). Por fim, menciona-se ainda as técnicas de escalonamento e centralização dos dados, em passo anterior à aplicação ao algoritmo de cálculo, o qual é realizado por meio da computação paralela com três *cores*.

Diferente da exposição dos resultados do item anterior, as respostas das simulações com variabilidade temporal serão apresentadas somente com base nos valores das métricas de desempenho para a série de teste. Isso permitirá observar a esperada redução da qualidade da previsão da série consoante o aumento da antecipação horária. Com efeito, a Tabela 4.26 contém os resultados de NSEiQ para as séries previstas das estações ST2 a ST8 na BHJ, considerando as variabilidades temporais. Esses resultados estão representados em meio gráfico na Figura 4.40

Tabela 4.26: Valores de NSEiQ na fase de teste segundo o adiantamento temporal

Série a ser prevista	Variabilidade temporal				
	1h	3h	6h	12h	24h
ST2	0.96	0.96	0.96	0.95	0.93
ST3	0.93	0.93	0.93	0.91	0.86
ST4	0.80	0.76	0.68	0.57	0.47
ST5	0.83	0.81	0.76	0.65	0.50
ST6	0.49	0.30	0.15	-0.06	0.07
ST7	0.64	0.51	0.38	0.17	0.26
ST8	0.64	0.52	0.17	-0.16	-0.08

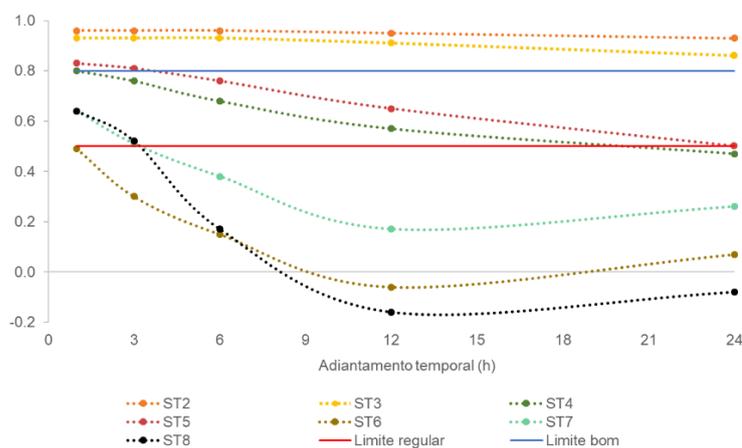


Figura 4.40: Valores de NSEiQ para previsão de vazões com variabilidade temporal

Estabelecendo como critério apenas o NSEiQ, podem ser generalizados três grupos de séries históricas que retornaram respostas distintas com relação à capacidade de previsão em função da sua antecipação. O primeiro grupo é composto pela previsão das séries ST2 e ST3, ambos com valores acima do limite correspondente à boa reprodução de vazões, mesmo com antecipação de 24h. Vale retomar que a PCH a extremo montante da bacia está localizada entre as estações ST2 e ST3 e, apesar disso, a série ST3 se mostrou bem reproduzível. O segundo grupo, composto pelas estações ST4 e ST5, apresentam boa capacidade de previsão de vazões na primeira hora e, no caso da ST5, até a terceira hora de antecipação. A partir de então, ocorre uma degradação contínua, cujos valores mantêm qualidade regular até a vigésima quarta hora para a previsão de ST5, e até a décima segunda hora para a previsão de ST4, o qual, a partir da antecipação de 24h, não há qualquer capacidade de reprodução de vazões. As três estações a jusante da BJJ (ST6, ST7 e ST8) compõem o terceiro grupo, formado por séries com comprometimento na previsão de vazões já desde as primeiras horas da variabilidade temporal. O fato de a métrica NSEiQ não possuir limite inferior, permite que valores negativos sejam alcançados, indicando ausência de qualquer correspondência real, o que foi observado na ST6 e na ST8 nas maiores antecipações preditivas.

Na Tabela 4.27 estão as informações relativas aos resultados de MAE, enquanto na Figura 4.41 estão as suas representações visuais.

Tabela 4.27: Valores de MAE na fase de teste segundo o adiantamento temporal

Série a ser prevista	Variabilidade temporal				
	1h	3h	6h	12h	24h
ST2	0.26	0.26	0.27	0.29	0.36
ST3	0.30	0.31	0.32	0.35	0.48
ST4	1.32	1.47	1.70	2.04	2.33
ST5	2.14	2.31	2.63	3.23	3.89
ST6	3.92	4.79	5.26	5.68	5.29
ST7	2.99	3.59	4.16	4.69	4.43
ST8	0.44	0.62	0.91	1.09	1.03

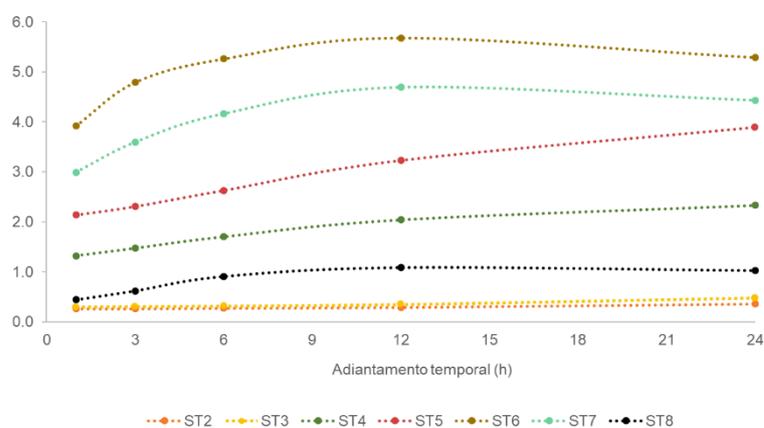


Figura 4.41: Valores de MAE para previsão de vazões com variabilidade temporal

Por se tratar de uma métrica absoluta, e não relativa, não existem faixas de valores que possam atribuir qualidade à previsão, tal como ocorre com o NSEiQ e o R^2 . No entanto, esse critério permite comparar os erros absolutos dos resultados entre si com relativa maior sensibilidade. Pela Figura 4.41, a definição de agrupamentos de séries segundo a capacidade de previsão não se mostrou tão evidente quanto o observado com a métrica anterior. Entretanto, houve certo padrão na distribuição dos resultados do MAE, tanto no que diz respeito às variabilidades temporais quanto no que compete à própria série a ser prevista. Novamente, as duas estações de montante se destacaram por alcançar os melhores resultados ao longo de qualquer antecipação horária. Um aspecto relevante é evidenciado ao observar os resultados de MAE da ST8, que se mantiveram relativamente próximos às duas estações de montante, mesmo na vigésima quarta hora de previsão. Excetuando a inversão da qualidade da previsão da série ST4

em relação a ST5, as demais séries apresentaram ordem de degradação semelhante ao obtido com o NSEiQ.

A Tabela 4.28 contém os resultados da previsão de vazões com variabilidade temporal no que diz respeito ao coeficiente de determinação R^2 , representado graficamente pela Figura 4.42.

Tabela 4.28: Valores de R^2 na fase de teste segundo o adiantamento temporal

Série a ser prevista	Variabilidade temporal				
	1h	3h	6h	12h	24h
ST2	0.97	0.97	0.97	0.97	0.97
ST3	0.93	0.93	0.93	0.93	0.91
ST4	0.82	0.81	0.79	0.74	0.65
ST5	0.82	0.80	0.80	0.81	0.77
ST6	0.62	0.56	0.47	0.32	0.55
ST7	0.74	0.72	0.49	0.38	0.49
ST8	0.66	0.55	0.26	0.07	0.09

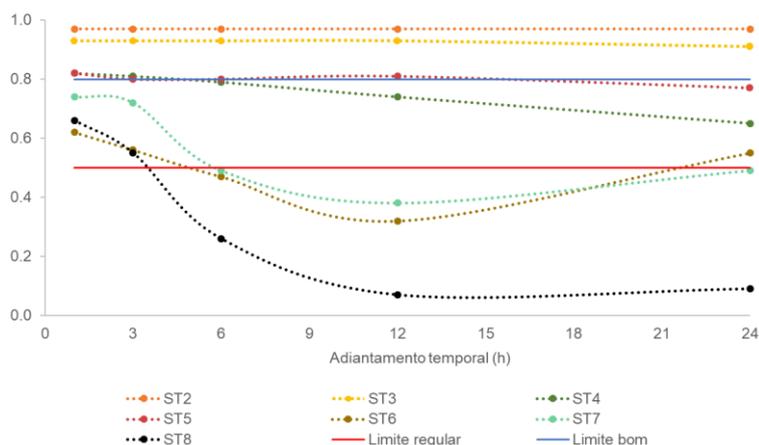


Figura 4.42: Valores de R^2 para previsão de vazões com variabilidade temporal

A distribuição da qualidade da previsão das séries históricas pelo ponto de vista da dispersão dos dados demonstrou relativa semelhança com a obtida pelo NSEiQ, com algumas distinções. As duas estações de montante mantiveram valores de R^2 superiores a 0,90 mesmo na vigésima quarta hora de antecipação preditiva. A série ST5 permaneceu com boa capacidade de reprodução das vazões até a décima segunda hora, enquanto a ST4 o fez apenas até a terceira hora. Ambas indicaram regular capacidade de previsão até a vigésima quarta hora. As séries ST6 e ST7 apresentaram regulares capacidades de previsão de vazão até a terceira hora, com

destaque para a ST7, que alcançou valores próximos ao índice que representa a boa reprodução de vazões. No entanto, houve forte redução dos valores de R^2 a partir da sexta hora, a ponto de indicar incapacidade preditiva até a décima segunda hora. No que concerne à qualidade da previsão da ST8, seus resultados se mostraram muito próximos da ST6 até a terceira hora, porém, passou a não exprimir qualquer correspondência com as vazões observadas a partir da sexta hora de antecipação preditiva. Curiosamente, houve melhora de qualidade da previsão com antecipação diária nas três estações de jusante, quando comparados aos resultados de 12h. Esse fato também ocorreu com o NSEiQ, no entanto, houve maior destaque no R^2 . Tal efeito pode ser explicado ao recordar que as previsões dessas duas estações foram realizadas com inclusão de variáveis regressoras compostas também por decomposições TWD, as quais podem ter maior compatibilidade com ciclos de 24h em relação aos de 12h.

Com algumas exceções, é possível notar a crescente limitação para a previsão das séries com variabilidade temporal na BHJ. Em síntese, houve boa reprodutibilidade de vazões nas estações de montante com menores antecipações preditivas, ao passo que as estações de jusante e com maiores antecipações não a realizam a contento. Esse fator ganha relevância se o intuito for o favorecimento de tomadas de decisão operacionais dos aproveitamentos hidrelétricos a montante da bacia, para que as observações a jusante respeitem limites mínimos de escoamento superficial consoante os requisitos ambientais e legais. Nesse sentido, evidentemente, existe uma relação direta entre o tempo que o operador possui para tomar essas decisões e o benefício que o sistema como um todo recebe ao compatibilizar os interesses para produção hidroenergética com a necessidade ambiental.

Desse modo, no que compete à previsão de vazões com diversos graus de antecipações, o modelo se mostrou eficiente dentro dos interesses da disponibilidade de tempo para as operações dos AH, com algumas restrições. Isso porque as melhores previsões com antecipações horárias se limitaram às estações de montante e, exceto a ST8 pelo ponto de vista dos erros absolutos médios, as estações de jusante não são claramente favorecidas, ou seja, justo aquelas localizadas na saída do sistema de cascata de aproveitamentos hidrelétricos.

Alguns fatores podem ser levantados para explicar a degradação da qualidade da previsão conforme o tempo e, de alguma forma, conforme o percurso a jusante. Evidentemente, o primeiro deles está associado à memória da série histórica, o que, segundo o estudo por meio das autocorrelações parciais, não se estende além de quatro horas nas estações ST1, ST2 e ST3,

e menor que isso nas demais séries. Outro aspecto importante é a relação da antecipação preditiva com o tempo de resposta dos fenômenos hidrológicos em uma bacia hidrográfica de pequena escala, como a BHJ. Com efeito, é possível que em algumas situações, o tempo de resposta hidrológico seja inferior à antecipação que se queira realizar a previsão. Finalmente, também pode ser pontuada a influência que o aproveitamento hidrelétrico gera no corpo hídrico, descaracterizando a associação entre variáveis de entrada e saída, de forma a promover, com tendência crescente, considerável aleatoriedade no comportamento das vazões. Esse fator se torna relevante, visto que nas estações de montante, a condição de previsibilidade de vazões é maior. Apesar de ser questão importante na previsão de séries de vazão com variabilidade temporal, esse último assunto é melhor abordado no item seguinte, sobre previsão de séries com variabilidade espacial.

4.3.4 Previsão de vazão considerando variabilidade espacial

O estudo dos ajustes de modelos realizado no item 4.3.2 – Previsão de vazão entre séries de estações adjacentes – serviu também para identificar configurações padrão a fim de orientar a implementação de previsão de séries temporais que analise modelos alimentados por variáveis regressoras originadas de outras estações que não só as contíguas. No presente item, é verificado o desempenho de modelos de previsão de vazão de estações de jusante formados por variáveis regressoras atribuídas a partir de combinações com todas as estações de montante, par a par.

Pelos mesmos motivos expostos no item anterior, foram utilizados apenas os modelos de regressão por Processos Gaussianos, com função *kernel* exponencial quadrática alimentada pelo hiperparâmetro *sigma* igual a 0,005. O ajuste ocorreu por meio da validação cruzada, com divisão da série em 75% para treino e 25% para teste, cuja validação do treino ocorreu por meio de 5-partições, avaliada pelos erros absolutos médios. Também igualmente, as séries de dados foram escalonadas e centralizadas, para posterior execução do modelo. Da mesma forma, o processo computacional ocorreu com três *cores* em paralelo.

Nessa tarefa, verificações preliminares apontaram que algumas variáveis de entrada diferentes das ajustadas na previsão com base em estações contíguas resultaram em respostas também diferentes, não necessariamente as melhores. Por essa razão, além da combinação de variáveis de entrada ajustadas no item 4.3.2 (conforme Tabela 4.25), foram examinadas composições constituídas por séries de jusante com defasagem temporal de uma hora e de duas horas, para

todos os pares de estações. Nessas avaliações, as variáveis regressoras foram combinadas com os subsinais TWD da série de montante melhor ajustados no item 4.3.2 (quando pertinente), acompanhadas ou não do sinal original de montante.

