

ANTÔNIO ALVES MEIRA NETO

Ponderação bayesiana de modelos utilizando diferentes séries de precipitação aplicada à simulação chuva-vazão na Bacia do Ribeirão da Onça.

Dissertação apresentada à Escola de Engenharia de São Carlos como parte dos requisitos para obtenção do título de Mestre em Ciências, Programa de Engenharia Hidráulica e Saneamento.

Orientador: Prof. Tit. Edson Cezar Wendland

VERSÃO CORRIGIDA

São Carlos

2013

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO,
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

A514p Alves Meira Neto, Antônio
Ponderação bayesiana de modelos utilizando
diferentes séries de precipitação aplicada à simulação
chuva-vazão na Bacia do Ribeirão da Onça. / Antônio
Alves Meira Neto; orientador Edson Cezar Wendland. São
Carlos, 2013.

Dissertação (Mestrado) - Programa de Pós-Graduação
e Área de Concentração em Hidráulica e Saneamento --
Escola de Engenharia de São Carlos da Universidade de
São Paulo, 2013.

1. Modelagem hidrológica. 2. SWAT. 3. SUFI-2. 4.
Ponderação Bayesiana de Modelos. 5. Bacia do Ribeirão
da Onça. 6. Precipitação. I. Título.

FOLHA DE JULGAMENTO

Candidato: Engenheiro **ANTONIO ALVES MEIRA NETO**.

Título da dissertação: "Análise de incertezas e ponderação bayesiana de modelos aplicadas à modelagem chuva-vazão da bacia do Ribeirão da Onça".

Data da defesa: 11/07/2013

Comissão Julgadora:

Prof. Titular **Edson Cezar Wendland (Orientador)**
(Escola de Engenharia de São Carlos/EESC)

Prof. Dr. **Eduardo Sávio Passos Rodrigues Martins**
(Universidade Federal do Ceará/UFC)

Prof. Dr. **Wilson dos Santos Fernandes**
(Universidade Federal de Minas Gerais/UFMG)

Resultado:

Aprovado

APROVADO

APROVADO

Coordenador do Programa de Pós-Graduação em Engenharia Hidráulica e Saneamento:

Prof. Titular **Edson Cezar Wendland**

Presidente da Comissão de Pós-Graduação:

Prof. Titular **Denis Vinicius Coury**

Serviço de Pós-Graduação
Protocolado em 11/07/2013
10

A Ivanka Ajdaric (*In memoriam*)

AGRADECIMENTOS

Primeiramente gostaria de agradecer à minha família: em especial aos meus pais, Rômulo e Yvonne, por estarem sempre ao lado, à minha irmã, Verena, por estar sempre em meu pensamento. Agradeço também ao tio Marko pelo constante apoio.

Durante minha estadia em São Carlos, pude conhecer pessoas maravilhosas, que me ajudaram muito a crescer, tanto pessoalmente quanto profissionalmente.

Em primeiro lugar gostaria de agradecer ao amigo André Simões, pelas orientações e amizade desde antes de minha vinda para São Carlos

Ao amigo Paulo Tarso pelo grande apoio ao meu desenvolvimento acadêmico e pela grande amizade que construímos. Também agradeço à Dulce, pela paciência, apesar das brincadeiras.

Ao amigo Stephan Birenbaum, pelos meses de convívio e amizade.

À amiga Natália Fischer, pela grande parceria e amizade.

Ao grande Mestre Murilo Cesar Lucas, pela amizade e parceria no LHC e dentro das quadras.

Ao amigo Carreirinha (Davi Diniz), pela amizade e parceria nos trabalhos de campo, de sala, e discussões acadêmicas.

Aos amigos do programa e de LHC e da pós-graduação, em especial à dupla dinâmica, Camilo Cabrera e Cristian Youlton, pelas discussões, bandejadas e companheirismo e ao Davi Andrade, pela parceria e pelo bom tempo de convívio juntos.

Ao professor Edson Wendland, por ter confiado em mim e pela amizade desenvolvida

Ao técnico Roberto Bergamo, sempre disposto a ajudar em tudo e fazer as idas a campo muito divertidas (Mas você tá entendendo???)

À ala das baianas: Marcelo Pessoa, Fred Martins e André Vieira, pelos momentos compartilhados, por terem sido meus amigos do peito, sempre prontos para ajudar.

Aos professores do programa, e funcionárias do SHS, Rose e Sá, pela constante ajuda, e demais funcionários da EESC-USP.

À CAPES, pela bolsa.

RESUMO

MEIRA NETO, A. A. **Ponderação bayesiana de modelos utilizando diferentes séries de precipitação aplicada à simulação chuva-vazão na Bacia do Ribeirão da Onça.** 2013. 110p. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2013.

Neste trabalho foi proposta uma estratégia de modelagem hidrológica para a transformação chuva vazão da Bacia do Ribeirão da Onça (B.R.O) utilizando-se técnicas de auto calibração com análise de incertezas e de ponderação de modelos. Foi utilizado o modelo hidrológico *Soil and Water Assessment Tool* (SWAT), por ser um modelo que possui uma descrição física e de maneira distribuída dos processos hidrológicos da bacia. Foram propostas cinco diferentes séries de precipitação e esquemas de interpolação espacial a serem utilizados como dados de entrada para o modelo SWAT. Em seguida, utilizou-se o método semiautomático *Sequential Uncertainty Fitting ver.-2* (SUFI-2) para a auto calibração e análise de incertezas dos parâmetros do modelo e produção de respostas com intervalos de incerteza para cada uma das séries de precipitação utilizadas. Por fim, foi utilizado o método de ponderação bayesiana de modelos (BMA) para o pós-processamento estocástico das respostas. Os resultados da análise de incerteza dos parâmetros do modelo SWAT indicam uma não adequação do método Soil Conservation Service (SCS) para simulação da geração do escoamento superficial, juntamente com uma necessidade de maior investigação das propriedades físicas do solo da bacia. A análise da precisão e acurácia dos resultados das séries de precipitação em comparação com a resposta combinada pelo método BMA sugerem a última como a mais adequada para a simulação chuva-vazão na B.R.O.

Palavras-chave: Modelagem hidrológica, análise de incertezas, SWAT. SUFI-2. ponderação bayesiana de modelos, bacia do Ribeirão da Onça, precipitação.

ABSTRACT

MEIRA NETO, A. A. **Ponderação bayesiana de modelos utilizando diferentes séries de precipitação aplicada à simulação chuva-vazão na Bacia do Ribeirão da Onça.** 2013. 110p. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2013.

This study proposed an approach to the hydrological modeling of the Ribeirão da Onça's Basin (B.R.O) based on automatic calibration and uncertainty analysis methods, together with model averaging. The Soil and Water Assessment Tool (SWAT) was used due to its distributed nature and physical description of hydrologic processes. An ensemble, composed by five different precipitation schemes, based on different sources and spatial interpolation methods was used. The Sequential Uncertainty Fitting ver-2 (SUFI-2) procedure was used for automatic calibration and uncertainty analysis of the SWAT model parameters, together with generation of streamflow simulations with uncertainty intervals. Following, the Bayesian Model Averaging (BMA) was used to merge the different responses into a single probabilistic forecast. The results of the uncertainty analysis for the SWAT parameters show that the Soil Conservation Service (SCS) model for surface runoff prediction may not be suitable for the B.R.O, and that more investigations about the soil physical properties at the Basin are recommended. An analysis of the accuracy and precision of the simulations produced by the precipitation ensemble members against the BMA simulation supports the use of the latter as a suitable framework for streamflow simulations at the B.R.O.

Keywords: Hydrological Modeling, uncertainty analysis, SWAT. SUFI-2, bayesian model averaging, Ribeirão da Onça basin, precipitation

LISTA DE FIGURAS

Figura 1 –Representação esquemática de um modelo matemático dinâmico, adaptado de Solomatine e Wagener (2011).	6
Figura 2 Classificação de modelos hidrológicos, adaptado de Refsgaard (1996).....	7
Figura 3 - Desenvolvimento do modelo SWAT, adaptado de Gassman et al., 2007.....	10
Figura 4 - Estratégia para calibração de modelos, adaptado de Gupta et al., (2005).....	11
Figura 5- Etapas da calibração de modelos, segundo Boyle et al., (2000).....	12
Figura 6 - Valores de função objetivo para os parâmetros UM, UK BM, BK, A e X do modelo SIXPAR. Adaptada de Duan et al., (1992).	19
Figura 7 - Relação entre incerteza dos parâmetros e dos resultados: à esquerda, o(s) valor(es) que um parâmetro pode possuir são refletidos nos resultados do modelo à direita: a) uma linha, para um único valor do parâmetro, ou uma faixa de respostas para o caso de faixas de variação para o parâmetro, como em b), c) e d). Na figura d), observa-se que tais resultados precisam ser comparados aos dados observados (linha vermelha).Adaptado de Abbaspour et al., (2007).....	22
Figura 8 - Formação da fdp resultante através do método BMA, adaptado de Raftery et al., (2005). 30	
Figura 9 – Localização Bacia do Ribeirão da Onça.....	32
Figura 10 - Mapa de uso do solo da B.R.O.....	34
Figura 11 - Mapa pedológico do Estado de São Paulo na região da BRO. Fonte: Castro Júnior (2008).	35
Figura 12 - Localização das estações de monitoramento climatológico na BRO.....	37
Figura 13 - Condição do escoamento dentro do Bueiro em situação de barramento à jusante da seção de medição.	39
Figura 14 - Fluxograma da utilização do modelo SWAT	41
Figura 15 - Resumo esquemático dos processos simulados pelo modelo SWAT. Fonte: Neitsch et al., (2011).....	44
Figura 16 – Fluxograma de criação de modelos competitivos para a B.R.O e análise de incertezas pelo método SUFI-2 e BMA.....	57
Figura 17 - Precipitação diária acumulada para as séries utilizadas durante o período de 2004 a 2008.	62
Figura 18 – Precipitação diária durante o mês de janeiro/2011 de acordo com as três fontes de dados de precipitação utilizadas.	63
Figura 19 - Vazões observadas para a BRO, períodos de calibração e validação.....	66
Figura 20 - Faixas finais de incerteza para os parâmetros calibrados utilizando o método SUFI-2, para as diferentes séries de precipitação consideradas na B.R.O. Em azul, as faixas finais de variação dos parâmetros, em vermelho os valores para a melhor simulação.....	71
Figura 21 - Faixas finais de incerteza para os parâmetros calibrados utilizando o método SUFI-2, para as diferentes séries de precipitação consideradas na B.R.O. Em azul, as faixas finais de variação dos parâmetros, em vermelho os valores para a melhor simulação.....	73
Figura 22 – Hietogramas e hidrógrafas das séries utilizadas, para o período de calibração durante os meses de JAN/FEV de 2009.	77
Figura 23 – Hietogramas e hidrógrafas das séries utilizadas, para o período de calibração durante os meses de DEZ/2009 a JAN/2010.	78

Figura 24 – Hietogramas e hidrógrafas dos modelos utilizados para o período de validação durante os meses de DEZ/2010 a FEV/ 2011.	80
Figura 25 – Hietograma e hidrógrafas dos modelos utilizados para o período de validação durante os meses de DEZ/2011 e DEZ/JAN de 2012.	81
Figura 26 - Incerteza das vazões para os modelos CRHEA, IDQ e BMA entre os meses de novembro/2008 a março/2009, período de calibração. Em cinza, as faixas de incertezas para a vazão e em vermelho os valores observados de vazão	86
Figura 27 - Incerteza das vazões para os modelos CRHEA, IDQ e BMA entre os meses de dezembro/2010 a março/2011, período de calibração. Em cinza, as faixas de incertezas para a vazão e em vermelho os valores observados de vazão.	87

LISTA DE TABELAS

Tabela 1 - Características físicas da BRO.....	33
Tabela 2 - Instrumentos utilizados na estação CRHEA-USP para medições de variáveis climáticas.	36
Tabela 3 - Descrição dos parâmetros de clima do modelo SWAT	42
Tabela 4 - Descrição dos parâmetros de solo do modelo SWAT	42
Tabela 5 - Dados de precipitação utilizadas para a criação de modelos competitivos.....	58
Tabela 6- Valores de Correlação Mensal e Diária entre as séries de precipitação analisadas entre os anos de 2004 a 2012.....	60
Tabela 7 – Avaliação estatística das séries de precipitação usadas no estudo	61
Tabela 8 - Correlação entre as séries diárias de precipitação utilizadas no estudo com as séries das estações climatológicas da fazenda Sto. Inácio e fazenda Monte Alegre.	63
Tabela 9 - Valores dos parâmetros referentes às propriedades físicas dos solos para a B.R.O.	64
Tabela 10 - Valores de CN utilizados para as diferentes culturas da B.R.O.....	65
Tabela 11 - Disponibilidade de dados de precipitação e vazão para a modelagem da B.R.O	65
Tabela 12 - Valores dos valores iniciais adotados pelo modelo SWAT para os parâmetros e as faixas iniciais de incerteza para o SUFI-2.	67
Tabela 13 – Índices estatísticos obtidos durante a calibração com o método SUFI-2 para a simulação hidrológica de diferentes fontes de dados de precipitação para a B.R.O.	70
Tabela 14 - Valores finais percentuais das incertezas dos parâmetros em relação à faixa inicial adotada (largura final/largura inicial).	71
Tabela 15 - Valores dos índices de avaliação de desempenhos dos modelos de precipitação e da média pelo método BMA (Valores satisfatórios: COE >0,50 ; PBIAS \pm 15%).	82
Tabela 16 - Valores de correlação entre os resultados das simulações, utilizadas pelo método BMA.	83
Tabela 17 - Avaliação do desempenho dos modelos quanto à capacidade preditiva, período de calibração.	85
Tabela 18 - Avaliação do desempenho dos modelos quanto à capacidade preditiva, período de validação.	85

SUMÁRIO

1. INTRODUÇÃO	1
2. OBJETIVOS	4
2.1. Objetivo Geral	4
2.2. Objetivos específicos.....	4
3. REVISÃO BIBLIOGRÁFICA	5
3.1. Modelos Hidrológicos	5
3.1.1. Propósitos da modelagem hidrológica e tipos de modelos hidrológicos	6
3.1.2. O modelo SWAT.....	9
3.2. Calibração de modelos hidrológicos	10
3.2.1. Funções objetivo.....	12
3.2.2. Métodos manuais e automáticos.....	13
3.2.3. Validação de modelos hidrológicos.....	15
3.3. Incertezas na modelagem hidrológica	16
3.3.1. Classificação das incertezas na modelagem hidrológica	17
4. MATERIAIS E MÉTODOS	32
4.1. Área de estudo	32
4.1.1. Localização e climatologia.....	32
4.1.2. Características físicas	33
4.1.3. Uso e ocupação do solo	34
4.1.4. Pedologia	35
4.1.5. Monitoramento das variáveis climáticas.	36
4.2. Modelo SWAT	40
4.2.3. SWAT e ArcSWAT.....	40
4.2.4. Parâmetros Climáticos e Gerador Climático	41
4.2.5. Parâmetros de Solos	42
4.2.6. Principais processos simulados pelo modelo SWAT	43
4.3. O Procedimento SUFI-2.....	51
4.3.3. Descrição Conceitual.....	51
4.3.4. O algoritmo SUFI-2.....	51
4.4. Ponderação Bayesiana de Modelos	54

4.4.3.	Conceitualização	54
4.4.4.	Definição dos parâmetros w_i e σ	56
4.5.	Criação e avaliação de modelos competitivos para a simulação das vazões na B.R.O.....	57
5.	RESULTADOS	60
5.1.	Inicialização do Modelo SWAT	60
5.1.1.	Comparação entre as diferentes entradas de precipitação	60
5.1.2.	Determinação dos parâmetros de solo e seu uso e ocupação	64
5.1.3	Períodos de calibração e validação	65
5.2.	Escolha das faixas iniciais de variação dos parâmetros	67
5.3	Avaliação geral do procedimento SUFI-2.....	69
5.4.	Incertezas dos parâmetros	70
5.5.	Avaliação do desempenho dos modelos	76
5.6.	Avaliação da incerteza preditiva	84
5.7	Avaliação geral e escolha de uma estratégia para a modelagem da B.R.O.....	89
6.	CONCLUSÕES	91
7.	REFERÊNCIAS BIBLIOGRÁFICAS	93
	APÊNDICE A - Algoritmo Expectation Maximization.....	103
	APÊNDICE B – Incerteza preditiva: períodos completos	105

1. INTRODUÇÃO

Com o crescimento econômico e populacional da Humanidade, a disponibilidade da água de forma adequada aos seus diversos usos passou a ser discutida. Este bem, antes imaginado como infinito, passou a se apresentar escasso em alguns casos e inapropriado à utilização em outros. A água, então, passou a ser considerada como um fator limitante do crescimento dos países. Apenas citando um exemplo de como a água vem tomando parte como centro de debates e ações de cunho global, foi declarada pela Organização das Nações Unidas a década de 2005 a 2015 como a década da "Água para a Vida", com o objetivo de promover esforços internacionais para o enfrentamento de problemas relacionados à água (ONU, 2010).

Dentre as ferramentas desenvolvidas pela ciência para a resolução de problemas na esfera dos Recursos Hídricos estão os modelos hidrológicos. Os modelos hidrológicos são representações simplificadas do ciclo hidrológico e desempenham um importante papel em várias áreas da Hidrologia, como em sistemas de alertas de cheias, agricultura, projeto de barragens, projeções de impactos provocados por mudanças climáticas ou mudanças de uso e ocupação do solo (SOLOMATINE e WAGENER, 2011). O crescimento da complexidade dos modelos hidrológicos, verificado nas últimas duas décadas, está intimamente atrelado ao aumento da capacidade de processamento dos computadores, à maior disponibilidade de dados hidrológicos observados e a uma maior compreensão da dinâmica dos processos hidrológicos (LIU e GUPTA, 2007). Um dos modelos hidrológicos mais utilizados na atualidade, o *Soil and Water Assessment Tool* (SWAT) (ARNOLD et al., 1998) tem sido testado para em diferentes condições climáticas, escalas espaciais e temporais, e com diferentes objetivos (GASSMAN et al., 2007), mostrando-se assim uma poderosa ferramenta tanto para fins de pesquisa como para tomada de decisões.

Entretanto, a capacidade dos modelos hidrológicos em satisfazer a crescente demanda por previsões hidrológicas ainda é limitada (BEVEN, 2005). O processo da modelagem hidrológica e as previsões obtidas pelos modelos estão sujeitos a várias incertezas (GUPTA et al., 2005; MORADKHANI e SOROOSHIAN, 2008; MONTANARI, 2009 e 2011), que

podem ser resumidas quanto às suas fontes em: (i) devido à percepção do modelo, (ii) relacionada aos dados observados, (iii) inerente aos parâmetros do modelo e (iv) quanto à estrutura do modelo. Desta forma, a previsão hidrológica aplicada à tomada de decisões ou a políticas de gerenciamento de recursos hídricos tem seu valor reduzido, caso não seja associada a estimativas de incerteza (GEORGAKAKOS, 2004).

A precipitação é considerada uma das mais importantes variáveis de entrada para a modelagem hidrológica (AJAMI et al., 2007), sendo que os processos relacionados ao fenômeno da precipitação são extremamente complexos e diversificados (KUTSOUIANNIS e LANGOUSIS, 2011). Estimativas precisas da precipitação em bacias hidrográficas estão sujeitas a diversos erros, que de forma geral estão relacionados à inabilidade das redes de monitoramento em capturar de forma correta a quantidade e a variabilidade da precipitação no espaço e no tempo (GUPTA et al., 2005). A dificuldade na determinação precisa deste fenômeno está presente nas mais diversas escalas de bacias hidrográficas, sendo que hipóteses como a da uniformidade espacial e pequena variabilidade espacial em pequenas áreas foram descartadas por diversos estudos ao longo dos anos (DUNCAN et al., 1993; FRAURÈS et al., 1995; GOODRICH et al., 1995).

A análise de incertezas na modelagem hidrológica tornou-se atualmente um dos mais importantes campos da Hidrologia, estando intimamente relacionada à calibração dos parâmetros e validação de modelos (MONTANARI, 2011). Dentre as técnicas atualmente utilizadas está o *Sequential Uncertainty Fitting Ver. 2* (SUFI-2) (ABBASPOUR et al., 2007). O SUFI-2 é um método semi-automático de autocalibração e análise de incertezas que busca a redução progressiva das incertezas dos resultados e dos parâmetros do modelo, e tem sido aplicado na análise de incertezas do modelo SWAT em estudos de mudanças climáticas e avaliação de disponibilidade hídrica (SCHUOL et al., 2008; FARAMARZI et al., 2009). Em recente estudo (YANG et al., 2008), o SUFI-2 foi comparado a outros métodos de calibração e análise de incertezas comumente usados, obtendo resultados semelhantes com um número de simulações significativamente inferior aos demais.

Uma das soluções para o problema da incerteza estrutural dos modelos é a ponderação bayesiana de modelos, ou BMA (do inglês *Bayesian Model Averaging*) (RAFTERY et al., 2005). O BMA é uma técnica de pós-processamento estatístico para a

produção de previsões probabilísticas de conjuntos de modelos (VRUGT et al., 2008), e vem sendo utilizada na modelagem hidrológica (DUAN et al., 2007; ZHANG et al., 2009).

Estudos recentes aplicaram a técnica BMA, para combinar simulações feitas a partir de diferentes fontes e esquemas de interpolação espacial da precipitação como forma de se considerar a incerteza relacionada à precipitação na modelagem hidrológica (STRAUCH et al., 2012; JIANG et al., 2012). Tais estudos apresentam-se como possíveis soluções para a contabilização da incerteza da precipitação na modelagem hidrológica, sendo também sugeridos para a simulação hidrológica em bacias hidrográficas com pouco monitoramento.

O presente estudo propõe a utilização do método SUFI-2 para a definição das incertezas dos parâmetros e das respostas do modelo SWAT condicionado a diferentes entradas de precipitação. Em seguida será feita uma ponderação das saídas provenientes de cada esquema de precipitação baseado no método BMA. A área de estudo é a Bacia do Ribeirão da Onça, localizada próxima ao município de São Carlos, São Paulo, que vem sendo estudada recentemente no âmbito dos recursos hídricos subterrâneos (BARRETO, 2005; GOMES, 2008; LUCAS 2012). Espera-se, que este trabalho sirva de auxílio para futuros estudos hidrológico da BRO.

2. OBJETIVOS

2.1. Objetivo Geral

Definição de uma abordagem para a simulação chuva-vazão da Bacia do Ribeirão da Onça, utilizando técnicas de auto calibração com análise de incerteza e combinação de diferentes respostas pela ponderação bayesiana de modelos.

2.2. Objetivos específicos

- Aplicação do modelo SWAT à Bacia do Ribeirão da Onça a partir de diferentes dados de entrada de precipitação.
- Análise de incertezas dos parâmetros do modelo SWAT e produção de respostas de vazão com faixas de incertezas para a Bacia do Ribeirão da Onça utilizando o método SUFI-2 para cada série de precipitação.
- Produção de uma resposta combinada com faixas de incertezas utilizando o método BMA.

3. REVISÃO BIBLIOGRÁFICA

3.1. Modelos Hidrológicos

Um modelo pode ser definido como uma representação simplificada de um processo ou fenômeno. Em Hidrologia, as partes do sistema ambiental terrestre que controlam o movimento e armazenamento de água são o objeto da modelagem (SOLOMATINE e WAGENER, 2011). Dooge (1973) resumiu um sistema como “qualquer estrutura, dispositivo, esquema ou procedimento, real ou abstrato, que inter-relacione, em um determinado referencial temporal, uma entrada ou estímulo, seja de matéria, energia ou informação, a uma saída ou resposta, de matéria, energia ou informação”.

Jain e Singh (2003) classificam os sistemas hidrológicos de acordo com as seguintes propriedades: (i) são sistemas físicos, pois representam um ente real; (ii) sequenciais, pois consistem em entradas, saídas e um meio de processamento; (iii) dinâmicos, pois cada entrada, a depender das condições anteriores, não resulta numa saída única. Dois conceitos importantes para o entendimento de um sistema e de sua modelagem matemática são os de variável e parâmetro. Variáveis, ou variáveis de estado, são quantidades de massa, energia ou informação que descrevem o estado do sistema, espacial e temporalmente. Parâmetros, por sua vez, descrevem propriedades específicas do sistema em estudo.

O exemplo típico de um sistema hidrológico é a bacia hidrográfica. A sua modelagem matemática busca simular os fluxos de matéria e energia através de suas fronteiras. A Figura 1, adaptada de Solomatine e Wagener (2011), apresenta esquematicamente a estrutura de um modelo matemático dinâmico e seus componentes. Temos como componentes principais as entradas (precipitação, temperatura, radiação solar), variáveis de estado (nível d'água do aquífero livre, umidade do solo, entre) e as saídas (vazão, evapotranspiração real, produção de sedimentos etc). Além desses elementos, os modelos requerem também valores dos estados iniciais do sistema (condições iniciais de umidade no solo, níveis dos aquíferos) e os valores dos parâmetros (condutividade hidráulica do solo, índice de área foliar, rugosidade dos cursos d'água, entre outros).




Figura 1 –Representação esquemática de um modelo matemático dinâmico, adaptado de Solomatine e Wagener (2011).

3.1.1. Propósitos da modelagem hidrológica e tipos de modelos hidrológicos

Os modelos hidrológicos são utilizados basicamente com dois propósitos: o de descrever o sistema em estudo, estabelecendo suas relações internas e fenômenos que nele ocorrem, e, também, fazer previsões sobre o comportamento deste sistema em situações que não foram observadas. As principais aplicações da modelagem hidrológica estão relacionadas à previsão de vazões, sistemas de alertas de cheias, previsão de áreas de inundação, estimativas de alterações no ciclo hidrológico decorrentes de mudanças de uso e ocupação do solo, ou de alterações climáticas (BEVEN, 2005).

Diversas classificações quanto aos tipos de modelos hidrológicos já foram apresentadas na literatura (CLARKE, 1973; TODINI 1988; WHEATER et al., 1993; SINGH 1995; TODINI 2007). Basicamente, podem-se dividir os modelos hidrológicos entre os conceitos de estocástico ou determinístico, concentrado ou distribuído, contínuo ou baseado em evento.

Os modelos determinísticos não consideram a aleatoriedade: para um mesmo conjunto de entradas e parâmetros, o mesmo resultado será produzido. Já os modelos estocásticos consideram a aleatoriedade nas suas respostas, devido às incertezas nas variáveis de entrada, condições de fronteira ou parâmetros do modelo. Os modelos determinísticos são divididos em três classes: conceituais, físicos e métricos (Figura 2).

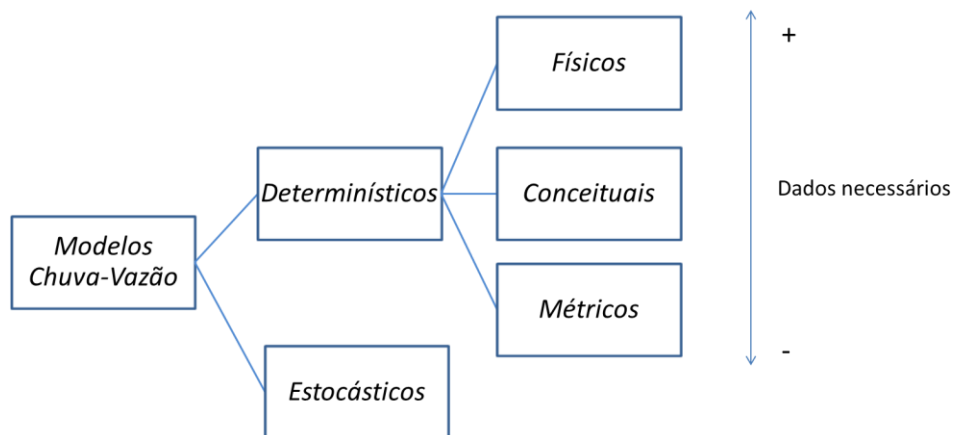


Figura 2 Classificação de modelos hidrológicos, adaptado de Refsgaard (1996)

Modelos concentrados consideram a bacia hidrográfica como uma unidade, e suas entradas, parâmetros, variáveis e saídas representam valores médios para toda a bacia. Já nos modelos distribuídos, as entradas, parâmetros, variáveis e saídas estão distribuídos pela bacia. Modelos baseados em eventos produzem saídas para períodos de tempo específicos, enquanto modelos contínuos simulam de forma contínua os fenômenos que ocorrem na bacia.

A classe mais comum de modelos hidrológicos são os modelos conceituais. Estes modelos são geralmente concentrados e representam esquematicamente os processos da bacia através de reservatórios, que são preenchidos por fluxos como chuva, infiltração ou percolação e são esvaziados através de processos de evaporação, escoamento e drenagem. Tais modelos tiveram origem nos anos 60. Os parâmetros dos modelos conceituais geralmente não são representados por entidades físicas, passíveis de serem medidas em campo. Para que estes modelos sejam aplicados, é necessário que seja executado um processo de calibração, manual ou automática, pela comparação com dados observados (WHEATHER et al., 2008). Em teoria, uma vez que estes parâmetros sejam calibrados, pode-se relacioná-los às características físicas da bacia estudada. Em muitos casos, porém, o grande número de parâmetros e suas inter-relações, associados ao uso de uma única medida de ajuste entre os dados simulados e observados, levam ao que foi definido por Beven (1993) como equifinalidade. Por equifinalidade entende-se a existência de múltiplos conjuntos de parâmetros de um modelo, assim como estruturas de modelos, que resultam em respostas

semelhantes. Uma vez que os parâmetros não possuem valores únicos, eles não podem ser associados a características físicas, o que limita a capacidade destes modelos em prever cenários futuros e simular fenômenos em bacias não monitoradas. São exemplos dessa classe de modelos, o modelo Stanford IV (CRAWFORD E LINSLEY, 1966) e o modelo HBV (BERGSTRÖM, 1976).

Com o contínuo crescimento da capacidade de processamento dos computadores, foram desenvolvidos, nos anos 80, os primeiros modelos físicos. Os modelos físicos possuem descrições mais detalhadas dos processos físicos que ocorrem na bacia, além de utilizarem as equações de conservação da massa, da energia e do momento. Isso se reflete na natureza de seus parâmetros, que são relacionados a grandezas físicas mensuráveis, como condutividade hidráulica do solo, índice de área foliar, entre outros. Era esperado que, devido à natureza mais física dos parâmetros, tais modelos pudessem ser utilizados para caso de bacias não monitoradas e também fossem capazes de fornecer respostas aos crescentes problemas ambientais (TODINI, 1988). Entretanto, uma vez que as medições em campo dos parâmetros físicos são feitas em escalas diferentes das unidades espaciais do modelo, e devido ao grande número de parâmetros e suas interações, os modelos físicos precisam ser calibrados, e assim como os modelos conceituais, enfrentam os mesmos problemas relacionados à equifinalidade. Um exemplo desta classe de modelos é o SHE (Système Hydrologique Européen) (Abott et al., 1986).

Os modelos métricos, também conhecidos como caixa preta, paramétricos ou modelos DD (do inglês *Data Driven*), são modelos empíricos baseados em observações. As equações utilizadas em tais modelos não têm como base uma descrição física dos processos, como no caso dos modelos vistos anteriormente, mas da análise dos dados de entrada e de saída. Um exemplo deste tipo de modelo é o hidrograma unitário (SHERMAN, 1932), bem como os métodos estatísticos da regressão linear, modelos auto-regressivos ARMA, ARIMA. Durante a última década, este tipo de modelo entrou numa nova fase, ganhando atenção devido ao desenvolvimento de técnicas de aprendizado de máquinas (SOLOMATINE e WAGENER, 2011).

3.1.2. O modelo SWAT

O modelo SWAT (ARNOLD et al., 1998), do inglês *Soil and Water Assessment Tool*, foi desenvolvido pelo Serviço de Pesquisa do Departamento Estadunidense de Agricultura (*United States Department of Agriculture, USDA*). O seu objetivo principal é a previsão do impacto causado pelas alterações do manejo do solo nos âmbitos da qualidade e quantidade de água, sedimentos e pesticidas em grandes bacias hidrográficas e a longo prazo, levando em consideração variados tipos de solo, cobertura vegetal e práticas agrícolas (NEITSCH et al., 2005).

O SWAT é o resultado de mais de 30 anos em experiências de modelagem hidrológica desenvolvidas pelo USDA. O SWAT é o descendente direto do SWRRB, *Simulator of Water Resources in Rural Basins*, (ARNOLD & WILLIAMS, 1987), que por sua vez foi desenvolvido tendo como base três outros modelos: o modelo CREAMS, *Chemical, Runoff and Erosion from Agricultural Management Systems* (KNISEL, 1980), GLEAMS, *Groundwater Loading Effects on Agricultural Management Systems*, (LEONARD et al., 1987) e por fim o *Environmental Impact Policy Climate* (IZAURRALDE et al. 2006), originalmente chamado EPIC, *Erosion Productivity Impact Calculator* (WILLIAMS et al. 1990).

No início da década de 90, foi adicionado ao SWRRB o modelo de propagação de vazões Routing Outputs to Outlet, ROTO, (ARNOLD et al., 1995) dando origem à primeira versão do SWAT. O SWAT vem passando por contínuos aperfeiçoamentos desde sua versão inicial, destacando-se a adição de rotinas cinéticas do modelo QUAL2E (Brown & Barnwell, 1987). Informações atualizadas e novas atualizações do SWAT estão disponíveis no site oficial do modelo (SWAT, 2013). A Figura 3, adaptada de Gassman et al. (2007) ilustra o desenvolvimento do modelo SWAT.

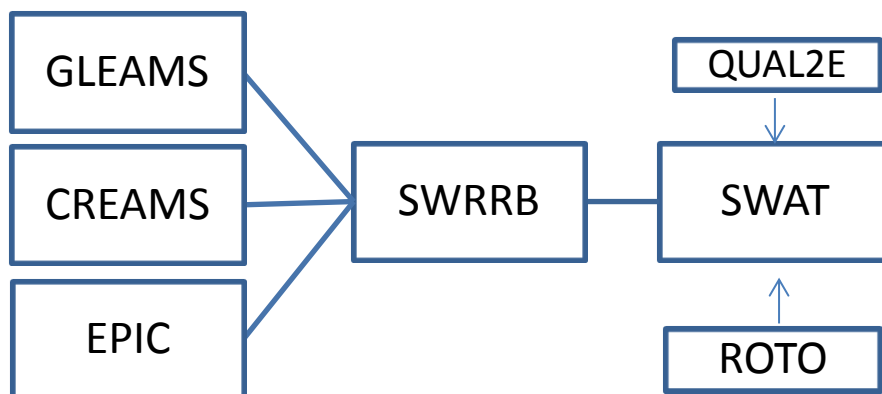


Figura 3 - Desenvolvimento do modelo SWAT, adaptado de Gassman et al., 2007

O modelo SWAT vem sendo utilizado largamente em diversos países e com diversas aplicações. No website do modelo SWAT (<http://swat.tamu.edu/>) está disponível uma extensa base de dados com artigos publicados em revistas indexadas. Após consulta realizada em maio de 2013, foi verificada a existência de 1273 artigos envolvendo a utilização do modelo em revistas internacionais. Em revisão feita por Gassman et al. (2007), foram observados à época mais de 250 artigos relacionados às suas aplicações, tanto para análise de quantidade como de qualidade da água, e em escalas que variam de micro bacias a bacias médias e grandes.

