

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE PESQUISAS HIDRÁULICAS
PROGRAMA DE PÓS-GRADUAÇÃO EM RECURSOS HÍDRICOS E
SANEAMENTO AMBIENTAL

ALINE MEYER OLIVEIRA

CONTRIBUIÇÕES DE ESTIMATIVAS DE SENSORIAMENTO REMOTO PARA A
MODELAGEM DE MÚLTIPLAS VARIÁVEIS HIDROLÓGICAS

PORTO ALEGRE

2020

ALINE MEYER OLIVEIRA

CONTRIBUIÇÕES DE ESTIMATIVAS DE SENSORIAMENTO REMOTO PARA A
MODELAGEM DE MÚLTIPLAS VARIÁVEIS HIDROLÓGICAS

Dissertação apresentada ao Programa de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental da Universidade Federal do Rio Grande do Sul como requisito parcial à obtenção do grau de mestre.

Orientador: Prof. Dr. Rodrigo Cauduro Dias de Paiva

PORTO ALEGRE

2020

CIP - Catalogação na Publicação

Meyer Oliveira, Aline
CONTRIBUIÇÕES DE ESTIMATIVAS DE SENSORIAMENTO
REMOTO PARA A MODELAGEM DE MÚLTIPLAS VARIÁVEIS
HIDROLÓGICAS / Aline Meyer Oliveira. -- 2020.
137 f.
Orientador: Rodrigo Cauduro Dias de Paiva.

Dissertação (Mestrado) -- Universidade Federal do
Rio Grande do Sul, Instituto de Pesquisas Hidráulicas,
Programa de Pós-Graduação em Recursos Hídricos e
Saneamento Ambiental, Porto Alegre, BR-RS, 2020.

1. modelagem hidrológica. 2. sensoriamento remoto.
3. calibração. I. Cauduro Dias de Paiva, Rodrigo,
orient. II. Título.

Elaborada pelo Sistema de Geração Automática de Ficha Catalográfica da UFRGS com os dados fornecidos pelo(a) autor(a).

ALINE MEYER OLIVEIRA

CONTRIBUIÇÕES DE ESTIMATIVAS DE SENSORIAMENTO REMOTO PARA A
MODELAGEM DE MÚLTIPLAS VARIÁVEIS HIDROLÓGICAS

Dissertação apresentada ao Programa de Pós-Graduação em
Recursos Hídricos e Saneamento Ambiental da
Universidade Federal do Rio Grande do Sul como requisito
parcial à obtenção do grau de mestre.

Aprovado em: Porto Alegre, 3 de abril de 2020.

Prof. Dr. Rodrigo Cauduro Dias de Paiva - UFRGS

Orientador

Prof. Dr. Pedro Luiz Borges Chaffe - UFSC

Examinador

Prof. Dr. Juan Martin Bravo - UFRGS

Examinador

Prof. Dr. Anderson Ruhoff - UFRGS

Examinador

AGRADECIMENTOS

Agradeço ao Prof. Rodrigo Paiva e ao Ayan Fleischmann pela orientação, pelos ensinamentos científicos, pela confiança no meu trabalho e pelas excelentes discussões.

Aos colegas e professores do HGE pela amizade, por propiciarem um ambiente de trabalho agradável, pelas discussões nas nossas reuniões semanais (Iluminandos): Prof. Walter Collischonn, Prof. Fernando Fan, Alice, Ana Paula e Prof. Cristóvão (UFPR), Arthur, Camila, Cleber, Duda, Elisa, Gabriel, Germano, Gustavo, Hugo, João, Júlio, Larissa, Leo, Marcelle, Matheus, Mino, Otávio, Pedro, Rafael, Renata, Siqueira, Sofia, Thainá, Thais, Sly. Agradeço também por terem emprestado seus computadores para eu rodar algumas calibrações.

Aos colegas do IPH, pelos momentos de descontração nos vôleis, nos RUs, nos congressos, nos finais de semana.

Às minhas queridas amigas Cristiane Fragata, Mel Guirro, Natália Moraes, e ao meu namorado Luiz Aginsky, que me apoiaram com carinho e sabedoria quando compartilhei tanto momentos de êxito quanto de dificuldade durante o período do mestrado.