A partir desses experimentos foi construído o Quadro 4.1, que contém as informações de entrada dos modelos de previsão para todas as combinações de pares de estações. Nesse quadro, as colunas indicam as séries ST2 a ST8 a serem previstas, enquanto as linhas representam as entradas de origem da variabilidade espacial, obtidas das séries ST1 a ST7, ou defasagem temporal da ST8, no último caso. É importante destacar que as variáveis regressoras denotadas por ST_x_lag1 e ST_x_lag2 , sendo “x” a série da estação a ser prevista, são as únicas que representam os dados de jusante de cada par de estações, de modo que todas as demais entradas são oriundas da estação de montante, a qual é representada por “ ST_{x-1} ”.

As combinações das variáveis de entrada provenientes das séries originais de montante, bem como suas decomposições, caracterizam a variabilidade espacial proposto no presente item. Os elementos com asterisco são aqueles compatíveis ao ajustado na primeira parte da previsão de vazões deste trabalho (dispostos na Tabela 4.25), cuja única variação é a série original de montante, de acordo com o par de estações avaliado. Todos os demais elementos consistem em derivações desse primeiro ajuste.

Quadro 4.1: Variáveis regressoras dos modelos de previsão com variabilidade espacial

	Séries a prever						
	ST2	ST3	ST4	ST5	ST6	ST7	ST8
ST1	ST1 + ST2_lag1 + ST2_lag2*	ST1 + ST3_lag1 + ST3_lag2*	ST4_lag1 + D3 + D4	ST5_lag1 + D3 + D4	ST1 + ST6_lag1 + D7 + D10*	ST1 + ST7_lag1 + ST7_lag2 + D1 + D3*	ST8_lag1 + ST8_lag2 + D9 + D10*
ST2		ST2 + ST3_lag1 + ST3_lag2*	ST4_lag1 + D3 + D4	ST5_lag1 + D3 + D4	ST2 + ST6_lag1 + ST6_lag2	ST2 + ST7_lag1 + ST7_lag2	ST8_lag1 + ST8_lag2 + D9 + D10*
ST3			ST3 + ST4_lag1 + D3 + D4*	ST5_lag1 + D3 + D4	ST3 + ST6_lag1	ST3 + ST7_lag1 + ST7_lag2	ST8_lag1 + ST8_lag2 + D9 + D10*
ST4				ST4 + ST5_lag1 + D3 + D4*	ST4 + ST6_lag1	ST4 + ST7_lag1 + ST7_lag2	ST4 + ST8_lag1 + ST8_lag2
ST5					ST5 + ST6_lag1 + D7 + D10*	ST5 + ST7_lag1 + ST7_lag2 + D1 + D3	ST5 + ST8_lag1 + ST8_lag2
ST6						ST6 + ST7_lag1 + D1 + D3*	ST8_lag1 + ST8_lag2 + D9 + D10*
ST7							ST8_lag1 + ST8_lag2 + D9 + D10*

Ao observar os elementos marcados com asterisco no Quadro 4.1, é constatado que a estrutura das variáveis de entrada equivalentes à primeira parte da previsão de vazões neste trabalho e utilizada como orientação para o ajuste no presente item 4.3.4, se manteve apenas em alguns pares. Esses casos foram encontrados na previsão de ST8 quando a alimentação de dados é

baseada nas séries de ST1, ST2, ST3 e ST6; ou quando a estação ST1 é utilizada como variável regressora para a previsão de ST3, ST6, ST7 e ST8. Em todos os demais ajustes, foram necessárias pequenas variações na alimentação dos modelos. Adicionalmente, vale pontuar que em algumas situações, a série original de montante, ST_{x-1} , não foi empregada, pois, combinada com outras variáveis, prejudicavam o desempenho da previsão. Assim, foram utilizadas apenas suas séries decompostas por meio da TWD, que se mostraram importantes nessas circunstâncias. Esses casos com emprego apenas dos subsinais das séries originais de montante foram observados na previsão de ST4 quando a entrada é baseada nos dados de ST1 e ST2; na previsão de ST5 quando a entrada é baseada nas séries ST1, ST2 e ST3; e na previsão de ST8 quando a entrada é baseada em ST1, ST2, ST3, ST6 e ST7. Esse fato reforça a valorização da decomposição de séries temporais para emprego nos modelos de regressão. Por fim, o uso da série do tipo ST_x_lag1 em todos os ajustes foi unânime.

A partir das composições que alimentaram os modelos de regressão, na Tabela 4.29 são mostrados os resultados de NSEiQ na fase de teste para todas as combinações de estações na bacia. Novamente, as colunas ST2 a ST8 correspondem às séries a serem previstas, enquanto as linhas ST1 a ST7 informam a origem das variáveis regressoras. Na sequência, a Figura 4.43 permite a visualização gráfica desses resultados, expondo par a par as combinações das previsões tendo como base as variáveis de entrada de montante. Junto a essa representação, também estão mostradas as faixas contendo os limites assumidos neste trabalho, equivalentes à boa capacidade de reprodução de vazões ($NSEiQ \geq 0,80$) e à regular capacidade de previsão ($0,80 > NSEiQ \geq 0,50$).

Tabela 4.29: Valores NSEiQ para previsão de vazão com variabilidade espacial

		Séries a prever						
		ST2	ST3	ST4	ST5	ST6	ST7	ST8
Variáveis regressoras de origem	ST1	0.96	0.93	0.78	0.81	0.47	0.39	0.64
	ST2		0.93	0.78	0.81	0.48	0.39	0.64
	ST3			0.80	0.82	0.48	0.41	0.63
	ST4				0.83	0.46	0.44	0.54
	ST5					0.49	0.42	0.54
	ST6						0.66	0.60
	ST7							0.64

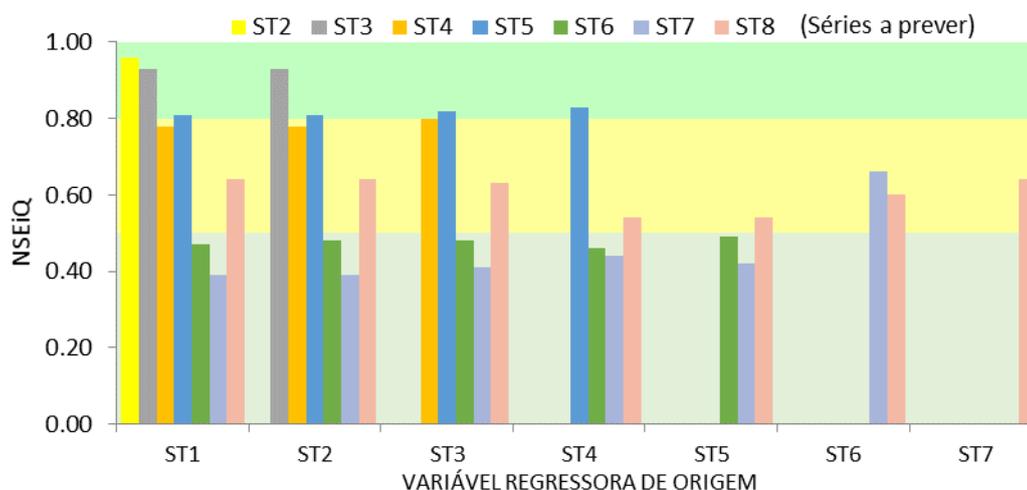


Figura 4.43: Visualização gráfica de NSEiQ na previsão com variabilidade espacial

Ao observar o desempenho das previsões com enfoque nas colunas da Tabela 4.29, é de fácil constatação a maior capacidade de previsão entre as estações de montante da bacia, limitadas até ST5. Para quase todas as combinações com as variáveis regressoras nas previsões de ST6 e de ST7, os resultados de NSEiQ se encontraram muito afastados dos demais modelos, com valores inferiores ao limiar que denota a incapacidade de reprodução das séries de vazão. Um aspecto interessante é pontuado exclusivamente na previsão de ST7 usando as entradas de ST6, cujo NSEiQ = 0,66, ou seja, bastante superior às demais previsões de ST7. Essa observação sugere a regular correspondência entre as séries de ST6 e ST7 e, ao mesmo tempo, a forte incompatibilidade do comportamento de ST6 e de ST7 frente às demais séries de montante. Quando correlacionada com outros resultados obtidos no presente trabalho, incluindo aqueles sobre a coerência *wavelet*, tal observação indica o grau de perturbação no comportamento fluvial, ocasionado, possivelmente, pela operação dos dois aproveitamentos hidrelétricos imediatamente a montante da estação ST6. Aparentemente, o mesmo ocorre em menor grau com o AH intermediário entre ST6 e ST7, bem como entre o ST7 e o ST8. É válido notar que as previsões de ST8 mantiveram valores de NSEiQ próximos entre si para todas as combinações de entradas de montante, desde ST1 até ST7, o que é abordado mais adiante.

A análise dos resultados de NSEiQ pelo ponto de vista da contribuição de cada variável de entrada para a previsão das estações de jusante, ou seja, por meio das linhas da Tabela 4.29,

evidencia a esperada tendência às maiores associações das séries quando próximas entre si. Conforme ocorre o afastamento espacial dessas estações, há degradação da performance dos modelos, com desempenhos mínimos nas previsões de ST6 e ST7, e alguma elevação nos valores de NSEiQ na estação ST8, posicionada a jusante do sistema de cascatas de AH.

Na Tabela 4.30 estão expostos os valores de MAE obtidos na aplicação dos modelos de previsão de vazão considerando a variabilidade espacial utilizando a mesma configuração de alimentação já explicada anteriormente. Em seguida, é mostrada a Figura 4.44, que permite a visualização gráfica desses resultados.

Tabela 4.30: Valores de MAE para previsão de vazão com variabilidade espacial

Variáveis regressoras de origem	Séries a prever						
	ST2	ST3	ST4	ST5	ST6	ST7	ST8
ST1	0.26	0.30	1.33	2.25	3.89	4.16	0.44
ST2		0.30	1.32	2.20	3.87	4.17	0.44
ST3			1.32	2.16	3.90	4.08	0.46
ST4				2.14	4.04	4.05	0.69
ST5					4.00	4.02	0.69
ST6						2.99	0.54
ST7							0.44

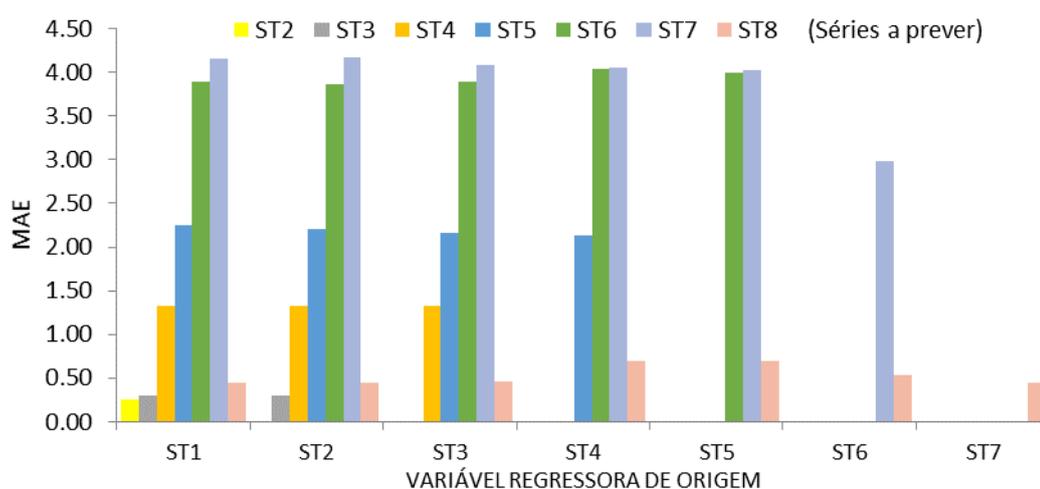


Figura 4.44: Visualização gráfica do MAE na previsão com variabilidade espacial

Analisada pelo critério MAE, a performance dos modelos seguiu padrão semelhante ao encontrado com o NSEiQ, com algumas modificações. Ou seja, houve degradação da qualidade da previsão em função da distância entre os pares de estações, melhor desempenho nos modelos de previsão das estações de montante e maior correspondência entre ST6 e ST7 face às demais combinações para a entrada de ST7, denotando certa incompatibilidade com as outras estações de montante. No entanto, duas considerações merecem destaque por se diferenciarem dos resultados analisados por NSEiQ. A primeira delas é que, pelo exame dos erros absolutos médios, a performance das previsões de ST4 se manteve notadamente melhor que aquela por ST5. A segunda consideração é mais relevante, e diz respeito ao desempenho das previsões de ST8, que se mostrou equiparável ao obtido com a previsão de ST3, ou seja, entre as de melhor qualidade de todo o sistema. Essa observação é condizente com aquela do item 4.3.2 – Previsão de vazão entre séries de estações adjacentes.

Os valores dos resultados do coeficiente de determinação R^2 para as previsões com variabilidade espacial na bacia estão expostos na Tabela 4.31 e podem ser visualizados graficamente na Figura 4.45. Os índices relativos à boa previsão ($R^2 \geq 0,80$) e à regular capacidade de previsão ($0,80 > R^2 \geq 0,50$) também são apresentados nessa ilustração.