3.2. Calibração de modelos hidrológicos

A calibração é o processo em que os parâmetros do modelo são ajustados, de forma que o modelo reproduza o comportamento das variáveis observadas na bacia hidrográfica da forma mais real possível. Desta forma, são necessários dados observados para a calibração, sendo estes dados normalmente as séries de vazões observadas em um ou mais locais da bacia. Segundo Gupta et al. (2005), considera-se um modelo adequadamente calibrado quando as seguintes características são encontradas: (i) o comportamento entrada - variáveis de estado - saídas do modelo são condizentes com as medições do comportamento da bacia; (ii) as respostas do modelo são acuradas e precisas, isto é, apresentam pequenos desvios e

uma incerteza relativamente pequena; (iii) a estrutura do modelo e seu comportamento são condizentes com o entendimento do comportamento hidrológico da bacia. A Figura 4 resume o processo de calibração de modelos hidrológicos, apresentando alguns aspectos do processo da tradução de sistemas naturais em modelos matemáticos.

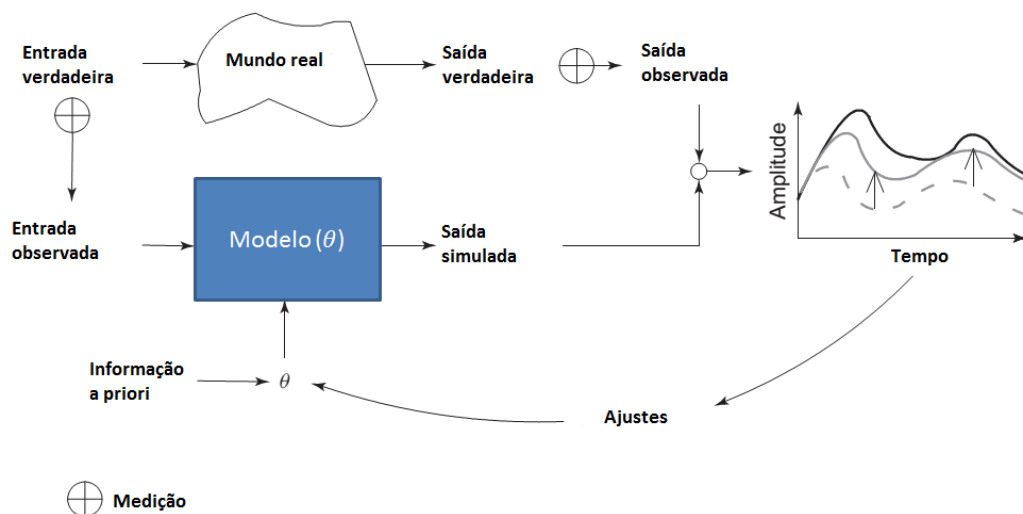


Figura 4 - Estratégia para calibração de modelos, adaptado de Gupta et al., (2005)

Boyle et al. (2000) propuseram um esquema de três níveis a ser aplicado para a calibração de modelos hidrológicos. O nível zero corresponde a uma estimativa das faixas iniciais dos valores para os parâmetros. Estas estimativas são feitas com base em tabelas e referências da literatura e ainda não são feitas simulações com o modelo para se comparar as respostas simuladas e observadas. No nível um, as estimativas dos valores dos parâmetros são feitas baseadas na análise de certos segmentos das hidrógrafas simuladas em comparação às observadas (recessão do hidrograma, por exemplo), de forma a se estudar os efeitos dos parâmetros isoladamente. No nível dois é feito um refinamento das faixas dos parâmetros baseado em índices de desempenho com uma detalhada análise da interação dos parâmetros. A Figura 5, a seguir, esquematiza os três níveis propostos para a calibração de modelos hidrológicos.

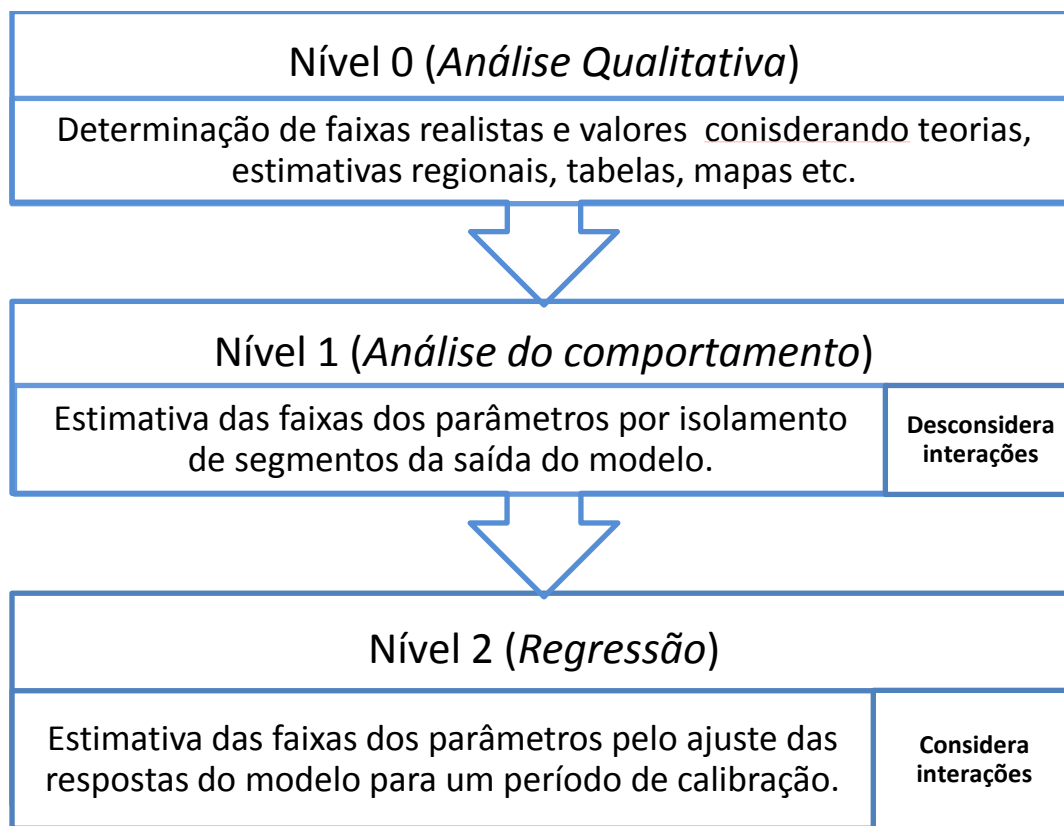


Figura 5- Etapas da calibração de modelos, segundo Boyle et al., (2000).

3.2.1. Funções objetivo

A comparação entre a resposta do modelo e os valores observados é, geralmente, feita a partir da avaliação visual das diferenças entre as respostas do modelo e os valores observados, e através de uma ou mais de uma função objetivo ($F.O$). Funções objetivo são índices numéricos relacionados à magnitude dos resíduos entre as séries observadas e simuladas. Busca-se, portanto, no processo de calibração a minimização, ou maximização, a depender da escolha destas funções. Podemos determinar o resíduo como (GUPTA et al., 2005):

$$e(\theta) = y_t^{obs} - y_t(\theta) \quad (1)$$

onde y_t^{obs} é o valor da variável observada no instante t , $y_t(\theta)$ é a resposta simulada pelo modelo no instante t e θ é o vetor de parâmetros do modelo. De acordo com Gupta et al.

(2005), as F.O's são geralmente funções que agregam o resíduo numa única medida, usando uma função pré-definida do tipo:

$$F(\theta) = F\{e_t(\theta), t = 1, 2, \dots, n\}. \quad (2)$$

As funções objetivo mais utilizadas são derivadas do método dos mínimos quadrados ponderados, ou WLS (*Weighted Least Squares*), possuindo a função do tipo:

$$F(\theta) = \sum_{t=1}^n w_t \cdot [y_t^{obs} - y_t(\theta)]^2, \quad (3)$$

em que w_t é o peso no instante t e n é o número de instantes analisados. Na ausência de informações adicionais, o valor dos pesos é igual à unidade para todos os t . Outras funções objetivo derivadas desta relação são o erro quadrático médio (MSE, *Mean Squared Error*), a raiz do erro quadrático médio (RMSE, *Root Mean Squared error*) e o índice de eficiência de Nash e Suttcliffe (COE) (NASH e SUTCLIFFE, 1970).

De acordo com a teoria da máxima verossimilhança, o uso de medidas baseadas na regressão linear pressupõe as seguintes características quanto à distribuição de probabilidades dos erros: (i) a probabilidade conjunta dos erros é normal e com média zero e (ii) os erros são independentes uns dos outros e possuem variância homogênea (SOROOSHIAN e GUPTA, 1995). Como estes pressupostos são geralmente violados, foram propostas novas funções estimadoras, baseadas na teoria da verossimilhança, como a HMLE (*Homoscedastic Maximum Likelihood Estimator*), proposta por Sorooshian e Dracup (1980), e a MLE (*Maximum Likelihood Estimator*), por Sorooshian (1981).

3.2.2. Métodos manuais e automáticos

O processo de calibração manual é, essencialmente, uma sequência iterativa de tentativa e erro, no qual são feitas alterações nos valores dos parâmetros, e, em seguida, as vazões simuladas e observadas são comparadas (SOROOSHIAN e GUPTA, 1995). Como cada parâmetro guarda uma relação conceitual ou física com os fenômenos que ocorrem na bacia, espera-se que através do ajuste de determinados parâmetros se possa reproduzir os efeitos esperados e ajustar as séries simuladas às observadas. Entretanto, no caso de modelos mais complexos, onde há um grande número de parâmetros que interagem entre si, os

resultados podem ser difíceis de prever. Neste caso, a calibração manual torna-se tarefa difícil, demandando tempo e experiência do usuário com modelo (GUPTA et al., 1999).

O surgimento dos métodos de calibração automática veio acompanhar a evolução da complexidade dos modelos hidrológicos, juntamente com o crescimento da capacidade dos computadores. Seu desenvolvimento deu-se pela necessidade de acelerar o processo de calibração, somado ao fato de existirem poucos especialistas para cada modelo hidrológico, e pela necessidade de previsões mais confiáveis e objetivas através dos modelos (SOROOSHIAN e GUPTA, 1995).

Os primeiros métodos de auto calibração foram desenvolvidos nas décadas de 1960 e 1970, baseados em técnicas de busca local (IBBIT e O'DONNEL, 1971; NASH e SUTCLIFFE, 1970). De acordo com Sorooshian e Gupta (1995), os métodos de busca local são projetados para encontrar eficientemente o mínimo de funções unimodais. Para estas funções qualquer estratégia que continuamente melhore o valor da função objetivo irá chegar a um valor mínimo (ou máximo) *independente da escolha do ponto inicial no espaço parametral*. Os algoritmos de busca local podem ser divididos em métodos diretos e métodos baseados em gradientes. Exemplos clássicos de método direto são o método simplex (NELDER e MEAD, 1965) e o método Rosenbrock (ROSENBROCK, 1960). Diversos estudos concluíram, porém, que métodos de busca local não são adequados para a localização de um ótimo global para modelos hidrológicos (IBBIT e O'DONNEL, 1971; JOHNSTON e PILGRIM, 1976), uma vez que as superfícies de resposta dos modelos hidrológicos são, na maioria das vezes multimodais, o que faz com que o sucesso desses métodos esteja atrelado à escolha do valor inicial (SOROOSHIAN e GUPTA, 1995).

No fim dos anos 80, surgiram os primeiros métodos de auto calibração de modelos hidrológicos baseados em técnicas de busca global. Uma característica dos algoritmos de busca global é o início simultâneo a partir de diferentes pontos do espaço dos parâmetros, que irão iterativamente evoluir em direção a regiões mais promissoras da superfície de resposta da função objetivo (GUPTA et al., 2005). Um dos algoritmos de busca global mais utilizados é o *Shuffled Complex Evolution* (SCE-UA) (DUAN et al., 1992), que através dos anos sofreu algumas variações dando origem a outros algoritmos, como o *Multi Objective Complex Evolution* (MOCOM-UA, YAPO et al., 1998), o *Shuffled Complex Evolution*

Metropolis (SCEM-UA, VRUGT et al., 2003) e o *Multi Objective Shuffled Complex Evolution Metropolis* (MOSCEM-UA, VRUGT et al., 2003b). Outros exemplos de algoritmos de busca global são o *Adaptive Random Search* (MASRI et al., 1980), algoritmos genéticos (HOLLAND, 1975) e *Simulated Annealing* (KIRKPATRICK et al., 1983).

3.2.3. Validação de modelos hidrológicos

O processo de validação consiste em testar o modelo para um período de dados observados diferente daquele usado para o processo de calibração. O objetivo da validação é verificar se durante a calibração os valores dos parâmetros foram estimados corretamente. Não é raro o modelo se comportar bem para o período de calibração, apresentando, entretanto, um desempenho inferior durante a validação. Quando isso ocorre, é necessário verificar o processo de calibração utilizado, levantando dúvidas sobre as considerações feitas sobre o sistema modelado (SOROOSHIAN e GUPTA, 1995).

Segundo Solomatine e Wagener (2011), o uso de medidas pontuais, como o coeficiente de eficiência de Nash e Stouffle, raiz do erro médio quadrado, entre outros, não é adequado. Gupta et al. (2008) propõe o uso de assinaturas informativas a respeito do comportamento do modelo, que permitiriam a determinar o quão consistente o modelo se apresenta.

Existem, entretanto, técnicas de calibração que prescindem de validação: são as chamadas técnicas de assimilação sequencial de dados (MORADKHANI et al., 2005), na qual o modelo tem seus parâmetros atualizados à medida que os dados são colhidos. Técnicas como o *Dual-State Parameter Estimation* (MORADKHANI et al., 2005), baseado na teoria do filtro de Kalman (EVENSEN, 2009) ou o BaRE (*Bayesian Recursive Estimation*), proposto por Thiemann et al. (2001), baseado na teoria da inferência bayesiana (BOX e TIAO, 1973), são exemplos de técnicas recentes utilizando o conceito da assimilação sequencial de dados.

3.3. Incertezas na modelagem hidrológica

Segundo Kundzewicz (1995), incerteza significa a falta de certeza sobre algo (processo, mecanismo, resultados, fatos), variando desde a completa falta de um conhecimento definitivo à existência de pequenas dúvidas a respeito do objeto de estudo. Segundo Solomatine e Wagener (2011), no contexto da modelagem hidrológica, pode-se definir incerteza como um estado que reflete a falta de certeza a respeito da saída de um processo físico ou um sistema de interesse. Segundo os mesmos autores, a incerteza da saída de um modelo é o estado ou condição de que esta saída não pode ser estimada de forma única. A incerteza é algo inerente às ciências hidrológicas, uma vez que observações, pressupostos, teorias, modelos, equações e parâmetros utilizados não reproduzem fielmente a realidade (KUNDZEWICZ, 1995). Somado a este fato, tem-se a escassez de dados para análises, algo comum na prática da hidrologia (MONTANARI et al., 2009).

Nas últimas duas décadas, muita atenção tem sido voltada para a análise de incertezas na modelagem hidrológica (PAPPENBERGER et al., 2006; PAPPENBERGER e BEVEN, 2006; MONTANARI, 2007; MONTANARI et al., 2009). O crescente aperfeiçoamento dos modelos e a ampliação do alcance de suas aplicações fez com que muitas questões a respeito das estimativas das incertezas na modelagem hidrológica surgissem. Os questionamentos mais urgentes dizem respeito à quantificação da confiabilidade das saídas de modelos hidrológicos, sejam estas saídas relacionadas a sistemas de monitoramento de enchentes em tempo real, ou a previsões de longo prazo, como na análise de mudanças de uso e ocupação do solo e mudanças climáticas (MONTANARI et al., 2009). Georgakakos et al., (2004) afirmam que uma previsão hidrológica aplicada à tomada de decisões ou a políticas de gerenciamento de recursos hídricos tem seu valor reduzido caso não seja associada a estimativas de incerteza.

A seara da análise de incertezas na modelagem hidrológica carece, entretanto, de terminologia e entendimento comuns a toda comunidade científica, havendo ainda muita confusão a respeito dos conceitos, terminologias e classificação dos métodos existentes (Montanari et al., 2007), fazendo com que não haja uma regra geral para se escolher um entre os vários métodos existentes (LIU e GUPTA 2007).

Outro problema a ser enfrentado, também relacionado à falta de unidade no discurso, é a dificuldade na transferência de conhecimento entre a academia os tomadores de decisão. Pappenberg e Beven (2006) discutiram os sete argumentos mais frequentes para a não utilização de técnicas de análise de incertezas por parte da comunidade científica, apresentando-os na seguinte ordem (i) a análise de incertezas não é necessária em caso de modelos físicos; (ii) a análise de incertezas não é útil para o entendimento dos processos hidrológicos; (iii) distribuições de incerteza não podem ser entendidas por tomadores de decisões e o público comum; (iv) a análise de incertezas não pode ser incorporada ao processo de tomada de decisões; (v) análises de incertezas são muito subjetivas; (vi) análises de incerteza são muito difíceis de serem realizadas e (vii) as incertezas não importam para a tomada de decisão final. Os autores discutiram cada um destes argumentos, evidenciando suas falhas salientando a necessidade de um código de prática para viabilizar a utilização dos métodos existentes.

3.3.1. Classificação das incertezas na modelagem hidrológica

Diversas são as causas das incertezas na modelagem hidrológica (GUPTA et al., 2005; MORADKHANI e SOROOSHIAN, 2008; MONTANARI, 2009 e 2011). Pode-se, de forma geral, classificar as incertezas na modelagem hidrológica como provenientes de 4 fontes: (i) originada devido à percepção do modelo, (ii) relacionada aos dados observados, (iii) inerente aos parâmetros do modelo e (iv) quanto à estrutura do modelo.

3.3.1.1. Incerteza quanto à percepção do modelo

O processo através do qual a bacia hidrográfica em estudo é pensada e seus principais processos hidrológicos são levados em consideração culmina no que foi definido por Beven (2001) de *perceptual model*. Esta fase da modelagem consiste num exercício intelectual, que irá mais tarde determinar a definição de um modelo conceitual da bacia. Este processo é pessoal e depende muito da experiência do hidrólogo, estando, portanto, sujeito a grandes incertezas.

3.3.1.2. Incerteza dos parâmetros

Como foi visto anteriormente, para que um modelo hidrológico seja utilizado, é necessária a determinação de seus parâmetros. Com o passar dos anos, modelos mais complexos foram surgindo, trazendo consigo desafios para a determinação dos valores que melhor representassem a realidade física da bacia, através de algoritmos de auto calibração baseados na busca de um ótimo global. Em estudo realizado por Duan et al., (1992), foi analisada a superfície de resposta para um modelo conceitual de seis parâmetros, chegando-se às seguintes observações a respeito desta superfície: (i) há mais de uma região de atração; (ii) cada região possui vários locais ótimos; (iii) a superfície tem quedas abruptas, com derivadas descontínuas; (iv) ela é aplainada em várias regiões, principalmente perto de valores ótimos; (v) existem diversas “cordilheiras”. A Figura 6, extraída do estudo citado, apresenta a distribuição dos valores da função objetivo escolhida em relação aos valores dos parâmetros, para cada um dos seis parâmetros estudados. As melhores simulações têm, neste caso, valores menores para a função objetivo.




Figura 6 - Valores de função objetivo para os parâmetros UM, UK BM, BK, A e X do modelo SIXPAR. Adaptada de Duan et al., (1992).

Os resultados deste estudo deram origem ao algoritmo de busca global SCE-UA, citado anteriormente, mas também chamaram atenção para o fato de existirem diversos locais com valores muito semelhantes para a função objetivo espalhados pelo espaço dos parâmetros, o que torna o problema da identificação de um conjunto único de parâmetros algo muito difícil. Para Beven (1993), os resultados deste e de outros exemplos semelhantes são indicativos da necessidade de uma mudança de paradigmas na modelagem hidrológica. O autor introduziu o conceito da equifinalidade na modelagem hidrológica. Tal conceito afirma

que a existência de múltiplos modelos e ou estruturas de parâmetros que resultem em resultados semelhantes de desempenho deve ser considerado como uma indicação da incerteza em relação a estes parâmetros e/ou estruturas na representação do sistema físico.

Uma das abordagens existentes que inclui a incerteza dos parâmetros dos modelos (e também de diferentes estruturas), e leva em consideração o princípio da equifinalidade, é o métodos de conjuntos (GUPTA et al., 2005). Tal abordagem se baseia na retenção de todos os modelos plausíveis, que devem ser considerados ao menos que alguma evidência contrária seja apresentada. Os métodos baseados nesta abordagem se utilizam geralmente da amostragem aleatória do espaço dos parâmetros pelo método Monte Carlo (MC). De maneira resumida, o método MC consiste em utilizar a amostragem aleatória para se produzir respostas sobre as quais, através da inferência estatística, serão extraídas informações acerca do sistema (LEMIEUX et al., 2008). De forma resumida, a simulação MC envolve os seguintes passos (SOLOMATINE e WAGENER, 2011): (i) amostrar as variáveis x_i de suas distribuições de probabilidades conjuntas; (ii) executar o modelo para cada uma das amostras x_i ; (iii) repetir os passos (i) e (ii), armazenando os resultados; e (iv) derivar, a partir dos resultados das simulações, as propriedades estatísticas, como função de distribuição acumulada e momentos.

Existem diversos métodos de auto calibração e análise de incertezas baseados em simulações MC e suas versões modificadas, onde pode-se citar o *Generalized Likelihood Uncertainty Estimation* (GLUE) (Beven e Binley, 1992), o algoritmo Metropolis (KUCZERA e PARENT, 1998), o algoritmo DREAM (VRUGT et al., 2008) e o SUFI-2 (ABBASPOUR et al., 2007). O método GLUE será brevemente detalhado, por se tratar de um dos métodos mais discutidos e utilizados, além de proporcionar um melhor entendimento à respeito das técnicas de análise de incertezas, de forma geral.

O método Generalized Likelihood Uncertainty Estimator (GLUE) foi proposto por Beven e Binley (1993) e é inspirado no método *Generalized Sensitivity Analysis* (GSA), apresentado por Spear e Hornberger (1980). O GLUE é baseado no princípio da equifinalidade, rejeitando o conceito de um modelo ou conjunto de parâmetros ótimo, e pode ser resumido nos seguintes passos: (i) decidir qual a estrutura ou estruturas de modelos a ser utilizada; (ii) através do método Monte Carlo, amostrar conjuntos de parâmetros a partir de

distribuições para estes parâmetros definidas à priori; (iii) avaliar cada simulação, comparando os resultados com os valores observados, através de uma medida de verossimilhança, e separando-as em adequadas ou não, a partir de um valor limiar pré-estabelecido da função de verossimilhança; (iv) descartar as simulações tidas como não adequadas e normalizar os valores das funções de verossimilhança para as simulações adequadas. Tais valores funcionam como pesos; (v) os pesos são utilizados para a construção de funções de probabilidade acumulada, podendo-se assim traçar limites de confiança para as simulações. Os mesmos pesos são utilizados para simulações futuras.

3.3.1.2.1. O método SUFI-2

O *Sequential Uncertainty Fitting Ver. 2*, SUFI-2 é um método semi-automático de autocalibração e análise de incertezas que busca a redução progressiva das incertezas dos resultados e dos parâmetros do modelo (ABBASPOUR et al., 2007). O SUFI-2 utiliza elementos do método GLUE (Beven e Binley, 1992), além de elementos da abordagem gradiente (KOOL e PARKER, 1988) modificados, para possibilitar uma busca global. Assim como o GLUE, o método SUFI-2 assume a existência de um conjunto de valores para os parâmetros, e não uma estimativa pontual que reproduza satisfatoriamente os dados observados. Ao contrário do GLUE, o SUFI-2 tem como estimativa final faixas de variação dos parâmetros. Pela Figura 7, percebe-se a diferença entre uma resposta baseada na estimativa pontual de um conjunto de parâmetros (a), em comparação com respostas provenientes de diferentes faixas de variação para o mesmo parâmetro (Figura 7, b e c).




Figura 7 - Relação entre incerteza dos parâmetros e dos resultados: à esquerda, o(s) valor(es) que um parâmetro pode possuir são refletidos nos resultados do modelo à direita: a) uma linha, para um único valor do parâmetro, ou uma faixa de respostas para o caso de faixas de variação para o parâmetro, como em b), c) e d). Na figura d), observa-se que tais resultados precisam ser comparados aos dados observados (linha vermelha). Adaptado de Abbaspour et al., (2007)

No método SUFI-2, a incerteza inicial dos parâmetros é representada por uma distribuição uniforme. Através da amostragem aleatória do espaço dos parâmetros e da análise das respostas obtidas, é feita uma comparação da melhor simulação com os dados observados (linha vermelha, Figura 7-d). A cada iteração são propostas novas faixas de variação e o efeito desse procedimento é a redução progressiva das incertezas dos parâmetros e dos resultados do modelo. A solução final será aquela que ao mesmo tempo contenha a maior parte dos dados observados (mais de 90% dos dados observados contidos no intervalo de 95% dos resultados) e seja precisa o suficiente (condição de que a distância média entre os percentis de 2,5% e 97,5% seja menor que o desvio padrão dos dados observados). O método SUFI-2 considera as incertezas estruturais e dos dados de forma implícita, uma vez que erros na estrutura do modelo e nos dados de entrada são refletidos nas resposta do modelo, e o

método utiliza a percentagem de dados observados capturados como critério de avaliação das incertezas.

O método SUFI-2 tem sido utilizado em diversas aplicações recentemente. Abbaspour et al. (2007) utilizaram o SUFI-2 para a calibração e análise de incertezas dos parâmetros do modelo SWAT utilizado para a simulação da vazão, produção de sedimentos e nutrientes na bacia do rio Thur, Suíça. Schuol et al. (2008) utilizaram o SUFI-2 para calibrar o modelo SWAT aplicado a todo o continente africano, num estudo de disponibilidade hídrica espacial e temporal daquele continente. Faramarzi et al. (2009) utilizaram o algoritmo SUFI-2 para calibrar o modelo SWAT para o Irã, com o objetivo de avaliar a disponibilidade hídrica para esse país, utilizando os conceitos de água verde e azul. Posteriormente, tal calibração serviu de base para a estimativa de impactos devido a mudanças climáticas, utilizando cenários de cinco modelos de circulação global (FARAMARZI et al., 2013).

Tendo em vista a variedade de técnicas de análise de incertezas existentes, Yang et al. (2008) compararam cinco destas técnicas: o GLUE, apresentado anteriormente, o método ParaSol (VAN GRIENSVEN e MEIXNER, 2006), métodos bayesianos baseados em técnicas Monte Carlo com cadeia de Markov, *Monte Carlo Markov Chain* (MCMC) e técnicas bayesianas com amostragem do tipo *Importance Sampling* (IS) (KUCZERA e PARENT, 1998), além do método SUFI-2. Nesse estudo, foi utilizado o modelo SWAT aplicado à bacia do rio Chaoe, na China. Os resultados indicam que a utilização do método MCMC é mais aconselhada, devido à sua base teórica mais consistente. Entretanto, os métodos GLUE, SUFI-2 e MCMC retornaram faixas de incerteza semelhantes, sendo que o método SUFI-2 obteve tais resultados com um número de simulações significativamente inferior aos demais.

3.3.1.3. Incerteza dos dados observados

Para a produção de seus resultados, os modelos hidrológicos utilizam-se de dados de entrada como precipitação, temperatura e velocidade do vento. Para a calibração, são utilizadas séries observadas, geralmente de vazão. Segundo Montanari (2011), para ambos os casos, as incertezas quanto aos dados observados originam-se das limitações das técnicas de medição (mal funcionamento dos equipamentos, técnicas de extrapolação da curva chave) e

da variabilidade temporal e espacial dos valores observados (variabilidade espacial da precipitação e variação temporal das vazões, por exemplo). Uma incerteza adicional ainda deve ser considerada quando o modelo é utilizado para fazer projeções climáticas, caso em que as próprias variáveis de entrada não foram obtidas por nenhum tipo de medição direta (SOLOMATINE e WAGENER, 2011)

Um dos estudos mais relevantes a respeito da incerteza proveniente dos erros da medição de vazão foi realizado por Sorooshian e Dracup (1980). Os autores propuseram um estimador dos parâmetros baseada na teoria da máxima verossimilhança, que leva em consideração a heterocedasticidade (variância não homogênea) dos dados de vazão observados.

3.3.1.3.1. A Precipitação como fonte de incertezas

A precipitação é considerada uma das mais importantes das variáveis de entrada para a modelagem hidrológica (AJAMI et al., 2007). A maior parte dos estudos envolvendo incertezas na modelagem hidrológica relacionadas aos dados observados diz respeito este fenômeno (GUPTA et al., 2005; MORADKHANI e SOROOSHIAN 2008; MONTANARI, 2011). A formação de nuvens e seu movimento, além de outros processos relacionados ao fenômeno da precipitação, são extremamente complexos e diversificados (KUTSOUIANNIS e LANGOUSIS, 2011). Gupta et al (2005) afirmam que a maior parte do erro nas estimativas da precipitação está relacionado à inabilidade das redes de monitoramento em capturar de forma correta a quantidade e a variabilidade da precipitação no espaço e no tempo.

Beven e Hornberger (1983) e Singh (1997) ressaltam que a importância de uma estimativa acurada da distribuição espacial da precipitação para a modelagem hidrológica é necessária devido a dois fatores. O primeiro diz respeito ao o volume total precipitado em uma bacia, que tem relação direta com o volume de escoamento gerado. Para se determinar este volume é necessário se levar em consideração a distribuição espacial da chuva sobre uma bacia. Deste problema surgem os questionamentos quanto à densidade da rede de monitoramento. Segundo os mesmos autores, além de Obled et al. (1994), a estimativa correta do volume total precipitado é mais importante que o padrão distribuição da chuva em

si. Em segundo lugar, existe a relação entre a variabilidade espacial e características mensuráveis do hidrograma, como pico de vazão e seu deslocamento temporal, como analisado em Wilson et al., (1973).

A hipótese de que a precipitação pode ser considerada uniforme para pequenas áreas é considerada em muitas aplicações de modelagem hidrológica. Goodrich et al (1995) sugerem que esta hipótese não é válida, após analisarem observarem variações de 4 a 14% do total precipitado numa distância de 100 metros num estudo aplicado a uma micro bacia.

No contexto do desempenho de modelos hidrológicos, é consenso entre os estudos que a densidade da rede de monitoramento exerce grande influência nos resultados dos modelos hidrológicos, sendo que estes tendem a serem melhores com o aumento da quantidade de postos de medição (DUNCAN et al., 1993; FAURÈS et al., 1995; CHAPLOT et al. 2005; ANCTIL, 2006; BÁRDOSSY e DAS, 2008;). Das et al. (2008) compararam a relação entre a densidade da rede de monitoramento de precipitação e diferentes esquemas de discretização espacial do modelo HBV. Os autores constataram que este modelo na versão totalmente distribuída (em comparação à semi distribuída, semi concentrada e concentrada) não obteve o melhor desempenho, como era de se esperar, sugerindo que tal resultado ocorreu pela incapacidade do método de interpolação utilizado de representar a variabilidade da precipitação na bacia.

Diversos estudos sugerem que a variabilidade da precipitação exerce uma grande influência nas respostas hidrológicas em bacias hidrográficas com pequenas dimensões (DAWDY e BERGMAN, 1969; MICHAUD e SOROOSHIAN 1994; FRAURÈS 1995; LOPES 1996; ANDREÁSSIAN 2001; BRONSTERT e BARDOSSY 2003). Fraurès et al. (1995) investigaram a hipótese da precipitação uniforme em escalas pequenas, aplicando um modelo distribuído a uma bacia de 4,4 hectares, e chegaram à conclusão que a utilização de somente uma estação de monitoramento da precipitação pode introduzir grandes incertezas na estimativa do escoamento. Andreàssian et al., (2001) analisaram os resultados de simulações hidrológicas para três bacias de diferentes tamanhos (71, 1120 e 10120 km²) utilizando três modelos de diferentes complexidades, e concluíram que bacias hidrográficas pequenas necessitam aparentemente de estimativas mais precisas de precipitação.

A variabilidade temporal e espacial da precipitação, nem sempre é capturada por redes de monitoramento terrestre, e vem encontrando grande apoio em estimativas baseadas em sensoriamento remoto. A precipitação obtida por sensoriamento remoto tem a vantagem de captar melhor a variabilidade espacial, permitindo estimativas de precipitação em lugares de difícil acesso, além de poder estimar precipitação em bacias sem monitoramento (GUPTA et al., 2005).

Segundo Montanari (2011), estimativas de precipitação por satélite são geralmente bem sucedidas em determinar a variabilidade espacial, mas sofrem de maiores incertezas no que diz respeito a estimativas pontuais. Por se tratarem de medidas indiretas de precipitação, as estimativas por satélite não estão livre de erros. Tiers e Peters-Lidard (2007), por exemplo, reportaram erros sistemáticos nas estimativas do satélite TRMM para os píxeis de corpos d'água continentais dos EUA, cujas causas foram, aparentemente, as deficiências em se considerar a emissividade de superfícies d'água. Clarke et al. (2011) atentam para o fato de que as incertezas existentes nas estimativas de precipitação baseadas em redes de monitoramento terrestre são substituídas por aquelas dos instrumentos utilizados pelos satélites e seus algoritmos de transformação de tais medidas em estimativas de precipitação na superfície terrestre. Estimativas de precipitação por satélite vêm sendo largamente utilizadas na modelagem hidrológica, seja em conjunto com estações em terra, utilizadas para a correção de desvios (COLLISCHONN et al., 2006; WAGNER et al., 2012; LI et al., 2012), ou sem correção (STISEN e SANDHOLT 2010; JIANG et al., 2012; SAGINTAYEV et al., 2012).

3.3.1.3.2. Técnicas de estimativas de incertezas considerando a precipitação

Montanari (2011) considera a estimativa das incertezas na modelagem hidrológica uma tarefa difícil, não existindo uma regra geral. No entanto, a solução através da integração de diferentes técnicas pode ser algo factível. Poucas são as técnicas que consideram explicitamente a incerteza da precipitação na formulação de seus algoritmos.

Uma forma de se abordar o problema da precipitação na análise de incertezas é a utilização de modelos de erro multiplicativos, nos quais se considera que a real entrada de

precipitação d_i é multiplicada por um fator de natureza estocástica m_i para se obter a precipitação medida d .

Dentre as metodologias existentes, está o *Bayesian Total Error Analysis* (BATEA) (KAVETSKI 2006a e 2006b). Este método propõe a consideração explícita de um modelo estatístico para o erro dos valores de precipitação e vazão observada, que, numa abordagem bayesiana, são refletidos na incerteza final dos parâmetros e das saídas do modelo.

Outra metodologia que considera explicitamente a incerteza nos valores de precipitação é o *Integrated Bayesian Uncertainty Estimator* (IBUNE) (AJAMI et al., 2007). Esta metodologia propõe a utilização de um modelo de erro multiplicativo para a precipitação, a utilização do algoritmo SCEM para a determinação das incertezas dos parâmetros e a técnica de ponderação bayesiana de modelos (BMA) para a consideração de diversos modelos. Um dos problemas em se utilizar modelos estocásticos de erros para a precipitação é a falta de validação de tais modelos com base em dados reais, sendo que poucos estudos já foram feitos com este fim (MCCMILLAN et al., 2011).

3.3.1.4. Incerteza na estrutura do modelo

Como discutido anteriormente, modelos são conjuntos de aproximações e simplificações da realidade, estando, portanto, sujeitos a incertezas, uma vez que estas aproximações podem ser inadequadas e omitem importantes aspectos do sistema a ser modelado (LIU e GUPTA 2007). Uma das consequências na incerteza estrutural do modelo é que este não é capaz de reproduzir todas as diferentes porções do hidrograma com um único conjunto de parâmetros (GUPTA et al., 2005).