Aos meus pais Dulce e Fernando, aos meus irmãos Guilherme e Douglas (e Letícia), avós e outros familiares: pelo apoio incondicional a qualquer atividade que eu me proponho.

Pelo apoio financeiro, agradeço às instituições Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), Universidade Federal do Rio Grande do Sul (UFRGS), Instituto de Pesquisas Hidráulicas (IPH), Programa de Pós Graduação em Recursos Hídricos e Saneamento Ambiental (PPGRHSA), Agência Nacional de Águas (ANA), Institut de Recherche pour le Developpement (IRD) e European Geosciences Union (EGU).

À banca (Prof. Pedro Chaffe, Prof. Juan Martin Bravo e Prof. Anderson Ruhoff) e aos revisores anônimos da WRR, que aceitaram avaliar meu trabalho, e forneceram diversas ideias para sua melhoria.

Muito obrigada!

RESUMO

Modelos hidrológicos são ferramentas importantes para diversas aplicações: sistemas de previsão, gestão de recursos hídricos, avaliação de impactos de mudanças climáticas, entre outras. Em geral, a calibração dos parâmetros de modelos é realizada com observações de vazão. No entanto, conjuntos de parâmetros resultantes da calibração com apenas uma variável (e.g., vazão) podem comprometer a correta representação de outras variáveis do ciclo hidrológico, em função de compensações nos parâmetros, de forma que o modelo estaria “acertando pelos motivos errados”. Uma alternativa é a calibração com múltiplas variáveis estimadas por sensoriamento remoto (SR). Estudos anteriores demonstraram o potencial desta técnica para melhorar estimativas de vazão, mas não analisaram em muita profundidade as outras variáveis do ciclo hidrológico. Neste estudo, um modelo de base física (MGB) é calibrado através do algoritmo de otimização multi-objetivo (MOCOM-UA), com vazão, mas também com estimativas de sensoriamento remoto de níveis (Jason-2), áreas inundadas (ALOS-PALSAR), anomalias no armazenamento de água (TWS, GRACE), evapotranspiração (ET, MOD16) e umidade do solo (SMOS). O método é testado para uma área de estudo no rio Purus, na Amazônia, e então replicado de forma simplificada para outras 3 áreas de estudo no Brasil, representativas de diferentes regimes hidro-climáticos. Resultados indicam que em alguns casos a calibração com variáveis de SR melhorou estimativas de vazão, e que evapotranspiração foi a variável que ofereceu mais contribuições às estimativas de vazão. Para a estimativa de outras variáveis do ciclo hidrológico, em alguns casos a calibração com uma variável melhorou a estimativa de outras, mas nem sempre, indicando que observações apresentam incertezas, ou que a estruturação ou parametrização do modelo está incorreta. Dentre as quatro regiões de estudo, o modelo mais consistente (i.e., calibração com uma variável resulta em melhora das outras) é o do rio Piquiri, no bioma Mata Atlântica, seguido pela bacia do bioma amazônico (Purus), Cerrado (Araguaia) e Caatinga (Pardo). Em geral, o modelo convergiu para diferentes conjuntos de parâmetros, dependendo da variável de calibração. Isto salienta que, a depender da variável de calibração, o modelo “acerta por motivos diferentes”. A abordagem de utilizar diferentes variáveis estimadas por SR se mostrou útil para fortalecer uma modelagem mais realística de variáveis hidrológicas (além de vazão).

Palavras-chave: modelagem hidrológica; sensoriamento remoto; calibração.