Tabela 4.31: Valores de R^2 para previsão de vazão com variabilidade espacial

		Séries a prever						
		ST2	ST3	ST4	ST5	ST6	ST7	ST8
Variáveis regressoras de origem	ST1	0.97	0.93	0.79	0.79	0.58	0.49	0.66
	ST2		0.93	0.79	0.80	0.59	0.49	0.66
	ST3			0.82	0.82	0.60	0.51	0.67
	ST4				0.82	0.61	0.56	0.67
	ST5					0.64	0.53	0.67
	ST6						0.75	0.65
	ST7							0.66

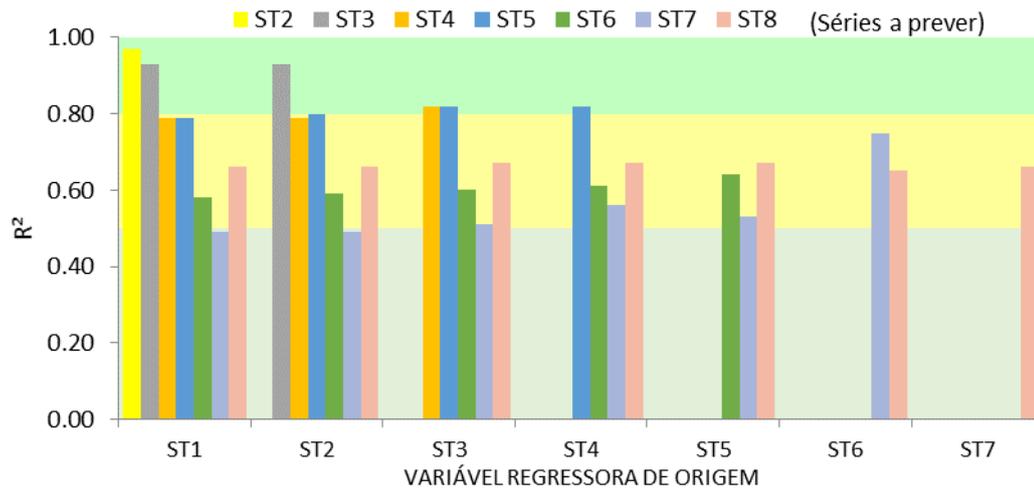


Figura 4.45: Visualização gráfica do R^2 na previsão com variabilidade espacial

De modo semelhante ao NSEiQ, a análise dos resultados com enfoque na característica de dispersão dos dados apontou melhor capacidade de reprodução de vazões nas estações de montante, sobretudo até ST5. Entretanto, houve expressiva perda de qualidade de desempenho nas previsões das estações de jusante, novamente com destaque para ST6 e ST7. Uma observação em especial diz respeito à qualidade das previsões de ST6, que, dessa vez, se mostrou consideravelmente melhor que ST7, aproximando-se de ST8.

No que tange à aplicabilidade operacional, a previsão de vazões com variabilidade espacial permite antever as séries por meio de modelos baseados em dados de estações que não somente as vizinhas, o que confere maior segurança a um eventual sistema de alerta na bacia. Com efeito, tal modelo de regressão possibilita constituir uma rede de relações entre séries de diferentes locais, oferecendo certa autonomia a algumas previsões. Um exemplo prático dessa aplicação é no caso de ausência de dados de uma ou mais séries de dados.

A dificuldade que os modelos apresentaram para a reprodução de vazões de determinadas séries, por exemplo ST6 e ST7, é coerente com resultados obtidos por Napolitano *et al.* (2011). Por meio de um estudo utilizando apenas as RNA, e comparando os modelos simples com modelos híbridos RNA + EMD, esses autores encontraram maiores erros na previsão de vazões diárias nos interstícios com grande quantidade de energia, interpretada como aqueles de elevada oscilação, quando comparados com séries predominantemente caracterizadas por oscilações médio-baixas. Isso pode ser explicado pela dificuldade de captura de informações suficientes a

fim de reproduzi-las posteriormente em uma fase de teste, o que ocorre pela ausência de padrões detectáveis pelos modelos de aprendizado de máquina e, concomitante ou não, em razão da maior não-linearidade dos processos envolvidos. Constatações como essas podem ser utilizadas pelo gestor de recursos hídricos com intuito de auxiliar determinadas regras de funcionamento dos aproveitamentos hidrelétricos, especialmente de jusante, de modo que suas operações resultem em menores oscilações do comportamento hídrico, o que, independentemente da implantação de um sistema de previsões de alerta, se aproximaria da naturalidade do escoamento fluvial.

Nos três critérios de desempenho de modelos, foi notado que as previsões de ST8 mantiveram valores próximos entre si para todas as combinações de entrada de montante, desde ST1 até ST7. Além disso, conforme descrito no Quadro 4.1, que dispõe sobre as variáveis regressoras dos modelos de previsão com variabilidade espacial, em todos os ajustes houve o emprego da série original de jusante com defasagem temporal mínima de uma hora. Tal observação suscitou a hipótese de os resultados da previsão de algumas séries, como a ST8, serem sobretudo decorrentes da relação com a própria série defasada, sem contribuições importantes advindas das estações de montante. Para essa averiguação, foi realizado um estudo comparativo a fim de analisar as vantagens da inserção das séries de montante no modelo de previsão de vazões frente ao uso de um modelo simplificado, sem dependência dos dados de montante.

Para tanto, foram simulados modelos de previsão sendo admitidos como entrada somente os dados da série a ser prevista (ST_x) com defasagem temporal horária (ST_x_lag1) ou de duas horas (ST_x_lag2), de acordo com o ajuste obtido na primeira etapa de previsão de vazões, indicado na Tabela 4.25. Seus resultados foram comparados com aqueles encontrados utilizando modelos de previsão de vazão que incluíssem dados originais da estação de montante (ST_{x-1}), por vezes, combinados com suas séries decompostas. Todos os modelos verificados obedeceram a conformação do tipo RPG + S/D ou RPG + TWD.

Com base nesse procedimento, foram organizadas tabelas que permitem contrastar a condição de aprimoramento ou não da performance dos modelos, quando inseridos dados da estação de montante, para cada par de estações. Assim, na Tabela 4.32 são apresentados os resultados comparativos de NSEiQ, enquanto na Tabela 4.33 estão os resultados de MAE e na Tabela 4.34 estão os resultados de R^2 para esse experimento.

Tabela 4.32: Desempenho dos modelos com o uso entrada das séries de montante em comparação ao uso exclusivo das séries de jusante, segundo o critério de NSEiQ

Para prever	Regressoras de jusante	NSEiQ teste	Regressoras de montante e jusante	NSEiQ teste	Desempenho com inclusão de variáveis regressoras de montante		
					Pior	Igual	Melhor
ST2	ST2_lag1 + ST2_lag2	0.96	ST1 + ST2_lag1 + ST2_lag2	0.96		X	
ST3	ST3_lag1 + ST3_lag2	0.93	ST2 + ST3_lag1 + ST3_lag2	0.93		X	
ST4	ST4_lag1	0.78	ST3 + ST4_lag1 + D3 + D4	<u>0.80</u>			X
ST5	ST5_lag1	0.81	ST4 + ST5_lag1 + D3 + D4	<u>0.83</u>			X
ST6	ST6_lag1	0.44	ST5 + ST6_lag1 + D7 + D10	<u>0.49</u>			X
ST7	ST7_lag1	0.36	ST6 + ST7_lag1 + D1 + D3	<u>0.66</u>			X
ST8	ST8_lag1 + ST8_lag2	0.54	ST8_lag1 + ST8_lag2 + D9 + D10	<u>0.64</u>			X

Tabela 4.33: Desempenho dos modelos com o uso entrada das séries de montante em comparação ao uso exclusivo das séries de jusante, segundo o critério de MAE

Para prever	Regressoras de jusante	MAE teste	Regressoras de montante e jusante	MAE teste	Desempenho com inclusão de variáveis regressoras de montante		
					Pior	Igual	Melhor
ST2	ST2_lag1 + ST2_lag2	0.27	ST1 + ST2_lag1 + ST2_lag2	<u>0.26</u>			X
ST3	ST3_lag1 + ST3_lag2	0.32	ST2 + ST3_lag1 + ST3_lag2	<u>0.30</u>			X
ST4	ST4_lag1	1.33	ST3 + ST4_lag1 + D3 + D4	<u>1.32</u>			X
ST5	ST5_lag1	2.21	ST4 + ST5_lag1 + D3 + D4	<u>2.14</u>			X
ST6	ST6_lag1	<u>3.99</u>	ST5 + ST6_lag1 + D7 + D10	4.00	X		
ST7	ST7_lag1	4.22	ST6 + ST7_lag1 + D1 + D3	<u>2.99</u>			X
ST8	ST8_lag1 + ST8_lag2	0.69	ST8_lag1 + ST8_lag2 + D9 + D10	<u>0.44</u>			X

Tabela 4.34: Desempenho dos modelos com o uso entrada das séries de montante em comparação ao uso exclusivo das séries de jusante, segundo o critério de R^2

Para prever	Regressoras de jusante	R^2 teste	Regressoras de montante e jusante	R^2 teste	Desempenho com inclusão de variáveis regressoras de montante		
					Pior	Igual	Melhor
ST2	ST2_lag1 + ST2_lag2	0.96	ST1 + ST2_lag1 + ST2_lag2	<u>0.97</u>			X
ST3	ST3_lag1 + ST3_lag2	0.93	ST2 + ST3_lag1 + ST3_lag2	0.93		X	
ST4	ST4_lag1	0.79	ST3 + ST4_lag1 + D3 + D4	<u>0.82</u>			X
ST5	ST5_lag1	0.80	ST4 + ST5_lag1 + D3 + D4	<u>0.82</u>			X
ST6	ST6_lag1	0.58	ST5 + ST6_lag1 + D7 + D10	<u>0.64</u>			X
ST7	ST7_lag1	0.48	ST6 + ST7_lag1 + D1 + D3	<u>0.75</u>			X
ST8	ST8_lag1 + ST8_lag2	<u>0.67</u>	ST8_lag1 + ST8_lag2 + D9 + D10	0.66	X		

A análise concomitante dos três critérios de desempenho demonstra a melhor condição de previsão de vazões quando são adicionados dados de montante (ST_{x-1}) combinados às séries de jusante, e, dependendo do ponto a ser previsto, com decomposições *wavelet* da série original de montante de cada par de estações. No entanto, uma exceção é pontuada, nas previsões das duas primeiras estações da bacia, onde os aproveitamentos hidrelétricos exercem menor transformação no comportamento hídrico. Isso porque nas previsões das séries ST2 e ST3 não houve expressiva diferença nos resultados gerais das três métricas de desempenho quando inseridas informações dos dados de montante de cada par. Essa característica é compatível com a análise das autocorrelações parciais, estudados no item 4.3.2, que indicam maior dependência da série com ela mesma nessas estações de montante da bacia, denotando alguma memória da série temporal com discretização horária.

A melhora do desempenho dos modelos de previsão quando há inserção de séries de montante, especialmente nos casos com maior efeito transformador dos hidrogramas, justifica o desenvolvimento de modelos de regressão não-linear por aprendizado de máquina, visto serem capazes de agregar diversas conexões entre os dados, e assim antever o comportamento futuro da série. Nessa circunstância, a condição do aumento relativo da complexidade do

comportamento fluvial também valoriza essa aplicação de modo integrado a um sistema de alerta de previsões na bacia hidrográfica, visto que nesses casos de aumento de complexidade, maiores esforços foram necessários para a implementação dos modelos.

4.3.5 Comentários gerais sobre os modelos de previsão de vazão

Os melhores ajustes dos modelos de previsão foram assumidos ao conceber a seguinte ordem hierárquica das métricas: NSEiQ, MAE e R^2 . Como foi notado, os modelos de regressão retornaram relativas boas respostas, tanto em relação às previsões por variáveis regressoras pelas estações vizinhas, quanto ao considerar as variabilidades temporal e espacial, sobretudo até a estação ST5.

Em toda a bacia, o pior ajuste ocorreu na previsão das séries ST6. De fato, mesmo nas verificações por meio de abordagens no domínio do tempo (primeiro objetivo específico deste trabalho), já se esperava dificuldade nas previsões dessa série, tendo em vista o intenso grau de oscilação e a elevada diferença entre as variâncias quando comparadas com as séries vizinhas. Vale lembrar que entre as estações telemétricas ST5 e ST6 são operadas a UHE Jauru e a PCH Indiavaí, sem monitoramento e divulgação pública de dados em escala horária em seu intermédio. Com isso, não é possível identificar se essa alteração brusca do comportamento do hidrograma decorre da operação de um ou dos dois aproveitamentos hidrelétricos. De toda forma, alterações em grau semelhante sequer foram observadas quando comparadas séries de diversos outros pares de AHs, mesmo nos experimentos com variabilidade espacial, situação em que eram ponderados vários AHs entre duas estações telemétricas.

Na maior parte dos casos em que são obtidas métricas de desempenho de previsão de vazões com qualidade razoável, como nas previsões ST6-ST7 e de ST7-ST8, os erros das vazões mínimas absolutas e dos primeiros quartis permaneceram consideravelmente pequenos. Esse aspecto favorece a proposta de um estudo de viabilidade para um programa de sistema de alertas com enfoque para o condicionamento às vazões mínimas, com possibilidade de intervenções excepcionais na operação dos AHs de montante para o atendimento das vazões críticas e de oscilações.

No que compete à capacidade de antecipação temporal, os modelos de previsão permitem abranger algumas escalas subdiárias e até diária, dependendo o caso. Eles apontam para a viabilidade de sistemas de alerta até a estação ST5 sem grandes dificuldades. Foi demonstrada a boa qualidade na reprodução de vazões com antecipação de 24h para as estações ST2 e ST3; ou de até 12h, com razoável qualidade, para as estações ST4 e ST5. No que tange às três estações de jusante, o tempo hábil de resposta para possíveis modificações das vazões turbinadas é consideravelmente limitado, indicando o tempo máximo de antecipação de até três horas. Sendo assim, alguns desafios se mostraram evidentes, especialmente quanto à inclusão dessas três estações de jusante em um eventual sistema de alerta. Vale retomar que os três empreendimentos de jusante na bacia (PCH Indiavaí, PCH Salto e PCH Figueirópolis), respectivamente localizados imediatamente a montante das estações ST6, ST7 e ST8, possuem similaridades em relação a diversas características construtivas, entre elas, a de serem operadas com vazão máxima e de serem dotadas de barragem de nível com interrupção completa do escoamento fluvial.

Particularmente em relação às previsões por RNA, a maioria dos melhores ajustes ocorreu com apenas um nó na camada intermediária. De alguma maneira, foi notado que essa característica se ressaltou nas melhores previsões, enquanto naquelas cujos resultados apresentaram pior desempenho, como em ST5-ST6, o modelo requisitou maior complexidade, exigindo aumento do número de nós intermediários. Durante a fase de ajuste, além da procura pelo número adequado de nós intermediários, houve também variação dos valores do hiperparâmetro *decay*, que se estendeu entre 0,005 e 0,5. Em relação às previsões por meio da RPG, em todos os casos, os melhores ajustes ocorreram com o parâmetro *sigma* $\sigma = 0,005$. Identificar esse padrão facilitou sobremaneira o ajuste dos modelos, pois os melhores resultados puderam ser encontrados com menor esforço computacional e humano, quando comparado com as RNA. Dessa forma, após encontrado o valor mais adequado do parâmetro *sigma*, as principais dificuldades se limitaram em variar as séries de entrada do modelo de Processos Gaussianos.