Wagener et al. (2003) afirmam que a escolha de uma medida geral de desempenho do modelo, através do processo de agregação dos resíduos durante o período de calibração, é responsável por ocultar o desempenho dos diferentes componentes do modelo isoladamente. A escolha de múltiplos objetivos durante a calibração, de forma a se avaliar o desempenho do modelo em diferentes aspectos, pode fornecer mais informação sobre a incerteza presente na estrutura utilizada. Uma solução baseada na otimização multicritério foi apresentada por Yapo et al. (1998), que propuseram o algoritmo MOCOM-UA, baseado na escolha de

simulações pertencentes ao conjunto de Pareto. Por conjunto de Pareto, entende-se um conjunto de soluções (diferentes conjuntos de parâmetros) no qual nenhuma solução pode ser considerada objetivamente melhor que a outra.

A aplicação de técnicas de análise de incertezas associadas à utilização de um único modelo são incapazes de contabilizar totalmente a incerteza proveniente da estrutura do modelo utilizado (AJAMI et al., 2007). Uma alternativa para se contornar o problema da incerteza estrutural dos modelos é a abordagem multi-modelos. Como já apontado por Beven (1993) pelo princípio da equifinalidade, semelhante às incertezas nos parâmetros de um único modelo, a complexidade dos sistemas a serem simulados faz com que múltiplos modelos para descrever o mesmo fenômeno devam ser testados. A própria metodologia GLUE propõe a utilização de múltiplos modelos na determinação das incertezas globais, como apontado por Beven (2006).

Uma das abordagens para a utilização de múltiplos modelos é a ponderação de modelos. As técnicas de ponderação de modelos tiveram sua origem em aplicações de modelos climáticos, como em Krishnamurti et al. (1999). Segundo Parrish et al. (2012), as técnicas de ponderação de modelos buscam superar as limitações dos modelos individuais através de uma combinação linear de suas saídas, originando assim uma nova resposta. Ajami et al. (2007) classificam as formas de se combinar as saídas de diferentes modelos em dois grupos. O primeiro grupo utiliza pesos obtidos deterministicamente para ponderar entre os diferentes modelos. Tais pesos podem ser iguais (equivalente a realizar uma média aritmética de todas as saídas), obtidos através de regressão linear múltipla, entre várias outras técnicas. Alguns exemplos da aplicação técnicas de combinação na modelagem hidrológica são os trabalhos de Shamseldin et al. (1997), Georgakakos et al. (2004) e Viney et al. (2009). Em comum a todos estes estudos é a conclusão de que o desempenho da resposta proveniente da ponderação entre os modelos geralmente supera todos os modelos do conjunto.

O segundo grupo de técnicas para a ponderação de modelos baseia-se em técnicas probabilísticas para a atribuição de pesos para os modelos. Dentre as técnicas existentes, a ponderação bayesiana de modelos, ou BMA (do inglês *Bayesian Model Averaging*) é a mais utilizada, e será discutida no item seguinte.

3.3.1.4.1. Ponderação Bayesiana de Modelos (*Bayesian Model Averaging-BMA*)

A ponderação bayesiana de modelos, ou BMA, proposta por Raftery et al. (2005), é uma técnica de pós processamento estatístico para a produção de previsões probabilísticas de conjuntos de modelos (VRUGT et al., 2008). No campo das ciências terrestres, o BMA teve suas primeiras aplicações na ponderação de modelos de previsão climática, sendo mais recentemente utilizado como uma forma de se ponderar as saídas de diversos modelos hidrológicos. O método BMA, ao contrário de outras técnicas de ponderação de modelos, considera as respostas de cada modelo como grandezas estocásticas através da adoção de funções densidade de probabilidade (*fdp*) para cada uma destas. A previsão obtida pela técnica BMA é uma *fdp* resultante da soma ponderada das *fdp*'s de cada um dos modelos. Considerando um conjunto contendo K modelos, a *fdp* obtida pelo método BMA, pela lei da probabilidade total, pode ser escrita como:

$$p(y_t|M_1, \dots, M_K) = \sum_{i=1}^K P(M_i|Y) \cdot P(y_t|M_i, Y), \quad (3)$$

onde $P(y_t|M_i, Y)$ é definido como a **distribuição** à posteriori da grandeza y no instante t , baseada no modelo M_i e nos dados observados durante a calibração Y . $P(M_i|Y)$ é a **probabilidade** à posteriori relativa a M_i ser o modelo correto, dado a série observada Y . As probabilidades à posteriori dos modelos, $P(M_i|Y)$, relacionados à capacidade preditiva dos modelos durante o período de calibração, somam à unidade e podem ser consideradas como pesos (w), de forma que a expressão anterior adquire a seguinte forma:

$$p(y_t|M_1, \dots, M_K) = \sum_{i=1}^K w_i \cdot P(y_t|M_i, Y), \quad (4)$$

A resposta obtida desta forma pode ser utilizada para se determinar limites de confiança dos resultados, podendo-se calcular assim a percentagem de dados incluídos numa determinada faixa de incerteza. Outra propriedade da saída obtida pelo método BMA é a sua média, que pode ser utilizada como uma previsão determinística (RAFTERY et al., 2005). A Figura 8, extraída de Raftery et al. (2005) exemplifica o método BMA, aplicado para a previsão da temperatura ao nível do mar, a partir de 5 modelos diferentes. As linhas pontilhadas são os limites para um nível de confiança de 95%, a linha vertical sólida é o valor

observado e a curva sólida é a *pdf* resultante da soma ponderada das *fdp*'s dos modelos utilizados.




Figura 8 - Formação da fdp resultante através do método BMA, adaptado de Raftery et al., (2005).

Diversos estudos aplicaram o método BMA no contexto da modelagem hidrológica (DUAN et al., 2007; ZHANG et al., 2009; BASTOLA et al., 2011). Duan et al. (2007) aplicaram em conjunto nove modelos, em três bacias distintas, chegando à conclusão que o modelo obtido pela média através do BMA obteve desempenho igual ou superior aos melhores modelos. Os autores também aplicaram um esquema de determinação dos pesos aplicado à diferentes faixas de vazão, obtendo resultados melhores através deste esquema. Zhang et al. (2010) aplicaram o modelo SWAT em duas bacias distintas, utilizando múltiplas estruturas para o cálculo da evapotranspiração e infiltração. O modelo foi calibrado usando algoritmos genéticos e posteriormente foi utilizado o método BMA para a determinação das faixas finais de incertezas. A diferença final entre a percentagem de dados contidos na faixa de incertezas para um intervalo de confiança de 95% pelo método BMA não foi maior do que 10% e os autores consideraram que a aplicação de ambos os métodos em conjunto pode ser uma estratégia para a redução das incertezas tendo em vistas aplicações para nortear políticas públicas. Vrugt e Robinson (2007) compararam as propriedades das previsões probabilísticas

obtidas pelo método *Ensemble Kalman Filter* com aquelas obtidas pelo método BMA utilizando cinco modelos. Os autores chegaram à conclusão de que o primeiro obteve melhor desempenho, mas atentaram para a flexibilidade do método BMA como técnica de estimativa da incerteza estrutural dos modelos.

Além de aplicações utilizando diferentes modelos ou diferentes estruturas de um mesmo modelo, o método BMA vem sendo utilizado como alternativa para a consideração das incertezas quanto à precipitação. Jiang et al. (2012) utilizaram o método BMA para combinar as simulações hidrológicas do modelo Xinangiang (ZHAO, 1992) a partir de três produtos de satélites, além de uma série obtidas pela rede terrestre de monitoramento. Os resultados foram considerados satisfatórios, sugerindo a metodologia como uma boa solução para bacias hidrográficas sem monitoramento. Strauch et al. (2012) utilizaram o modelo SWAT para a bacia do rio Piripau, no DF do Brasil, simulando a vazão a partir de diferentes esquemas de precipitação. O objetivo do estudo foi propor uma metodologia para a modelagem hidrológica em bacias com pouco monitoramento, e os resultados indicam que a utilização de conjuntos de modelos baseados em diferentes entradas de precipitação podem prover previsões de vazão mais confiáveis.

4. MATERIAIS E MÉTODOS

4.1. Área de estudo

4.1.1. Localização e climatologia

O estudo foi realizado na bacia hidrográfica do Ribeirão da Onça (B.R.O), com área de 65 km² e localizada no município de Brotas (entre os paralelos 22°10' e 22°15' de latitude sul e entre os meridianos 47°55' e 48° de longitude oeste) (Figura 9).

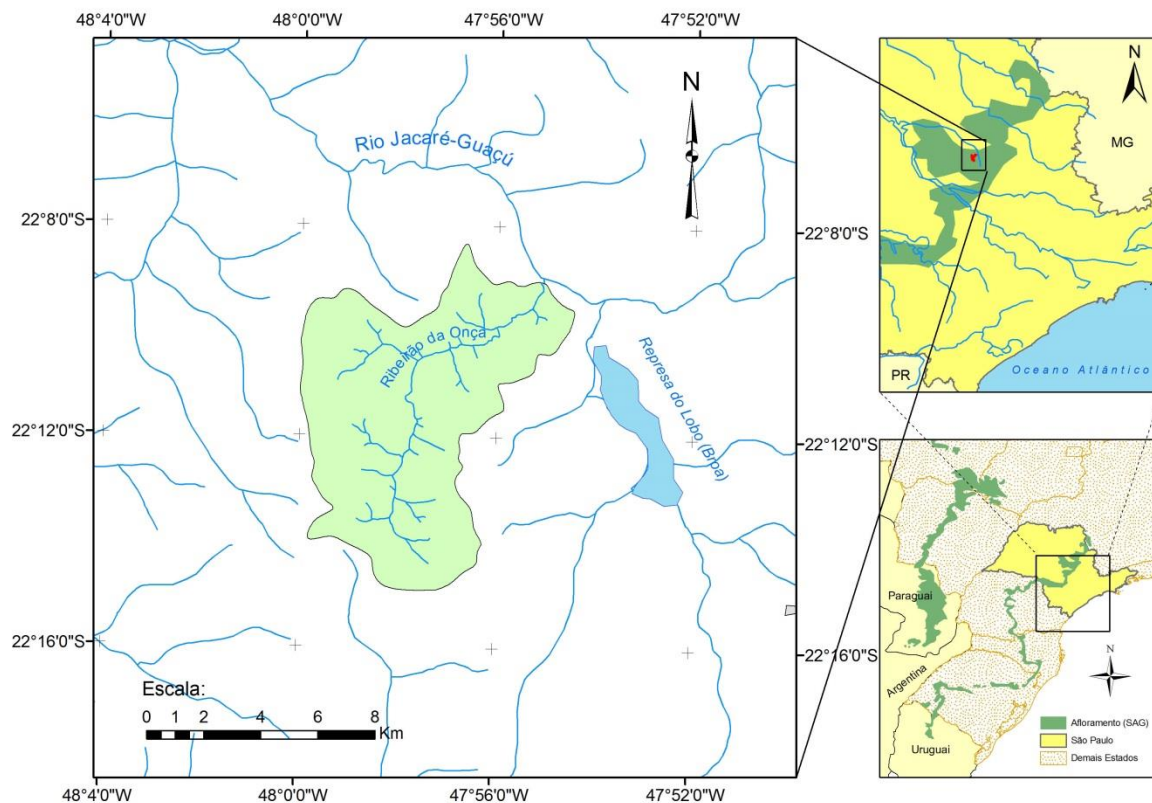


Figura 9 – Localização Bacia do Ribeirão da Onça

Os dados climatológicos usados como referência foram obtidos na Estação Climatológica do Centro de Recursos Hídricos e Ecologia Aplicada da USP (CRHEA-USP), de coordenadas geográficas 22°10'13,7''S e 47°53'55''W (*datum* WGS 84). Tais dados mostram que a temperatura média anual da região é de 20,5 °C e a precipitação média anual

oscila entre 1300 e 1400 mm. Segundo a classificação climática de Köppen, a bacia possui clima subtropical úmido com chuvas de verão e clima subtropical úmido com inverno seco.

4.1.2. Características físicas

A caracterização física da bacia foi realizada por Mattos et al. (1984) e Preto Filho (1990) apud Pompêo (1990) com base em curvas de nível em escala 1:10.000. Os valores obtidos em tais estudos estão resumidos na tabela abaixo:

Tabela 1 - Características físicas da BRO.

Característica	Valor
Área de drenagem	65 km ²
Perímetro	42 km
Comprimento axial	11 km
Extensão do curso d'água principal	16 km
Comprimento total dos cursos d'água	55 km
Altitude máxima	840 m
Altitude mínima	640 m
Declividade média	7,6 m/km

A densidade de drenagem, Dd , é um índice amplamente utilizado para descrição de redes de drenagem naturais, retornando o comprimento dos cursos d'água por unidade de área (Horton, 1945). Pompêo (1990), ao calcular a densidade de drenagem da B.R.O, encontrou o valor de 0,95 km/km², o que significa um desenvolvimento mediano do sistema de drenagem.

O coeficiente de compacidade, Kc , é a razão entre o perímetro da bacia e o perímetro de um círculo de igual área. Quanto mais próximo da unidade, maior será a potencialidade para picos de enchentes. O valor de Kc encontrado é igual a 1,47 e indica que a bacia do Ribeirão da Onça não é sujeita a enchentes.

4.1.3. Uso e ocupação do solo

A bacia do Ribeirão da Onça é tipicamente rural, havendo cultivos de citros, cana-de-açúcar, soja e plantações de eucalipto. Uma pequena parcela da bacia é utilizada como pasto. A principal cultura da bacia é a de eucaliptos, ocupando em média cerca de 35% da área ao longo dos últimos 5 anos. As culturas presentes na B.R.O foram desenvolvidas em uma região cuja vegetação nativa era o cerrado. Apenas uma pequena parcela desta vegetação ainda está presente na bacia, existindo sob a forma de mata ciliar, ao longo dos cursos d'água. O mapa a seguir ilustra a distribuição espacial das culturas na bacia:

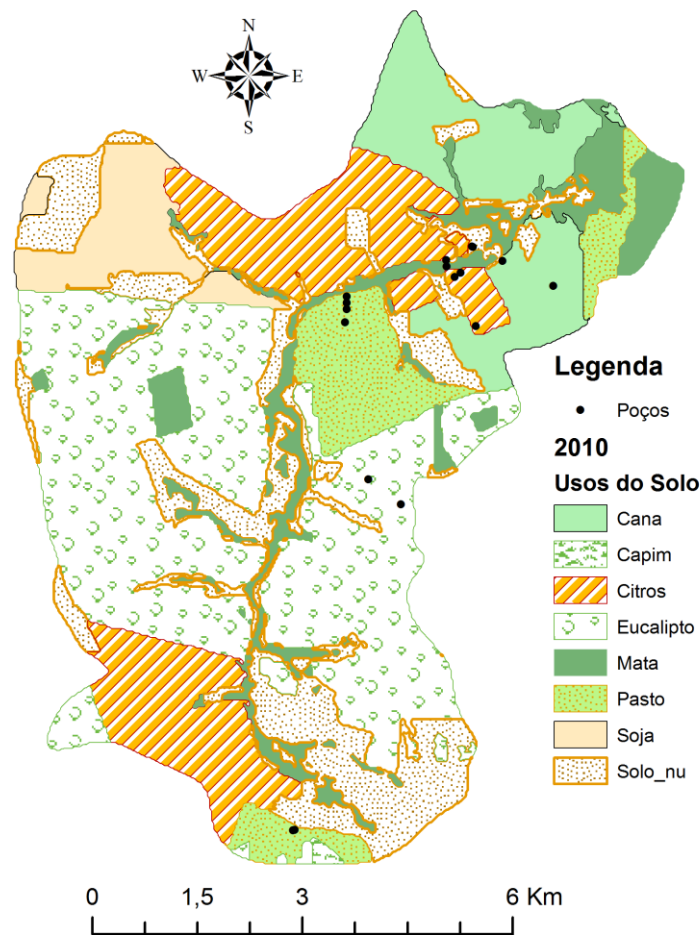


Figura 10 - Mapa de uso do solo da B.R.O.

4.1.4. Pedologia

De acordo com Castro Junior (2008), há cinco tipos pedológicos principais (Figura 11): areias quartzosas profundas, latossolo vermelho-amarelo álico, latossolo roxo eutrófico, terra roxa distrófica ou eutrófica, solos hidromórficos do tipo Gley, e latossolos vermelho-escuros distróficos ou álicos.

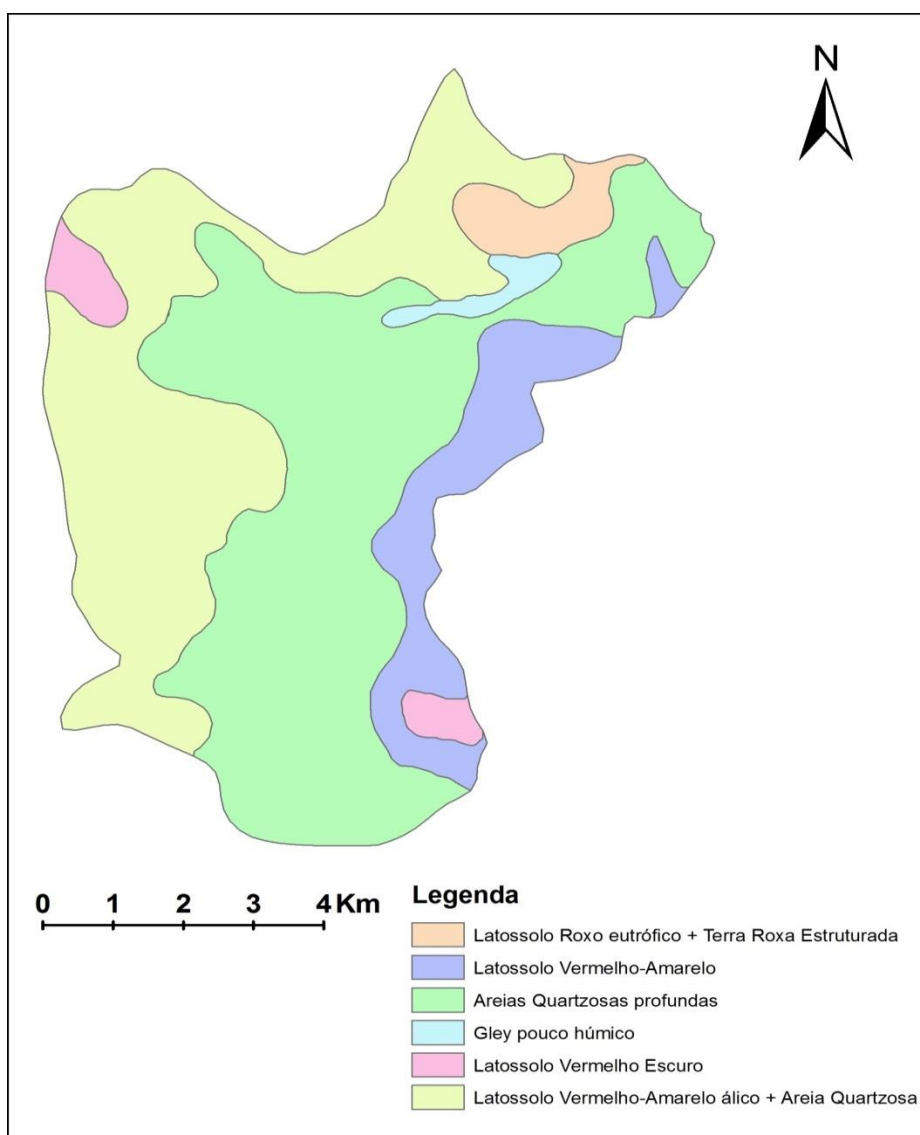


Figura 11 - Mapa pedológico do Estado de São Paulo na região da BRO. Fonte: Castro Júnior (2008).

4.1.5. Monitoramento das variáveis climáticas.

A bacia do Ribeirão da Onça localiza-se próxima à estação climatológica do CRHEA-USP. Nesta estação são realizadas medidas de diversas variáveis climatológicas desde o início da década de 1970. As principais variáveis, em valores diários, bem como o método utilizado para a sua obtenção estão resumidos na Tabela 2.

Tabela 2 - Instrumentos utilizados na estação CRHEA-USP para medições de variáveis climáticas.

Variável	Método
Temperatura máxima do ar, °C	Termômetro de mercúrio
Temperatura mínima do ar, °C	Termômetro de mercúrio
Velocidade do vento, $km.h^{-1}$	Anemômetro de conchas à 0,5 e 2,0 m
Precipitação, mm	Pluviômetro Ville de Paris
Radiação solar, $cal.cm^{-2}.dia^{-1}$	Actinógrafo
Umidade relativa	Termohigrógrafo de cabelo

4.1.5.1. Monitoramento da precipitação

4.1.5.1.1. Estações pluviométricas

Além da estação climatológica do CRHEA-USP, o monitoramento da precipitação é feito em outras estações ao longo da B.R.O. A Agência Nacional de Águas (ANA) possui uma estação pluviométrica localizada na região sul da bacia. A estação, de código 2247197, está em funcionamento desde 1976. Tanto a estação ANA quanto a estação CRHEA funcionam com pluviômetros do tipo *ville de Paris*, e são lidas todos os dias às 7 horas da manhã. Duas estações climatológicas adicionais foram instaladas recentemente e registram a precipitação em intervalos de 10 em 10 minutos: A estação localizada na fazenda Santo Inácio, instalada em maio de 2010 e a estação localizada na fazenda Monte Alegre, instalada em junho de 2011. Na Figura 12 pode-se verificar a localização das estações na B.R.O.

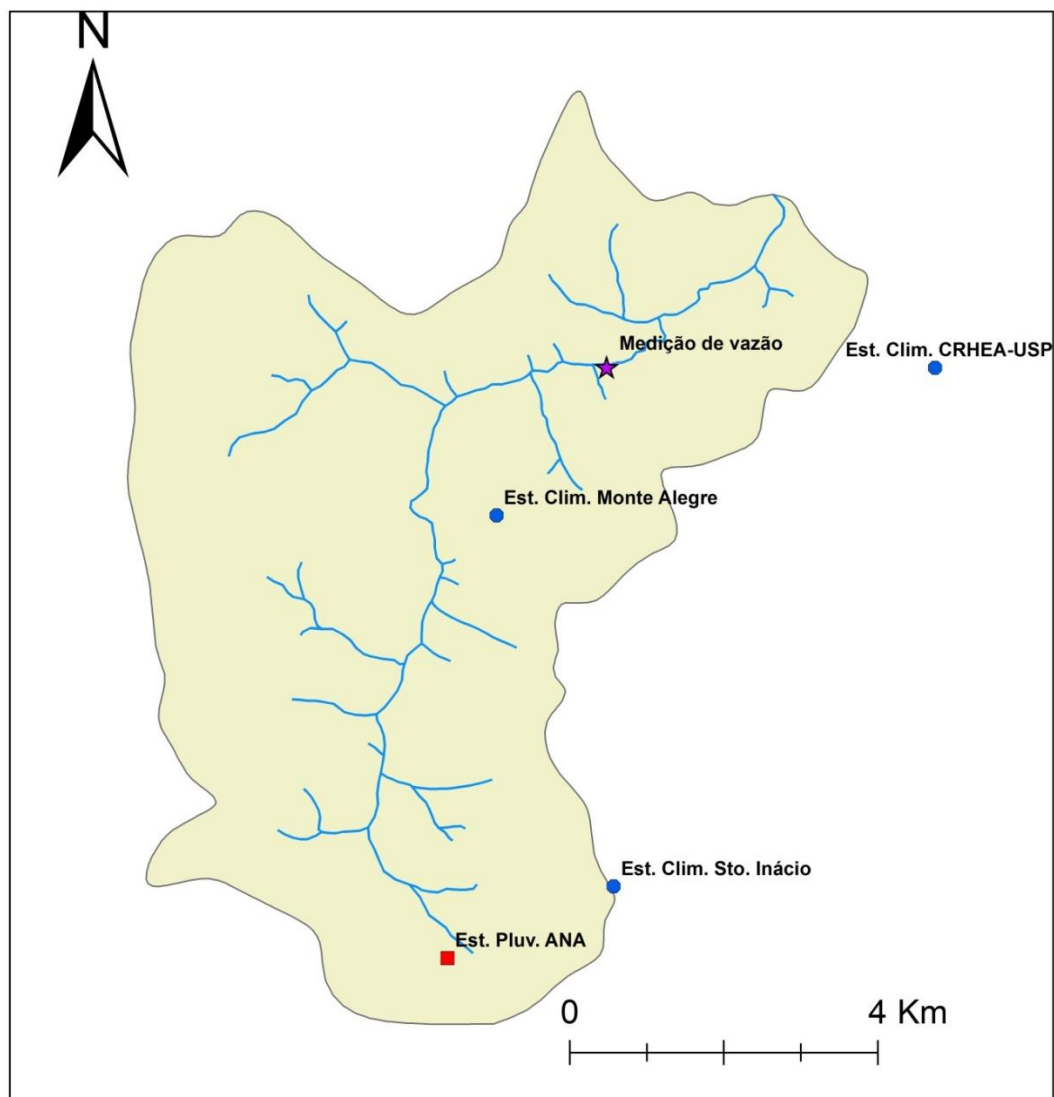


Figura 12 - Localização das estações de monitoramento climatológico na BRO.

4.1.5.1.2. O satélite TRMM

A precipitação medida por meio de satélites vem se tornando uma ferramenta importante nas análises hidrológicas. O seu uso ganha destaque principalmente em regiões de difícil acesso e, principalmente, em países em desenvolvimento, onde a rede de monitoramento é escassa e os dados são de má qualidade (HUGHES, 2006). O uso de precipitação medida por satélite (assim como outros produtos de sensoriamento remoto) pode

ser encarado também como uma fonte de dados na modelagem hidrológica de bacias não monitoradas.

A TRMM é uma missão conjunta entre a Agência Espacial Norte Americana (*NASA*) e a Agência de exploração Aeroespacial Japonesa (*JAXA*) desenvolvida para monitorar e estudar as precipitações nos trópicos (KUMMEROW et al., 2000; ROZANTE et al., 2010). Os produtos desta missão são previsões em tempo real (TR) e previsões recalibradas com base em medições em terra. O produto utilizado nesta pesquisa é o 3B42, que consiste em estimativas com uma resolução temporal de 3 horas. Os valores horários foram acumulados para atender à escala diária. A resolução espacial corresponde a pixels de 0,25 por 0,25 graus, que representa uma área de aproximadamente 650 km². O pixel utilizado foi aquele onde a BRO está completamente inserida.

4.1.5.2. Monitoramento da vazão

O monitoramento contínuo dos níveis vazões do Ribeirão da Onça teve início no ano de 2007. A metodologia utilizada consistiu, inicialmente, num sistema de boia e contrapeso, mais tarde substituído por um Diver datalogger (da marca Schlumberger), que funciona como um linígrafo, registrando em intervalos de 15 minutos os níveis d'água a montante de dois bueiros localizados próximos ao exutório da bacia (Figura 12 e Figura 13). Tais níveis são convertidos em carga hidráulica atuante sobre os bueiros. A transformação da carga hidráulica em valores de vazão é feita pela equação de Henderson (1966). Considerando H a carga hidráulica atuante e D o diâmetro do bueiro, temos para relações H/D menores que 0,8 a seguinte equação:

$$Q = 1,503 \cdot H^{1,9} \cdot D^{0,6}, \quad (5)$$

em que Q é a vazão (m³/s), H é a carga hidráulica (m) e D é o diâmetro do bueiro (m). Para relações H/D maiores que 0,8, é utilizada a equação:

$$Q = 1,378 \cdot H^{1,5} \cdot D. \quad (6)$$

Para que seja válida, a equação de Henderson pressupõe a transição do regime de escoamento fluvial para torrencial na passagem do escoamento pelos bueiros. Logo após os bueiros, à margem do ribeirão, estão instaladas bombas de captação de água, para prover água de irrigação a uma das fazendas existentes no território da bacia. Para que o sistema

funcione, é necessário que se suba o nível d'água na entrada das tubulações de sucção. Por diversas vezes, a fim de se conseguir tal aumento do nível d'água, são realizados barramentos a jusante do sistema de captação, o que provoca um remanso. Tal remanso acaba por afetar as características do escoamento dentro dos bueiros, que não mais passam pelo regime crítico, invalidando a equação utilizada.

Além dos valores lidos automaticamente pelos aparelhos, são feitas medições com um molinete a cada 15 dias. Tais valores ajudam a validar a equação utilizada e também a verificar situações em que a equação do bueiro não pode ser utilizada.




Figura 13 - Condição do escoamento dentro do Bueiro em situação de barramento à jusante da seção de medição.

4.2. Modelo SWAT

4.2.3. SWAT e ArcSWAT

O SWAT é um modelo físico, semi-distribuído, que simula os processos físicos de uma bacia hidrográfica em tempo contínuo, operando no passo diário. O modelo foi desenvolvido como ferramenta para avaliação do efeito de diferentes manejos de solo e variações climáticas nas produções da vazão líquida e sedimentos.

Neste estudo, o modelo SWAT foi utilizado através da plataforma ArcSWAT (Winchell et al., 2010). A interface ArcSWAT é uma extensão para o *software* de geoprocessamento ArcGIS, onde os dados de entrada para o modelo são carregados e as simulações são executadas.

Os dados exigidos pelo modelo são cartográficos e tabulares, sendo os primeiros divididos em: (i) Modelo Digital de Elevação (MDE); (ii) Mapa de tipos de Solo; (iii) Mapa de uso e ocupação do solo. Os dados tabulares, inseridos no modelo por meio de planilhas digitais, são: (i) Características físicas dos solos da área de estudo; (ii) Características climáticas da área de estudo.

A discretização espacial é feita através de sub-bacias, geradas a partir do MDE, e conectadas entre si através de uma rede de drenagem. Dentro das sub-bacias são geradas unidades de resposta hidrológica, ou HRU (do inglês *Hydrologic Response Unit*). As HRU são combinações únicas entre diferentes tipos de solo, uso e ocupação do mesmo, e declividades do terreno. As HRU não são espacialmente definidas, mas sim valores de área total dentro de determinada sub-bacia com determinada combinação entre os fatores citados, não havendo, portanto, interação entre as mesmas (ARNOLD et al., 2011). O seguinte fluxograma (Figura 14) expõe esquematicamente o funcionamento da interface ArcSWAT.

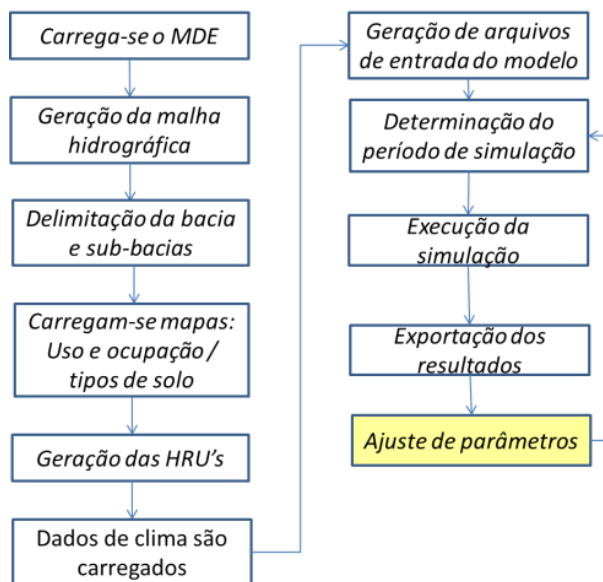


Figura 14 - Fluxograma da utilização do modelo SWAT

4.2.4. Parâmetros Climáticos e Gerador Climático

O modelo SWAT necessita de dados diários de precipitação, temperaturas máxima e mínima, radiação solar, umidade relativa do ar e velocidade do vento. A espacialização das variáveis climáticas é feita associando-se os dados da estação climatológica mais próxima ao centróide cada sub-bacia.

O gerador climático WXGEN (SHARPLEY e WILLIAMS, 1990) funciona com base em valores médios e tem o objetivo de simular dados diários para variáveis faltantes, bem como preencher as falhas das séries de variáveis que foram medidas. A tabela abaixo contém a descrição dos parâmetros médios mensais de entrada requeridos pelo gerador climático.

Tabela 3 - Descrição dos parâmetros de clima do modelo SWAT

Parâmetro	Descrição
TMPMX	Temperatura máxima diária de cada mês, °C
TMPMN	Temperatura mínima diária de cada mês, °C
TMPSTDMX	Desvio padrão para temperatura máxima de cada mês, °C
TMPSTDMN	Desvio padrão para temperatura mínima de cada mês, °C
PCPMM	Precipitação total diária média de cada mês, <i>mm H₂O</i>
PCPSTD	Desvio padrão para precipitação total diária, <i>mm H₂O</i>
PCPSKW	Coefficiente de assimetria para a precipitação diária
PR_W1	Probabilidade de haver chuva após um dia sem chuva
PR_W2	Probabilidade de haver chuva após um dia com chuva
PCPD	Número médio de dias com chuva, num determinado mês
RAINHHMX	Chuva máxima com duração de 30 minutos, <i>mm H₂O</i>
SOLARAV	Radiação solar diária para cada mês, <i>MJ/m²/dia</i>
DEWPT	Ponto de orvalho diário para cada mês, °C
WNDVAV	Velocidade do vento diária para cada mês, <i>m/s</i>

4.2.5. Parâmetros de Solos

Para a entrada dos dados referentes aos diferentes tipos de solo, o modelo requer uma série de informações, sendo que cada tipo de solo pode possuir até cinco camadas com distintas propriedades físicas. A seguir estão resumidos os parâmetros exigidos pelo SWAT.

Tabela 4 - Descrição dos parâmetros de solo do modelo SWAT

Parâmetro	Descrição
NLAYERS	Número de camadas do solo em questão
HYDRGRP	Grupo hidrológico (A, B, C ou D)
SOL_ZMX	Profundidade máxima alcançada pela raiz, <i>mm</i>
SOL_Z	Profundidade, da superfície até o fundo da camada, <i>mm</i>
SOL_BD	Densidade do solo, <i>g/cm³</i>
SOL_AWC	Quantidade de água possível de ser armazenada no solo, <i>mm/mm</i>
SOL_K	Condutividade hidráulica do solo saturado, <i>mm/h</i>
SOL_CBN	Quantidade de carbono orgânico, <i>% do peso do solo</i>
SOL_CLAY	Quantidade de argila, <i>% do peso do solo</i>
SOL_SILT	Quantidade de silte, <i>% do peso do solo</i>
SOL_SAND	Quantidade de areia, <i>% do peso do solo</i>
SOL_ROCK	Quantidade de rochas, <i>% do peso do solo</i>
SOL_ALB	Albedo do solo, <i>%</i>
USLE_K	Fator de erodibilidade, <i>0.013.t. m². h / (m³.t.cm)</i>

A definição dos parâmetros de granulometria do solo para o modelo SWAT foi baseado em ensaios feitos em laboratório com material retirado dos diferentes solos da bacia. A determinação da condutividade hidráulica saturada foi obtida através de medidas com permeâmetro de Guelph a profundidades de 20 e 40 cm em diferentes tipos de solo e coberturas vegetais. O parâmetro da quantidade de água disponível no solo foi obtido através da função de pedotransferência de Saxton e Rawls (2006), que utiliza apenas granulometria e teor de matéria orgânica. A escolha dos valores dos parâmetros para as camadas mais profundas de solo foi feita de modo a seguir a tendência natural que se imagina para a bacia, estando sujeita, portanto, a significativa incerteza.

4.2.6. Principais processos simulados pelo modelo SWAT

4.2.6.1. Balanço hídrico

As rotinas hidrológicas presentes no modelo SWAT incluem os processos na zona vadosa (infiltração, evaporação, consumo de água pelas plantas, escoamento sub-superficial e percolação) e o fluxo de água subterrânea. O ciclo hidrológico simulado pelo SWAT segue a seguinte equação de balanço hídrico a ser realizada em cada HRU:

$$SW_t = SW_0 + \sum (R_{day} - Q_{surf} - w_{seep} - Q_{gw} - E_a), \quad (7)$$

Em que SW_t é a quantidade de água final no solo (mm H_2O), SW_0 é a quantidade de água inicial no solo para um dia i (mm H_2O), t é o tempo (dias), R_{day} é a precipitação no dia i (mm H_2O), Q_{surf} é o escoamento superficial no dia i (mm H_2O), E_a é a quantidade de água evapotranspirada no dia i (mm H_2O), w_{seep} é a quantidade de água entrando na zona vadosa (mm H_2O) e Q_{gw} é a contribuição da água subterrânea ao escoamento total no curso d'água (fluxo de base). A Figura 15 esquematiza os principais processos simulados pelo SWAT:




Figura 15 - Resumo esquemático dos processos simulados pelo modelo SWAT. Fonte: Neitsch et al., (2011).

4.2.6.2. Formulação do Escoamento Superficial

O modelo SWAT permite que se calcule o escoamento superficial através de dois métodos: Green & Ampt (1911) ou Soil Conservation Service (SCS, 1972). O primeiro método utiliza dados de precipitação em intervalos sub-diários, e por isso não foi considerado neste trabalho. O SWAT utiliza uma versão modificada do método Soil Conservation Service (SCS, 1972), que será apresentada a seguir. A equação do SCS para a determinação do escoamento superficial é:

$$Q_{surf} = \frac{(R_{day} - I_a)^2}{(R_{day} - I_a + S)}, \quad (8)$$

em que Q_{surf} é o escoamento superficial acumulado ou precipitação efetiva, em mm H_2O . O termo I_a representa as abstrações iniciais (infiltração, interceptação da chuva pela vegetação)

no dia (mm H₂O), S é o parâmetro de retenção no dia (mm H₂O) e R_{day} é precipitação diária, em mm de H₂O. O termo Ia é calculado como Ia=0,2S.

O parâmetro de retenção S varia de acordo com o tipo e uso do solo, além da declividade do terreno, podendo ser definido por:

$$S = 25,4 \left(\frac{1000}{CN} - 10 \right), \quad (9)$$

em que CN é o curva número, que irá variar de 0 a 100, sendo 0 referente à situação de total permeabilidade e 100 à de total impermeabilidade solo. O CN é função da transmissividade do solo, seu uso e suas condições antecedentes de umidade. Os tipo de solo, segundo o SCS, são os seguintes:

A: Solos com altas taxas de transmissividade de água.

B: Solos com moderadas taxas de transmissividade de água.

C: Solos com baixas taxas de transmissividade de água.

D: Solos com taxas de transmissividade de água muito baixas.

Os valores de CN estão condicionados a uma entre as três condições de umidade antecedentes: Condição 1, equivalente ao ponto de murcha das plantas; Condição 2, situação de umidade média e Condição 3, equivalente ao solo saturado. Como a maioria dos valores tabelados do CN referem-se à Condição 2, as seguinte equações fazem a correção desta para as outras condições:

$$CN_1 = CN_2 - \frac{20(100 - CN_2)}{100 - CN_2 + \exp[2,533 - 0,063(100 - CN_2)]} \quad (10)$$

$$CN_3 = CN_2 \exp[0,00673(100 - CN_2)] \quad (11)$$

4.2.6.2.1. Atualização do parâmetro de retenção

O modelo SWAT atualiza o valor do parâmetro de retenção, S , baseado na quantidade de água no perfil do solo a cada dia simulado. Para tal, a seguinte equação é utilizada:

$$S = S_{max} \cdot \left(1 - \frac{SW}{[SW + \exp(w_1 - w_2 \cdot SW)]} \right), \quad (12)$$

em que S_{max} é o maior valor que o parâmetro de retenção pode atingir em qualquer dia (mm), SW é a quantidade de água no perfil de solo, excluindo-se o valor referente ao ponto de murcha (mm H_2O). Os parâmetros w_1 e w_2 são coeficientes de forma. O valor de S_{max} é calculado resolvendo-se a equação 12 utilizando o valor de CN_1 . Os coeficientes de forma são obtidos resolvendo-se a equação acima, assumindo-se que: (i) o parâmetro de retenção para o valor de CN com condição de umidade 1 refere-se à quantidade de água equivalente ao ponto de murcha do perfil de solo, (ii) o parâmetro de retenção para o valor de CN com condição de umidade 1 refere-se à quantidade de água equivalente à capacidade de campo do perfil de solo, e (iii) o valor do CN para o solo completamente saturado é igual a 99 ($S=2,54$). Sendo assim, temos os seguintes valores:

$$w_1 = \ln \left[\frac{FC}{1 - S_3 \cdot S_{max}^{-1}} - FC \right] + w_2 \cdot FC \quad (13)$$

$$w_2 = \frac{\left(\ln \left[\frac{FC}{1 - S_3 \cdot S_{max}^{-1}} - FC \right] - \ln \left[\frac{SAT}{1 - 2,54 \cdot S_{max}^{-1}} - SAT \right] \right)}{SAT - FC} \quad (14)$$

em que w_1 é o primeiro coeficiente de forma, w_2 é o segundo coeficiente de forma, FC é a quantidade de água no perfil de solo quando na capacidade de campo (mm H_2O), S_3 é o parâmetro de retenção para o CN da condição de umidade antecedente 3 (solo saturado), S_{max} é o parâmetro de retenção para o CN da condição de umidade antecedente 1 (ponto de murcha), SAT é a quantidade de água no perfil de solo quando completamente saturado (mm H_2O) e 2,54 é o valor do parâmetro de retenção para um CN de 99.

O valor diário do CN é calculado, utilizando-se o parâmetro de retenção diário calculado pela equação 12, sendo, portanto, igual a:

$$CN = \frac{25400}{(S + 254)}, \quad (15)$$

em que CN é o valor da curva número para o dia em questão e S é o parâmetro de retenção calculado com base na quantidade de água no solo para este dia.

4.2.6.3. Percolação

A percolação ocorre, quando a quantidade de água de uma camada é superior à capacidade de campo da mesma e a camada abaixo desta não se encontra saturada. Caso a camada em questão seja a última, a água percola para a zona vadosa. O processo da percolação é calculado pelo modelo SWAT seguindo a seguinte rotina:

O volume disponível para a percolação é calculado como:

$$\text{se: } SW_{ly} \geq FC_{ly}, \quad SW_{ly,excess} = SW_{ly} - FC_{ly}, \quad (16)$$

$$\text{se: } SW_{ly} < FC_{ly}, \quad SW_{ly,excess} = 0, \quad (17)$$

sendo $SW_{ly,excess}$ (mm H_2O) o volume drenável de água para uma determinada camada ly , SW_{ly} (mm H_2O) a quantidade água de uma camada de solo ly e FC_{ly} (mm H_2O) a capacidade de campo da camada de solo em questão

Tem-se como a quantidade de água que passa de uma camada para a outra, em mm de H_2O :

$$w_{perc,ly} = SW_{ly,excess} \cdot \left(1 - \exp\left[\frac{-\Delta t}{TT_{perc}}\right]\right), \quad (18)$$

onde Δt é o intervalo de tempo (24 h), TT_{perc} é o tempo para atravessar a espessura da camada ly (h). O tempo de saturação (TT_{perc}) é obtido pela seguinte equação:

$$TT_{perc} = \frac{(SAT_{ly} - FC_{ly})}{K_{sat}}, \quad (19)$$

onde SAT_{ly} é a quantidade de água no solo para saturação (mm H_2O) e K_{sat} é a condutividade hidráulica (mm/h).

4.2.6.4. Escoamento sub-superficial

O modelo SWAT calcula a contribuição lateral, ou escoamento sub-superficial em conjunto com a percolação. Para o cálculo do escoamento deste, é utilizado um modelo de armazenamento cinemático proposto por Sloan et al. (1984), que pode ser descrito pela seguinte equação:

$$q_{lat} = 0,0024 \cdot \left(\frac{2 \cdot SW_{ly,excess} \cdot K_{sat} \cdot slp}{\theta_d \cdot L_{hill}} \right), \quad (20)$$

onde $SW_{ly,excess}$ é o volume drenável de água para uma determinada camada ly de solo (mm H_2O), slp é a declividade da vertente, θ_d é a quantidade de água drenável da camada de solo (mm/mm) e L_{hill} é o comprimento da vertente (m).

4.2.6.5. Fluxo de águas subterrâneas

Para o cálculo do fluxo de base há de se entender, inicialmente, como o modelo SWAT processa as informações referentes à água subterrânea. O modelo simula a existência de dois aquíferos, um superficial, não confinado, e um profundo, confinado. Toda a água que adentra o aquífero profundo é considerada como perdida, indo contribuir ao escoamento em algum ponto fora da bacia (ARNOLD *et al.*, 1993).

O balanço hídrico da água subterrânea no aquífero superficial é representado pela equação:

$$aq_{sh,i} = aq_{sh,i-1} + w_{rchrq,sh} - Q_{gw} - w_{revap} - w_{pump,sh}, \quad (21)$$

em que $aq_{sh,i}$ (mm) é a quantidade de água no aquífero livre no dia "i", $aq_{sh,i-1}$ (mm) é a quantidade de água no aquífero livre no dia anterior, $w_{rchrq,sh}$ a recarga do aquífero superficial (mm), Q_{gw} é escoamento de base (mm), w_{revap} (mm) é a quantidade de água que se desloca do aquífero para o solo e $w_{pump,sh}$ é a quantidade de água bombeada (mm).

A recarga do aquífero livre se dá pela seguinte equação:

$$w_{rchrq,sh} = w_{rchrgh} - w_{deep}, \quad (22)$$

onde w_{rchrg} é a recarga total ao sistema subterrâneo, proveniente da percolação na última camada de solo (mm) e w_{deep} é a água que passa para o aquífero confinado (mm). Finalmente, a transferência entre o aquífero livre e o profundo se dá pela equação:

$$w_{deep} = \beta_{deep} \cdot w_{rchrg}, \quad (23)$$

sendo β_{deep} o coeficiente de percolação do aquífero raso para o profundo.

4.2.6.5.1. Escoamento de base

O modelo utiliza a equação de regime permanente de Hooghoudt (1940), assumindo que a variação do fluxo de água subterrânea é linearmente relacionada à variação do nível freático:

$$Q_{gw} = \frac{8000 \cdot K_{sat}}{L_{gw}^2} \cdot h_{wtbl}, \quad (24)$$

em que Q_{gw} é a contribuição do escoamento de base no canal principal do rio num dia i (mm H_2O), L_{gw} é a distância do extremo da sub-bacia ao canal principal (m), h_{wtbl} é a altura do nível freático (m). A variação do nível freático devido à recarga é calculada por (SMEDEMA e RYCROFT, 1983):

$$\frac{dh_{wtbl}}{dt} = \frac{w_{rchrg,sh} - Q_{gw}}{800 \cdot \mu}, \quad (25)$$

em que $\frac{dh_{wtbl}}{dt}$ é a variação do nível freático no aquífero livre no tempo (mm/dia) e μ é a porosidade específica do aquífero livre (m/m). Pode-se combinar as equações 24 e 25:

$$\frac{dQ_{gw}}{dt} = 10 \cdot \frac{K_{sat}}{\mu \cdot L_{gw}^2} \cdot (w_{rchrg,sh} - Q_{gw}) = \alpha_{gw} \cdot (w_{rchrg,sh} - Q_{gw}), \quad (26)$$

em que α_{gw} é a constante de recessão do escoamento de base. Integrando-se a equação anterior no tempo, tem-se:

$$Q_{gw,i} = Q_{gw,i-1} \cdot \exp[-\alpha_{gw} \cdot \Delta t] + w_{rchrg,sh} \cdot (1 - \exp[-\alpha_{gw} \cdot \Delta t]), \quad (27)$$

em que $Q_{gw,i}$ é a contribuição do aquífero livre para o escoamento para o canal principal no dia i ($\text{mm } H_2O$), $Q_{gw,i-1}$ é a contribuição do dia $i-1$ ($\text{mm } H_2O$) e Δt é o passo de tempo (diário). Não havendo recarga do aquífero livre, tem-se:

$$Q_{gw} = Q_{gw,0} \cdot \exp[-\alpha_{gw} \cdot t], \quad (28)$$

Onde $Q_{gw,0}$ é a contribuição subterrânea para o escoamento para o canal principal no início da recessão e t é o tempo, em dias, decorrido desde o início da recessão.

4.2.6.6. Evapotranspiração

4.2.6.6.1. Evapotranspiração potencial

Existem três métodos para o cálculo da evapotranspiração potencial através do modelo SWAT: Priestley-Taylor, Hargreaves e Penman-Monteith (NEITSCH *et al.*, 2011), sendo que estes variam quanto à quantidade de dados de entrada necessários para o cálculo.

Foi escolhida a equação de Penman-Monteith, por se tratar daquela com maior embasamento físico dos processos de evapotranspiração, além do fato de que todas as variáveis de entrada necessárias para a sua utilização estarem disponíveis para o período de estudo.

4.2.6.6.2. Evapotranspiração real

A evapotranspiração real se dá pela soma de três componentes: (i) evaporação da água interceptada pelas folhas, (ii) evaporação da água do solo e (iii) evaporação da água das plantas (transpiração). A evaporação proveniente da interceptação é parte componente do termo de abstrações iniciais (I_a) da equação do SCS. Uma vez calculada a evapotranspiração potencial, o modelo calcula a evaporação do solo e das plantas de forma separada, semelhante ao método descrito por Ritchie (1972): a evaporação do solo é função da evapotranspiração potencial e do índice de área foliar (LAI), sendo calculada pelo uso de funções exponenciais da profundidade do solo e da quantidade de água no solo.

4.3. O Procedimento SUFI-2

4.3.3. Descrição Conceitual

O procedimento de autocalibração e análise de incertezas utilizado neste estudo será o *Sequential Uncertainty Fitting, versão 2* (SUFI-2) (ABBASPOUR et al., 2007). No SUFI-2, a incerteza dos parâmetros é retratada através de uma distribuição uniforme de probabilidade. Os parâmetros possuem uma faixa inicial de incerteza larga, que tende a reduzir com o decorrer das iterações. O processo chega ao fim quando dois critérios são atendidos (ABBASPOUR et al., 2007): (1) o intervalo de incertezas com 95% de probabilidade (95PPU) das previsões contém a maior parte das observações e (2) a “espessura” média da faixa de incerteza das previsões pode ser considerada pequena. O método SUFI-2 foi aplicado neste estudo através da interface SWATCUP (Abbaspour, 2011).

O método SUFI-2

4.3.4. O algoritmo SUFI-2

Será apresentada aqui uma breve descrição do algoritmo SUFI-2, de acordo com Abbaspour et al. (2007) e Yang et al. (2008).

Passo 1: É definida a função objetivo a ser utilizada no processo de auto calibração. É sabido que diferentes funções objetivo resultam em diferentes superfícies de resposta (DUAN et al., 1992), o que por sua vez se traduz em diferentes combinações entre parâmetros que resultem num valor ótimo. A notação para a função objetivo utilizada será “g”. Para o presente estudo foi escolhido o Coeficiente de Eficiência de Nash-Sutcliffe (COE) como função objetivo. O COE será explicado no item 4.5.

Passo 2: Neste passo, são definidos os valores mínimos e máximos absolutos para cada parâmetro:

$$b_j : b_{j,abs_min} \leq b_j \leq b_{j,abs_max}, j = 1, \dots, m, \quad (29)$$

Onde b_j é o “j” ésimio parâmetro a ser calibrado de um total de m parâmetros.

Passo 3: Este passo representa uma etapa altamente recomendada no processo de calibração de modelos hidrológicos: a análise de sensibilidade preliminar dos parâmetros previamente escolhidos. A análise de sensibilidade permite uma maior compreensão de como cada parâmetro atua na resposta do modelo, bem como os valores onde cada parâmetro se faz mais influente.

Passo 4: São definidas as faixas iniciais de variação de cada parâmetro:

$$b_j : [b_{j,min} \leq b_j \leq b_{j,max}], j = 1, \dots, m \quad (30)$$

Passo 5: São geradas “n” combinações entre os parâmetros através do método de amostragem Hipercubo Latino (MCKAY et al., 1979). Cada uma das “n” combinações resultará em uma simulação do modelo na referida iteração. Segundo os desenvolvedores do método, o número “n” deverá variar entre 500 e 1000. A seguir são realizadas, portanto, “n” simulações e os valores da variável de interesse (neste caso, vazões simuladas no exutório da bacia) são salvos. Para o presente estudo será consideradas 500 simulações por iteração.

Passo 6: São calculados os valores da função objetivo (g) para cada uma das “n” simulações.

Passo 7: Neste passo, é realizada uma série de medidas para a avaliação dos resultados obtidos na iteração. Inicialmente, é calculada a matriz de sensibilidade J de $g(\mathbf{b})$:

$$J_{ij} = \frac{\Delta g_i}{\Delta b_j}, \quad i = 1, \dots, C_2^n, \quad j = 1, \dots, m, \quad (31)$$

em que C_2^n é o número total de combinações possíveis entre duas simulações, que por sua vez será o número de linhas da matriz de sensibilidade, e j é o número de colunas (número de parâmetros). Em seguida o equivalente à matriz Hessiana, H , é calculada pelo método de Gauss-Newton, ignorando as derivadas de alta ordem:

$$H = J^t J. \quad (32)$$

Uma estimativa da porção inferior da matriz de covariância dos parâmetros, C , é calculada baseada no teorema de Cramer-Rao (PRESS et al., 1992):

$$C = s_g^2 (H)^{-1}, \quad (33)$$

em que s_g^2 é a variância dos valores da função objetivo para as “n” simulações. Os valores estimados para o intervalo de confiança de 95% de probabilidade de um parâmetro b_j , calculado pelos elementos da diagonal de C :

$$s_j = \sqrt{C_{jj}} \quad (34)$$

$$b_{j,lower} = b_j^* - t_{v,0.025} s_j \quad (35)$$

$$b_{j,upper} = b_j^* + t_{v,0.025} s_j \quad (36)$$

Em que b_j^* é o valor do parâmetro b_j para a simulação de melhor valor da função objetivo e v é o grau de liberdade ($n-m$).

Passo 8: São calculados o 95PPU e o respectivo valor do POC (porcentagem de valores observados inclusos na envoltória do 95PPU) e o valor do fator-r, obtido pela seguinte fórmula:

$$fator - r = \frac{\frac{1}{k} \sum_{i=1}^k (y_i^{97.5\%} - y_i^{2.5\%})}{\sigma_{obs}}, \quad (37)$$

em que $y_i^{97.5\%}$ e $y_i^{2.5\%}$ representam os valores superior e inferior da 95PPU e σ_{obs} o desvio padrão dos dados observados. O método SUFI-2 considera a incerteza dos dados observados de vazão ao atribuir uma variação percentual média às vazões observadas, sendo que tal variação irá influenciar os resultados para o POC. Neste estudo foi adotado o valor 10%, de acordo com recomendações obtidas em comunicações com os desenvolvedores do método, além de análise dos valores de vazão medidos em campo.

Passo 9: Como as incertezas dos parâmetros são inicialmente grandes, os valores iniciais dos fatores r e POC tendem a não ser satisfatórios. Para a realização de novas iterações, as faixas de variação dos parâmetros são atualizadas pelas seguintes fórmulas:

$$b'_{j,min} = b_{j,lower} - \max \left[\frac{(b_{j,lower} - b_{j,min})}{2}, \frac{(b_{j,max} - b_{j,upper})}{2} \right], \quad (38)$$

$$b'_{j,max} = b_{j,lower} + \max \left[\frac{(b_{j,lower} - b_{j,min})}{2}, \frac{(b_{j,max} - b_{j,upper})}{2} \right], \quad (39)$$

em que b' são os valores atualizados. Os valores atualizados de $b_{j,min}$ e $b_{j,max}$ representam uma faixa reduzida de variação dos parâmetros, a qual será utilizada caso uma nova iteração

seja necessária. A aceitação dos novos valores de variação dos parâmetros é realizada pelo usuário, que pode inclusive alterá-los, caso as novas faixas ultrapassem limites considerados realistas para a representação da bacia.

4.4. Ponderação Bayesiana de Modelos

4.4.3. Conceitualização

No processo tradicional de modelagem, o modelador tem de escolher um modelo entre vários existentes para a descrição/simulação do fenômeno de interesse. Essa escolha é considerada uma fonte de incertezas, pelo fato de se estar excluindo outros modelos também plausíveis e com diferentes vantagens/desvantagens na descrição do fenômeno.

A Ponderação Bayesiana de Modelos, ou BMA (do inglês *Bayesian Model Averaging*), é uma técnica originalmente desenvolvida no campo da estatística para contornar o problema da existência de múltiplos modelos e foi aplicada pela primeira vez para o caso de modelos dinâmicos por Raftery et al. (2005). A técnica BMA pode ser classificada como um pós-processamento estatístico de conjuntos de modelos (VRUGT et al., 2006). Estudos recentes que aplicaram a BMA na modelagem hidrológica e climatológica comprovaram a capacidade desta técnica em produzir previsões mais acuradas e precisas do que aquelas advindas dos modelos individualmente (VRUGT et al., 2007; DUAN et al., 2007; ZHANG et al., 2009; STRAUCH et al., 2012).

Neste estudo, a técnica BMA foi utilizada para a ponderação dos múltiplos modelos competidores, originados de valores de entrada de precipitação diferentes, segundo a metodologia proposta por Strauch et al. (2012).

Considerando inicialmente a variável de interesse y neste estudo, a vazão, tem-se $Y^f = \{y^{f_1}, \dots, y^{f_k}\}$ o conjunto das previsões para a variável de interesse, obtidas através de k modelos, para os intervalos de 1 a T , de forma que $y^{f_i} = [y_1^{f_i}, y_2^{f_i}, \dots, y_T^{f_i}]$. Considera-se $Y = \{y_1, y_2, \dots, y_T\}$ como sendo o vetor dos dados observados para o período de calibração, com comprimento T . Pelo método BMA, cada previsão y^{f_i} está associada a uma função densidade de probabilidade (*fdp*), $P(y_t|M_i, Y)$, que pode ser interpretada como a *fdp* de y

para o instante t , condicionada ao modelo M_i e aos dados Y . De acordo com a lei da probabilidade total, a previsão da variável y pelo BMA é representada por:

$$p(y_t|M_1, \dots, M_k) = \sum_{i=1}^k P(M_i|Y) \cdot P(y_t|M_i, Y), \quad (40)$$

em que $P(M_i|Y)$ é a probabilidade *a posteriori* do modelo M_i , refletindo a capacidade do modelo i em representar os dados observados. Se somadas, as probabilidades *a posteriori* resultam na unidade, adotando $w_i = P(M_i|Y)$ temos:

$$\sum_{i=1}^k w_i = 1. \quad (41)$$

Desta forma, os valores w_k podem ser considerados como pesos. A *fdp* resultante do método BMA é, portanto, uma média das *fdps* de cada modelo ponderadas por suas respectivas probabilidades *a posteriori*.

A média das previsões produzida pelo método BMA é igual à média de entre as previsões das previsões individuais, f_k , ponderadas pelos seus respectivos pesos, w_k .

$$E[y_t|M_1, \dots, M_k] = \sum_{i=1}^k w_i y_t^{f_i}. \quad (42)$$

Este valor pode ser entendido como a previsão determinística da variável de interesse obtida pelo método BMA, podendo ser comparado com as previsões individuais de cada modelo. Referindo-se ao passo de tempo como t , a variância da previsão obtida pelo método BMA pode ser descrita como (RAFTERY et al., 2005):

$$Var[y_t|M_1, \dots, M_k] = \sum_{i=1}^k w_i (y_t^{f_i} - \sum_{i=1}^k w_i y_t^{f_i}) + \sigma^2. \quad (43)$$

A variância da previsão BMA é composta por duas partes, inter e intra modelos: o primeiro termo, do lado direito da equação, representa a dispersão entre as previsões, enquanto o segundo termo refere-se à incerteza dos modelos individualmente.

Para a aplicação do modelo BMA, é necessário, inicialmente, definir o tipo de distribuição para as *fdp's* condicionais, $P(y_t|M_i, Y)$. Neste estudo será adotada a distribuição normal, por critério de simplicidade. É sabido que a distribuição normal não é a melhor distribuição para a representação de dados de séries de vazões, porém, estudos recentes (ZHANG et al., 2009; STRAUCH et al., 2012) aplicaram o modelo BMA utilizando esta distribuição e obtiveram resultados satisfatórios.

4.4.4. Definição dos parâmetros w_i e σ

A determinação dos parâmetros w_k e σ do modelo BMA foi feita de acordo com a metodologia proposta por Raftery et al. (2005). Considerando o vetor de parâmetros $\theta = \{w_1, \dots, w_k, \sigma^2\}$ como aquele a ser estimado, a solução será encontrada pela utilização do método da máxima verossimilhança (FISHER, 1922) aplicado à função densidade de probabilidade condicional apresentada anteriormente:

$$p(y_t|M_1, \dots, M_k) = \sum_{i=1}^k w_i \cdot P(y_t|M_i, Y), \quad (44)$$

A função de verossimilhança, $L(\theta)$, é definida como a probabilidade dos valores observados terem sido gerados por um determinado grupo de parâmetros. O estimador de máxima verossimilhança, $\hat{\theta}$, é o vetor dos parâmetros que maximiza a função verossimilhança, ou seja, é o conjunto de parâmetros que maximiza probabilidade dos dados observados terem ocorrido.

Por questões de simplicidade algébrica e estabilidade numérica, é preferível a maximização do logaritmo natural da função de verossimilhança, $l(\theta)$. Uma vez que a função \ln tem crescimento constante em $(0, \infty)$, os máximos de ambas as soluções, $L(\theta)$ e $l(\theta)$, coincidirão (CASELLA e BERGER, 2002). O problema posto será a maximização do logaritmo natural da função de verossimilhança, que pode ser escrito como:

$$l(\theta|M_1, \dots, M_k, Y) = \sum_{t=1}^T \ln \sum_{k=1}^k w_i \cdot P(y_t|M_i, Y) \quad (45)$$

Como se trata de um problema sem solução explícita, há de se utilizar algum método numérico para a estimativa dos parâmetros. Seguindo a metodologia proposta por Raftery et al. (2005), foi utilizado o algoritmo Expectation Maximization (EM) (DEMPSTER et al., 1977; MCLAHAN e KRISHNAN, 1997). O algoritmo EM é um método para encontrar o estimador de máxima verossimilhança em problemas de mistura finita, quando este pode ser apresentado em termos de quantidades não observadas, que se conhecidas tornariam o problema solucionável de uma forma direta. O algoritmo EM não garante que o máximo atingido seja a solução ótima global e, portanto, é sensível à determinação inicial dos valores de θ . Estudos recentes apontam para a calibração do modelo BMA por meio de técnicas multi-objetivo (VRUGT e ROBINSON, 2007) e baseadas no método *Monte Carlo Markov*

Chain (MCMC) (VRUGT et al., 2008). Para uma descrição passo-a-passo do algoritmo EM, consultar o Apêndice A

O algoritmo do método BMA utilizado neste estudo foi executado através de um código para o programa MATLAB, como proposto em Vrugt e Robinson (2007), e obtido em correspondência com os autores.

4.5. Criação e avaliação de modelos competitivos para a simulação das vazões na B.R.O.

O foco principal deste trabalho foi a análise das incertezas dos parâmetros do modelo SWAT decorrente da utilização de diferentes séries de precipitação juntamente com a utilização destas diferentes séries para a produção de uma resposta conjunta. Sendo assim, foram testadas diferentes formas de entrada para a precipitação para a Bacia do Ribeirão da Onça pelo modelo SWAT. O processo utilizado neste estudo é semelhante ao utilizado em Strauch et al. (2012), e tem seu fluxograma geral retratado na Figura 16.

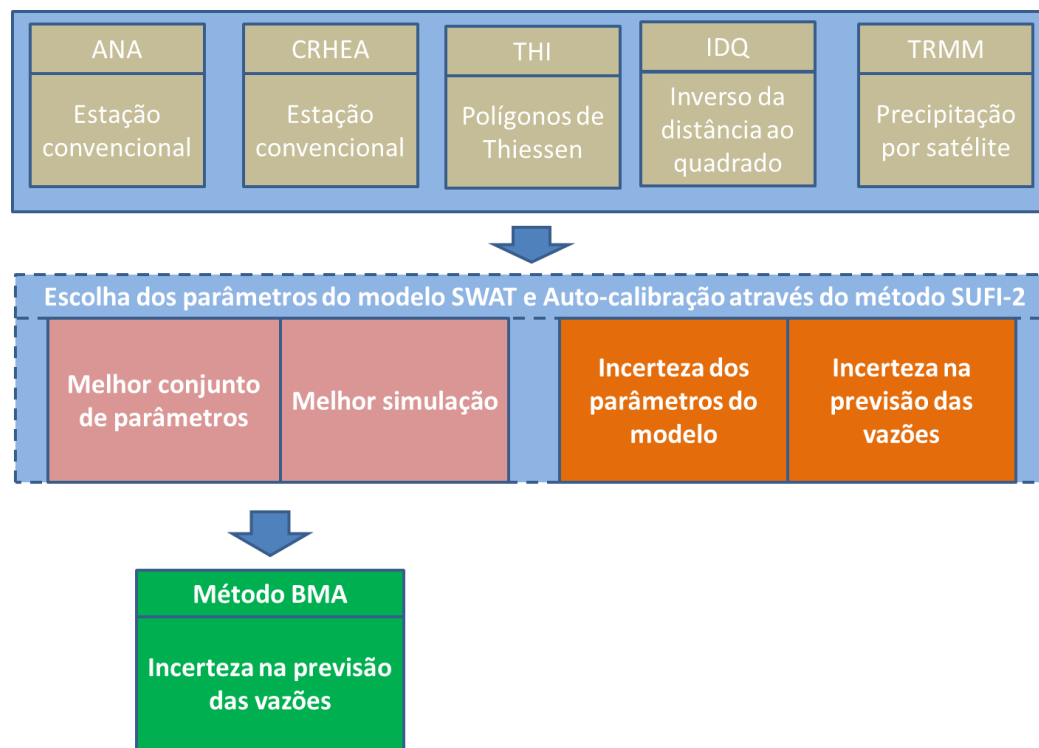


Figura 16 – Fluxograma de criação de modelos competitivos para a B.R.O e análise de incertezas pelo método SUFI-2 e BMA.

Cada esquema de precipitação irá alimentar o modelo SWAT, que terá a incerteza dos parâmetros analisada pelo procedimento de auto calibração SUFI-2. Os dados de entrada de precipitação escolhidos estão apresentados na Tabela 5.

Tabela 5 - Dados de precipitação utilizadas para a criação de modelos competitivos

<i>Modelos baseados nos dados de precipitação para a B.R.O</i>	
<i>Nome</i>	<i>Dados de entrada</i>
CRHEA	Precipitação uniforme sobre a bacia, utilizando os dados da estação CRHEA-USP
ANA	Precipitação uniforme sobre a bacia, utilizando os dados da estação ANA
IDQ	Precipitação espacializada entre as sub-bacias pelo método de inverso da distância à estação ao quadrado.
THI	Precipitação espacializada entre as sub-bacias pelo método dos polígonos de Thiessen (THIESSEN, 1911).
TRMM	Precipitação uniforme sobre a bacia, utilizando o produto 3B42 do satélite <i>TRMM</i>

A escolha dos parâmetros a serem calibrados através do procedimento SUFI-2, bem como a faixa inicial de variação destes, foi feita através do processo de calibração manual. Desta forma, o conhecimento prévio do comportamento da bacia foi levado em consideração.

Conforme o procedimento SUFI-2, cada modelo foi avaliado conforme o POC e o fator r obtidos em cada iteração. Quanto menor for a diferença entre o POC e cobertura esperada a do intervalo de incertezas, melhor será considerada o desempenho do intervalo de incertezas (ZHANG et al., 2009). Desta forma, para um intervalo de incerteza de 95%, do qual se espera incluir 95% dos dados observados, valores de POC próximos a 0,95 indicam um melhor desempenho do intervalo de incertezas. Segundo Abbaspour et al. (2007), valores próximos a 1,0 para o fator r são considerados como desejáveis. Neste estudo, o critério de parada para a calibração através do SUFI-2 foi a obtenção de um fator $r \leq 1$.

Um estudo realizado por Moriasi et al. (2008) sobre os métodos de avaliação do desempenho do modelo SWAT apontou para o Coeficiente de Eficiência de Nash-Sutcliffe (COE) (NASH & SUTCLIFFE, 1970) e o Desvio Percentual (PBIAS) como os testes estatísticos mais adequados. Tais índices podem ser escritos como:

$$COE = 1 - \frac{\sum_{t=1}^T (y_t - f_t)^2}{\sum_{t=1}^T (y_t - \bar{y})^2}, \quad (46)$$

$$PBIAS(\%) = \frac{\sum_{t=1}^T (y_t - f_t)}{\sum_{t=1}^T y_t} \cdot 100 \quad (47)$$

em que y_t é o valor de vazão observado no instante t , f_t é o valor de vazão simulado para o mesmo instante, \bar{y} é a média dos valores observados e T é o número total de dados observados. O COE é uma medida normalizada (varia entre $-\infty$ e 1), que compara o erro quadrático médio com a variância dos dados observados. Implicitamente, o COE compara o desempenho de um modelo em relação a uma previsão de valor constante e igual à média dos dados observados (GUPTA e SCHAEFLI, 2007). A Tendência Percentual (PBIAS) é um índice que quantifica a tendência média dos dados simulados em serem maiores ou menores que os valores observados, com valores negativos indicando uma superestimação e valores positivos indicando uma subestimação. Segundo extensa revisão sobre aplicações do modelo SWAT realizada por Moriasi et al. (2007), chegou-se à conclusão de que simulações satisfatórias com o modelo devem possuir valores de COE maiores que 0,5 para e entre $\pm 25\%$ para o PBIAS.

Para complementar as análises foi avaliado também o coeficiente de determinação, R^2 :

$$R^2 = \frac{(\sum_{t=1}^T (y_t - \bar{y})(f_t - \bar{f}))^2}{\sum_{t=1}^T (y_t - \bar{y})^2 \sum_{t=1}^T (f_t - \bar{f})^2}, \quad (48)$$

em que \bar{f} é a média dos valores simulados. O R^2 varia entre 0 e 1, e representa a proporção da variância total observada que é explicada pelo modelo, com maiores valores representando uma melhor performance do modelo.

Após o procedimento de auto calibração foram escolhidas os melhores resultados de cada modelo do conjunto, a serem utilizadas no método BMA. A escolha da melhor simulação referente à última iteração de cada um dos modelos competitivos foi baseada nos índices estatísticos de avaliação dos resultados apresentados acima.

5. RESULTADOS

5.1. Inicialização do Modelo SWAT

5.1.1. Comparação entre as diferentes entradas de precipitação

Neste item, serão analisadas as diferenças entre as séries de precipitação utilizadas. A tabela a seguir apresenta as correlações entre a precipitação média na bacia, obtida pelos diferentes esquemas, na escala diária e mensal. Os dados utilizados referem-se aos anos de 2004 a 2012, que abrangem a simulação com o modelo SWAT, a partir do período de aquecimento.

Tabela 6- Valores de Correlação Mensal e Diária entre as séries de precipitação analisadas entre os anos de 2004 a 2012.