No que concerne às variáveis regressoras para os modelos como um todo, houve razoável consenso sobre as reais vantagens da inserção de sinais decompostos, quais as frequências mais adequadas, ou qual tipo de decomposição temporal melhor se ajustou ao comportamento das séries. Com alguma tolerância, é possível admitir que modelos híbridos RPG apresentaram boas respostas com componentes espectrais de alta frequência. Isso porque as cinco melhores

previsões entre estações adjacentes ocorreram com subsinais até o D4, para o RPG + TWD, e até o imf4, para o RPG + EMD. Não foram encontradas na literatura científica aplicações de modelos de previsão de vazão horária com implementação da RPG, em circunstâncias semelhantes às utilizadas neste trabalho, para a comparação dos resultados.

Por se tratar de uma bacia de pequenas dimensões, bem como de empreendimentos de pequena escala, acredita-se que o intervalo disponibilizado pela previsão de vazões das estações a jusante seja suficiente para que, a partir dessas estimativas, o gestor possa decidir sobre a manutenção ou não da abertura das pás móveis dos rotores, e a subsequente execução dessas medidas nos aproveitamentos hidrelétricos.

O tempo de processamento computacional entre o emprego dos modelos RNA e RPG foi semelhante, considerando a extensão do sinal original de 2048h. As principais variações do tempo ocorreram em razão do número de entradas e da grade de parâmetros na fase de treinamento. Nesse sentido, vale salientar que o tempo requerido pelos Processos Gaussianos aumenta exponencialmente em função do comprimento da série de dados. Essa característica é inerente ao método do RPG, que faz uso de operações matriciais para estabelecer as conexões entre as variáveis explicativa e resposta. Com efeito, séries temporais muito extensas podem inviabilizar o uso da RPG, sendo esta a sua principal desvantagem. Em contrapartida, séries menores a favorecem.

Por fim, a apreciação dos resultados por meio de três principais critérios de desempenho de modelos utilizados em diversos pares de estações denotou a importância do planejamento da definição das métricas, relacionadas com o foco para cada aplicação. Neste trabalho, algumas vezes, os critérios relativos NSEiQ e R^2 apontaram qualidades de previsão distintas entre grupos de diferentes previsões, quando comparados principalmente com o MAE. Isso pode ter relação com a característica absoluta do MAE e a faixa mais representativa dos desvios das previsões, concentrados ora nas maiores, ora nas menores magnitudes. Portanto, para a escolha da melhor combinação dessas medidas frente aos ajustes, foram ponderadas peculiaridades tais como a insensibilidade do NSEiQ frente aos erros de maiores valores e a possibilidade de erros sistemáticos não serem detectados pelo MAE.

5 CONCLUSÕES

O presente trabalho visa contribuir com a minimização de suposições não científicas a respeito da construção de diversas pequenas barragens sem estudo integrado das respostas nas vazões de curto período ao longo do rio. Em razão da maioria dos empreendimentos ter características de impacto ambiental reduzido, como a operação a fio d'água, esse assunto tem gerado grande especulação sobre as interferências que são causadas pelos aproveitamentos hidrelétricos.

Na primeira fase de resultados desta pesquisa, o comportamento do padrão dos hidrogramas de estações telemétricas intermediárias a uma cascata de aproveitamentos hidrelétricos foi analisado por meio de duas abordagens principais. A primeira delas se limita ao domínio do tempo, com discretização em escala horária. A segunda análise de padrão de vazões abrange o domínio tempo-frequência, com discretização em escala diária.

No tocante aos indicadores de alterações hidrológicas no domínio do tempo, os resultados evidenciaram efeitos de *hydropeaking* que submetem os ciclos naturais da bacia, indicando sobretudo elevação de intensidade das oscilações nas estações a jusante. Por um lado, houve pouco aumento de oscilações no trecho fluvial ST2-ST3, onde se localiza a primeira barragem, de alguma maneira se aproximando ao comportamento observado a montante. Por outro lado, os segmentos fluviais intermediários às estações ST3-ST4, ST5-ST6 e ST7-ST8 se destacaram em relação à mudança relacionada às inflexões dos hidrogramas. Ainda assim, mesmo para as demais estações a jusante das barragens, outras análises permitiram constatar que as amplitudes de vazão aumentaram expressivamente quando comparadas com as observações das duas estações a montante do primeiro barramento.

Com referência à análise de periodicidades no domínio tempo-frequência, a transformada *wavelet* contínua demonstrou que pode contribuir substancialmente para o entendimento do comportamento hidrológico de uma bacia, permitindo analisar os efeitos cíclicos das séries históricas. O método concebido para a análise periódica por meio da potência espectral *wavelet* e da coerência *wavelet* pareceu ser vantajoso, visto não requerer especificações prévias de eventos ou ciclos relevantes. Além disso, essa abordagem dispensou informações sobre características físicas dos reservatórios ou ainda procedimentos operacionais dos AHs.

Embora não possam ser firmadas declarações conclusivas em relação à mudança de padrões cíclicos na bacia, uma vez que a contribuição incremental não pôde ser isolada dos efeitos das barragens, há fortes evidências de que as operações de turbina causem alteração no comportamento oscilatório das vazões. Em um sistema hídrico sem mudanças no comportamento fluvial, é esperado o aumento da importância das oscilações de longo período e a atenuação das oscilações de curto prazo; ou, pelo menos, a manutenção dos ciclos naturais durante do percurso, supostamente semelhantes aos observados nas estações ST1 e ST2. No entanto, as análises de WPS e WCO apontaram a situação contrária.

A partir do entendimento de que o funcionamento de um sistema de cascata de pequenos AHs seja suficiente para modificar o comportamento do padrão oscilatório natural de vazões, a segunda parte dos resultados do presente trabalho se dedicou ao desenvolvimento de modelos de regressão não-linear para previsão de vazões em escala horária. O intuito principal é oferecer subsídios para um eventual sistema de alerta de vazões críticas e assim auxiliar a tomada de decisões em uma bacia hidrográfica sob as condições relatadas ao longo deste trabalho.

Após descartada a viabilidade de previsão de vazões por *baselines* como o ARIMA, foram desenvolvidos ao todo seis modelos de previsão, constituídos pela combinação das técnicas de aprendizado de máquina RNA e RPG sem decomposição de séries temporais e com decomposição via TWD e EMD. Três grandes grupos de aplicações foram implementados. O primeiro deles consistiu em alimentações prioritariamente por séries de vazões registradas nas estações adjacentes de montante e defasagens temporais da estação de jusante, considerando antecipação horária. Esse primeiro grupo foi importante para realizar verificações preliminares com os modelos frente aos hiperparâmetros e tipos de preditores, bem como para estabelecer critérios gerais de modelagem na bacia. Assumida a estrutura dos melhores modelos e suas configurações de ajuste, foi implementado o segundo grupo de aplicações para a previsão, porém, considerando cinco diferentes intervalos temporais horários, interpretados como de discretizações representativas à tomada de decisão dos operadores dos AHs. Por fim, o terceiro grupo foi constituído por variabilidade espacial de previsão de vazões, ao ponderar todas as combinações das séries de montante de cada par de estações como variável regressora dos modelos.

Em síntese, os resultados com os três grupos de previsão verificados no presente trabalho apresentaram performance aproximadamente padronizada. Foram obtidos melhores

desempenhos nas estações de montante e menores antecipações horárias, além de algumas limitações nas previsões das estações de jusante. Ainda assim, mesmo nessas estações de jusante, os erros dos valores mínimos absolutos e dos primeiros quartis de vazão, em geral, se mostraram relativamente pequenos.

No que compete à experiência com o desenvolvimento e aplicação das duas técnicas de aprendizado de máquina implementadas neste trabalho, a RPG retornou resultados pouco superiores à RNA. Contudo, seu maior diferencial se evidenciou pelo aspecto pragmático do emprego da regressão por Processos Gaussianos, tanto para o ajuste (pela menor quantidade de hiperparâmetros e suas variabilidades), quanto em relação à estabilidade dos resultados ante as diversas entradas examinadas, denotando maior robustez.

De tal modo, na aplicação da RPG, é necessário estabelecer uma estrutura que requer alguma prévia sobre a natureza da série que se deseja modelar, o que é expresso pela função de covariância, ou, função *kernel*. A função *kernel* exponencial quadrática possui comportamento suavizado, e se mostrou adequada às séries utilizadas neste trabalho. Adicionalmente, o modelo híbrido RPG + TWD tendeu a retornar melhores resultados, especialmente quando utilizados subsinais de maiores frequências nas entradas desses modelos. Possivelmente, essas menores frequências dos componentes TWD são compatíveis, ao menos em parte, com algum comportamento cíclico remanescente no corpo hídrico, mesmo após a passagem da água pelas turbinas. Apesar da usual alimentação de modelos com subsinais decompostos, em todos os casos, foi permanente incluir os dados da série a ser prevista com defasagem temporal horária na combinação com outras variáveis regressoras.

Os estudos de previsão de vazão desenvolvidos nesta pesquisa se basearam em modelos orientados por dados, os quais permitiram relacionar matematicamente as informações extraídas exclusivamente pelas séries temporais de vazão. Assim, não foram necessários dados multivariados, contendo, por exemplo, fatores relacionados à hidroclimatologia, consumo de energia elétrica ou regras operacionais dos AHs. Com efeito, ao admitir entradas e saídas correspondentes, associadas a processos internos que dependem do modelo utilizado, foi possível obter estimativas de vazão sem qualquer informação pertinente ao processo físico do funcionamento dos aproveitamentos hidrelétricos, incluindo a própria regra de operação desses AHs. Nesse sentido, a utilização de um suposto modelo físico para a compreensão dos fenômenos estudados poderia assumir um caráter complexo e dinâmico, que possivelmente

exigiria frequentes reconfigurações a cada mudança de operação do sistema. Claramente, a obtenção de resultados por intermédio de modelos orientados por dados se demonstrou importante, tendo em vista a grande quantidade de detalhes intrínsecos ao sistema de cascata desses empreendimentos, cujas informações normalmente não são de fácil disponibilidade.

Tal como é esperado para modelos supervisionados de aprendizado de máquina, as séries de entradas exercem influência direta na qualidade da previsão consoante a identificação de padrões com as variáveis resposta. Sendo assim, foi constatado que a dificuldade na reprodução de vazões da série de teste é diretamente proporcional à perturbação que o empreendimento hidrelétrico é capaz de provocar no hidrograma. Isso se mostrou evidente ao contrastar os resultados sobre a alteração de padrões dos ciclos de vazão, da primeira parte deste trabalho, com as respostas dos modelos de previsão, apresentadas na segunda parte.

De modo geral, é possível afirmar que os objetivos propostos para o presente trabalho foram alcançados. Entretanto, são necessárias considerações relativas a determinadas questões não exploradas e que podem ser assumidas como recomendações para desenvolvimentos futuros. Essa abordagem é elencada no próximo capítulo.

6 RECOMENDAÇÕES

No que compete à abordagem sobre os ciclos predominantes de vazão no sistema de cascatas de aproveitamentos hidrelétricos, o emprego da transformada *wavelet* contínua permitiu avaliar alterações significativas no padrão cíclico em determinadas escalas temporais, que variaram de aproximadamente quatro dias a pouco menos que 64 dias. Ressalta-se que a presente pesquisa se limitou a identificar essas interferências, entretanto, não se estendeu para as fronteiras do conhecimento em relação a quais consequências são provocadas à comunidade biótica ou ao ecossistema, em razão dessas imposições às características hidrológicas naturais.

Em relação ao desenvolvimento de modelos de previsão de vazão, algumas recomendações para trabalhos futuros são pontuadas. Ainda que haja diversas proposições para a definição dos dados de entrada, grande parte dos trabalhos realiza essa etapa unicamente por tentativa e erro, muitas vezes sem análise detalhada do desempenho matemático ou ocorrência de supertreinamento. Neste trabalho, tal emprego foi evitado, ao assumir alguns critérios anteriores a essa prática. No entanto, em última medida, muitas definições ainda foram realizadas por esse meio, o que se tornou desgastante ao operador. Logo, em situações com diversas possibilidades de combinações de preditores (por exemplo, quando há decomposições de séries), recomenda-se adotar técnicas automatizadas para extrair o melhor conjunto de entradas que possam eliminar variáveis desnecessárias e reduzir a complexidade dos modelos. Nesse sentido, pesquisas que tratam desse assunto podem levar tal abordagem adiante por meio de otimização computacional para estabelecer índices relacionados à contribuição de cada variável regressora ao compor um modelo (CRONE & KOURENTZES, 2010; OLIVEIRA *et al.*, 2015).

Outro desafio para trabalhos futuros diz respeito ao desenvolvimento de um modelo de regressão que contrabalanceie bons resultados de previsão de vazões com as incertezas preditivas iterativamente, e de forma a propagar as estimativas de previsões e incertezas para estações de jusante compondo uma estrutura de correlação temporal e espacial. No âmbito de modelos de regressão, é cientificamente consensual a necessidade de aprimoramentos de previsões que informam não só a estimativa pontual, mas também a segurança sobre essa estimativa. Nesse sentido, a regressão por Processos Gaussianos apresenta vantagem, visto que a distribuição marginal do valor estimado é intrínseca à formulação do modelo (RASMUSSEN & WILLIAMS, 2006). No entanto, algumas abordagens para estimativas de intervalos

preditivos com o uso do RNA, geralmente baseados em *ensemble*, também merecem atenção (KHOSRAVI *et al.* 2011; KASIVISWANATHAN *et al.* 2016).

Os resultados obtidos no decorrer desta pesquisa ressaltam a importância do gerenciamento dos recursos hídricos na bacia de forma mais complexa que somente aquele que define o licenciamento ambiental para o uso da água. De certa forma, os modelos desenvolvidos neste trabalho podem servir de subsídio a um eventual sistema de alerta de vazões mínimas no âmbito de um planejamento integrado. É válido pontuar que a responsabilidade sobre esse sistema cabe a uma entidade maior que a assumida por um único empreendimento. Em outras palavras, essa atribuição deveria ser de um órgão com compromisso relacionado à segurança do sistema hídrico local ou entidade criada pelo complexo de empreendimentos, ou ainda o ONS, se essa passar a assumir responsabilidade também sobre questões do ecossistema, e não apenas a pertinente à disponibilidade de água e de energia elétrica.