	<u>Correlação mensal</u>						<u>Correlação diária</u>				
	ANA	CRHEA	IDQ	THI	TRMM		ANA	CRHEA	IDQ	THI	TRMM
ANA	1,00					ANA	1,00				
CRHEA	0,91	1,00				CRHEA	0,73	1,00			
IDQ	0,99	0,95	1,00			IDQ	0,98	0,85	1,00		
THI	1,00	0,94	1,00	1,00		THI	0,99	0,81	1,00	1,00	
TRMM	0,89	0,91	0,92	0,91	1,00	TRMM	0,39	0,42	0,42	0,42	1,00

Percebe-se que para a escala mensal há um forte indício de relação linear entre as estimativas, com valores altos para todos os modelos ($r > 0,89$). As correlações entre as séries diárias de pluviômetros (ANA, CRHEA, IDQ, THI) apresentaram valores altos. Entretanto, valores inferiores foram obtidos quando confrontados com os dados de precipitação do satélite TRMM.

Na Tabela 7 estão apresentados alguns índices complementares para a análise das séries que foram utilizadas, de forma semelhante à análise procedida por Clarke et al. (2011).

Tabela 7 – Avaliação estatística das séries de precipitação usadas no estudo

	ANA	CRHEA	IDQ	THIESSEN	TRMM
<i>Precipitação média anual (mm)</i>	1514,7	1528,2	1518,6	1517,3	1607,1
<i>Quantil 95% da precipitação diária</i>	26,9	27,0	26,4	26,1	24,8
<i>Quantil 75% da precipitação diária</i>	1,4	1,6	2,2	2,3	3,6
<i>Quantil 50% da precipitação diária</i>	0,0	0,0	0,0	0,0	0,0
<i>Número médio de dias com chuva por ano</i>	121,1	128,5	145,5	191,4	149,3
<i>Precipitação diária máxima observada (mm)</i>	163,0	158,4	132,0	140,4	102,7

*Período analisado, 2004-2012

Nota-se uma grande semelhança entre os valores de precipitação anual média entre as séries obtidas por pluviômetros, enquanto os dados do satélite TRMM sugerem uma que a precipitação foi superestimada. Quanto à análise dos quantis de precipitação, as séries apresentam semelhança entre si. A análise dos valores da quantidade média de dias com precipitação indica uma tendência do satélite TRMM em estimar mais eventos de precipitação do que de fato ocorreram, quando comparado com os valores das estações ANA e CRHEA. A diferença entre a série TRMM e as demais se deu provavelmente por esta se tratar de uma estimativa espacial da precipitação. Cabe ressaltar que a área da bacia (62 km²) é significativamente menor que o píxel (aproximadamente 650 km²) que a contém. Além disto, os dados do satélite TRMM são relativos à medidas indiretas da precipitação, obtidas a partir da calibração dos sensores do satélite. A Figura 17, a seguir, apresenta as precipitações acumuladas para as séries utilizadas durante o período de 2004 a 2008. Pode se ver claramente a tendência dos dados do TRMM de serem maiores que os demais, especialmente a partir de junho de 2009.




Figura 17 - Precipitação diária acumulada para as séries utilizadas durante o período de 2004 a 2008.

Uma análise dos valores extremos de cada série indica uma grande diferença entre as fontes de precipitação utilizadas, não só na magnitude de cada evento como também na ocorrência no tempo de cada um. Os eventos extremos apresentados ocorreram em janeiro de 2011. A Figura 18 retrata a grande diferença temporal entre os registros das estações em terra e do satélite TRMM. Tal resultado salienta importância da adoção de esquemas de interpolação espacial para a precipitação na B.R.O, além de explicitar as incertezas quanto à escolha de diferentes métodos de entrada para a precipitação na modelagem hidrológica.

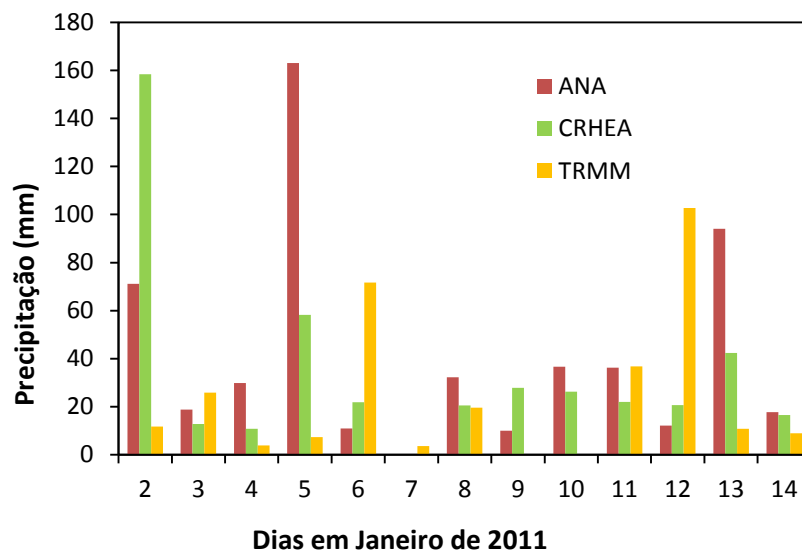


Figura 18 – Precipitação diária durante o mês de janeiro/2011 de acordo com as três fontes de dados de precipitação utilizadas.

Uma outra forma de se atestar as relações entre as séries de precipitação utilizadas neste estudo está representada na Tabela 8. Nesta tabela, estão exibidos os valores de correlação entre as séries ANA, CRHEA e TRMM com os dados de estações climatológicas das Fazendas Santo Inácio e Monte Alegre, que não foram utilizadas neste estudo por não compreenderem um período suficientemente longo de dados. Os dados utilizados para o cálculo das correlações correspondem ao período de maio de 2010 a outubro de 2012 (916 dados) para a estação Santo Inácio, e junho de 2011 a outubro de 2012, para a estação Monte Alegre.

Tabela 8 - Correlação entre as séries diárias de precipitação utilizadas no estudo com as séries das estações climatológicas da fazenda Sto. Inácio e fazenda Monte Alegre.

	<i>Índices de Correlação</i>	
	Estação Santo Inácio	Estação Monte Alegre
CRHEA	0,631	0,69
ANA	0,734	0,62
TRMM	0,619	0,72

Percebe-se que ao se comparar os dados de ambas as estações com as séries de precipitação em estudo as diferenças entre as correlações passam a ser menores,

principalmente quanto aos dados do satélite TRMM, que obteve valores de correlação maiores que 0,60. As estações climatológicas Sto. Inácio e Monte Alegre registram os dados no intervalo de 0 horas às 24 horas, de forma semelhante aos dados do satélite, cujo intervalo original é de 3 horas e que foram acumulados para resultar em precipitação diária. Este resultado sugere, portanto, a utilização dos dados do satélite TRMM como uma fonte de dados competitiva às outras apresentadas.

5.1.2. Determinação dos parâmetros de solo e seu uso e ocupação

A Tabela 9 enumera os valores dos parâmetros de solo utilizados para as simulações.

Tabela 9 - Valores dos parâmetros referentes às propriedades físicas dos solos para a B.R.O.

	Areia Quartzosa			Latossolo		
	<i>Camada 1</i>	<i>Camada 2</i>	<i>Camada 3</i>	<i>Camada 1</i>	<i>Camada 2</i>	<i>Camada 3</i>
<i>SOL_Z</i>	100	500	1200	100	500	1200
<i>SOL_AWC</i>	0,05	0,06	0,15	0,06	0,08	0,15
<i>SOL_K</i>	120	90	30	90	60	30
<i>SOL_BD</i>	1,7	1,7	1,7	1,7	1,7	1,7
<i>SOL_CBN</i>	4,0	2,0	1,0	4,0	2,0	1,0
<i>SOL_ALB</i>	0,15	-	-	0,15	-	-
<i>SOL_CLAY</i>	1,2	4,1	5,0	2,0	5,0	10,0
<i>SOL_SILT</i>	6,6	7,4	10,0	9,1	15,0	10,0
<i>SOL_SAND</i>	92,1	88,5	85,0	88,8	80,0	75,0
<i>SOL_ROCK</i>	0,0	0,0	0,0	0,0	0,0	0,0
<i>Grupo Hidrológico</i>	A			A		
<i>Profundidade total (mm)</i>	1200			1200		

Durante o período de calibração manual, foi verificada a necessidade de aumentar a profundidade do solo nas áreas com eucalipto para que fosse satisfeita a demanda de evapotranspiração da cultura. Desta forma, os valores de profundidades das camadas do solos nas HRU's com a cobertura vegetal de eucaliptos foram aumentados, totalizando uma profundidade de 3500 mm, sendo a profundidade de cada camada aumentada proporcionalmente aos valores iniciais.

Os valores do parâmetro CN associados a cada tipo de cobertura foram obtidos com base no manual do National Resources Conservation Service (NRCS, 2004), onde se buscou escolher as culturas que mais se aproximavam daquelas da bacia. A Tabela 10 apresenta os valores adotados.

Tabela 10 - Valores de CN utilizados para as diferentes culturas da B.R.O

Uso do solo	Valor do CN utilizado
<i>Pastagem</i>	36
<i>Eucalipto</i>	30
<i>Citros</i>	32
<i>Mata ciliar</i>	30

5.1.3 Períodos de calibração e validação

A escolha dos períodos de calibração e validação deu-se pela intersecção entre os períodos com dados disponíveis de precipitação e monitoramento da vazão. Como a série de precipitações da estação da ANA possuía uma falha entre janeiro e outubro de 2008, este mês marca o início das simulações. A tabela Tabela 11 ilustra os períodos analisados.

Tabela 11 - Disponibilidade de dados de precipitação e vazão para a modelagem da B.R.O

Nome	Escala	2007	2008	2009	2010	2011	2012
CRHEA	<i>Diária</i>						
ANA	<i>Diária</i>						
TRMM	<i>3 em 3 horas</i>						
Vazões	<i>Horária</i>						

Legenda

Período sem falhas
 Período com falhas
 Período sem dados

Os dados de vazão possuem falhas nos períodos correspondentes ao represamento à jusante da seção de medições e períodos em que houve falha no equipamento, como comentado na seção 4.1.5.2. Os períodos de calibração e validação foram escolhidos de forma que em ambos os casos houvesse o mesmo número de estações chuvosas. Desta forma,

e também devido à quantidade de dados descartados durante o ano de 2011, os períodos de calibração e validação possuem 634 e 408 valores observados, respectivamente. Na Figura 19 podem se observar os valores de vazão utilizados neste estudo, bem como os períodos que foram descartados.

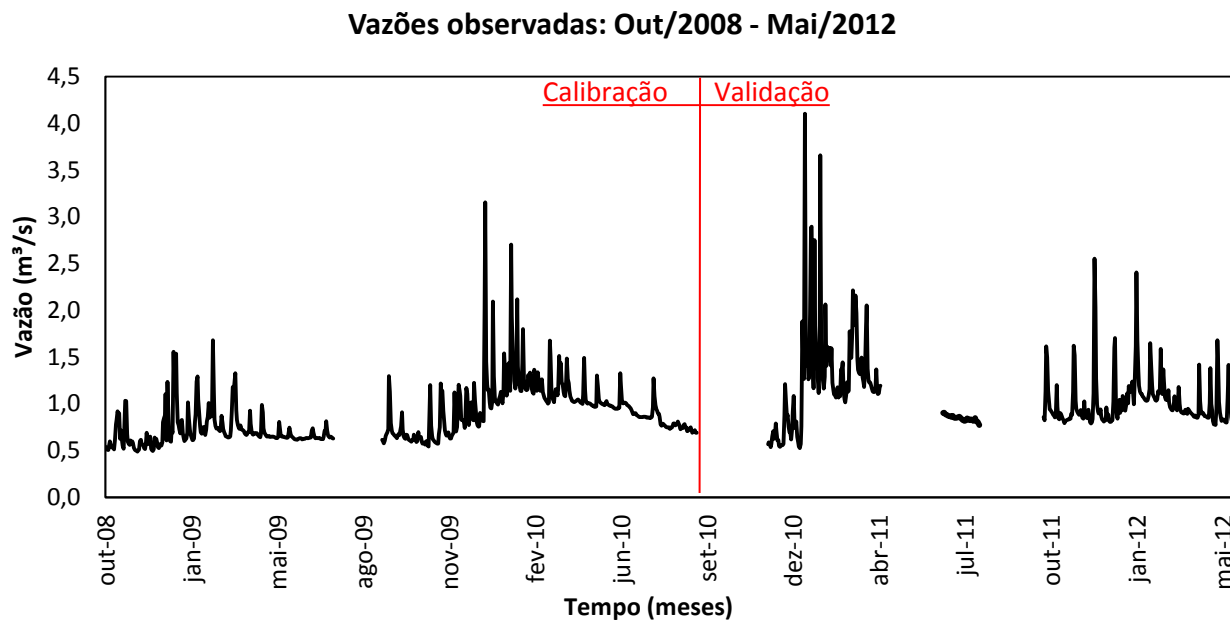


Figura 19 - Vazões observadas para a BRO, períodos de calibração e validação.

A média das vazões observadas para o período de calibração é de $0,85 \text{ m}^3/\text{s}$, enquanto a média para o período de validação é igual a $1,05 \text{ m}^3/\text{s}$, uma diferença de 25%. Nota-se uma pequena diferença entre os regimes dos dois períodos, com destaque para a estação chuvosa de dezembro de 2010 a fevereiro de 2011, caracterizada por altos valores de vazões.

5.2. Escolha das faixas iniciais de variação dos parâmetros

A escolha dos parâmetros a serem calibrados foi baseada numa análise feita através de diversas rodadas de calibração manual do modelo. Como resultado deste processo foram definidas as faixas de incertezas iniciais para os parâmetros, apresentadas na Tabela 12.

Tabela 12 - Valores dos valores iniciais adotados pelo modelo SWAT para os parâmetros e as faixas iniciais de incerteza para o SUFI-2.

<i>Parâmetro</i>	Valores iniciais	Faixa de variação inicial	
		Minímo	Máximo
CN2	Variável (Tabela 10)	-40%	40%
SURLAG	4,00	0,01	4,00
LAT_TTIME(dias)	Variável	0,5	2,5
SLSOIL	Variável	-20%	20%
SOL_AWC	Variável (Tabela 9)	-40%	40%
SOL_K	Variável (Tabela 9)	-40%	40%
SOL_Z	Variável (Tabela 9)	-10%	30%
ESCO	0,75	0,50	1,00
GW_DELAY (dias)	45	10	35
ALPHA_BF	0,048	0,001	0,003
GW_REVAP	0,002	0,02	0,20
REVAPMN	0,0	0,0	500,0

O parâmetro CN2 é o valor do CN para as diversas culturas. A variação aplicada a este parâmetro foi de $\pm 40\%$ em relação aos valores iniciais de cada cultura. As faixas iniciais de variação inicial do parâmetro foram inicialmente largas, para permitir que diferentes formas de resposta do escoamento superficial na bacia fossem simuladas. O parâmetro SURLAG, coeficiente de retardo do escoamento superficial, permite ao modelo que o escoamento superficial produzido num dia seja retardado, para o caso de bacias com tempos de concentração maiores que um dia. Optou-se por incluir este parâmetro após processo de calibração manual, durante o qual foi verificado que o modelo SWAT previa um escoamento superficial muito alto para a bacia, apesar de os valores escolhidos para as propriedades do

solo e valor do CN serem condizentes com a realidade física da bacia. A faixa escolhida permite, entretanto, que todo escoamento superficial produzido seja liberado no mesmo dia (SURLAG próximo a 4) ou então seja retardado (SURLAG próximo ao limite inferior, zero).

Como resultado da calibração manual, foi verificada a necessidade de incluir dois parâmetros relativos à produção do escoamento subsuperficial. O primeiro, LAT_TTIME, controla o tempo de viagem do escoamento subsuperficial nas camadas do solo do momento em que este foi gerado até atingir um trecho do rio. A faixa de variação inicial deste parâmetro foi estimada com base em rodadas de calibração manual, comparando-se visualmente as vazões simuladas pelo modelo com as vazões observadas. O segundo, SLSOIL, controla o comprimento da rampa do modelo utilizado para o cálculo do escoamento subsuperficial. O valor inicial deste parâmetro é assinalado pela interface SIG do modelo como sendo igual ao comprimento da vertente da sub-bacia. Entretanto, este valor é normalmente superestimado (ARNOLD et al. 2011). Por fim, foi proposta uma variação inicial de $\pm 20\%$ para este parâmetro, a partir do valor padrão estimado pela interface GIS.

Os parâmetros referentes às propriedades dos solos (SOL_K, SOL_AWC e SOL_Z) foram variados de forma a refletir o conhecimento acerca de seus valores mais realistas. Com isso, os valores de SOL_K, que tiveram suas estimativas iniciais baseadas em medições in-situ, receberam uma variação inicial menor que o parâmetro SOL_AWC, estimado com base no modelo de pedotransferência apresentado no item 4.2.5. Já a escolha da variação inicial do parâmetro SOL_Z foi feita com base nas respostas do modelo durante a calibração manual.

O parâmetro ESCO é responsável por compensar a demanda evaporativa do solo ao longo de sua profundidade, como forma de levar em conta o efeito de capilaridade. Valores próximos à unidade permitem que mais água das camadas mais profundas seja utilizada para evaporação. A variação inicial deste parâmetro deu-se entre os valores considerados realistas para o mesmo, após correspondência com os desenvolvedores do modelo.

O parâmetro ALPHA_BF representa a constante de recessão do escoamento de base. A escolha da faixa inicial de variação inicial deste parâmetro se baseou em estudos já realizados sobre a recessão do hidrograma da B.R.O. (LUCAS, 2012). O parâmetro GW_DELAY representa o tempo para a água percorrer a zona não saturada. Esse valor teve suas faixas iniciais de variação ajustadas durante a calibração manual. Os parâmetros

GW_REVAP e REVAPMN representam, em conjunto, o deslocamento de água do aquífero para a zona não saturada para suprir as demandas evaporativas do solo e das plantas. Apesar de ter sido verificada uma baixa sensibilidade do modelo a esses parâmetros, eles foram considerados durante o processo de auto calibração. O parâmetro GW_REVAP variou inicialmente entre os limites máximos aconselhados para o modelo SWAT (ARNOLD et al., 2011) enquanto os valores iniciais para a variação do REVAPMN foram obtidos a partir da calibração manual.

5.3 Avaliação geral do procedimento SUFI-2

A Tabela 13 apresenta os índices estatísticos relaciona cada iteração necessária para se atingir o critério de parada adotado, obtidos durante o procedimento SUFI-2. Os dados apresentados auxiliam o entendimento conceitual do procedimento SUFI-2: a cada iteração são reduzidas as faixas de variação dos parâmetros, centradas no valor correspondente à melhor simulação. A redução do espaço de amostragem do “hipercubo latino” para uma região centrada num valor ótimo reflete-se na obtenção de índices de desempenho superiores após cada iteração, de maneira geral.

Outro aspecto do procedimento SUFI-2 a ser observado é o progressivo aumento da quantidade de valores observados contidos na envoltória das incertezas das vazões simuladas, representado pelo aumento dos valores do POC, e a redução da espessura da faixa de incertezas, representada pelo fator r . Observa-se também que a obtenção de valores do fator r que atendessem ao critério de parada (fator $r \leq 1$) deu-se ao custo da redução do POC em quase todas as séries de precipitação utilizadas.

Observou-se uma grande diferença entre o número de iterações necessárias para cada uma das séries de precipitação utilizadas, variando de 2 iterações (1000 simulações), como no caso da série THIESSEN, até 7 iterações (3500 simulações) para a série TRMM. Este resultado evidencia como diferentes esquemas de entrada para a precipitação podem influenciar na busca por resultados satisfatórios através de um mecanismo automático de calibração, o que sugere que a precipitação seja uma importante fonte de incertezas mesmo em casos de pequenas bacias hidrográficas, como a B.R.O.

Quanto ao tempo necessário para as rodadas, foram necessários cerca de 50 minutos por cada iteração, realizadas num computador com processador Intel Core I7, com 4gb de memória RAM.

Tabela 13 – Índices estatísticos obtidos durante a calibração com o método SUFI-2 para a simulação hidrológica de diferentes fontes de dados de precipitação para a B.R.O.

<i>Série de Precipitação</i>	<i>Índices</i>	<i>Calibração - Iterações</i>						
		<i>1</i>	<i>2</i>	<i>3</i>	<i>4</i>	<i>5</i>	<i>6</i>	<i>7</i>
ANA	<i>POC</i>	0,79	0,82					
	<i>Fator r</i>	1,96	0,97					
	<i>R²</i>	0,69	0,70					
	<i>COE</i>	0,69	0,68					
CRHEA	<i>POC</i>	0,77	0,96	0,97	0,93			
	<i>Fator r</i>	1,92	1,67	1,60	0,90			
	<i>R²</i>	0,71	0,73	0,75	0,76			
	<i>COE</i>	0,68	0,72	0,74	0,76			
IDQ	<i>POC</i>	0,83	0,88	0,87				
	<i>Fator r</i>	1,95	1,15	0,86				
	<i>R²</i>	0,75	0,75	0,75				
	<i>COE</i>	0,71	0,73	0,74				
THIESSEN	<i>POC</i>	0,84	0,83					
	<i>Fator r</i>	1,88	1,00					
	<i>R²</i>	0,71	0,72					
	<i>COE</i>	0,68	0,70					
TRMM	<i>POC</i>	0,86	0,94	0,95	0,98	0,94	0,92	0,87
	<i>Fator r</i>	2,27	3,32	1,81	2,67	1,57	1,28	0,82
	<i>R²</i>	0,50	0,55	0,57	0,58	0,58	0,58	0,59
	<i>COE</i>	0,42	0,52	0,57	0,57	0,58	0,58	0,59

5.4. Incertezas dos parâmetros

Uma vez que valores aceitáveis do POC e do fator r tenham sido atingidos, as faixas de variação dos parâmetros corresponderão às incertezas finais dos parâmetros (SCHUOL, 2008). As faixas finais dos parâmetros obtidos pelo SUFI-2 (em azul) e o valor de cada parâmetro para a melhor simulação da última iteração de calibração (círculos vermelhos) estão apresentados esquematicamente na Figura 20 e Figura 21. Esses resultados estão apresentados também na Tabela 14, onde estão apresentados as incertezas finais, em percentuais referentes às faixas de incertezas iniciais para os parâmetros calibrados, segundo a seguinte fórmula:

$$\text{Incerteza final}(\%) = \frac{\text{Faixa de incerteza para o parâmetro "j"}}{\text{Faixa de incerteza para o parâmetro "j"}} \cdot 100 \quad (45)$$

Tabela 14 - Valores finais percentuais das incertezas dos parâmetros em relação à faixa inicial adotada (largura final/largura inicial).

Incerteza final dos parâmetros (% Incerteza inicial)

<i>Modelo/ Parâmetro</i>	ANA	CRHEA	IDQ	THI.	TRMM	<i>Média</i>
<i>CN</i>	76,1	47,4	68,9	81,5	17,5	58,3
<i>SURLAG</i>	50,3	19,6	36,4	56,3	14,8	35,5
<i>LAT_TTIME</i>	51,3	34,0	31,1	52,9	7,5	35,4
<i>SLSOIL</i>	50,1	22,8	60,9	79,3	13,3	45,3
<i>SOL_AWC</i>	55,7	97,5	48,4	52,3	22,8	55,3
<i>SOL_K</i>	50,1	29,3	44,1	58,5	26,3	41,7
<i>SOL_Z</i>	79,3	37,3	63,4	70,5	14,4	53,0
<i>ESCO</i>	52,3	31,7	41,3	72,7	11,0	41,8
<i>GW_DELAY</i>	73,7	20,5	37,5	62,5	23,8	43,6
<i>ALPHA_BF</i>	28,4	28,1	22,8	31,0	3,5	22,8
<i>GW_REVAP</i>	52,2	12,8	42,2	84,3	5,7	39,4
<i>REVAPMN</i>	64,9	9,3	44,4	61,9	34,6	43,0
<i>Média</i>	57,0	32,5	45,1	63,6	16,3	

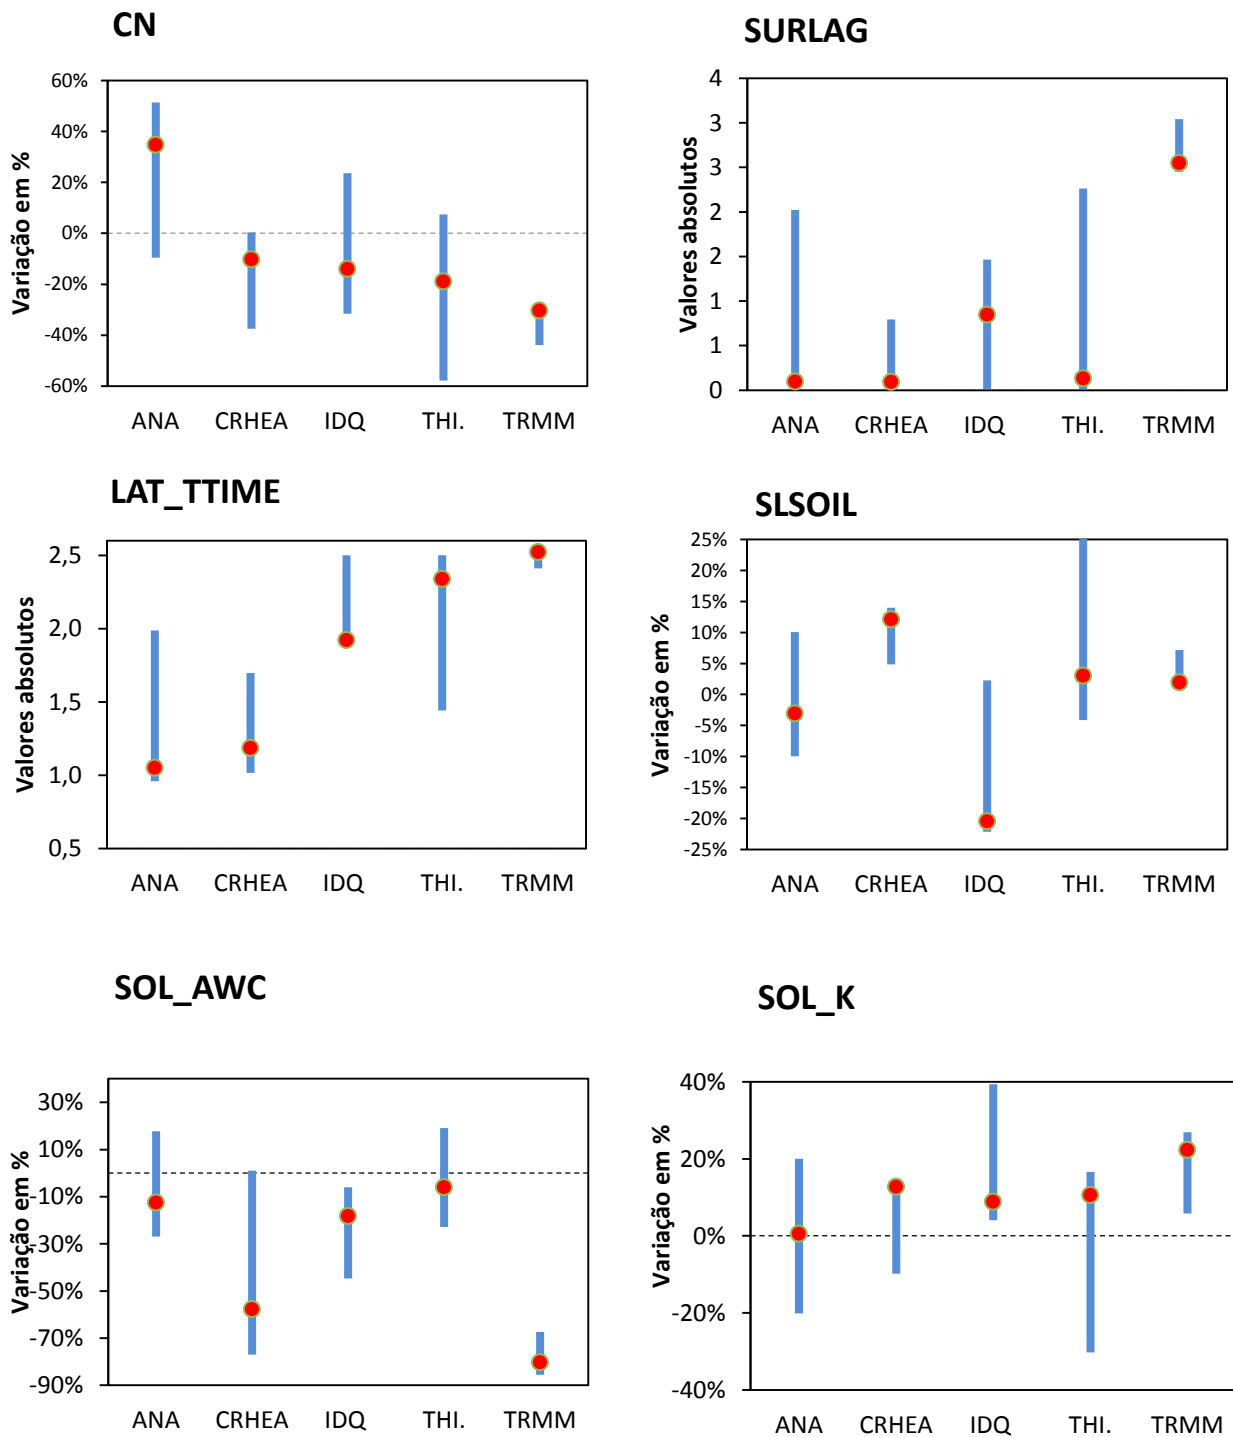


Figura 20 - Faixas finais de incerteza para os parâmetros calibrados utilizando o método SUFI-2, para as diferentes séries de precipitação consideradas na B.R.O. Em azul, as faixas finais de variação dos parâmetros, em vermelho os valores para a melhor simulação

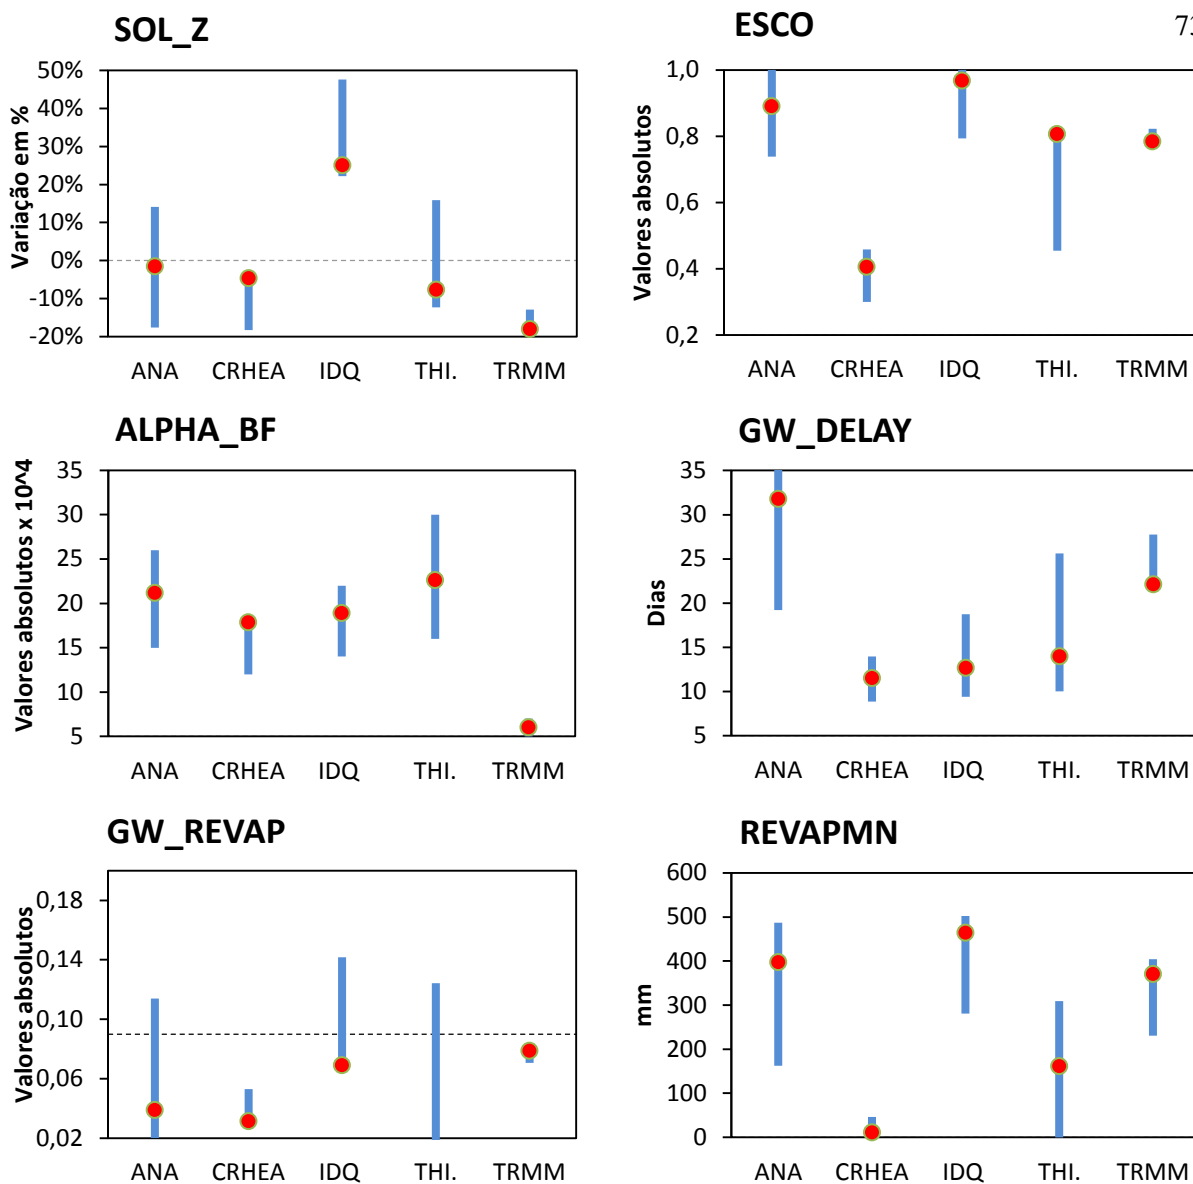


Figura 21 - Faixas finais de incerteza para os parâmetros calibrados utilizando o método SUFI-2, para as diferentes séries de precipitação consideradas na B.R.O. Em azul, as faixas finais de variação dos parâmetros, em vermelho os valores para a melhor simulação.

Uma verificação inicial dos resultados para todos os parâmetros envolvidos no processo de calibração permite que sejam feitas algumas observações. Em primeiro lugar, o resultado para cada parâmetro com sua respectiva faixa de variação é uma demonstração da existência de mais de uma solução (conjunto de parâmetros) adequada para o modelo SWAT, hipótese defendida pelo princípio da equifinalidade na modelagem hidrológica (BEVEN, 2006) e verificada nesta aplicação do modelo SWAT à B.R.O.

Em segundo lugar, pode-se perceber uma grande heterogeneidade quanto aos valores finais de incerteza dos parâmetros entre as séries de precipitação utilizadas. Cada esquema de precipitação retornou em diferentes regiões nas quais o modelo melhor se comportou, evidenciando a equifinalidade também entre modelos rodados a partir de diferentes esquemas de precipitação. Isso indica a necessidade de levar-se em conta a incerteza quanto à precipitação na modelagem da B.R.O.