Seguramente, as ferramentas desenvolvidas e exploradas no presente trabalho podem contribuir com o auxílio à tomada de decisões para melhor operar um grupo de empreendimentos. Portanto, a partir do conhecimento do comportamento de vazões a montante é possível antecipar ou evitar maiores prejuízos sociais e ambientais em determinadas condições hidrológicas críticas. Nesse sentido, dois aspectos que requerem maiores estudos são destacados. O primeiro deles está relacionado aos limites para os extremos mínimos nos hidrogramas, por ser a faixa em que o efeito amortecedor dos reservatórios é majorado, visto que em geral os AHs a fio d'água tendem a não reduzir as vazões máximas. O segundo aspecto é concernente ao grau de oscilação dos hidrogramas de jusante dos empreendimentos, o que pode alterar pulsos de curta duração, principalmente.

Em particular na bacia hidrográfica onde foram aplicados os métodos desenvolvidos nesta pesquisa, a eventual implantação de um sistema de alerta que inclua as estações ST6 e ST7 certamente pode ser reforçada com adaptações no procedimento operacional dos AHs de forma a aproximar as descargas ao padrão oscilatório de montante. É importante salientar que essa é uma demanda já bastante discutida na primeira parte dos resultados do presente trabalho, sobre efeitos nos ciclos de vazão da bacia hidrográfica, e que foi reforçada na segunda parte. Desse modo, além de favorecer o comportamento hídrico natural e todos os fatores bióticos envolvidos em qualquer magnitude de vazões, tal medida beneficia a captura das relações entrada-saída pelos modelos de aprendizado de máquina. Consequentemente, o tempo de resposta que os

operadores dos AH possuem para se adaptar a modificações que se fizerem necessárias é ampliado, resultando em maior adequabilidade do sistema de alerta de vazões tanto nos segmentos fluviais intermediários à cascata de AHs quanto à sua jusante.

Com referência às previsões de ST8, seus resultados se mostraram com qualidade ligeiramente superior às duas estações imediatamente a montante. No entanto, isso não exclui a sugestão de que essa estação também passe por um programa de readequação no seu sistema de operação. É importante destacar que, até o momento, a estação ST8 é considerada a mais relevante no monitoramento de um eventual sistema de alerta na bacia, visto estar localizada a extremo jusante do complexo de cascatas de AHs. Com efeito, sua defluência é a principal responsável por dar a tônica ao comportamento de vazões que irá se propagar ao longo do corpo hídrico sem outras grandes interferências antrópicas pontuais.

Por fim, não obstante a bacia do rio Jauru possuir área de contribuição total de 15.800 km², a área de estudo compreendeu o monitoramento pelas estações telemétricas, ou seja, 3.093 km². No entanto, a corrente pesquisa se dá no contexto de uma região hidrográfica de 362.376 km² com grande interdependência de muitas variáveis que garantem a manutenção do sistema hídrico e que passa por intensa transformação do uso do solo e da água sem compreensão científica suficiente para assegurar o equilíbrio necessário. Ao retomar esse aspecto, no que compete ao uso de recursos hídricos, destaca-se que mais estudos são necessários para o aprimoramento da compreensão do potencial de modificação de padrões de ciclos de água e também das condições de previsão de vazões, de modo a incorporar modelos com outras pequenas bacias hidrográficas vizinhas que também passam por transformação. Nesse sentido, é válido mencionar o interesse comum na elaboração de um sistema de alerta integrado a toda a grande planície de inundação.

7 REFERÊNCIAS BIBLIOGRÁFICAS

- ABDULLAH, I. 2016. Wavelet Coherence using R: Tutorial. Disponível em: https://rpubs.com/ibn_abdullah/rwcoher. Acesso em: 16 Jan 2018.
- ADAMOWSKI, J; CHAN, HF. 2011. A wavelet neural network conjunction model for groundwater level forecasting. *J. Hydrol.*, v. 407, n. 1, p. 28-40.
- ADAMOWSKI, J; CHAN, E; PRASHER, S; OZGA-ZIELINSKI, B; SLIUSAREVA, A; 2012. Comparison of multiple linear and non-linear regression, autoregressive integrated moving average, artificial neural network, and wavelet artificial neural network methods for urban water demand forecasting in Montreal, Canada. *Water Resour. Res.*, v. 48, n. 1.
- ADDISON, PS. 2017. *The illustrated wavelet transform handbook: introductory theory and applications in science, engineering, medicine and finance*. CRC Press.
- AGUIRRE, LA. 2015. *Introdução à identificação de sistemas –Técnicas lineares e não-lineares aplicadas a sistemas reais*. 4ª Ed. Belo Horizonte: Editora UFMG.
- ANA. 2019. Agência Nacional de Águas. *Elaboração de empreendimentos hidrelétricos na região hidrográfica do rio Paraguai*. Relatório de andamento 03: Potenciais impactos de barragens sobre o regime hidrológico nos rios da RH Paraguai. Brasília/DF. Disponível em: <https://www.ana.gov.br/gestao-da-agua/planejamento-dos-recursos-hidricos/plano-de-recursos-hidricos-rio-paraguai/estudos-de-avaliacao-dos-efeitos-da-implantacao-de-empreendimentos-hidreletricos/relatorio-final-de-diagnostico_hidrologia_parte1.pdf>. Acesso em: 24 jun 2020.
- ANA/GEF/PNUMA/OEA. 2004. *Implementação de práticas de gerenciamento integrado de bacia hidrográfica para o Pantanal e bacia do Alto Paraguai*: relatório final. Brasília: ANA.
- ANEEL. 2002. Agência Nacional de Energia Elétrica. *Atlas de energia elétrica do Brasil*. Brasília: ANEEL.
- ANEEL. 2020. Agência Nacional de Energia Elétrica. *Sistema de informações de geração da ANEEL – SIGA*. Disponível em: <<https://bit.ly/2IGf4Q0>>. Acesso em 24 jun 2020.
- ASSAD, ED; SANO, EE; MASUTOMO, R; CASTRO; LHR; SILVA, FAM. 1993. Veranicos na região dos cerrados brasileiros: frequência e probabilidade de ocorrência. *Pesquisa Agropecuária Brasileira*, v. 28, n. 9.
- AYALEW, TB; KRAJEWSKI, WF; MANTILLA, R; WRIGHT, DB; SMALL, SJ. 2017. Effect of spatially distributed small dams on flood frequency: insights from the soap creek watershed. *Journal of Hydrologic Engineering*, v. 22, n. 7.
- BOX, GEP; JENKINS, G M. 1970. *Time series analysis: Forecasting and control*. San Francisco: Holden-Day.
- BRAGA, AP; CARVALHO, APLF; LUDERMIR, TB. 2007. *Redes neurais artificiais: teoria e aplicações*. 2ª Ed. Rio de Janeiro: LTC Editora.
- BRUDER, A; TONOLLA, D; SCHWEIZER, SP; VOLLENWEIDER, S; LANGHANS, SD; WÜEST, A. 2016. A conceptual framework for hydropeaking mitigation. *Science of The Total Environment*, v. 568, p. 1204-1212.
- CAIXETA, RG. 2016. *Uma abordagem computacional para predição de mortalidade em UTIs baseada em agrupamento de Processos Gaussianos*. Dissertação (Mestrado em Ciência da Computação) – Universidade Federal de Goiás, Goiânia - GO.

- CAMPOS, MM; TRITICO, HM; GIRARD, P; ZEILHOFER, P; HAMILTON, SK; FANTIN-CRUZ, I. 2020. Predicted impacts of proposed hydroelectric facilities on fish migration routes upstream from the Pantanal wetland (Brazil). *River Res Appl*, v. 36, n. 3, p. 452-464.
- CARVALHO, JRP; ASSAD, ED; EVANGELISTA, SEM; PINTO, HS. 2013. Estimation of dry spells in three Brazilian regions - Analysis of extremes. *Atmos. Res*, v. 132-133, p. 12-21.
- CAZELLES B; CHAVEZ, M; BERTEAUX, D. MÉNARD, F; VIK, JO; JENOUVRIER, S; STENSETH, NC. 2008. Wavelet analysis of ecological time series. *Oecologia*, v. 156, n. 2, p. 287-304.
- CIRIA, TP; LABAT, D; CHIOGNA, G. 2019. Detection and interpretation of recent and historical streamflow alterations caused by river damming and hydropower production in the Adige and Inn river basins using continuous, discrete and multiresolution wavelet analysis. *Journal of Hydrology*, v. 578.
- CHOLLET, F; ALLAIRE, JJ. 2018. *Deep Learning with R*. Manning Publications.
- COSTA, V. 2017. Correlation and Regression. In: NAGHETTINI, M (Ed.). *Fundamentals of Statistical Hydrology*. Cham: Springer.
- COSTA, V; FERNANDES, W. 2017. Bayesian estimation of extreme flood quantiles using a rainfall-runoff model and a stochastic daily rainfall generator. *J. Hydrol.*, v. 554, p. 137-154.
- COUTO, TB A.; OLDEN, JD. 2018. Global proliferation of small hydropower plants - science and policy. *Frontiers in Ecology and the Environment*, v. 16, n. 2, p. 91-100.
- CRONE, SF.; KOURENTZES, N. 2010. Feature selection for time series prediction – A combined filter and wrapper approach for neural networks. *Neurocomputing*, v. 73, n. 10-12, p. 1923-1936.
- CUNHA, CN; JUNK, WJ. 2015. A classificação dos Macrohabitats do Pantanal Mato-grossense. In: CUNHA, CN; PIEDADE, MTF; JUNK, WJ (Org). *Classificação e delineamento das áreas úmidas brasileiras e de seus macrohabitats*. Cuiabá: EdUFMT, p. 77-122.
- DAWSON, CW; ABRAHART, RJ.; SEE, LM. 2007. HydroTest: a web-based toolbox of evaluation metrics for the standardised assessment of hydrological forecasts. *Environmental Modelling & Software*, v. 22, n. 7, pp. 1034–1052.
- FANTIN-CRUZ, I; PEDROLLO, O; GIRARD, P; ZEILHOFER, P; HAMILTON, SK. 2015. Effects of a diversion hydropower facility on the hydrological regime of the Correntes River, a tributary to the Pantanal floodplain, Brazil. *J. Hydrol*, v. 531, 810-820.
- FENCL, JS, MATHER, ME, COSTIGAN, KH, DANIELS, MD. 2015. How big of an effect do small dams have? Using geomorphological footprints to quantify spatial impact of low-head dams and identify patterns of across-dam variation. *PLoS One*, v. 10, n.11.
- GABOR, D. 1948. Theory of communications. Part 1: The analysis of information. *J. Institut. Electr. Engrs.*, v. 95, n. 38, p. 429-441.
- GAP. 2015. Grupo de acompanhamento da elaboração do plano de recursos hídricos da região hidrográfica do Paraguai. *Termos de referência para a elaboração do plano de recursos hídricos da região hidrográfica do rio Paraguai PRH- Paraguai*. ANA/CEHIDRO-MT/CERH-MS. Jun 2015. 55p.
- GEVREY, M.; DIMOPOULOS, I.; LEK, S. 2003. Review and comparison of methods to study the contribution of variables in artificial neural network models. *Ecol Model*, v. 160, n. 3.

- GOUHIER, TC; GRINSTED, A; SIMKO, V. 2019. Conduct univariate and bivariate wavelet analyses: Package 'biwavelet', version 20.19. Publication: 01 ago 2019.
- GRINSTED, A.; MOORE, JC; JEVREJEVA, S. 2004. Application of the cross wavelet transform and wavelet coherence to geophysical time series. *Nonlinear Proc Geoph*, v. 11.
- GROSSMANN, A; MORLET, J. 1984. Decomposition of Hardy function into square integrable wavelets of constant shape. *SIAM J. Math. Anal.*, v. 15, n. 4, p. 723-736.
- GUPTA, HV; SOROOSHIAN, S; YAPO, PO. 1998. Toward improved calibration of hydrologic models: Multiple and noncommensurable measures of information. *Water Resources Research*, v. 34, n. 4, p. 751-763.
- HAAS, NA; O'CONNOR, BL; HAYSE, JW; BEVELHIMER, MS; ENDRENY, TA. 2014. Analysis of daily peaking and run-of-river operations with flow variability metrics, considering subdaily to seasonal time scales. *J Am Water Resour As*, v. 50, n. 6, 1622-1640.
- HAUER, C; SIVIGLIA, A; ZOLEZZI, G. 2016. Hydropeaking in regulated rivers – From process understanding to design of mitigation measures. *Sci Total Environ*, v. 579, 22-27.
- HYNDMAN, RJ; ATHANASOPOULOS, G. 2018. *Forecasting: principles and practice*. OTexts.
- HUANG, NE; SHEN, Z; LONG, SR; WU, MC; SHIH, HH; ZHENG, Q; YEN, N; TUNG, CC; LIU, HH; 1998. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proc. Roy. Soc. Lond*, v. 454, n. 1971, p. 903-995.
- HUANG, NE; WU, Z. 2008. A review on Hilbert-Huang transform: Method and its applications to geophysical studies. *Reviews of geophysics*, v. 46, n. 2.
- HUANG, Y; SCHMITT, FG; LU, Z; LIU, Y. 2009. Analysis of daily river flow fluctuations using empirical mode decomposition and arbitrary order Hilbert spectral analysis. *J. Hydrol*, n. 373, v.1-2, 103-111.
- HUANG, S; CHANG, J; HUANG, Q; CHEN, Y. 2014. Monthly streamflow prediction using modified EMD-based support vector machine. *J. Hydrol*, v. 511, 764-775.
- ISMAIL, S; PANDIAHI, SM; SHABRI, A; MUSTAPHA, A. 2018. Comparative Analysis of River Flow Modelling by Using Supervised Learning Technique. In: *Journal of Physics: Conference Series*. IOP Publishing. 11p.
- JAIN, SK; MANI P, JAIN, SK; PRAKASH, P; SINGH, VP; TULLOS, D; KUMAR, S; AGARWAL, SP; DIMRI, AP. 2018. A Brief review of flood forecasting techniques and their applications. *International Journal of River Basin Management*, v. 16, n. 3, p. 329-344
- JUNK, WJ; BAILEY, PB; SPARKS, RE. 1989. The flood pulse concept in river-floodplain systems. *Can. J. Fish. Aquatic.*, v. 106, 110-127.
- KARATZOGLOU, A; SMOLA, A; HORNIK, K; NATIONAL ICT AUSTRALIA; MANISCALCO M; TEO, CH. 2019. *Kernel-Based Machine Learning Lab*. Version 0.9-29. Technical report, CRAN R. 12 nov 2019.
- KASIVISWANATHAN, KS; HE, J; SUDHEER, KP; TAY, JH. 2016. Potential application of wavelet neural network ensemble to forecast streamflow for flood management. *J. Hydrol*, v. 536, p. 161-173.

- KHOSRAVI, A; NAHAVANDI, S; CREIGHTON, D; ATIYA, AF. 2011. Lower upper bound estimation method for construction of neural network-based prediction intervals. *IEEE Transactions on Neural Networks*, v. 22, n. 3, p. 337-346.
- KIBLER, KM; ALIPOUR, M. 2017. Flow alteration signatures of diversion hydropower: An analysis of 32 rivers in southwestern China. *Ecohydrology*, v. 10, n. 5.
- KUMAR, D; KATOCH, SS. 2015. Sustainability suspense of small hydropower projects: A study from western Himalayan region of India. *Renewable Energy*, v. 76, p. 220-233.
- LABAT, D; ABABOU, R; MANGIN, A. 2000. Rainfall-runoff relations for karstic springs. Part II: continuous wavelet and discrete orthogonal multiresolution analyses. *J. Hydrol.*, v. 238, n. 3.
- LIU, Y; LIANG, XS; WEISBERG, RH. 2007. Rectification of the bias in the wavelet power spectrum. *Journal of Atmospheric and Oceanic Technology*, v. 24, n. 12, p. 2093-2102.
- LIU, Y; YANG, W; YU, Z; LUNG, I; YAROTSKI, J; ELLIOTT, J; TIESSEN, K. 2014. Assessing effects of small dams on stream flow and water quality in an agricultural watershed. *Journal of Hydrologic Engineering*, v. 19, n. 10.
- LU, W; LEI, H; YANG, D; TANG, L; MIAO, Q. 2018. Quantifying the impacts of small dam construction on hydrological alterations in the Jiulong River Basin of Southeast China. *J. Hydrol.*, v. 567, p. 382-392.
- MAHESWARAN, R; KHOSA, R. 2012. Comparative study of different wavelets for hydrologic forecasting. *Computers & geosciences*, v. 46, p. 284-295.
- MAIER, HR; JAIN, A; DANDY, GC; SUDHEER, KP. 2010. Methods used for the development of neural networks for the prediction of water resource variables in river systems: current status and future directions. *Environmental Modelling & Software*, v. 25, n. 8, 891-909.
- MALLAT, GS. 1989. A theory for multiresolution signal decomposition: the wavelet representation. *IEE Trans. Pattern Anal. Mach. Intell.*, v., 11, n. 7, p. 674-693.
- MARAUN, D; KURTHS, J. 2004. Cross wavelet analysis: significance testing and pitfalls. *Nonlinear Processes in Geophysics*, v. 11, n. 4.
- MISITI, M; MISITI, Y, OPPENHEIM, G; POGGI, JM. 2018. Matlab Wavelet Toolbox User's Guide. Revised for Version 4.15 (Release 2015b).
- MOSAVI, A, OZTURK, P, CHAU, KW. 2018. Flood prediction using machine learning models: Literature review. *Water SA*, v. 10, n. 11.
- MOTA, HO. 2011. Processamento de sinais de descargas parciais em tempo real com base em wavelets e seleção de coeficientes adaptativa espacialmente. Tese (Doutorado em Engenharia Elétrica) – UFMG, Belo Horizonte.
- NAPOLITANO, G; SERINALDI, F; SEE, L. 2011. Impact of EMD decomposition and random initialisation of weights in ANN hindcasting of daily stream flow series: An empirical examination. *Journal of Hydrology*, v. 406, n. 3-4, p. 199-214.
- NEVES, CF; MOURA, TGR; FORTES, CJ. 2012. Aplicação da Transformada de Hilbert-Huang para caracterização da dinâmica costeira. Parte 1: grandezas escalares. *Rev. Bras. Rec. Hídricas*, v. 17, n. 2, p. 143-146.
- NOURANI, V; BAGHANAM, AH; ADAMOWSKI, J; KISI, O. 2014. Applications of hybrid wavelet-Artificial Intelligence models in hydrology: A review. *J. Hydrol.*, v. 514, 358-377.

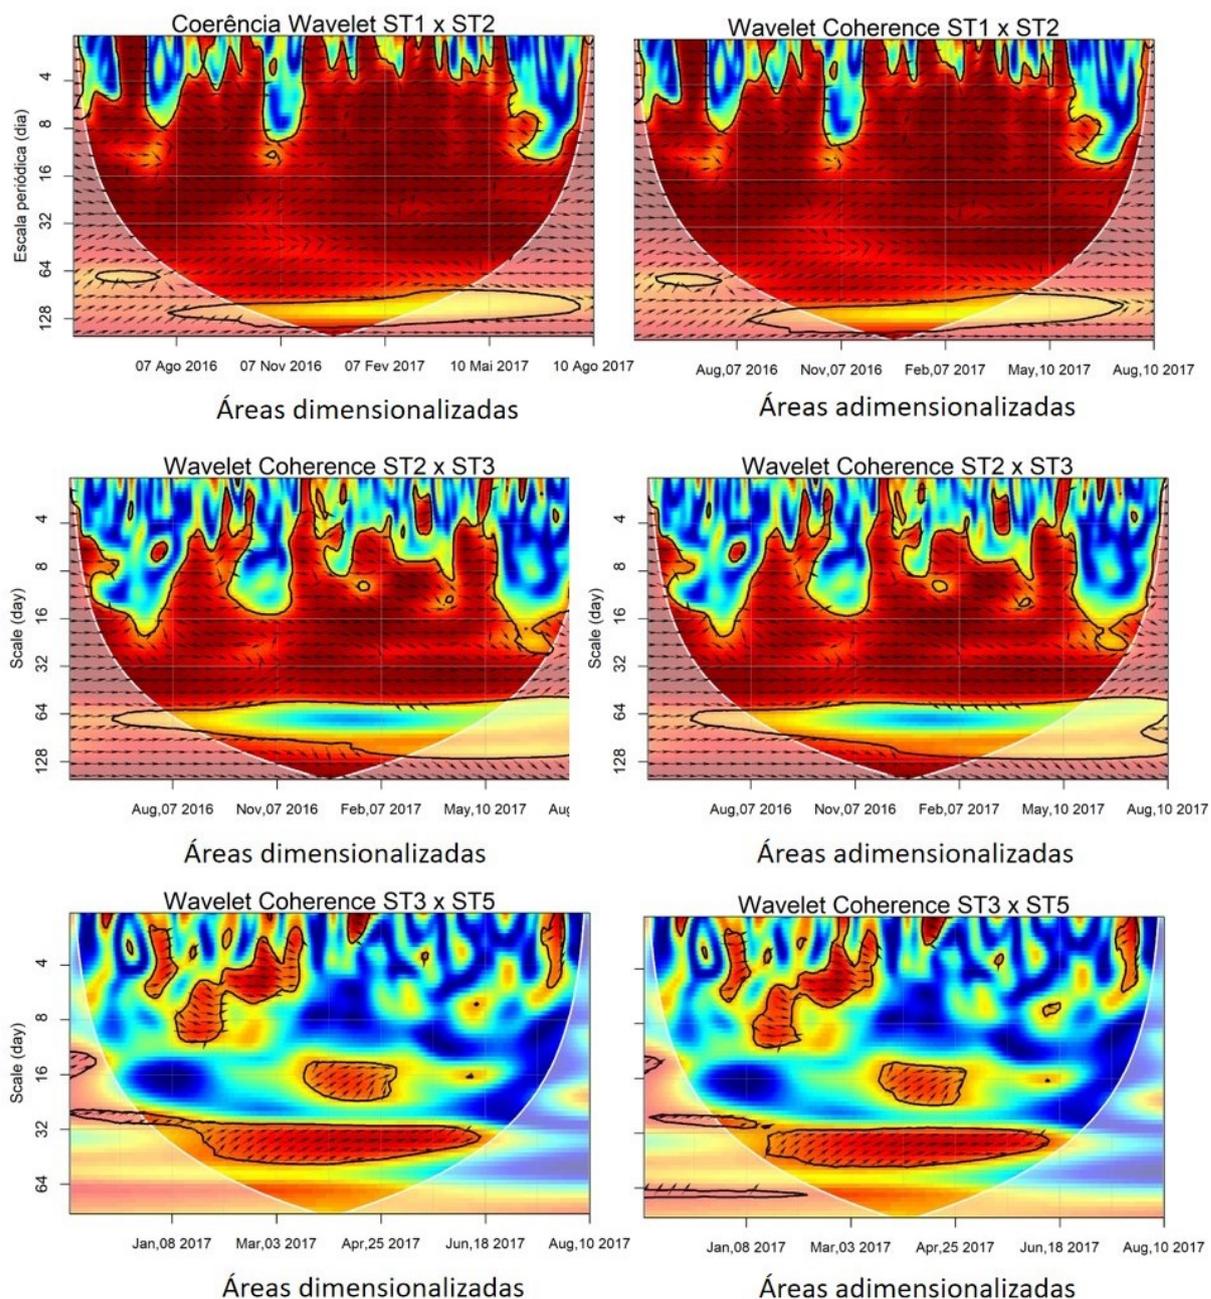
- OLIVEIRA, GG; PEDROLLO, OC; CASTRO, NMR. 2015. Simplifying artificial neural network models of river basin behaviour by an automated procedure for input variable selection. *Engineering Applications of Artificial Intelligence*, v. 40, p. 47-61.
- OLIVEIRA, MD; HAMILTON, SK; CALHEIROS, DF. 2019. Mass balances of dissolved solutes, nutrients, and suspended sediment as water moves through the Pantanal wetland to its outflow (Paraguay River). *Brazilian Journal of Water Resources*, v. 24, p. 1-15.
- ONS. 2017. Operador Nacional do Sistema Elétrico. *Manual de procedimentos da operação – Módulo 10*. Cadastro de informações operacionais hidráulicas da bacia do rio Paraguai. Código CD-OR.PY.PGY, Revisão 03, Item 2.3, vigência a partir de 27 Out 2017.
- ORD, K; FILDES, R; KOURENTZES, N. 2017. *Principles of business forecasting*, 2nd Ed. Wessex Press, Inc., New York, NY, USA. 544 p.
- ÖZGER, M; MISHRA, AK; SINGH, VP. 2010. Scaling characteristics of precipitation data in conjunction with wavelet analysis. *J. Hydrol.*, v. 395, n. 3-4, p. 279-288.
- PERTUSSATTI, CA. 2013. Veranicos no estado do Mato Grosso: análise da variabilidade espaço-temporal e modelagem estatística. Dissertação (Mestrado em Tecnologia Ambiental e Recursos Hídricos) – Universidade de Brasília, Brasília - DF.
- PERTUSSATTI, CA; LIMA, CHR; LEMOS, GM. 2013. A variabilidade espacial dos veranicos no estado do Mato Grosso. In: XX Simpósio Brasileiro de Recursos Hídricos. 2013. Bento Gonçalves, RS. *Anais...* Porto Alegre: ABRH.
- POFF, NL; SCHIMIDT, J. 2016. How dams can go with the flow. *Science*, v. 353, n. 6304.
- PUSHPALATHA, R; PERRIN, C; LE MOINE, N; ANDRÉASSIAN, V. 2012. A review of efficiency criteria suitable for evaluating low-flow simulations. *J. Hydrol.*, n. 420, pp. 171–182.
- RAMSAR. 2019. Ramsar Sites Information Services. Disponível em: <https://rsis.ramsar.org/>. Acesso em: 21 jun 2019.
- RASMUSSEN, CE; WILLIAMS, CK. 2006. *Gaussian processes for machine learning*. Cambridge, MA: MIT press.
- RASOULI, K; HSIEH, WW; CANNON, AJ. 2012. Daily streamflow forecasting by machine learning methods with weather and climate inputs. *J. Hydrol*, v. 414, p. 284-293.
- REBOITA, MS; GAN, MA; ROCHA, RP; AMBRIZZI, T. 2010. Regimes de precipitação na América do Sul: uma revisão bibliográfica. *Revista Brasileira de Meteorologia*, v. 25, n. 2.
- RICHTER, BD; BAUMGARTNER, JV; POWELL, J; BRAUN, DP. 1996. A method for assessing hydrologic alterations within Ecosystems. *Conservation Biology*, v. 10, n. 4, p. 1163-1174.
- RÖSCH, A; SCHMIDBAUER, H. 2018. Computational Wavelet Analysis. R Package: WaveletComp, version 1.1. Publication: 18 mar 2018.
- SANTOS, CAG; FREIRE, PKMM; TORRENCE, C. 2013. A transformada wavelet e sua aplicação na análise de séries hidrológicas. *Rev. Bras. Rec. Hídric.*, v. 18, n. 3, p. 271-280.
- SCHAEFLI, B; MARAUN, D; HOLSCHNEIDER, M. 2007. What drives high flow events in the Swiss Alps? Recent developments in wavelet spectral analysis and their application to hydrology. *Advances in Water Resources*, v. 30, n. 12, p. 2511-2525.