Por fim, a largura final da faixa de incerteza de cada parâmetro está relacionada também ao número de iterações necessárias para atingir o critério de parada adotado. Pode-se perceber tal fato ao analisar os valores médios apresentados na Tabela 14 para cada uma das series, em que se percebe a relação direta entre a incerteza média dos parâmetros do modelo (linha inferior da tabela). com o número de iterações necessárias para a calibração apresentados na Tabela 13.

O parâmetro CN apresentou a maior incerteza final entre os parâmetros calibrados. As séries ANA e THIESSEN foram as que obtiveram a maior incerteza final do parâmetro (variações finais de -10% a 50% e de -58% a -7%), algo que se sugere ter sido influenciado pelo reduzido número de iterações requeridas para tais modelos (duas iterações). Considerando a importância do parâmetro CN na formulação do escoamento superficial pelo modelo SWAT, tal incerteza final do parâmetro pode ser atribuída a uma não predominância do escoamento superficial na bacia, algo já notado em estudo anterior (RIBEIRO, 2012), e também confirmado pelos valores deste parâmetro para as melhores simulações, que quase em sua totalidade tendem a reduzir o escoamento superficial produzido na bacia. O parâmetro SURLAG se concentrou para todos os modelos, com exceção do TRMM, próximo ao limite inferior. Os valores de SURLAG para as melhores simulações foram quase em sua totalidade próximos ou inferiores à unidade. A adoção de tais valores tem como efeito um retardo do escoamento superficial gerado pelo modelo na bacia.

O resultado da faixa final de incertezas para o parâmetro LAT_TTIME foi analisado junto com os valores finais do parâmetro SLSOIL, pois ambos tratam do processo de escoamento subsuperficial. Os valores finais de LAT_TTIME apontam para uma resposta mais rápida do escoamento subsuperficial pelas séries ANA e CRHEA em relação aos modelos restantes. Há de se lembrar que a faixa inicial escolhida para o parâmetro LAT_TIME não foi

muito abrangente, baseando-se na experiência adquirida durante o processo de calibração manual e nas suposições feitas a respeito do funcionamento hidrológico da bacia. Já o parâmetro de comprimento da rampa do modelo de escoamento subsuperficial, SLSOIL, produziu valores variados entre as séries, ora se concentrando em valores acima do valor padrão (modelos CRHEA, THIESSEN e TRMM), ora em torno deste valor, como no modelo ANA, ou então subestimando os valores padrão, como no modelo IDQ.

Os valores finais para o parâmetro da quantidade disponível de água no solo, SOL_AWC, demonstram uma clara tendência de redução dos valores iniciais adotados. Tal resultado mostra que os valores iniciais, obtidos pela função de pedotransferência adotada são aparentemente maiores que os que ocorrem na bacia. Campanhas de campo para a aferição in loco do valor podem fornecer resultados mais esclarecedores. Os valores finais de condutividade hidráulica saturada (SOL_K) indicam comportamentos variados entre os modelos, apontando para uma relativa incerteza do modelo quanto a esse parâmetro. Entretanto, percebe-se que os valores do parâmetro para a melhor simulação foram, em todos os casos, superiores aos valores inicialmente adotado. Os resultados para o parâmetro de profundidade do solo (SOL_Z) encontram-se dentro da faixa inicial de incerteza adotada, com exceção do modelo IDQ, que superestimou os valores de profundidade do solo.

O parâmetro ESCO apresentou um comportamento variado. Os resultados para as séries ANA, IDQ e TRMM, indicam que foi necessário aumentar a evaporação do solo, ao contrário da série CRHEA, na qual o fenômeno foi reduzido. Já a série THIESSEN apresentou uma larga incerteza final para o parâmetro.

Quanto aos parâmetros de água subterrânea, temos que a constante de recessão do escoamento de base, ALPHA_BF, variou pouco entre as séries, confirmando as estimativas já realizadas anteriormente sobre o valor do mesmo (LUCAS, 2012). Destoando desta tendência apenas a série modelo TRMM. O tempo decorrido entre a saída da água da zona de raízes até o aquífero livre, GW_DELAY, apresentou resultados semelhantes entre as séries CRHEA, IDQ e THIESSEN, sendo suas larguras finais de incertezas provavelmente relacionadas ao número de iterações necessárias a cada uma. Já a série ANA apresentou valores concentrados em uma faixa de valores superior, indicando uma resposta mais rápida do aquífero para esta série. O modelo TRMM apresentou valores intermediários. Os parâmetros REVAPMN e GW_REVAP

precisam ser analisados em conjunto, uma vez que controlam em conjunto o processo de compensação da demanda evaporativa pelo aquífero. Pela variabilidade das faixas finais do parâmetro REVAPMN é sugerida uma grande incerteza a respeito desse processo, uma vez que o fenômeno ocorre para diferentes faixas de valores de água no aquífero livre a depender da série de precipitação utilizada. Entretanto, os valores finais de GW_REVAP, concentrados na metade inferior, indicam que o fenômeno foi em geral subestimado.

5.5. Avaliação do desempenho dos modelos

Na sequência, a Figura 22 e a Figura 23 apresentam uma comparação entre as hidrógrafas resultantes dos melhores resultados da última iteração do método SUFI-2 para as séries de precipitação e também a média obtida pelo BMA, juntamente com as vazões observadas e as precipitação para alguns meses do período de calibração.

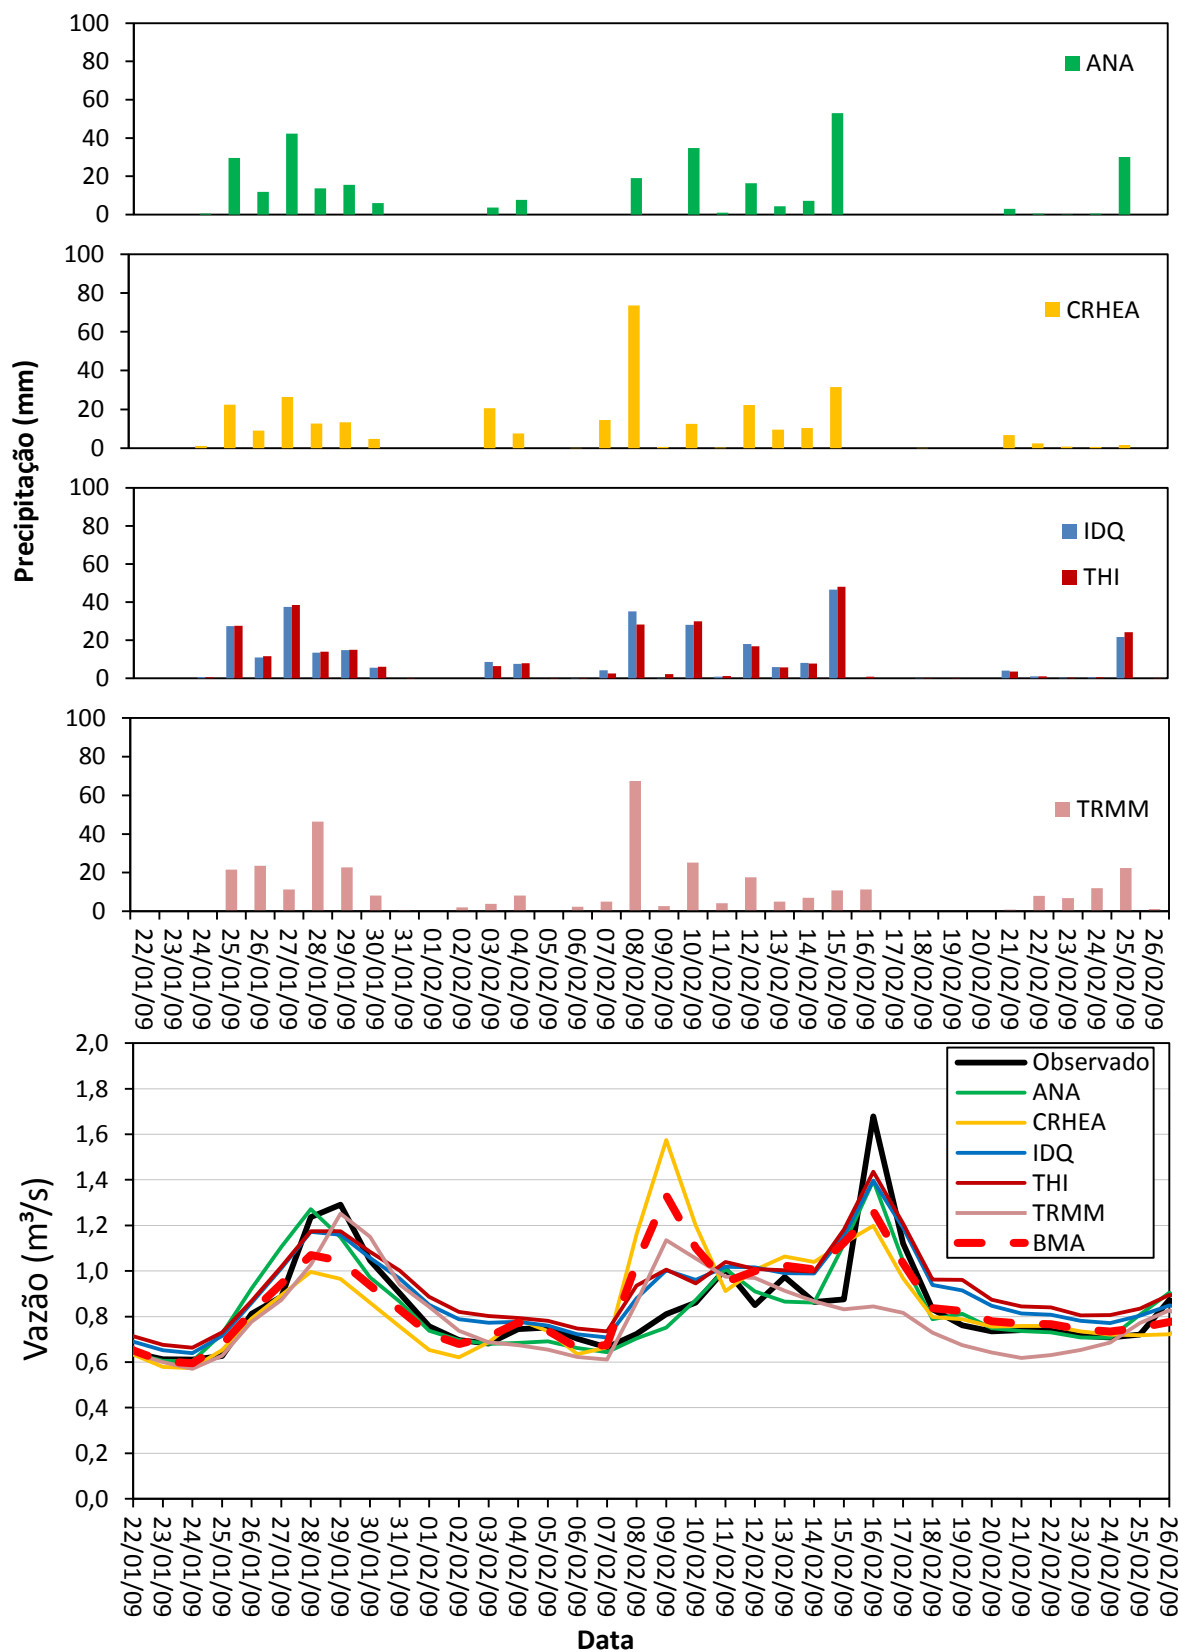


Figura 22 – Hietogramas e hidrógrafas das séries utilizadas, para o período de calibração durante os meses de JAN/FEV de 2009.

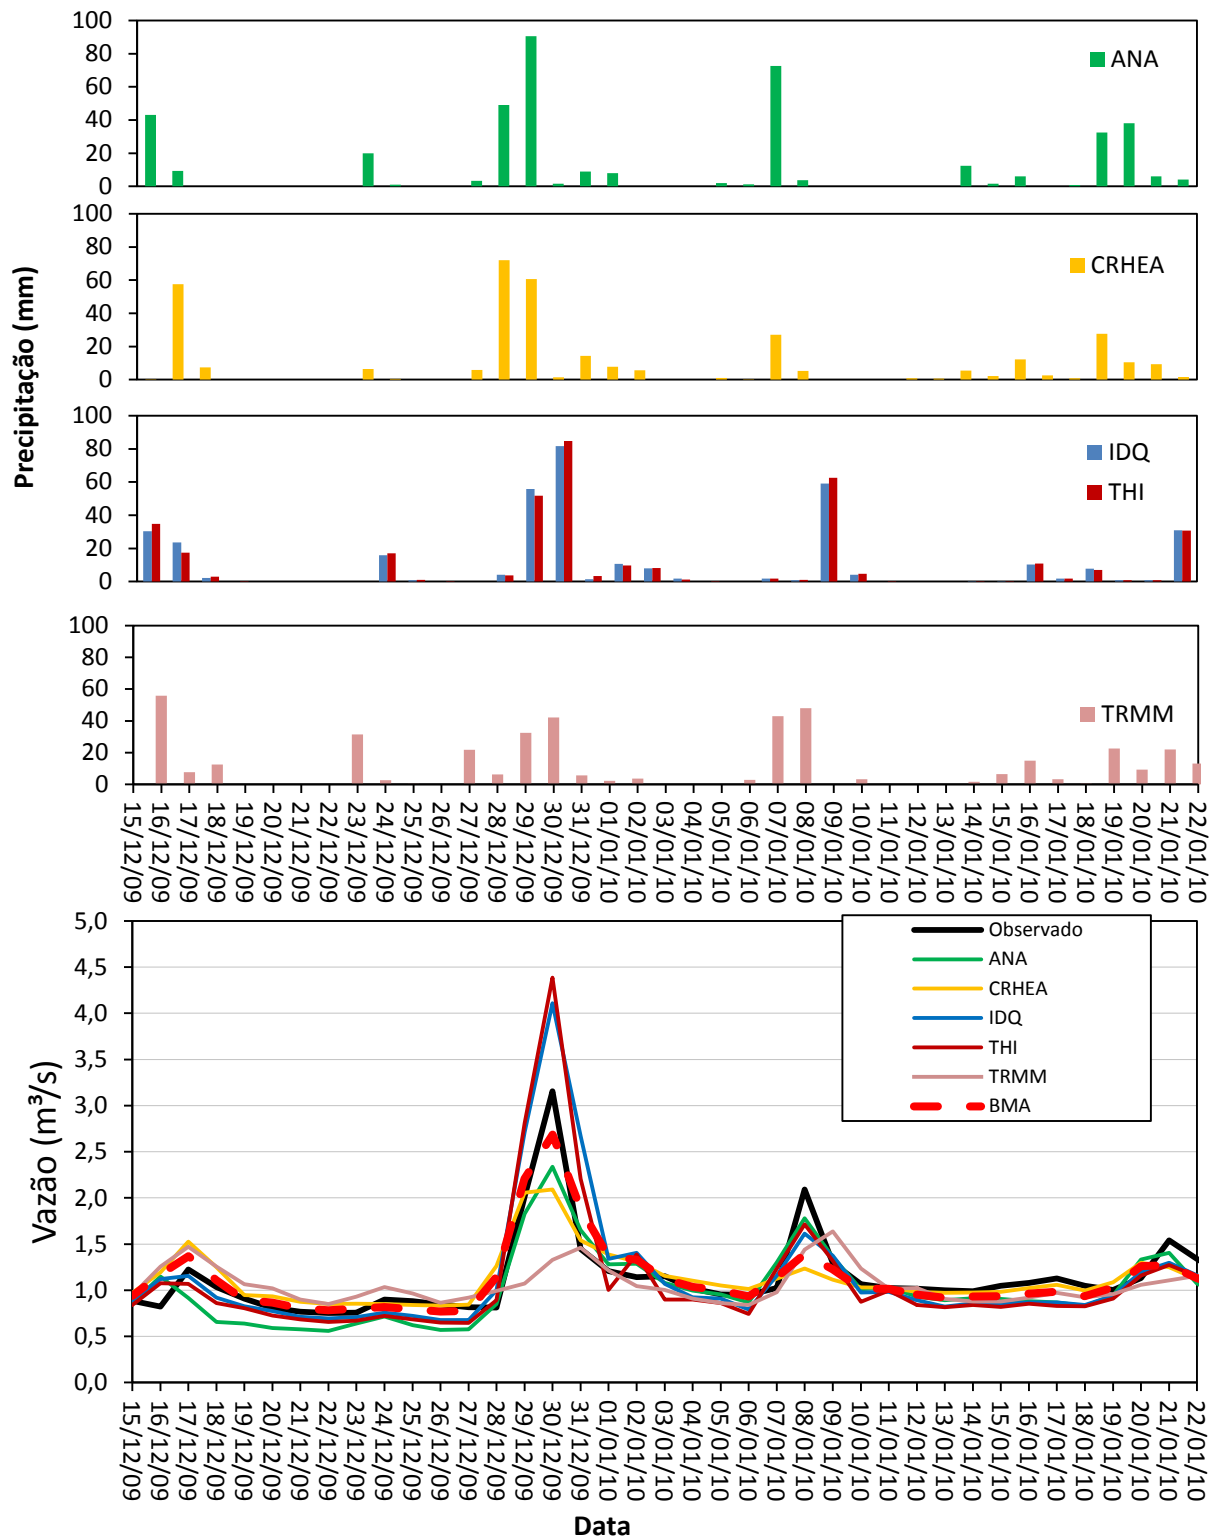


Figura 23 – Hietogramas e hidrógrafas das séries utilizadas, para o período de calibração durante os meses de DEZ/2009 a JAN/2010.

Ao analisarem-se visualmente os resultados das diferentes séries de precipitação, percebe-se que há uma discordância entre as precipitações das diferentes fontes de dados, bem como a influência dessas diferenças nas respostas do modelo SWAT. Um exemplo disso é percebido ao se analisar o início do mês de fevereiro de 2009 (Figura 22), em que a séries ANA e TRMM registraram eventos de precipitação mais intensos que as demais fontes, algo que foi refletido nas vazões produzidas pelo modelo SWAT, porém não verificadas no exutório da bacia. De forma análoga, para o dia 15 de fevereiro de 2009, o satélite TRMM não registrou precipitação significativa, ao contrário das outras séries, sendo tal evento refletido nas vazões observadas.

Percebe-se também que a média obtida pelo modelo BMA tende a compensar as deficiências das diferentes séries, como se pode notar no dia 30/12/2009 (Figura 23), em que o pico de vazão resultante da média pelo método BMA foi inferior ao pico de vazão resultante dos modelos THIESSEN e IDQ, com magnitude superiores à observada, ao mesmo tempo sendo maior que aqueles produzidos pelas séries ANA, CRHEA e TRMM. Percebe-se que o resultado do BMA para esse evento foi mais próximo ao valor observado. Isso sugere a ponderação de modelos como uma técnica atraente quando se pretende levar em consideração as incertezas provenientes da precipitação.

Entretanto, deve-se notar que o modelo BMA, por ser uma média ponderada de diversas respostas irá ser influenciado por aquela de maior peso (ver Tabela 15 e discussão a seguir). Percebe-se pela Figura 22, que o modelo BMA reproduziu os valores de vazão gerados pela série CRHEA, que neste caso não se adequaram bem aos valores de vazão observados.

Na Figura 24 e na Figura 25 estão representados os resultados para os modelos de precipitação e a média pelo método BMA para o período de validação. De forma semelhante às características analisadas nos parágrafos acima, têm-se grande variabilidade quanto aos eventos de precipitação durante os primeiros dias de janeiro de 2010 (Figura 24), associado a um pico de vazão observada de aprox. $4,0 \text{ m}^3/\text{s}$. Neste caso o modelo BMA foi o que melhor reproduziu este pico. Na Figura 25, de forma semelhante à Figura 22, percebe-se a reprodução de um pico de vazão não observado pela série CRHEA, o que influenciou o resultado para este mesmo evento pelo modelo BMA.

Como discutido no item 3.3.1.3.1, mesmo se tratando de uma pequena bacia hidrográfica, é notável a variabilidade da precipitação no tempo e também a diferença de intensidade dos eventos obtidos pelas diferentes fontes de precipitação. Dessa forma, sugere-se o uso de múltiplas fontes de registro da precipitação torna-se uma alternativa para se contornar esse problema.

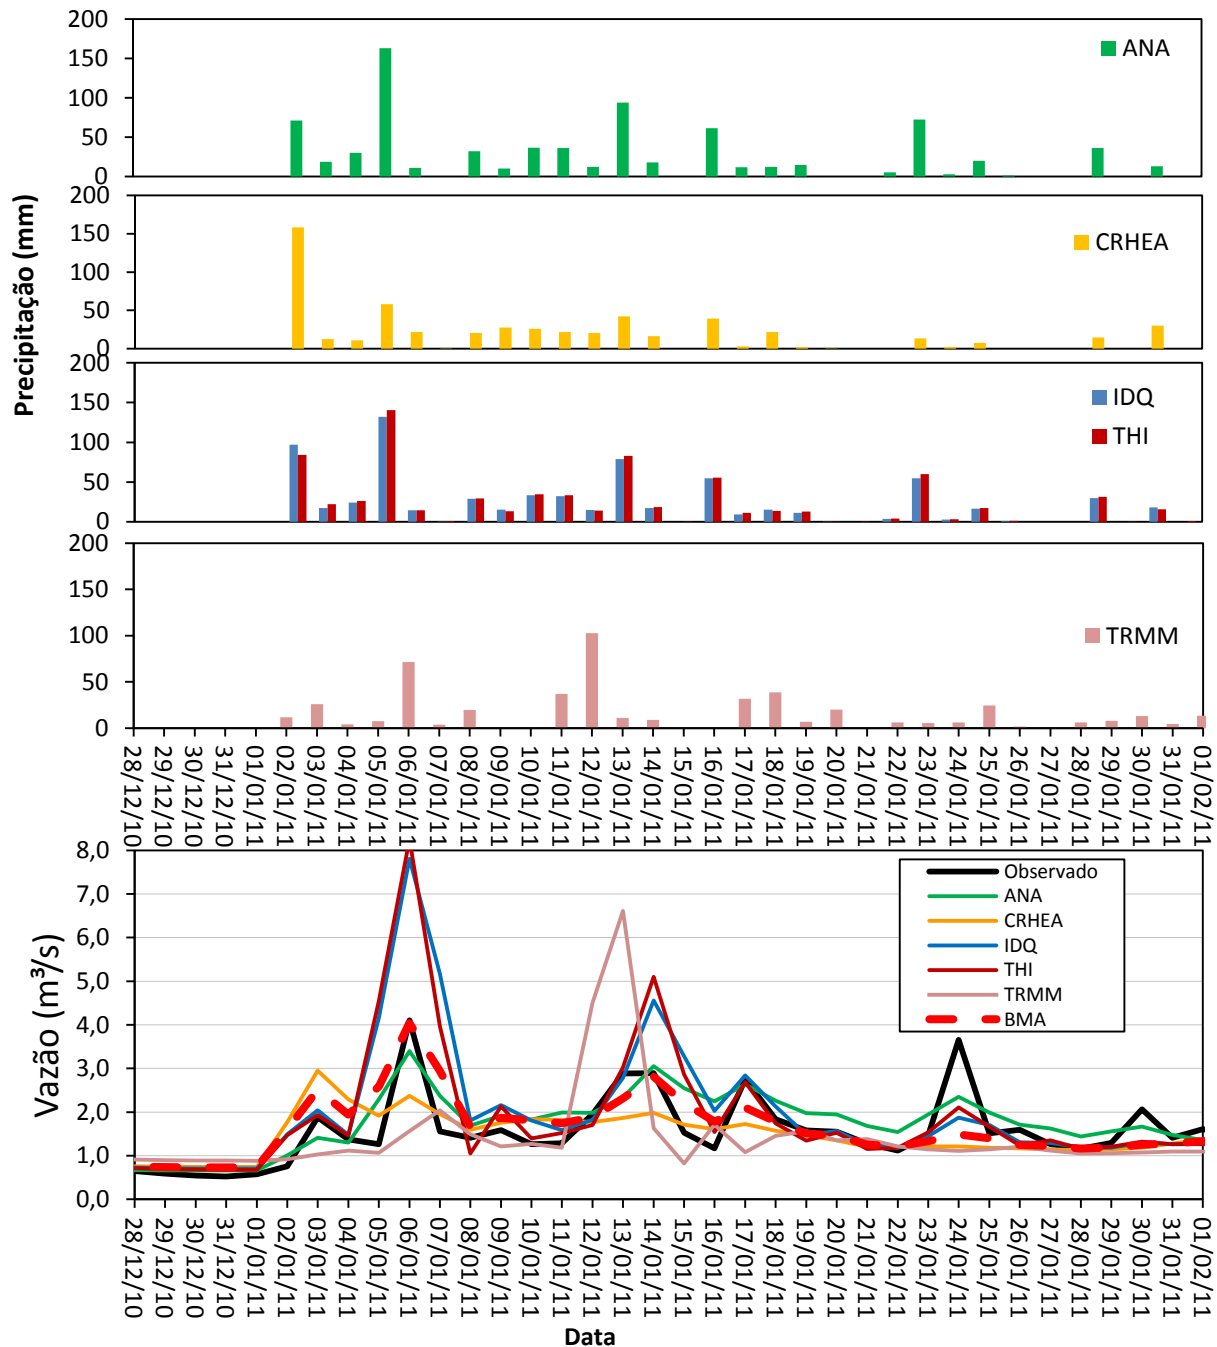


Figura 24 – Hietogramas e hidrógrafas dos modelos utilizados para o período de validação durante os meses de DEZ/2010 a FEV/ 2011.

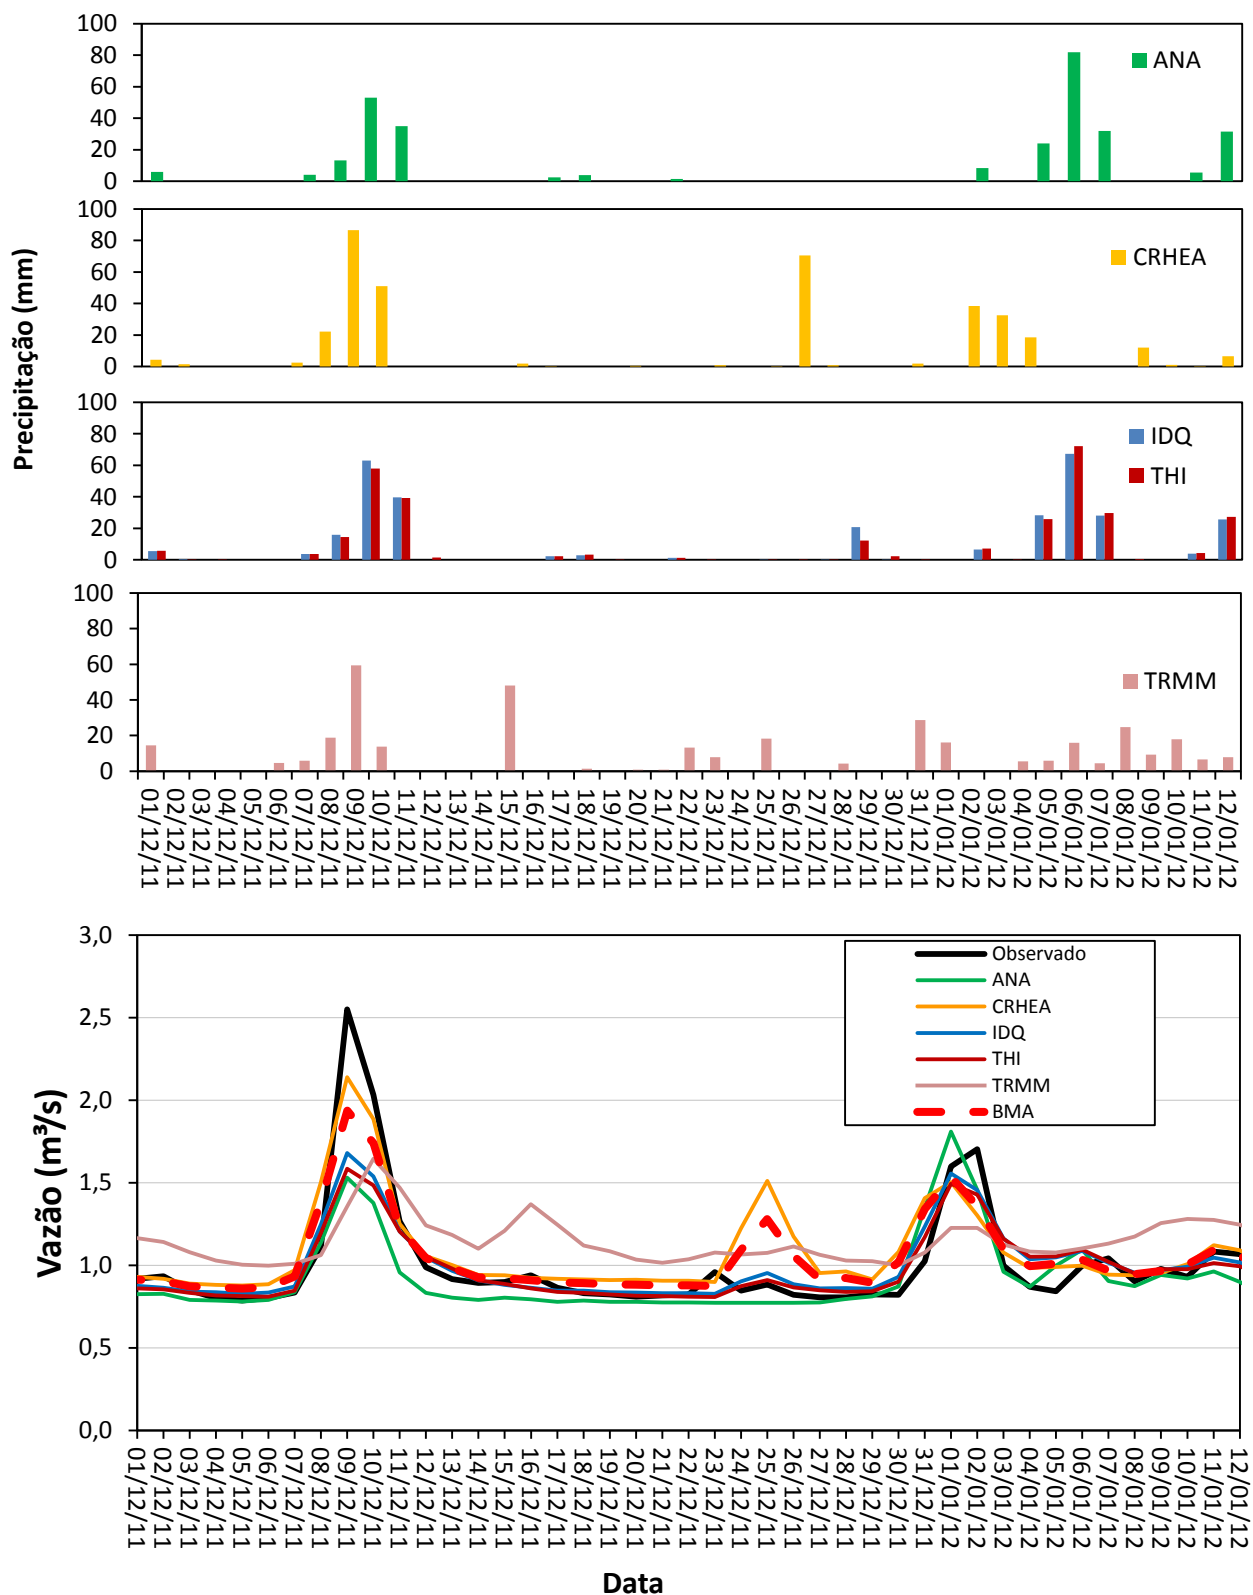


Figura 25 – Hietograma e hidrógrafas dos modelos utilizados para o período de validação durante os meses de DEZ/2011 e DEZ/JAN de 2012.

Na Tabela 15 estão representados os índices de desempenho relativos à melhor simulação da última iteração do método SUFI-2 para cada uma das séries de precipitação, além da média pelo método BMA, para os períodos de calibração e validação. Estão apresentados também os pesos atribuídos pelo método BMA para cada uma das séries.

Ainda na Tabela 15, estão apresentados, sob o título “*Validação SUFI-2*”, os resultados referentes às melhores simulações obtidas entre os 500 simulações realizadas na rodada de validação, e não devem ser confundidos com os valores de validação obtidos pelos conjuntos de parâmetros que melhor se ajustaram durante a calibração.

Tabela 15 - Valores dos índices de avaliação de desempenhos dos modelos de precipitação e da média pelo método BMA (Valores satisfatórios: COE >0,50 ; PBIAS \pm 15%).

	<i>Calibração</i>			<i>Pesos "w"</i>	<i>Validação</i>			<i>Validação SUFI-2</i>		
	COE	PBIAS	R ²		COE	PBIAS	R ²	COE	PBIAS	R ²
ANA	0,68	3,6%	0,70	0,07	0,67	0,8%	0,67	0,70	0,0%	0,71
CRHEA	0,76	-0,2%	0,76	0,60	0,55	-7,5%	0,60	0,58	-5,3%	0,63
IDQ	0,74	0,1%	0,75	0,00	0,15	-7,2%	0,54	0,29	7,9%	0,58
THI	0,70	-1,4%	0,72	0,30	0,17	-6,3%	0,55	0,46	1,7%	0,58
TRMM	0,59	-0,3%	0,59	0,03	-0,03	-7,1%	0,20	0,03	-3,7%	0,22
BMA	0,82	0,1%	0,82	-	0,65	-6,8%	0,69	-	-	-

O desempenho de todos os modelos durante o período de calibração está localizado acima do valor para o qual a simulação pode ser considerada satisfatória quanto ao COE e o PBIAS (COE > 0,5 e PBIAS = \pm 15%). A série que obteve o mais alto índice do COE foi o CRHEA, seguido da série IDQ. O pior desempenho entre as séries foi o TRMM, que gerou os piores índices. Nota-se que nenhum modelo obteve os melhores valores nos três índices dispostos na tabela, o que sugere a necessidade de se considerar diferentes modelos de precipitação para as simulações hidrológicas da B.R.O. Pode-se notar, também, a superioridade dos resultados do modelo BMA em relação aos demais, algo que confirma resultados encontrados em outras pesquisas (VRUGT e ROBINSON, 2007; ZHANG et al., 2009; STRAUCH et al., 2012).

Os valores dos pesos calculados pelo método BMA refletem não somente o desempenho dos modelos durante o período de calibração, mas também a correlação entre as diferentes previsões (RAFTERY et al., 2005; VRUGT e ROBINSON, 2007). Os pesos atribuídos para cada um dos modelos durante o período de calibração apresentaram uma grande variabilidade. Com exceção da série CRHEA, que recebeu o maior peso ($w=0,60$) e também possui o maior índice de COE ($= 0,76$). Percebe-se pela Tabela 16 que há uma grande correlação entre as séries THIESSEN e IDQ. Tal similaridade resulta em pouco ganho de informação pelo método BMA, que se refletiu nos pesos atribuídos, de 0,30 para a série THIESSEN (terceiro melhor desempenho) e zero para o modelo IDQ. Já a série ANA, que possui o quarto melhor valor para o COE, foi atribuído o peso de 0,07, seguido pela série TRMM, que recebeu o menor COE e ao qual foi assinalado um peso igual a 0,03.

Tabela 16 - Valores de correlação entre os resultados das simulações, utilizadas pelo método BMA.

	ANA	IDQ	THI	CRHEA	TRMM
ANA 1	1,00				
IDQ 1	0,93	1,00			
THI	0,93	0,99	1,00		
CRHEA 1	0,83	0,85	0,82	1,00	
TRMM	0,70	0,70	0,65	0,81	1,00

Os resultados obtidos pelas séries de precipitação para o período de validação são claramente inferiores. Apenas dois modelos apresentaram índices estatísticos acima do satisfatório. É importante observar que os modelos que obtiveram os melhores desempenhos durante o período de calibração e validação não foram os mesmos. Esses resultados influenciaram o desempenho do modelo BMA, uma vez que o peso atribuído durante o processo de calibração é utilizado para ponderar as simulações no período de validação. Entretanto, o modelo BMA obteve um bom desempenho na validação, com valores muito próximos à melhor série de precipitação (ANA), superando-a inclusive em relação ao critério R^2 .

Alguns fatores podem ter sido responsáveis por tal diferença entre desempenhos na calibração e validação. Em primeiro lugar, a quantidade total de dados observados foi pequena, o que limita a variabilidade de regimes e fenômenos a serem simulados pelo modelo. Isso resulta numa adequação precária dos parâmetros à realidade da bacia. Cabe ressaltar também a diferença de 25% entre a vazão média observada entre o período de calibração e validação, como apresentado no item 5.1.3.

Por último, uma comparação entre os valores da validação através da utilização dos melhores parâmetros obtidos na calibração com os valores da melhor simulação da rodada de validação pelo SUFI-2 deixa clara a desvantagem da determinação de um valor único para os parâmetros do modelo: para o período de validação, o desempenho do melhor modelo (conjunto de parâmetros) do período de calibração foi suplantado por aquele obtido pela faixa final de incertezas dos parâmetros. Este resultado indica que a escolha de faixas de variação para os parâmetros pode ser uma solução adequada para as simulações utilizando o modelo SWAT para a B.R.O.

5.6. Avaliação da incerteza preditiva

Neste item serão analisados os resultados de cada série de precipitação, além do método BMA, quanto à precisão de suas respostas. A Tabela 17 e Tabela 18 exibem os valores do *POC* e do fator *r* obtidos por cada um dos modelos durante o período de calibração e validação, a um intervalo de confiança de 95%. Os resultados estão organizados por estação chuvosa (outubro a março) e estação seca (abril a setembro), além do resultado para cada período por completo.

As Figuras 26 e 27 expõem os resultados acima para alguns meses do período de calibração e validação dos modelos CRHEA, IDQ e BMA. Os gráficos para todo o período de calibração e validação para todos os modelos está presente no Apêndice B.

Tabela 17 - Avaliação do desempenho dos modelos quanto à capacidade preditiva, período de calibração.

	Calibração (Out/2008 - Set/2010)					
	Geral		Estação seca		Estação úmida	
	<i>fator r</i>	<i>POC</i>	<i>fator r</i>	<i>POC</i>	<i>fator r</i>	<i>POC</i>
ANA	0,97	0,82	1,44	0,96	0,84	0,70
CRHEA	0,90	0,93	1,38	0,98	0,77	0,89
IDQ	0,86	0,87	1,28	0,97	0,74	0,78
THIESSEN	1,00	0,83	1,46	0,97	0,87	0,73
TRMM	0,82	0,87	1,34	0,94	0,66	0,80
BMA	1,29	0,98	1,76	1,00	1,19	0,96

Tabela 18 - Avaliação do desempenho dos modelos quanto à capacidade preditiva, período de validação.

	Validação (Nov/2010 - Maio/2012)					
	Geral		Estação seca		Estação úmida	
	<i>fator r</i>	<i>POC</i>	<i>fator r</i>	<i>POC</i>	<i>fator r</i>	<i>POC</i>
ANA	0,89	0,83	1,68	0,95	0,91	0,79
CRHEA	0,71	0,67	1,68	0,29	0,69	0,81
IDQ	0,75	0,91	1,59	0,94	0,72	0,90
THIESSEN	0,88	0,89	1,80	0,95	0,86	0,87
TRMM	0,62	0,64	1,60	0,71	0,57	0,62
BMA	1,15	0,90	2,15	0,75	1,15	0,96

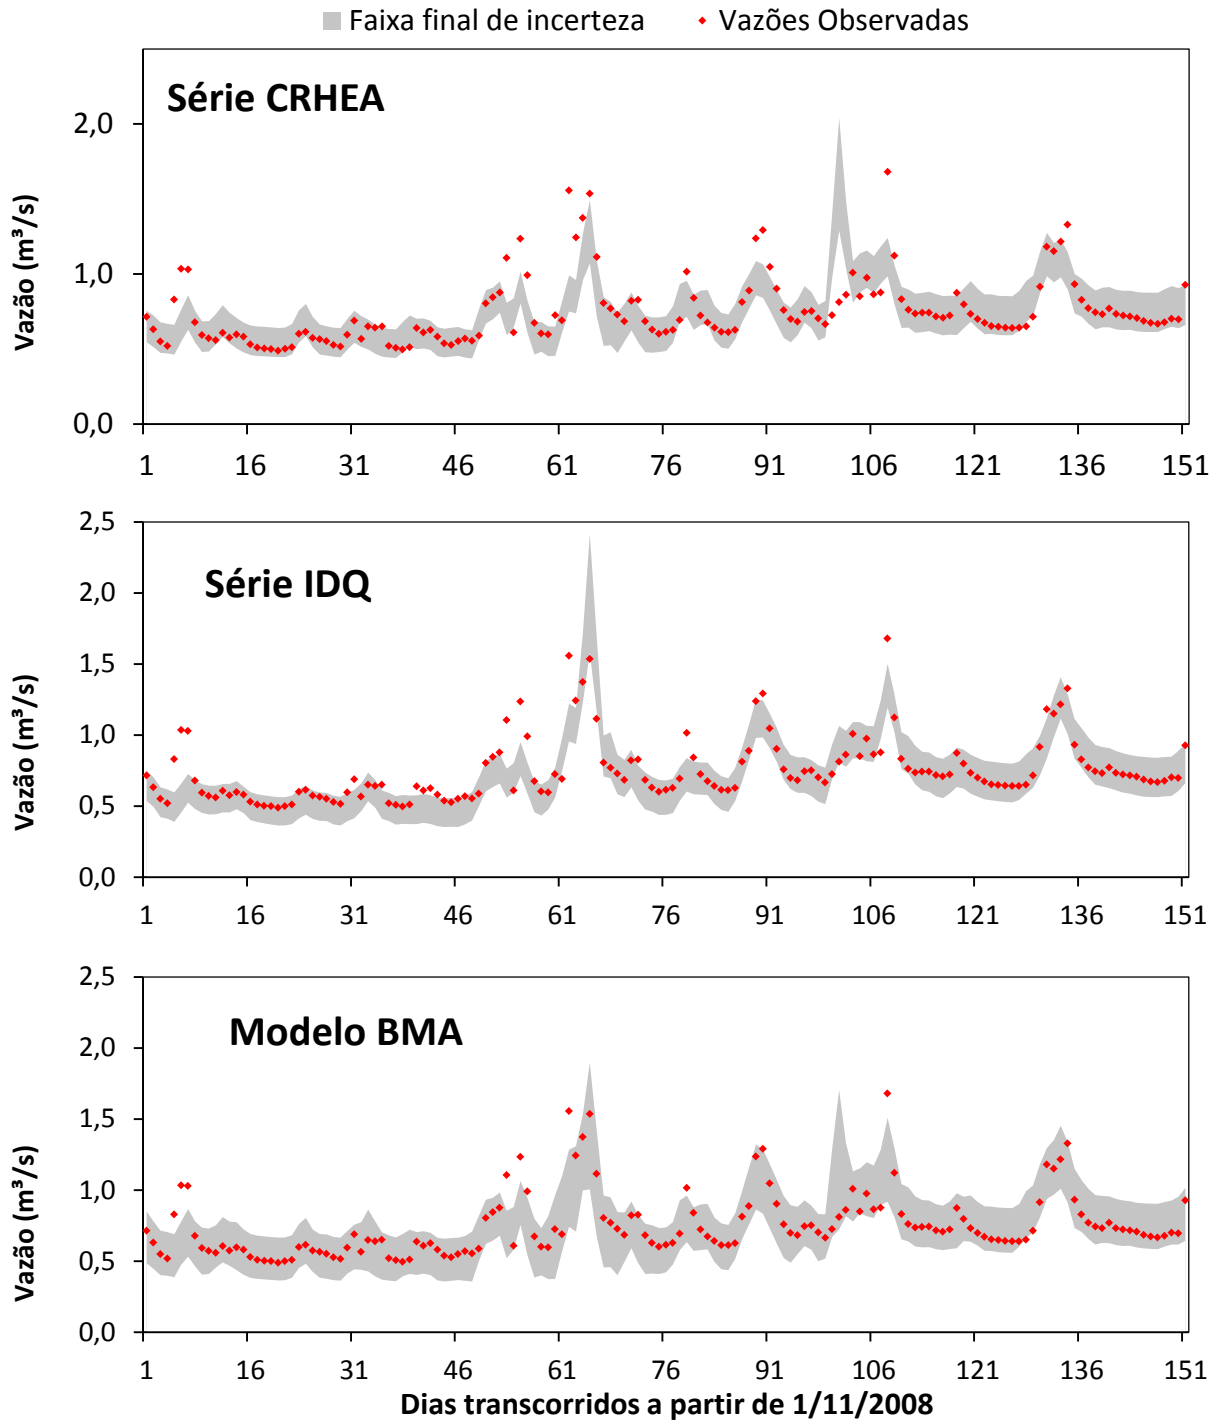


Figura 26 - Incerteza das vazões para os modelos CRHEA, IDQ e BMA entre os meses de novembro/2008 a março/2009, período de calibração. Em cinza, as faixas de incertezas para a vazão e em vermelho os valores observados de vazão

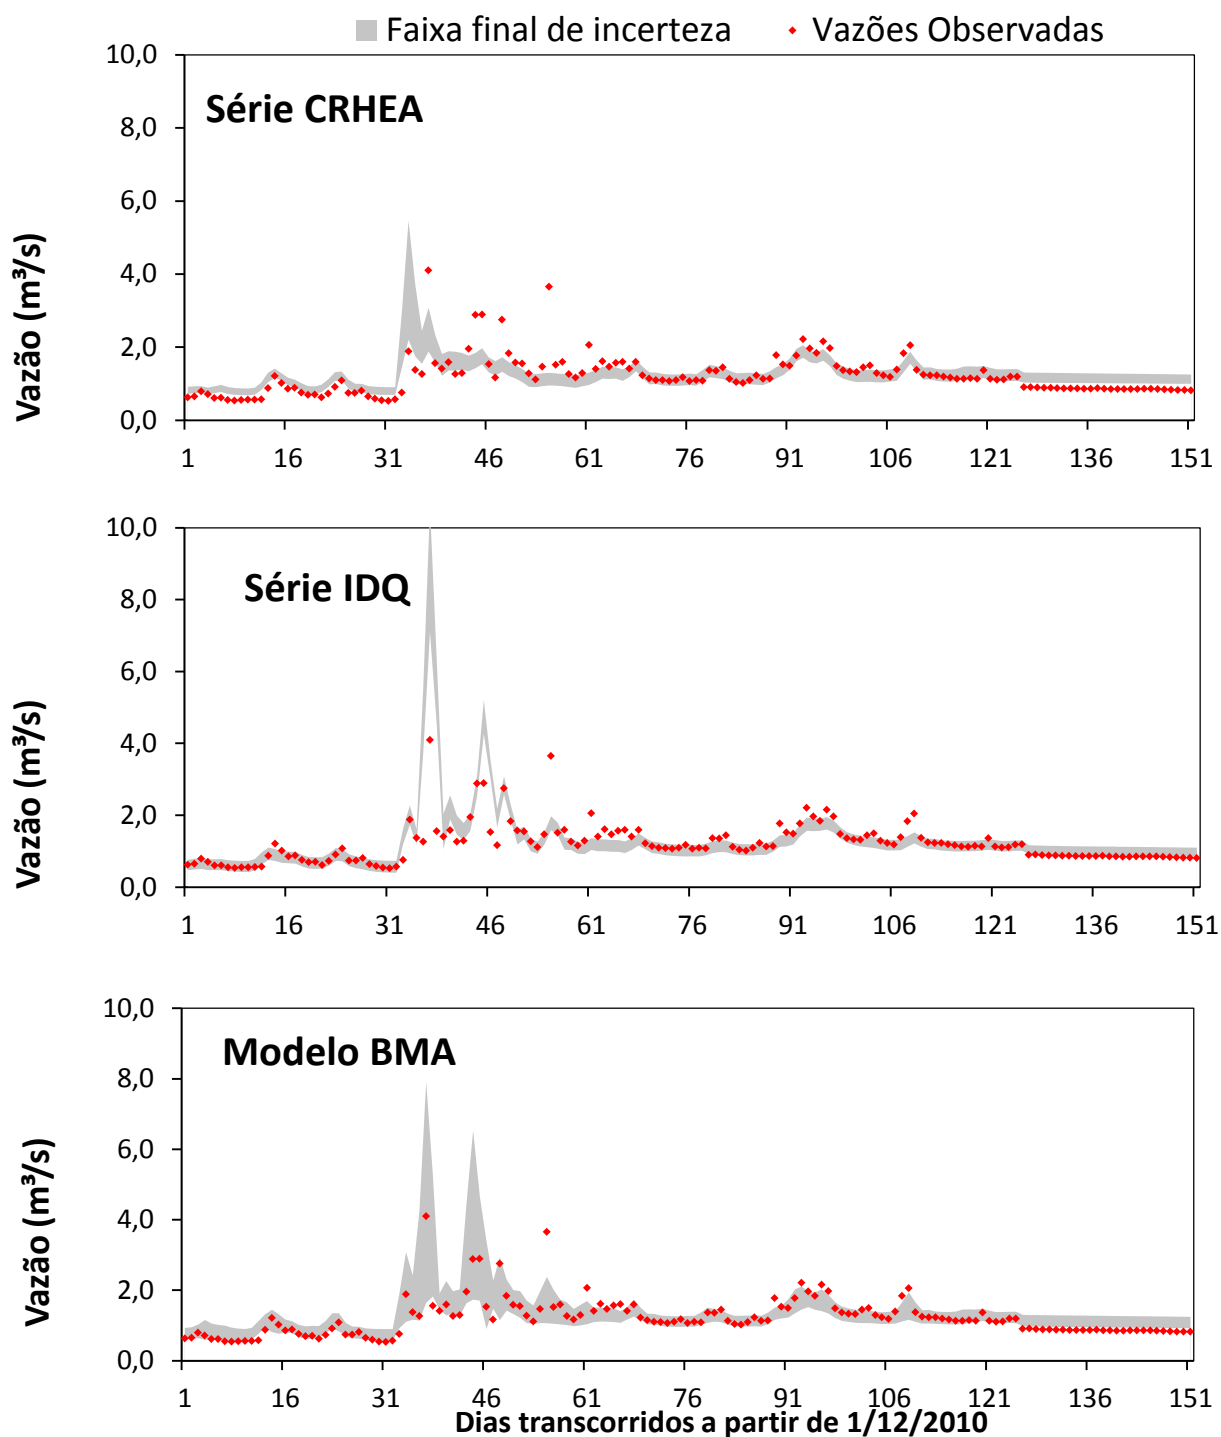


Figura 27 - Incerteza das vazões para os modelos CRHEA, IDQ e BMA entre os meses de dezembro/2010 a março/2011, período de calibração. Em cinza, as faixas de incertezas para a vazão e em vermelho os valores observados de vazão.

Numa análise dos períodos completos percebe-se que, tanto na calibração quanto na validação, houve poucos modelos com um valor de POC próximo ao desejado (0,95). Entre os períodos de calibração e validação houve uma grande alternância entre os modelos com melhor desempenho. A série de precipitação que obteve o valor de POC mais próximo ao desejado durante a calibração foi a CRHEA, com uma pequena subestimação (-2%). Esta mesma série obteve o segundo pior POC (0,67) na validação. A série IDQ, que obteve um POC razoável durante a calibração (0,87) obteve o melhor valor durante a validação (0,91), associado também a uma pequena subestimação (-4%). Quanto ao fator r , os valores obtidos pelos modelos de precipitação foram semelhantes durante ambos períodos, atingindo valores menores que 1.

O modelo BMA obteve o segundo maior POC para o período de calibração e validação (0,98 e 0,90, respectivamente), apresentando uma leve superestimação das incertezas durante a calibração (+3%) e uma leve subestimação para a validação (-5%). Os valores do fator r obtidos em ambos períodos foram um pouco superiores à unidade em ambos os períodos, sendo menor para a validação (1,15). Isto sugere que as faixas de incerteza obtidas pelo método são um pouco mais largas que o ideal. Supõe-se que isso se origine no fato de que a variância calculada pelo método BMA atribua a variância final à combinação das variâncias intra e inter-modelos, como explicado no item 4.4.3, e não somente à dispersão entre os diferentes resultados (variância inter-modelos).

Ao se analisar o desempenho das séries durante a estação seca, pode-se perceber que todas as séries de precipitação obtiveram um maior POC, associados a maiores valores de fator r . Essa combinação indica uma provável superestimação das incertezas dos parâmetros relacionados à geração do escoamento de base, que predomina durante tal estação. Tal incerteza vem a ser refletida no modelo BMA, com um POC de 1,0 e o maior fator r para o período de calibração (1,76). Percebe-se também uma piora na qualidade dos resultados entre o período de calibração e validação, principalmente para o modelo CRHEA e TRMM, que aparentemente não reproduziram bem o escoamento de base durante a validação. Como a série CRHEA recebeu o maior peso, isso afetou os resultados para o modelo BMA (POC = 0,75), que sofreu uma queda acentuada para esta estação.

Para a estação úmida, os modelos de precipitação obtiveram resultados com baixos valores para o fator r , no entanto, à custa de valores de POC mais distantes de 0,95. Tal fato pode ter ocorrido devido à capacidade limitada do modelo em reproduzir o escoamento superficial, verificado durante o processo de calibração manual e análise de incerteza dos parâmetros que controlam o fenômeno. Percebe-se que o modelo BMA comportou-se de maneira consistente em ambos períodos, retornando valores baixos do fator r aliados a um POC muito próximo a 0,95, superando os modelos de precipitação analisados isoladamente.

É importante observar que não houve a predominância de uma série de precipitação sobre as outras do conjunto, no que diz respeito aos índices estatísticos que avaliam o desempenho da incerteza na capacidade preditiva. A série CRHEA, que obteve bom desempenho na calibração, não repetiu tais resultados para o período de validação, sendo suplantado pelo modelo IDQ. Já o modelo BMA reproduziu valores satisfatórios de POC em ambos os períodos, porém, às custas de valores altos do fator r , se comparado as séries de precipitação. Quanto ao desempenho de todos os resultados analisados em conjunto, percebe-se que nem as séries de precipitação, nem a previsão probabilística do modelo BMA obtiveram resultados ideais para todas as condições climáticas.

5.7 Avaliação geral e escolha de uma estratégia para a modelagem da B.R.O.

Diante da diversidade das análises feitas e resultados apresentados até aqui, é necessário se discutir a respeito da escolha da estratégia de modelagem para a bacia do Ribeirão da Onça que seja ao mesmo tempo realista e eficaz. Como citado no item 3.2, segundo Gupta et al. (2005), espera-se que um modelo calibrado possa reproduzir o comportamento da bacia hidrográfica de forma acurada e precisa, ou seja, com pequenos desvios e incertezas, respectivamente.

A análise da precisão das respostas obtidas foi realizada pelos índices estatísticos de comparação entre respostas únicas e os valores observados de vazão. Como discutido no item 5.5, tal análise apontou para um desempenho claramente superior do modelo BMA em comparação às séries de precipitação para o período de calibração. No período de validação,

o modelo BMA obteve resultados muito semelhantes à melhor série (ANA), sendo levemente inferior nos quesitos COE e PBIAS, e obtendo um R^2 um pouco superior.

Diante desta semelhança quanto aos resultados, uma análise qualitativa dos desempenhos das séries de precipitação e do modelo BMA é necessária. Como foi apresentado no item 5.5, ao se analisar a Figura 23, percebe-se a vantagem do modelo BMA em relação às séries isoladamente: por se tratar de um resultado agregado, as deficiências das séries de precipitação, que ora resultaram em picos elevados (IDQ e THI), ora resultaram em picos abaixo do observado (ANA, CRHEA) foram atenuadas, apresentando o modelo BMA o resultado que mais se aproximou do valor observado. Esta mesma vantagem pode ser observada na Figura 24, para o período de validação. Desta forma, reconheceu-se o modelo BMA como aquele que produziu as respostas mais precisas e de acordo com o comportamento físico da bacia.

A acurácia das respostas foi feita através da análise do fator r , que está relacionado à espessura média da faixa de incertezas das respostas. A análise isolada do fator r não permite uma avaliação clara da incerteza preditiva de um modelo, sendo mais esclarecedora a sua análise junto ao POC. A grande alternância do desempenho das séries quanto à incerteza preditiva entre os períodos de calibração e validação é um fator contra a adoção de uma única série para as simulações hidrológicas na B.R.O. O modelo BMA apresentou resultados que variaram menos entre a calibração e a validação, o que o torna uma opção mais confiável sob o ponto de vista das incertezas preditivas.

Uma desvantagem do método BMA é o tempo e recursos consumidos em se criar diferentes resultados. A análise dos pesos atribuídos pelo método às séries de precipitação permitiu uma avaliação da importância relativa das séries e seu impacto na resposta obtida. Desta forma, a série IDQ pode ser excluída do conjunto, como forma de se diminuir o tempo necessário para a aplicação do método. Apesar de receber um peso maior que a série IDQ, a análise da acurácia e precisão dos resultados obtidos com a série TRMM permitiu classificá-la como uma alternativa não competitiva e sua exclusão do conjunto é recomendada.

6. CONCLUSÕES

Neste trabalho foi proposta uma estratégia para a modelagem hidrológica da Bacia do Ribeirão da Onça utilizando-se o modelo SWAT levando-se em consideração as incertezas dos parâmetros dos modelos e utilizando-se diversas séries de entrada para a precipitação.

Foi verificado que os parâmetros do modelo SWAT possuem faixas de incerteza que variam a depender da série de precipitação utilizada. Foi verificado também que o número de iterações necessárias para se obter um resultado satisfatório através do método SUFI-2 variou entre as diferentes séries de precipitação. Tais resultados salientam a importância de se levar em consideração diversas fontes/esquemas de precipitação na modelagem hidrológica da B.R.O.

O parâmetro com a maior faixa final de incerteza foi o CN, diretamente ligado à produção do escoamento superficial. Tal resultado sugere uma não adequação do método SCS para modelagem de tal fenômeno e uma maior necessidade de se entender os mecanismos de produção do escoamento superficial na B.R.O. Os valores finais dos parâmetros relacionados à produção do escoamento subsuperficial, aliados aos valores baixos de CN sugerem tal processo como dominante das respostas da B.R.O à precipitação.

Os parâmetros relacionados às propriedades físicas do solo tiveram seus valores iniciais sugeridos a partir de medições em campo, e sua incerteza final sugere uma maior necessidade de medições em campo para estimativas de valores mais realistas. O valor do parâmetro de água disponível no solo (SOL_AWC), estimado com base em uma equação de pedotransferência terminaram por se concentrar em regiões distantes àquela dos valores estimados inicialmente grandes incertezas, confirmando a necessidade estimativas baseadas em medições de campo e coletas para análise em laboratório do solo da B.R.O.

A análise estatística das diferentes séries de precipitação indicou que as estimativas oriundas do satélite TRMM diferem consideravelmente das demais na configuração diária, apresentando entretanto uma boa concordância na escala mensal. Foi verificada também uma tendência das estimativas do TRMM em superestimar os totais precipitados. Supõe-se que isto ocorreu pois tais estimativas se tratam de medidas indiretas da precipitação e correspondem a estimativas espacial em escala maior que as dimensões da B.R.O.

Quando feita uma comparação das respostas do modelo SWAT a partir de diferentes fontes e esquemas de interpolação da precipitação com aquela obtida pela ponderação probabilística do método BMA verificou-se que a última apresenta-se como a alternativa mais adequada para as simulações na B.R.O. Esta alternativa não está, no entanto, livre de erros, uma vez que seu resultado depende do desempenho das simulações individuais geradas.

Foi sugerido que para a utilização mais eficaz do método BMA, pode se prescindir das séries de precipitação obtidas pelo satélite TRMM e do esquema de interpolação por inverso da distância ao quadrado, uma vez que foram atribuídos pesos muito pequenos a estas séries no processo de ponderação.

7. REFERÊNCIAS BIBLIOGRÁFICAS

ABBASPOUR, K. C.; YANG, J.; MAXIMOV, I.; SIBER, R.; BOGNER, K.; MIELEITNER, J.; ZOBRIST, J.; SRINIVASAN, R. Modelling hydrology and water quality in the pre-alpine/alpine Thur watershed using SWAT. **Journal of Hydrology**, v. 333, n. 2-4, p. 413-430, Feb 15 2007.

ABBOT, M. B.; BATHURST, J. C.; CUNGE, J. A.; O'CONNELL, P. E.; RASMUSSEN, J. An introduction to the European Hydrological System – Systeme Hydrologique Europeen, SHE. 1. History and philosophy of a physically based, distributed modeling system. **Journal of Hydrology**, v. 87, p. 45-59, 1986

AJAMI, N. K.; DUAN, Q.; SOROOSHIAN, S. An integrated hydrologic Bayesian multimodel combination framework: Confronting input, parameter, and model structural uncertainty in hydrologic prediction. **Water Resources Research**, v. 43, n. 1, Jan 9 2007.

ANCTIL, F. LAUZON, N.; ANDREASSIAN, V. OUDIN, L.; PERRIN, C. Improvement of rainfall-runoff forecasts through mean areal rainfall optimization. **Journal of Hydrology**, v. 328, n. 3-4, p. 717-725, Sep 15 2006.

ANDRADE, M. A.; MELLO, C. R. D.; BESKOW, S. Simulação hidrológica em uma bacia hidrográfica representativa dos Latossolos na região Alto Rio Grande, MG. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 17, p. 69-76, 2013.

ANDREASSIAN, V. PERRIN, C.; MICHEL, C.; USART-SACNHEZ, I. LAVABRE, J. Impact of imperfect rainfall knowledge on the efficiency and the parameters of watershed models. **Journal of Hydrology**, v. 250, n. 1-4, p. 206-223, 2001.

ARNOLD, J. G.; WILLIAMS, J. R. Validation of SWRRB: Simulator for water resources in rural basins. . **Journal of the American Water Resources Association**, v. 113, n. 2, p. 243-256, 1987.

ARNOLD, J. G.; WILLIAMS, J. R.; MAIDMENT, D. R. Continuous-time water and sediment-routing model for large basins. **Journal of Hydrologic Engineering**. v. 121, n. 2, p. 171-183, 1995.

ARNOLD, J. G.; SRINIVASAN, R.; MUTTIAH, R. S.; WILLIAMS, J. R. Large area hydrologic modeling and assessment - Part 1: Model development. **Journal of the American Water Resources Association**, v. 34, n. 1, p. 73-89, Feb 1998.

BARDOSSY, A.; DAS, T. Influence of rainfall observation network on model calibration and application. **Hydrology and Earth System Sciences**, v. 12, n. 1, p. 77-89, 2008.

BARRETO, C. E. A. G. **Balanço hídrico em zona de afloramento do sistema aquífero guarani a partir de monitoramento hidrogeológico em bacia representativa**. Dissertação (Mestrado em Hidráulica e Saneamento) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2006.

BASTOLA, S.; MURPHY, C.; SWEENEY, J. The role of hydrological modelling uncertainties in climate change impact assessments of Irish river catchments. **Advances in Water Resources**, v. 34, n. 5, p. 562-576, May 2011.

BERGSTRÖM, S. Development and application of a conceptual runoff model for Scandinavian catchments. **SMHI Reports RHO**, no. 7. Norrköping, Suécia. 1976

BEVEN, K. Prophecy, reality and uncertainty in distributed hydrological modeling. **Advances in Water Resources**, v. 16, n. 1, p. 41-51, 1993.

BEVEN K. J. **Down to Basics: Runoff Processes and The Modelling Process**. In: _____. Rainfall-Runoff Modelling – The Primer. Inglaterra: Wiley & Sons, 2001. Cap. 1, p. 1–23

_____. A manifesto for the equifinality thesis. **Journal of Hydrology**, v. 320, n. 1-2, p. 18-36, Mar 30 2006.

BEVEN, K.; BINLEY, A. The future of distributed models - model calibration and uncertainty prediction. **Hydrological Processes**, v. 6, n. 3, p. 279-298, Jul-Sep 1992.

BEVEN, K. J. Rainfall-Runoff Modeling: Introduction. In: **Encyclopedia of Hydrological Sciences**: John Wiley & Sons, Ltd, 2006.

BEVEN, K. J.; HORNBERGER, G. M. Assessing the effect of spatial pattern of precipitation in modeling stream-flow hydrographs. **Water Resources Bulletin**, v. 18, n. 5, p. 823-829, 1982.

BOX, G. E. P.; TIAO, G. C. **Bayesian inference in statistical analysis**. Reading, Addison-Wesley Publishing Company, 1973.

BOYLE, D. P.; GUPTA, H. V.; SOROOSHIAN, S. Toward improved calibration of hydrologic models: Combining the strengths of manual and automatic methods. **Water Resources Research**, v. 36, n. 12, p. 3663-3674, Dec 2000.

BRONSTERT, A.; BARDOSSY, A. Uncertainty of runoff modelling at the hillslope scale due to temporal variations of rainfall intensity. **Physics and Chemistry of the Earth**, v. 28, n. 6-7, p. 283-288, 2003.

BROWN, L. C.; BARNWELL JR., T. O. The enhanced water quality models QUAL2E-UNCAS: Documentation and user manual. EPA document EPA/600/3-87/007. Athens Georgia.: USEPA

CHAPLOT, V.; SALEH, A.; JAYNES, D. B. Effect of the accuracy of spatial rainfall information on the modeling of water, sediment, and NO₃-N loads at the watershed level. **Journal of Hydrology**, v. 312, n. 1-4, p. 223-234, Oct 10 2005.

CLARKE, R. T. A review of some mathematical models used in hydrology, with observations on their calibration and use. **Journal of Hydrology**, v. 19, n. 1, p. 1-20, 1973.

CLARKE, R. T. et al. Issues of spatial correlation arising from the use of TRMM rainfall estimates in the Brazilian Amazon. **Water Resources Research**, v. 47, May 26 2011.

COLLISCHONN, B.; COLLISCHONN, W.; MORELLI TUCCI, C. E. Daily hydrological modeling in the Amazon basin using TRMM rainfall estimates. **Journal of Hydrology**, v. 360, n. 1-4, p. 207-216, Oct 15 2008.

CRAWFORD, N. H.; LINSLEY, R. K. Digital simulation in hydrology: Stanford Watershed Model IV. Department of Civil Engineering, Stanford University, Technical Report no. 39, California, EUA, 1966.

DAS, T.; BARDOSSY, A.; ZEHE, E.; HE, Y. Comparison of conceptual model performance using different representations of spatial variability. **Journal of Hydrology**, v. 356, n. 1-2, p. 106-118, 2008.

DAWDY, D. R.; BERGMANN, J. M. Effect of rainfall variability on streamflow simulation. **Water Resources Research**, v. 5, n. 5, p. 958-&, 1969.

DOOGE, J. C. I. Linear theory of hydrologic systems. **Technical Bulletin no. 1468**, Agricultural Research Service, United States Department of Agriculture, 1973.

DUAN, Q.; AJAMI, N. K.; GAO, X.; SOROOSHIAN, S. Multi-model ensemble hydrologic prediction using Bayesian model averaging. **Advances in Water Resources**, v. 30, n. 5, p. 1371-1386, May 2007.

DUAN, Q. Y.; SOROOSHIAN, S.; GUPTA, V. Effective and efficient global optimization for conceptual rainfall-runoff models. **Water Resources Research**, v. 28, n. 4, p. 1015-1031, Apr 1992.

DUNCAN, M. R.; AUSTIN, B.; FABRY, F. AUSTIN, G. L. The effect of gauge sampling density on the accuracy of streamflow prediction for rural catchments. **Journal of Hydrology**, v. 142, n. 1-4, p. 445-476, Feb 1993.

EVENSEN, G. **Data Assimilation: The Ensemble Kalman Filter**. Berlin, Springer, 2009,

FARAMARZI, M.; ABBASPOUR, K. C.; SCHULIN, R.; YANG, H. Modelling blue and green water resources availability in Iran. **Hydrological Processes**, v. 23, n. 3, p. 486-501, 2009.

_____. Modeling impacts of climate change on freshwater availability in Africa. **Journal of Hydrology**, v. 480, p. 85-101, Feb 14 2013.

FAURES, J. M.; GOODRICH, D. C.; WOOLHISER, D. A.; SOROOSHIAN, S. IMPACT OF SMALL-SCALE SPATIAL RAINFALL VARIABILITY ON RUNOFF MODELING. **Journal of Hydrology**, v. 173, n. 1-4, p. 309-326, 1995.

GARBOSSA, L. H. P.; VASCONCELOS, L. R. C.; LAPA, K. R.; BLAINSKI, E.; PINHEIRO, A. The use and results of the Soil and Water Assessment Tool in Brazil: A review from 1999 until 2010. In: 2011 INTERNATIONAL SWAT CONFERENCE & WORKSHOPS, 2011, Toledo, Espanha, 2011.

GASSMAN, P. W.; REYES, M. R.; GREEN, C. H.; ARNOLD, J. G. The soil and water assessment tool: Historical development, applications, and future research directions. **Transactions of the Asabe**, v. 50, n. 4, p. 1211-1250, Jul-Aug 2007.

GEORGAKAKOS, K. P.; SEO, D-J.; GUPTA, H.; SCHAAKE, J. BUTTS, M. B. Towards the characterization of streamflow simulation uncertainty through multimodel ensembles. **Journal of Hydrology**, v. 298, n. 1-4, p. 222-241, 2004.

GOMES, L. H. **Mecanismos de infiltração e recarga em zona de afloramento do Aquífero Guarani**. Dissertação (Mestrado em Hidráulica e Saneamento) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2008.

GOODRICH, D. C.; FAURES, J. M.; WOOLHISER, D. A.; LANE, L. J.; SOROOSHIAN, S. Measurement and analysis of small-scale convective storm rainfall variability. **Journal of Hydrology**, v. 173, n. 1-4, p. 283-308, Dec 1995.

GUPTA, H. V.; BEVEN, K. J.; WAGENER, T. Model Calibration and Uncertainty Estimation. In: **Encyclopedia of Hydrological Sciences**: John Wiley & Sons, Ltd, 2006.

GUPTA, H. V.; SOROOSHIAN, S.; YAPO, P. O. Status of automatic calibration for hydrologic models: comparison with multilevel expert calibration. **Journal of Hydrologic Engineering**, v. 4, n. 2, p. 135-143, Apr 1999.

GUPTA, H. V.; WAGENER, T.; LIU, Y. Reconciling theory with observations: elements of a diagnostic approach to model evaluation. **Hydrological Processes**, v. 22, n. 18, p. 3802-3813, Aug 30 2008.

IBBIT, R. P.; O'DONNELL, T. Fitting methods for conceptual catchment models. **Journal of the Hydraulics Division**. v. 97, n. 9, p. 1331-1342, 1971.

IZZARRAULDE, R. C.; WILLIAMS, J. R.; MCGILL, W. B.; ROSENBERG, N. J.; QUIROGA JAKAS, M. C. Simulating soil C dynamics with EPIC: Model description and testing against long-term data. **Ecological Modelling**. v. 192, n. 3-4, p. 362-384, 2006.