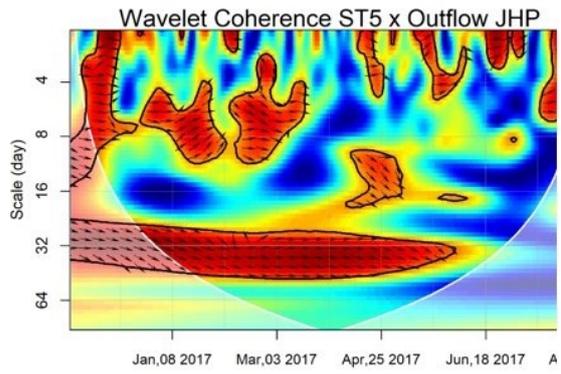
- SCHULZ, E; SPEEKENBRINK, M; KRAUSE, A. 2018. A tutorial on Gaussian process regression: Modelling, exploring, and exploiting functions. *Journal of Mathematical Psychology*, v. 85, p. 1-16.
- SHANKAR, BU; MEHER, SK; GHOSH, A. 2011. Wavelet-fuzzy hybridization: feature extraction and land-cover classification of remote sensing images. *Appl. Soft Comput*, v. 11, n. 3, p. 2999-3011.
- SHOAIB, M; SHAMSELDIN, AY; MELVILLE, BW. 2014. Comparative study of different wavelet based neural network models for rainfall-runoff modeling. *J. Hydrol.*, v. 515, 47-58.
- SHOAIB, M; SHAMSELDIN, AY; MELVILLE, BW; KHAN, MM. 2016. Hybrid Wavelet Neural Network Approach. In: SHANMUGANATHAN, S; SAMARASINGHE, S (Ed.). In: *Artificial Neural Network Modelling*. Studies in Computational Intelligence. Springer International Publishing Switzerland, p. 127-142.
- SIGEL/ANEEL. 2017. Sistema de Informações Georreferenciadas do Setor Elétrico. Disponível em: <<http://sigel.aneel.gov.br/sigel.html>>. Acesso em 13 mar 2017.
- SILVA, EA; TUCCI, CEM. 1998. Relação entre as vazões máximas diárias e instantâneas. *Rev. Bras. Rec. Hídric.*, v. 3, n. 1, p. 133-151.
- SILVA, ACCD. 2015. Impactos cumulativos de hidrelétricas sobre a hidrologia e qualidade da água de um rio contribuinte do Pantanal. Dissertação (Mestrado em Recursos Hídricos) – Universidade Federal de Mato Grosso, Cuiabá – MT.
- SILVA, IN; SPATTI, DH; FLAUZINO; RA. 2016. *Redes neurais artificiais para engenharia e ciências aplicadas*. 2ª Ed. São Paulo: Artliber.
- SILVEIRA. 2005. Desempenho de fórmulas de tempo de concentração em bacias urbanas e rurais. *Bras. Rec. Hídric.*, v. 10, n. 1. p. 5-23.
- SMITH, LC; TURCOTTE, DL; ISACKS, BL. 1998. Stream flow characterization and feature detection using a discrete wavelet transform. *Hydrol. Proces.*, v. 12, n. 2, p.233-249.
- SNIEDER, E; SHAKIR, R; KHAN, UT. 2019. A comprehensive comparison of four input variable selection methods for artificial neural network flow forecasting models. *J. Hydrol*, v. 583.
- SOLOMATINE, PD; OSTFELD, A. 2008. Data-driven modelling: some past experiences and new approaches. *J Hydroinform*, v. 10, n. 1, 3-22.
- SUN, AY; WANG, D; XU, X. 2014. Monthly streamflow forecasting using Gaussian process regression. *J. Hydrol*, v. 511, p. 72-81.
- TERÄSVIRTA, T; LIN, C; GRANGER, CWJ. 1993. Power of the neural network linearity test. *Journal of time series analysis*, v. 14, n. 2, p. 209-220.
- TIWARI, MK, CHATTERJEE, C. 2010. Development of an accurate and reliable hourly flood forecasting model using wavelet-bootstrap-ANN (WBANN) hybrid approach. *J. Hydrol.*, v. 394, p. 458-470.
- TONGAL, H; DEMIREL, MC; MORADKHANI, H. 2017. Analysis of dam-induced cyclic patterns on river flow dynamics. *Hydrological Sciences Journal*, v. 62, n. 4.
- TORRENCE, C; COMPO, GP. 1998. A practical guide to wavelet analysis. *Bull. Am. Meteorol. Soc.*, vol 79, n. 1, 61-78.

- TORRENCE, C; WEBSTER, PJ. 1999. Interdecadal changes in the ENSO–monsoon system. *Journal of Climate*, v. 12, n. 8.
- TRAPLETTI, A; HORNIK, K; LEBARON, B. 2018. *Time series analysis and computational finance*: R Package: tseries. version 0.10-46. Publication: 19 nov 2018.
- VELEDA, D, MONTAGNE, R; ARAUJO, M. 2012. Cross-Wavelet Bias Corrected by Normalizing Scales. *Journal of Atmospheric and Oceanic Technology*, v. 29, p.1401-1408.
- VERA, C; HIGGINS, W; AMADOR, J; AMBRIZZI, T; GARREAUD, R; GOCHIS, GUTZLER, D; D; LETTENMAIER, D; MARENGO, CR; MECHOSO, J; NOGUES-PAEGLE, J; DIAS, PLS; ZHANG, C. 2006. Toward a unified view of the American monsoon systems. *Journal of climate*, v. 19, n. 20, 4977-5000.
- WHITE, MA; SCHMIDT, JC; TOPPING, DJ. 2005. Application of wavelet analysis for monitoring the hydrologic effects of dam operation: Glen Canyon Dam and the Colorado River at Lees Ferry, Arizona. *River Res Appl*, v. 21, n. 5, 551-565.
- YANG, M; SANG, YF; LIU, C; WANG, Z. 2016. Discussion on the Choice of Decomposition Level for Wavelet Based Hydrological Time Series Modeling. *Water*, v. 8, n. 5.
- ZHANG, Z; ZHANG, Q; SINGH, VP. 2018. Univariate streamflow forecasting using commonly used data-driven models: literature review and case study. *Hydrological Sciences Journal*, v. 63, n. 7, p. 1091-1111.

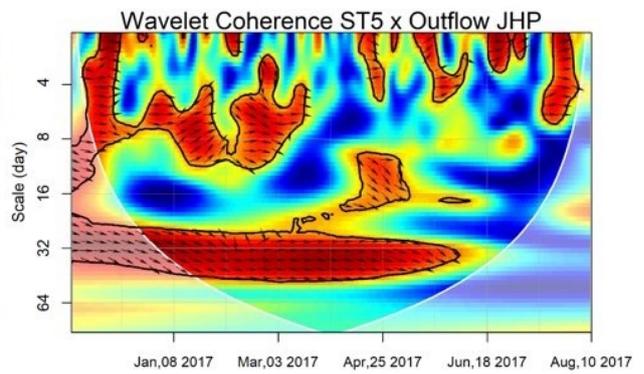
8 APÊNDICE A: COMPARAÇÃO ENTRE COERÊNCIAS WAVELET COM VAZÕES DIMENSIONALIZADAS E ADIMENSIONALIZADAS PELA ÁREA DA BACIA

Comparativo da análises de coerência *wavelet* com vazões originais e adimensionalizadas em função da área de drenagem de cada estação, conforme referenciado no item 4.2.3 – Efeitos nos ciclos de vazão no domínio tempo-frequência em escala diária – TWC.

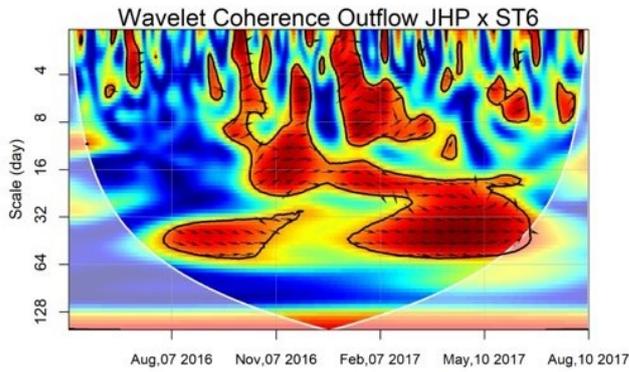




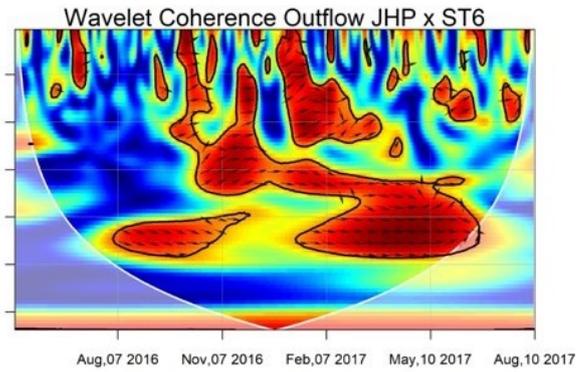
Áreas dimensionalizadas



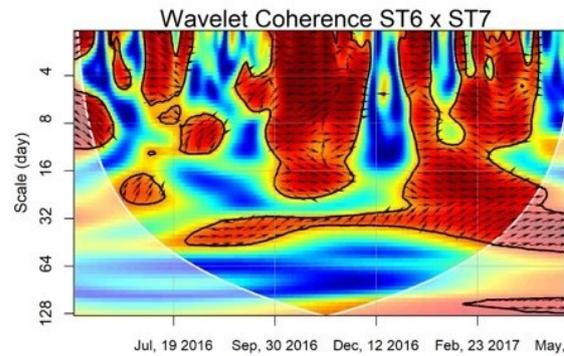
Áreas adimensionalizadas



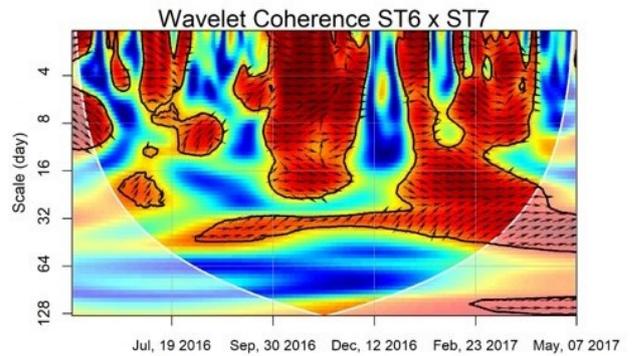
Áreas dimensionalizadas



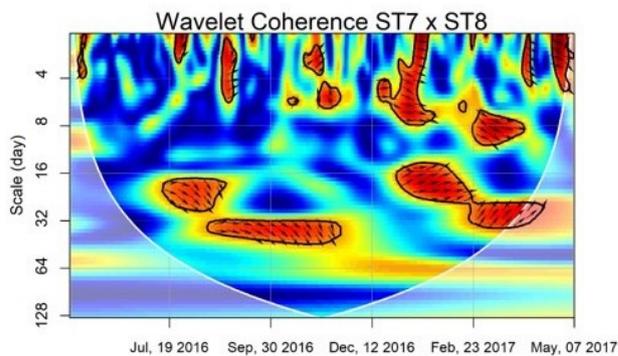
Áreas adimensionalizadas



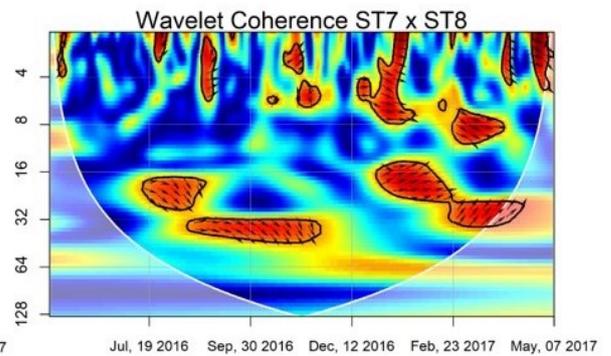
Áreas dimensionalizadas



Áreas adimensionalizadas



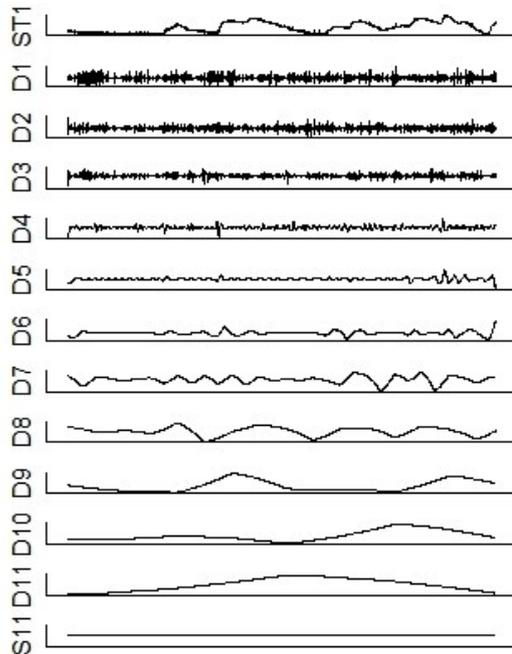
Áreas dimensionalizadas



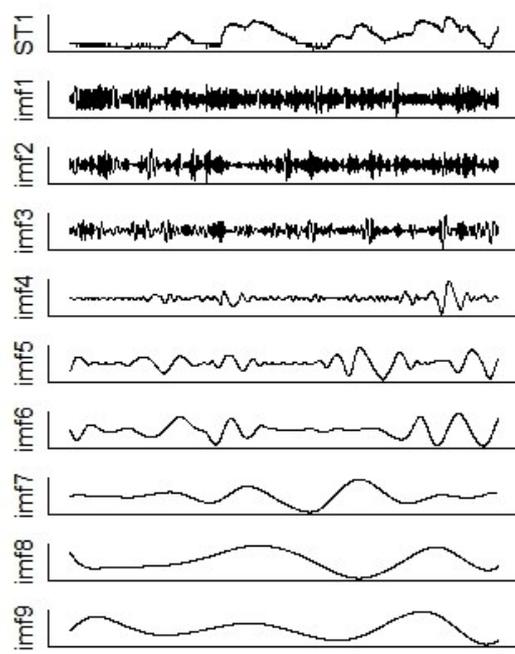
Áreas adimensionalizadas

9 APÊNDICE B: SÉRIES TEMPORAIS DECOMPOSTAS POR TRANSFORMADA WAVELET DISCRETA (TWD) E POR DECOMPOSIÇÃO EM MODOS EMPÍRICOS (EMD)