JIANG, S.; REN, L.; HONG, Y.; YONG, B.; YANG, X.; YUAN, F.; MA, M. Comprehensive evaluation of multi-satellite precipitation products with a dense rain gauge network and optimally merging their simulated hydrological flows using the Bayesian model averaging method. **Journal of Hydrology**, v. 452, p. 213-225, Jul 25 2012.

JOHNSTON, P. R.; PILGRIM, D. H. Parameter optimization for watershed models. **Water Resources Research**, v. 12, n. 3, p. 477-486, 1976 1976.

KAVETSKI, D.; KUCZERA, G.; FRANKS, S. W. Bayesian analysis of input uncertainty in hydrological modeling: 1. Theory. **Water Resources Research**, v. 42, n. 3, Mar 8 2006.

KNISEL, W. G. CREAMS, a field-scale model for chemicals, runoff, and erosion from agricultural management systems. **USDA Conservation Research Report No. 26**. Washington, D.C.: USDA. 1980

KOOL, J. B.; PARKER, J. C. Analysis of the inverse problem for transient unsaturated flow. **Water Resources Research**, v. 24, n. 6, p. 817-830, Jun 1988.

KOUTSOYIANNIS, D.; LANGOUSIS, A.; Precipitation. In: PETER, W. (Ed.). **Treatise on Water Science**. Oxford: Elsevier, 2011. p.27-77.

KRISHNAMURTI, T. N.; KISHTAWAL, C. M.; LAROW, T. E.; BACHIOCHI, D. R.; ZHANG, Z.; WILLIFORD, C. E.; GADGIL, S.; SURENDRAN, S. Improved weather and seasonal climate forecasts from multimodel superensemble. **Science**, v. 285, n. 5433, p. 1548-1550, Sep 3 1999.

KUCZERA, G.; PARENT, E. Monte Carlo assessment of parameter uncertainty in conceptual catchment models: the Metropolis algorithm. **Journal of Hydrology**, v. 211, n. 1-4, p. 69-85, Nov 1998.

KUNDZEWICZ, Z. W. Hydrological uncertainty in perspective. In:_____(Ed.). **New uncertainty concepts in hydrology and water resources**. Cambridge. Cambridge University Press, 1995

LEMIEUX, C. The Monte Carlo Method. In:_____. Monte Carlo and Quasi-Monte Carlo Sampling, Nova Iorque, Springer, 2009.

LEONARD, R. A.; KNISEL, W. G.; STILL, D. A. GLEAMS: Groundwater loading effects of agricultural management systems. **Transactions of the ASAE**. v. 30, n. 5, p. 1403-1418, 1987.

LI, X.-H.; ZHANG, Q.; XU, C.-Y. Suitability of the TRMM satellite rainfalls in driving a distributed hydrological model for water balance computations in Xinjiang catchment, Poyang lake basin. **Journal of Hydrology**, v. 426, p. 28-38, Mar 21 2012.

LIU, Y.; GUPTA, H. V. Uncertainty in hydrologic modeling: Toward an integrated data assimilation framework. **Water Resources Research**, v. 43, n. 7, Jul 3 2007.

LOPES, V. L. On the effect of uncertainty in spatial distribution of rainfall on catchment modelling. **Catena**, v. 28, n. 1-2, p. 107-119, Dec 1996.

LUCAS, M. C. **Influência da precipitação e do uso do solo sobre a taxa de recarga em zona de afloramento do Sistema Aquífero Guarani**. Dissertação (Mestrado em Hidráulica e Saneamento) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2012.

MACHADO, R. E.; VETTORAZZI, C. A. Simulação da produção de sedimentos para a microbacia hidrográfica do Ribeirão dos Marins (SP). **Revista Brasileira de Ciência do Solo**, v. 27, p. 735-741, 2003.

MALDONADO, L. H. **Validação experimental de modelotologias para a quantificação contínua de vazão no Ribeirão da Onça**. Dissertação (Mestrado em Hidráulica e Saneamento) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2009.

MASRI, S. F.; BEKEY, G. A.; SAFFORD, F. B. A global optimization algorithm using adaptative random search. **Applied Mathematics and Computation**, v. 7, p. 353-375, 1980.

MCMILLAN, H.; JACKSON, B.; CLARK, M.; KAVETSKI, D.; WOODS, R. Rainfall uncertainty in hydrological modelling: An evaluation of multiplicative error models. **Journal of Hydrology**, v. 400, n. 1-2, p. 83-94, Mar 30 2011.

MICHAUD, J. D.; SOROOSHIAN, S. Effect of rainfall-sampling errors on simulations of desert flash floods. **Water Resources Research**, v. 30, n. 10, p. 2765-2775, Oct 1994.

MONTANARI, A. What do we mean by 'uncertainty'? The need for a consistent wording about uncertainty assessment in hydrology. **Hydrological Processes**, v. 21, n. 6, p. 841-845, Mar 15 2007.

MONTANARI, A.; Uncertainty of Hydrological Predictions. In: PETER, W. (Ed.). **Treatise on Water Science**. Oxford: Elsevier, 2011. p.459-478.

MONTANARI, A.; SHOEMAKER, C. A.; VAN DE GIESEN, N. Introduction to special section on Uncertainty Assessment in Surface and Subsurface Hydrology: An overview of issues and challenges. **Water Resources Research**, v. 45, Oct 30 2009.

MORADKHANI, H.; SOROOSHIAN, S.; GUPTA, H. V.; HOUSER, P. R. Dual state-parameter estimation of hydrological models using ensemble Kalman filter. **Advances in Water Resources**, v. 28, n. 2, p. 135-147, 2005.

MORADKHANI, H.; SOROOSHIAN, S. General Review of Rainfall-Runoff Modeling: Model Calibration, Data Assimilation, and Uncertainty Analysis. In: SOROOSHIAN, S. et al. (Ed.). **Hydrological Modelling and the Water Cycle**: Springer Berlin Heidelberg, v.63, 2008. p.1-24. (Water Science and Technology Library).

MORIASI, D. N.; ARNOLD, J. G.; VAN LIEW, M. W.; BINGNER, R. L.; HARMEL R. D.; VEITH, T. L. Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. **Transactions of the ASABE**, St. Joseph, v. 50, n. 3, p. 885-900. 2007

NASH, J. E.; SUTCLIFFE, J. V. River flow forecasting through conceptual models part I — A discussion of principles. **Journal of Hydrology**, v. 10, n. 3, p. 282-290, 1970.

NEITSCH S. L.; ARNOLD, J. G.; KINIRY, J. R.; WILLIAMS, J. R. Soil and Water Assessment Tool – Theoretical Documentation: Version 2005. Temple: Blackland Research Center, Texas Agricultural Experiment Station. 494 p. 2005.

NELDER, J. A.; MEAD, R. A simplex method for function minimization. **Computer Journal**, v. 7, p. 308-313, 1965.

OBLER, C.; WENDLING, J.; BEVEN, K. The sensitivity of hydrological models to spatial rainfall patterns - an evaluation using observed data. **Journal of Hydrology**, v. 159, n. 1-4, p. 305-333, Jul 1994.

PAPPENBERGER, F.; BEVEN, K. J. Ignorance is bliss: Or seven reasons not to use uncertainty analysis. **Water Resources Research**, v. 42, n. 5, May 16 2006.

PAPPENBERGER, F.; HARVEY, H.; BEVEN, K.; HALL, J.; MEADOWCROFT, I. Decision tree for choosing an uncertainty analysis methodology: a wiki experiment. **Hydrological Processes**, v. 20, n. 17, p. 3793-3798, Nov 15 2006.

PARRISH, M. A.; MORADKHANI, H.; DECHANT, C. M. Toward reduction of model uncertainty: Integration of Bayesian model averaging and data assimilation. **Water Resources Research**, v. 48, Mar 20 2012.

POMPÊO, C. A. **Balço hídrico da zona não-saturada do solo na Bacia do Ribeirão da Onça**. Tese (Doutorado em Hidráulica e Saneamento) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 1990.

RAFTERY, A. E.; GNEITING, T.; BALABDAOUI, F.; POLAKOWSKI, M. Using Bayesian model averaging to calibrate forecast ensembles. **Monthly Weather Review**, v. 133, n. 5, p. 1155-1174, May 2005.

RIBEIRO, A. S. **Modelagem chuva-vazão utilizando o *framework* JAMS em área de afloramento do Sistema Aquífero Guarani**. Dissertação (Mestrado em Hidráulica e Saneamento) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2012.

ROSENBROCK, H. H. An automatic method for finding the greatest or least value of a function. **Computer Journal**, v. 9, p. 175-184, 1960

SAGINTAYEV, Z.; SULTAN, M.; KHAN, S. D.; MAHMOOD, K.; YAN, E.; MILEWSKI, A.; MARSALA, P. A remote sensing contribution to hydrologic modelling in arid and inaccessible watersheds, Pishin Lora basin, Pakistan. **Hydrological Processes**, v. 26, n. 1, p. 85-99, Jan 1 2012.

SCHUOL, J.; ABBASPOUR, K. C.; YANG, H.; SRINIVASAN, R.; ZEHNDER, A. J. B. Modeling blue and green water availability in Africa. **Water Resources Research**, v. 44, n. 7, Jul 9 2008.

SHAMSELDIN, A. Y.; OCONNOR, K. M.; LIANG, G. C. Methods for combining the outputs of different rainfall-runoff models. **Journal of Hydrology**, v. 197, n. 1-4, p. 203-229, Oct 1997.

SHERMAN, L. K. Streamflow from rainfall by unit-graph method. **Engineering News Record**, v. 108, p. 501-505, 1932.

SINGH, V. P. Effect of spatial and temporal variability in rainfall and watershed characteristics on stream flow hydrograph. **Hydrological Processes**, v. 11, n. 12, p. 1649-1669, Oct 15 1997.

SOLOMATINE, D. P.; WAGENER, T.; Hydrological Modeling. In: PETER, W. (Ed.) **Treatise on Water Science**. Oxford: Elsevier, 2011. p.435-457.

SOROOSHIAN, S. Parameter-estimation of rainfall - runoff models with heteroscedastic streamflow errors - the non-informative data case. **Journal of Hydrology**, v. 52, n. 1-2, p. 127-138, 1981 1981.

SOROOSHIAN, S.; DRACUP, J. A. Stochastic parameter-estimation procedures for hydrologic rainfall-runoff models - correlated and heteroscedastic error cases. **Water Resources Research**, v. 16, n. 2, p. 430-442, 1980.

SOROOSHIAN, S.; GUPTA, V. K. Model Calibration. In: SINGH, V. P. et al. (Ed.) Computer Models of Watershed Hydrology, Littleton, Colorado: Water Resources Publication, p. 23-67. 1995.

SPEAR, R. C.; HORNBERGER, G. M. Eutrophication in peel inlet .2. Identification of critical uncertainties via generalized sensitivity analysis. **Water Research**, v. 14, n. 1, p. 43-49, 1980.

SRINIVASAN, M. S.; GERARD-MARCHANT, P.; VEITH, T. L.; GBUREK, W. J.; STEENHUIS, T. S. Watershed scale modeling of critical source areas of runoff generation and phosphorus transport. **Journal of the American Water Resources Association**, v. 41, n. 2, p. 361-375, Apr 2005.

STRAUCH, M.; BERNHOFER, C.; KOID, S.; VOLK, M.; LORZ, C. MAKESCHIN, F. Using precipitation data ensemble for uncertainty analysis in SWAT streamflow simulation. **Journal of Hydrology**, v. 414, p. 413-424, Jan 11 2012.

THIEMANN, M. TROSSET, M; GUPTA, H.; SOROOSHIAN, S. Bayesian recursive parameter estimation for hydrologic models. **Water Resources Research**, v. 37, n. 10, p. 2521-2535, Oct 2001.

UZEIKA, T. **Aplicabilidade do modelo SWAT (Soil and Water Assessment Tool) na simulação da produção de sedimentos em uma pequena bacia hidrográfica rural**. 144 p. Dissertação (Mestrado) - Instituto de Pesquisas Hidráulicas. Universidade Federal do Rio Grande do Sul. 2009.

TIAN, Y.; PETERS-LIDARD, C. D. Systematic anomalies over inland water bodies in satellite-based precipitation estimates. **Geophysical Research Letters**, v. 34, n. 14, Jul 24 2007.

TODINI, E. Rainfall-runoff modeling - past, present and future. **Journal of Hydrology**, v. 100, n. 1-3, p. 341-352, Jul 30 1988.

_____. Hydrological catchment modelling: past, present and future. **Hydrology and Earth System Sciences**, v. 11, n. 1, p. 468-482, 2007 2007.

VAN GRIENSVEN, A.; MEIXNER, T. Methods to quantify and identify the sources of uncertainty for river basin water quality models. **Water Science and Technology**, v. 53, n. 1, p. 51-59, 2006 2006.

VERBURG, P. H.; SOEPBOER, W.; VELDKAMP, A.; LIMPIADA, R.; ESPALDON, V.; MASTURA, S. S. A. Modeling the spatial dynamics of regional land use: The CLUE-S model. **Environmental Management**, v. 30, n. 3, p. 391-405, Sep 2002.

VINEY, N. R.; BORMANN, H.; BREUER, L.; BRONSTERT, A.; CROKE, B. F. W.; FREDE, H.; GRAEFF, T.; HUBRECHTS, L.; HUISMAN, J.A.; JAKEMAN, A. J.; KITE, G. W.; LANINI, J.; LEAVESLEY, G.; LETTENMAIER, D. P.; LINDSTROEM, G.; SEIBERT, J.; SIVAPALAN, M.; WILLEMS, P. Assessing the impact of land use change on hydrology by ensemble modelling (LUCHEM) II: Ensemble combinations and predictions. **Advances in Water Resources**, v. 32, n. 2, p. 147-158, Feb 2009.

VRUGT, J.; DIKS, C. H.; CLARK, M. Ensemble Bayesian model averaging using Markov Chain Monte Carlo sampling. **Environmental Fluid Mechanics**, v. 8, n. 5-6, p. 579-595, 2008.

VRUGT, J. A.; GUPTA, H. V.; BASTIDAS, L. A.; BOUTEN, W.; SOROOSHIAN, S. Effective and efficient algorithm for multiobjective optimization of hydrologic models. **Water Resources Research**, v. 39, n. 8, Aug 20 2003.

_____. A Shuffled Complex Evolution Metropolis algorithm for optimization and uncertainty assessment of hydrologic model parameters. **Water Resources Research**, v. 39, n. 8, Aug 1 2003.

VRUGT, J. A.; ROBINSON, B. A. Treatment of uncertainty using ensemble methods: Comparison of sequential data assimilation and Bayesian model averaging. **Water Resources Research**, v. 43, n. 1, Jan 17 2007.

VRUGT, J. A.; TER BRAAK, C. J. F.; DIKS, C. G. H.; ROBINSON, B. A.; HYMAN, J. M.; HIGDON, D. et al. Accelerating Markov Chain Monte Carlo Simulation by Differential Evolution with Self-Adaptive Randomized Subspace Sampling. **International Journal of Nonlinear Sciences and Numerical Simulation**, v. 10, n. 3, p. 273-290, Mar 2009.

WAGENER, T.; MCINTYRE, N.; LEES, M. J.; WHEATER, H. S.; GUPTA, H. V. Towards reduced uncertainty in conceptual rainfall-runoff modelling: Dynamic identifiability analysis. **Hydrological Processes**, v. 17, n. 2, p. 455-476, Feb 15 2003.

WAGNER, P. D.; FIENER, P. WILKEN, F.; KUMAR, S.; SCHNEIDER, K. Comparison and evaluation of spatial interpolation schemes for daily rainfall in data scarce regions. **Journal of Hydrology**, v. 464, p. 388-400, Sep 25 2012.

WILLIAMS, J. R. The erosion productivity impact calculator (EPIC) model: A case history. **Philosophical Transactions of the Royal Society**, v. 329, n. 1255 p. 421-428, 1990.

WILSON, C. B.; VALDES, J. B.; RODRIGUEZ-ITURBE, I. Influence of the spatial-distribution of rainfall on storm runoff. **Water Resources Research**, v. 15, n. 2, p. 321-328, 1979.

YANG, J. REICHERT, P. ABBASPOUR, K. C.; XIA, J.; YANK, H. Comparing uncertainty analysis techniques for a SWAT application to the Chaohe Basin in China. **Journal of Hydrology**, v. 358, n. 1-2, p. 1-23, Aug 30 2008.

YAPO, P. O.; GUPTA, H. V.; SOROOSHIAN, S. Multi-objective global optimization for hydrologic models. **Journal of Hydrology**, v. 204, n. 1-4, p. 83-97, Jan 30 1998.

ZHANG, X.; SRINIVASAN, R.; BOSCH, D. Calibration and uncertainty analysis of the SWAT model using Genetic Algorithms and Bayesian Model Averaging. **Journal of Hydrology**, v. 374, n. 3-4, p. 307-317, Aug 15 2009.

ZHAO, R. J.; LIU, X. R. The Xinanjiang model. In: SINGH, V. P. et al. (Ed.) *Computer Models of Watershed Hydrology*, Littleton, Colorado: Water Resources Publication, p. 215-232. 1995.

ZHOU, F.; XU, Y.; CHEN, Y.; XU, C. Y.; GAO, Y.; DU, J. Hydrological response to urbanization at different spatio-temporal scales simulated by coupling of CLUE-S and the SWAT model in the Yangtze River Delta region. **Journal of Hydrology**, v. 485, p. 113-125, Apr 2 2013.

SOLOMATINE, D. P.; WAGENER, T.; Hydrological Modeling. In: PETER, W. (Ed.) **Treatise on Water Science**. Oxford: Elsevier, 2011. p. 435-457.

APÊNDICE A - Algoritmo Expectation Maximization

Para a definição do modelo BMA utilizando o método da máxima verossimilhança, tem-se o seguinte problema de maximização:

$$\text{MAX } l(\theta|M_1, \dots, M_k, Y) = \text{MAX} \sum_{t=1}^T \ln \left(\sum_{k=1}^i w_i \cdot P(y_t|M_i, Y) \right).$$

Assumindo que $P(y_t|M_i, Y)$ é normalmente distribuída e escrita como $g(y_t|y_t^{fi}, \sigma^2)$, a equação anterior pode ser reescrita como:

$$\text{MAX } l(\theta|M_1, \dots, M_k, Y) = \text{MAX} \sum_{t=1}^T \ln \left(\sum_{k=1}^i w_i \cdot g(y_t|y_t^{fi}, \sigma^2) \right).$$

O problema se torna então a definição dos pesos w_i e da variância σ^2 que maximizem a função anterior. O algoritmo *Expectation Maximization* é capaz de solucionar problemas de misturas finitas, como é o caso do modelo BMA (MCLACHLAN e KRISHNAN, 2008). Para tanto, é introduzida uma variável não observada $z_k(t)$, que obedece a seguinte regra:

$$z_k(t) = \begin{cases} 1, & \text{para a melhor previsão no tempo } t \\ 0, & \text{caso contrário} \end{cases}$$

Ou seja, para cada tempo t a variável z será igual a 1 somente para um modelo. O algoritmo EM alterna entre dois passos, o de expectativa (E) e o de maximização (M). Ele inicia com palpites iniciais θ^0 para o vetor de parâmetros θ . No passo E, os $z_k(t)$ são calculados baseados nos atuais palpites. No passo M, θ é estimado com base nos valores calculados de $z_k(t)$. Em suma tem-se as seguintes etapas, seguindo Duan et al. (2007):

Inicialização:

Iteração (Iter) zero.

$$w_k^0 = 1/k$$

$$\sigma^{2(0)} = \frac{1}{kT} \cdot \sum_{t=1}^T \sum_{i=1}^k (y_t - y_t^{fi})^2$$

$$l(\theta^0) = \sum_{t=1}^T \ln \left(\sum_{i=1}^k w_i^0 \cdot g_i(y_t | y_t^{f_i}, \sigma^{2(0)}) \right).$$

Passo Expectativa:

$$\text{Iter} = \text{Iter} + 1$$

Para $i = 1, 2, \dots, k$ e $t = 1, 2, \dots, T$ fazer:

$$z_{i,t}^{\text{Iter}} = \frac{g(y_t | y_t^{f_i}, \sigma^{2(\text{Iter}-1)})}{\sum_{i=1}^k g(y_t | y_t^{f_i}, \sigma^{2(0)})}$$

Passo Maximização:

$$w_i^{\text{Iter}} = \frac{1}{T} \sum_{t=1}^T z_{i,t}^{\text{Iter}}$$


$$\sigma^{2(\text{Iter})} = \frac{1}{T} \cdot \sum_{t=1}^T \sum_{i=1}^k z_{i,t}^{\text{Iter}} (y_t - y_t^{f_i})^2$$

$$l(\theta^{\text{Iter}}) = \sum_{t=1}^T \ln \left(\sum_{i=1}^k w_i^{\text{Iter}} \cdot g_i(y_t | y_t^{f_i}, \sigma^{2(\text{Iter})}) \right).$$


Continuar enquanto, $|l(\theta^{\text{Iter}}) - l(\theta^{\text{Iter}-1})| < \varepsilon$.

APÊNDICE B – Incerteza preditiva: períodos completos

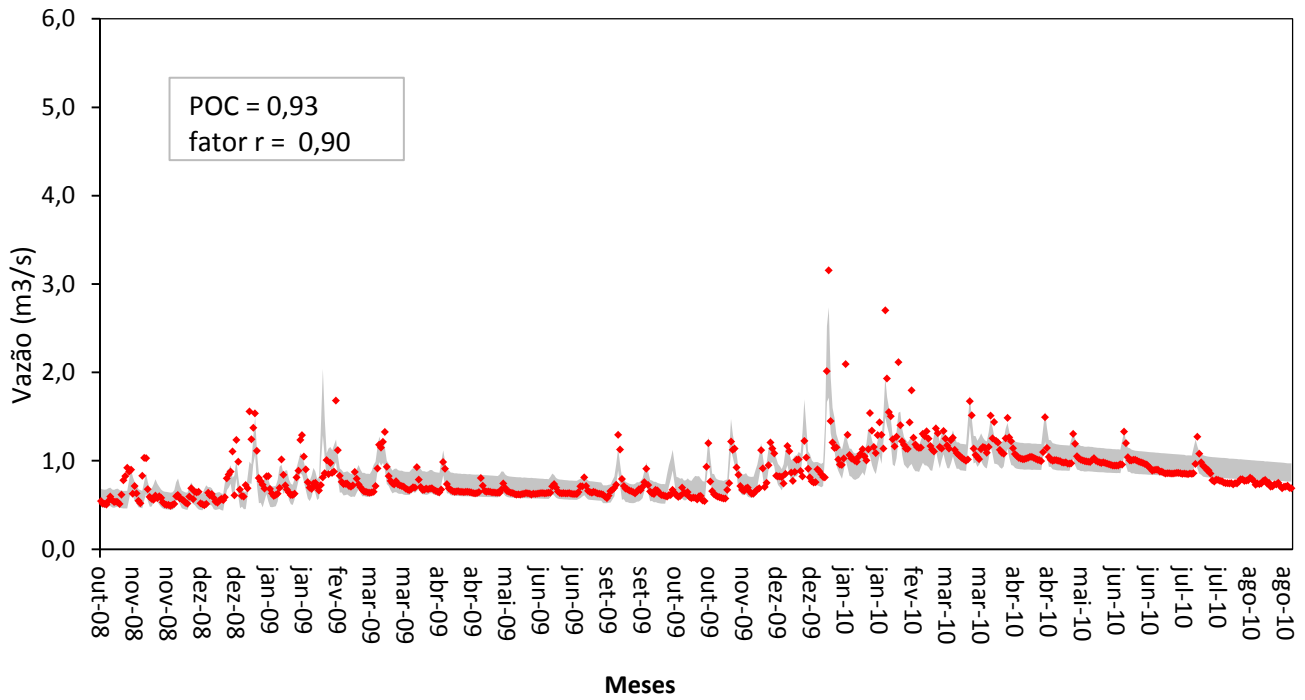
Série ANA - Calibração



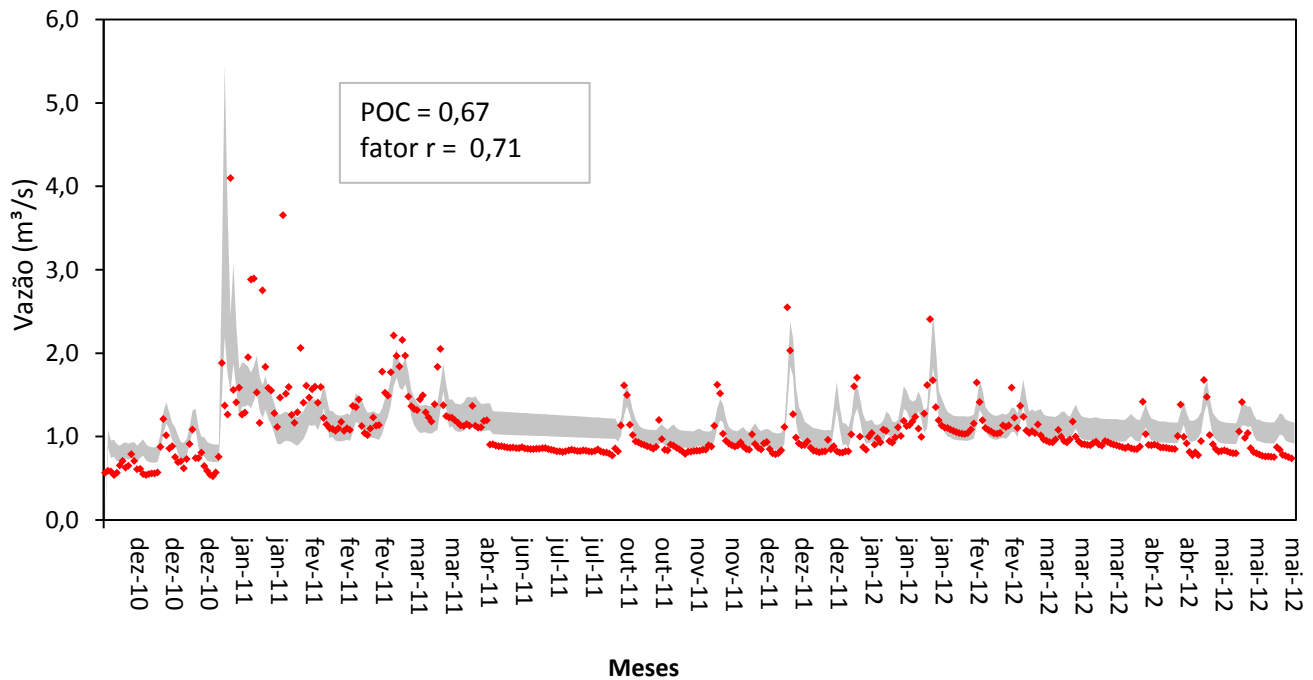
Série ANA - Validação




Série CRHEA - Calibração



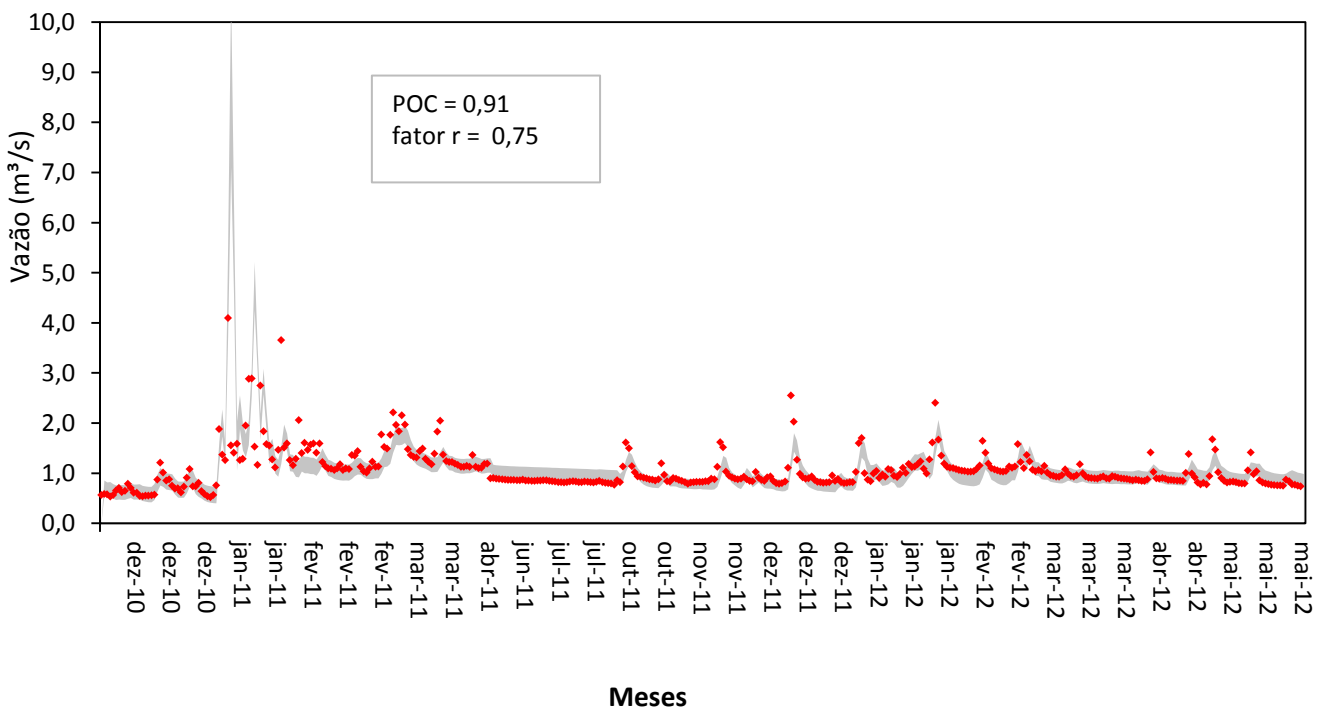
Série CRHEA - Validação




Série IDQ - Calibração



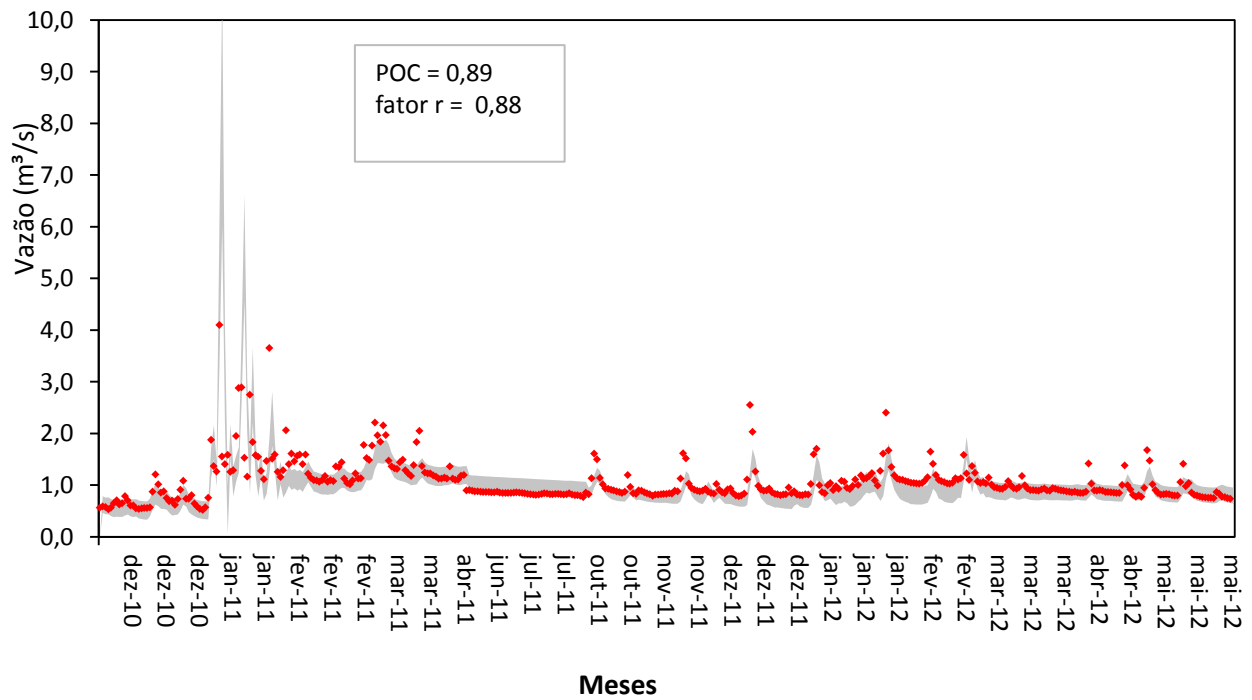
Série IDQ - Validação




Série THIESSEN - Calibração



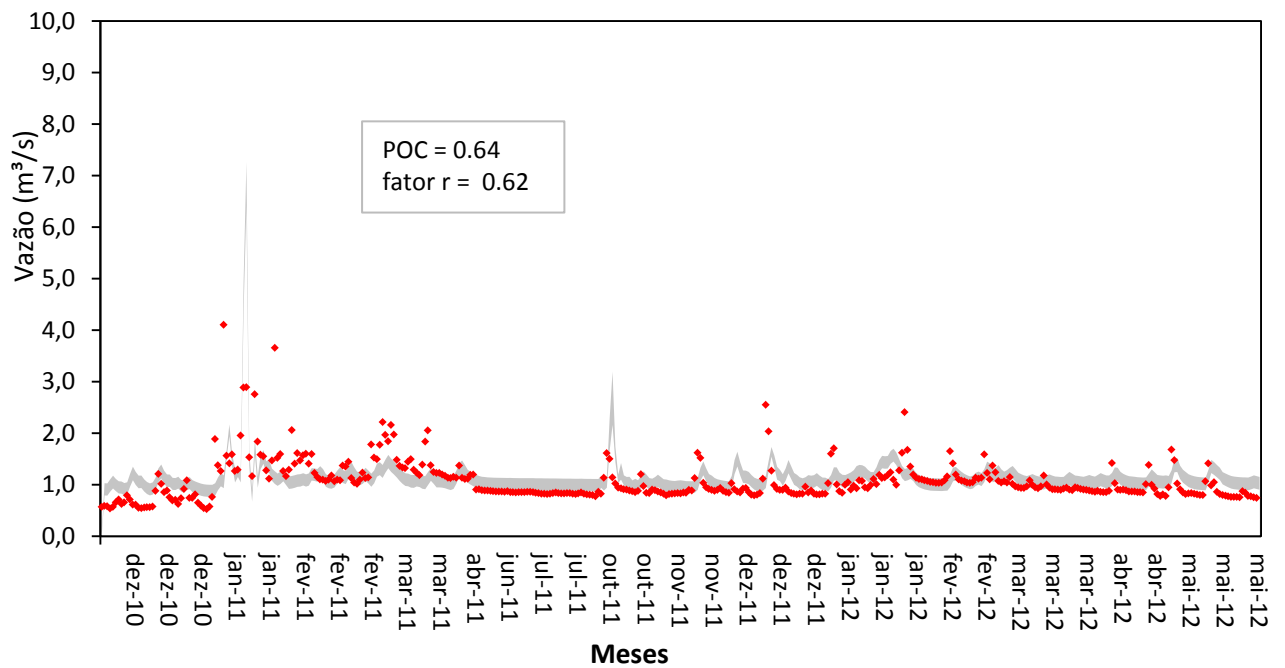
Série THIESSEN - Validação




Série TRMM - Calibração



Série TRMM - Validação



Série BMA - Calibração



Série BMA - Validação