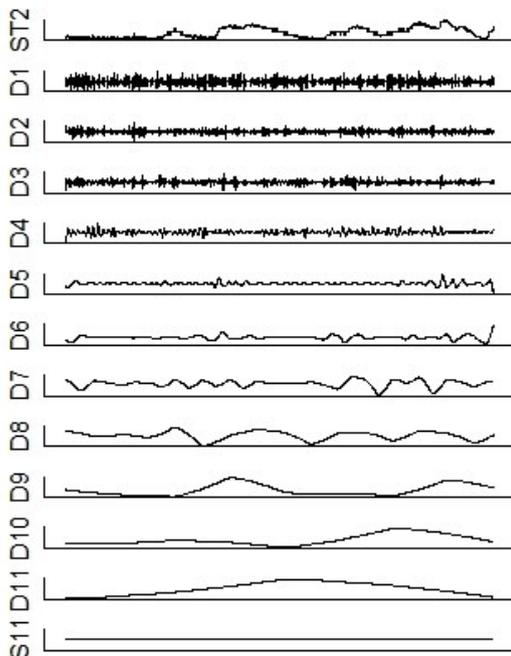
TWD ST1



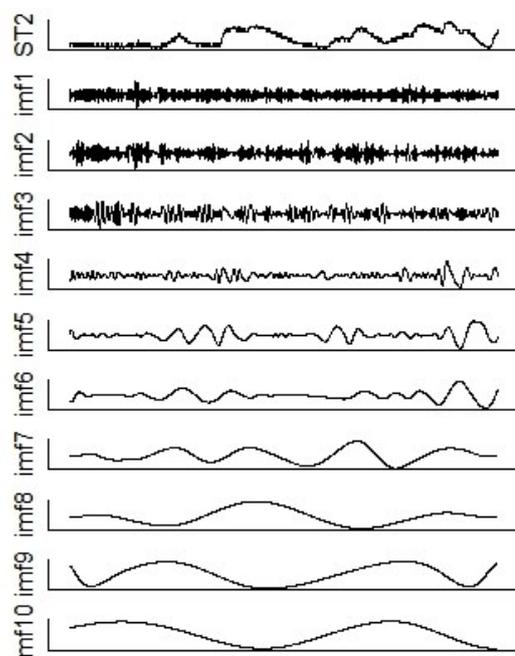
EMD ST1



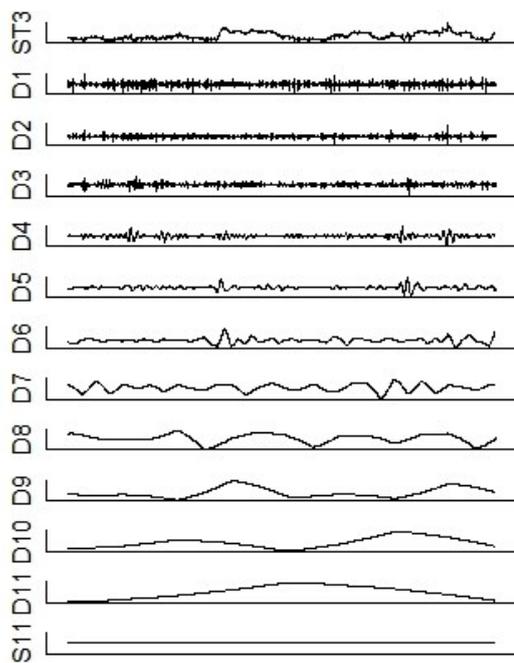
TWD ST2



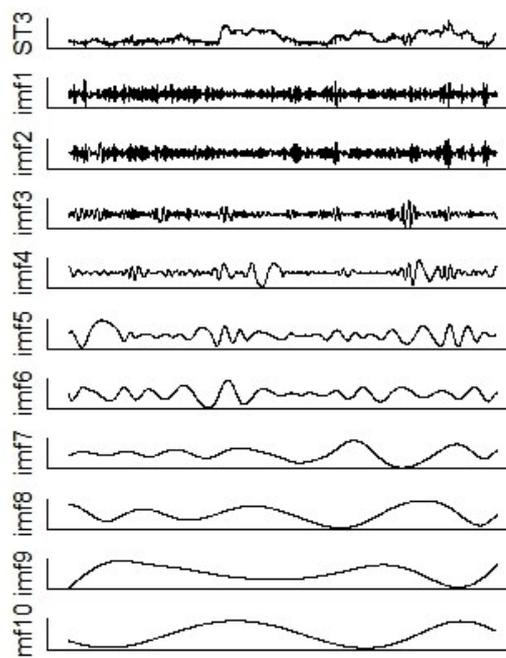
EMD ST2



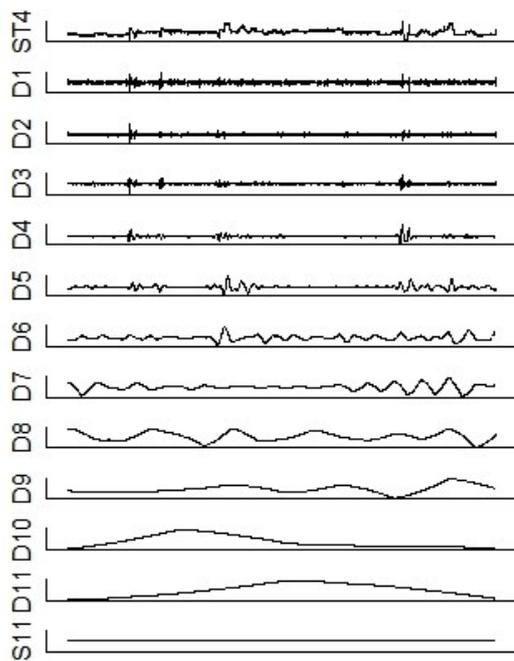
TWD ST3



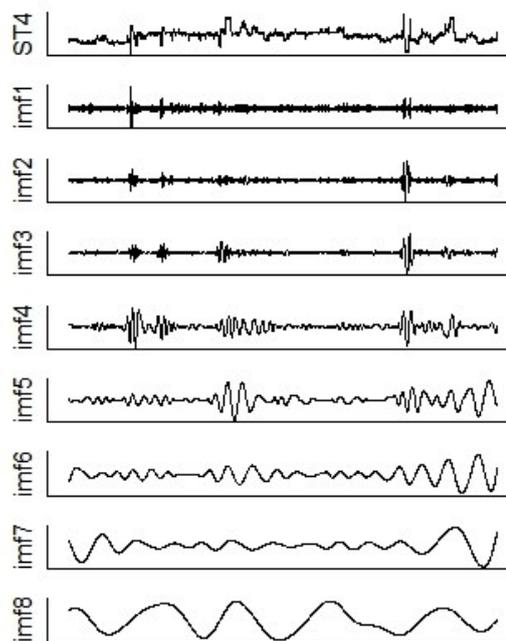
EMD ST3



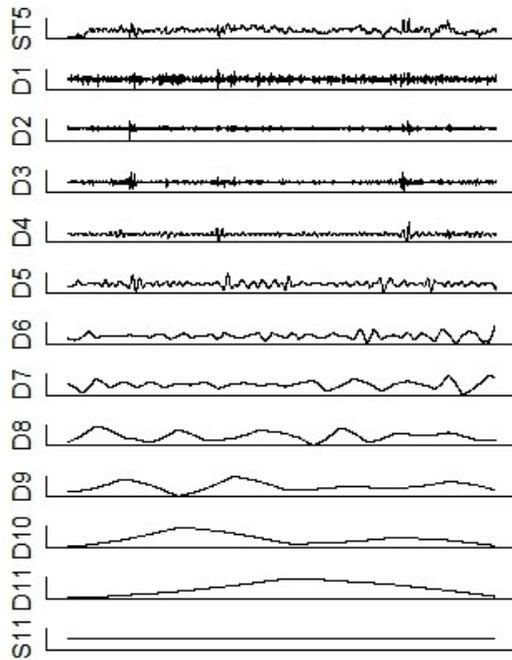
TWD ST4



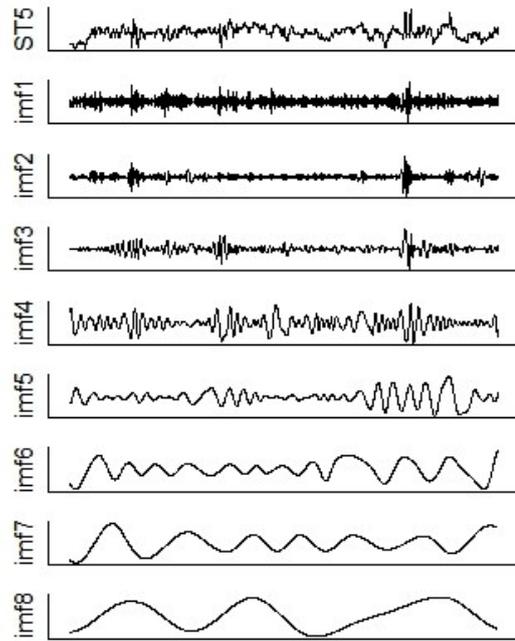
EMD ST4



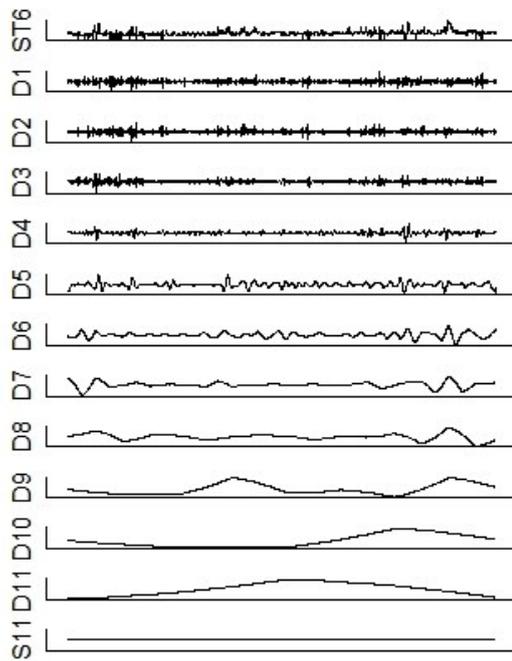
TWD ST5



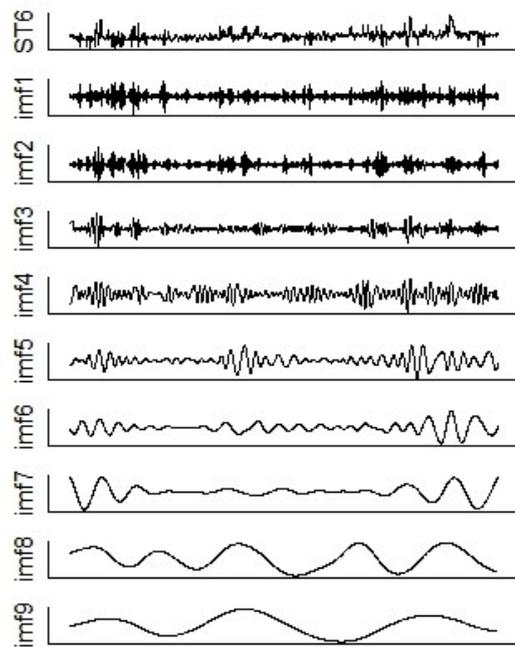
EMD ST5



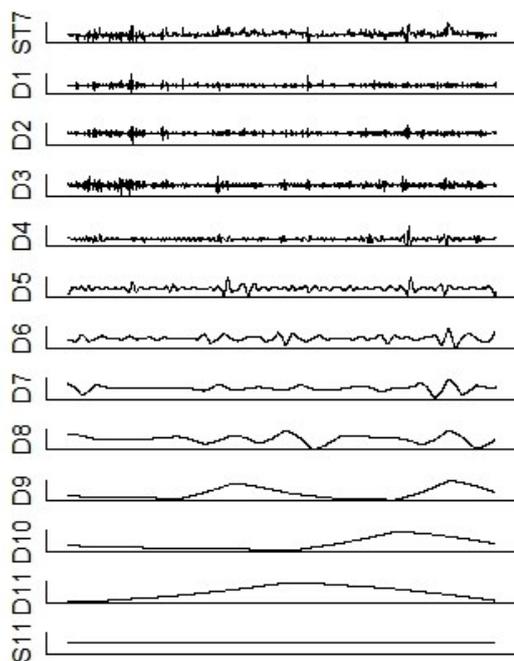
TWD ST6



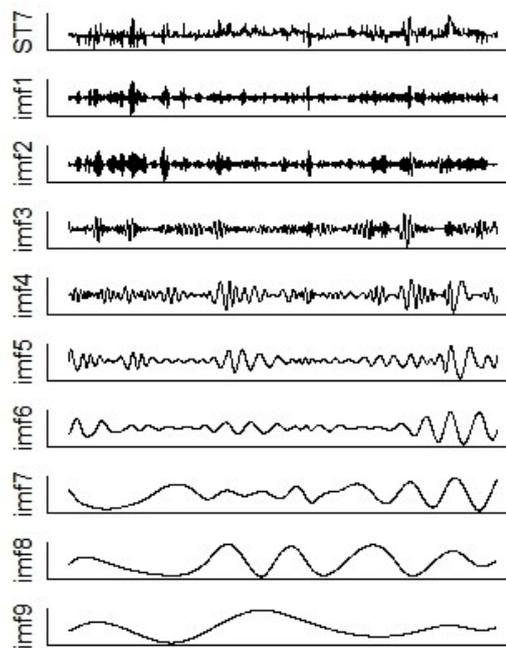
EMD ST6



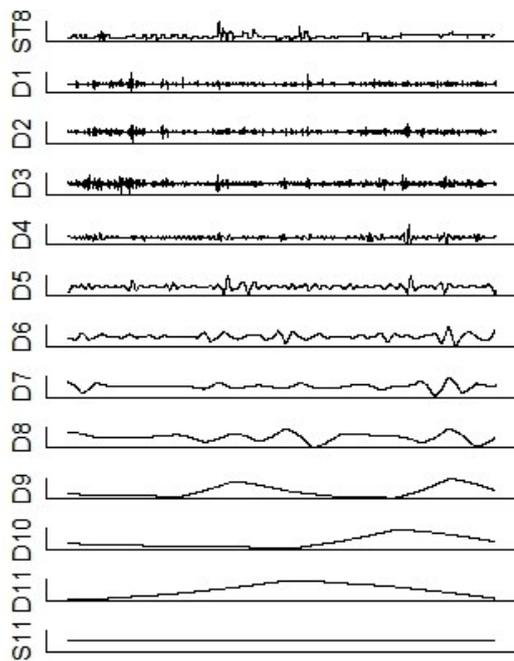
TWD ST7



EMD ST7



TWD ST8



EMD ST8