ABSTRACT

Hydrological models are important tools for many applications: forecasting systems, water resources management, climate change impact evaluation, among others. Usually, calibration of parameters in hydrological models is performed with streamflow observations. However, resulting parameter sets based on only one variable (e.g., streamflow) might compromise the correct representation of other variables in the water cycle, because of compensations between parameters, in a way that the model might be “getting the right answers for the wrong reasons”. One alternative is to calibrate the model parameters with multiple remote sensing (RS)-derived variables. Previous studies demonstrated its potential to improve discharge estimates, but few studies analyzed deeply the impacts on other variables in the water cycle. In this study, a physically based model (MGB) is calibrated with the multi-objective algorithm MOCOM-UA with streamflow, but also with RS estimates of water level (Jason-2), flood extent (ALOS-PALSAR), total water storage anomalies (TWS, GRACE), evapotranspiration (ET, MOD16), and soil moisture (SMOS). The method is tested for a study area in Purus river basin, in Amazon, and then replicated in a simpler framework to other 3 study areas in Brazil, in differing representative hydro-climatic regimes. Results indicate that in some cases, RS-based calibration improved streamflow estimates, and the variable that contributed the most to streamflow estimates was ET. For the other water cycle variables, in some cases calibration with a variable improved estimate of other variables, but not always, which indicates that observations have uncertainties, or that the model structure or parametrization might be incorrect. Within the four study regions, the most consistent model (i.e., calibration with a variable improved other variables) was in the “*Mata Atlântica*” biome (Piquiri), followed by Amazonian Purus, “*Cerrado*” (Araguaia), and semi-arid basin Pardo. In general, the model converged to different parameter sets, depending on the calibration variable. This highlights that, depending on the calibration variable, the model might “get the right results for differing reasons”. The approach of using multiple RS-variables proved to be useful towards a more realistic modelling of hydrological variables (besides streamflow).

Keywords: hydrological modeling; remote sensing; calibration.

Sumário

CAPÍTULO 1. Introdução.....	11
1.1 Motivação	11
1.2 Objetivos.....	15
1.3 Organização do texto	15
CAPÍTULO 2. Fundamentos teóricos.....	16
2.1. Modelagem hidrológica	16
2.2. Calibração de modelos hidrológicos.....	18
2.3. Sensoriamento remoto aplicado à modelagem hidrológica	20
2.3.1. Precipitação	21
2.3.2. Umidade do solo.....	21
2.3.3. Evapotranspiração	22
2.3.4. Altimetria.....	23
2.3.5. Extensão de águas superficiais	23
2.3.6. Armazenamento de água terrestre (TWS)	24
CAPÍTULO 3. Contribuição de sensoriamento remoto para a calibração da modelagem de múltiplas variáveis hidrológicas.....	25
3.1 Introduction.....	27
3.1.1 Literature review on calibration of hydrological models with RS data....	29
Methods	32
3.2.....	32
3.2.1 Experimental design	32
3.2.2 Study area: Purus River Basin.....	33
3.2.3 Hydrological-hydrodynamic model: MGB	34
3.2.4 A priori uncertainty of model parameters.....	35
3.2.5 Sensitivity analysis	35

3.2.6	Model setup	36
3.2.7	Model calibration.....	37
3.2.8	Calibration/Evaluation Data	38
3.2.9	Model Outputs	40
3.3	Results and discussion	41
3.3.1	Sensitivity analysis	41
3.3.2	How do model uncertainties relate to uncertainties in observations?	42
3.3.3	Which sets of parameters are related to which variables?.....	42
3.3.4	Which variables are inter-related?.....	43
3.4	Model calibration	44
3.4.1	How RS-based model calibration improves discharge estimates?	44
3.4.2	How RS-based model calibration improves representation of the water cycle?	48
3.4.3	What is the added value of complementary RS observations?.....	50
3.5	Are we getting the right results for the right sets of parameters?.....	51
3.6	Spatial Evaluation	53
3.7	Conclusion	54

CAPÍTULO 4. Contribuição de sensoriamento remoto para a calibração da modelagem de múltiplas variáveis hidrológicas em diferentes condições hidro-climáticas

57

4.1	Introdução	58
4.2	Métodos.....	59
4.2.1	Desenho experimental	59
4.2.2	Áreas de estudo.....	61
4.2.3	O modelo MGB	64
4.2.4	Incerteza a priori dos parâmetros do modelo.....	65
4.2.5	Análise de sensibilidade	66
4.2.6	Calibração do modelo	66

4.2.7	Dados de entrada do modelo	67
4.2.8	Dados de calibração/avaliação e compatibilização com o MGB	69
4.2.9	Avaliação dos resultados	73
4.3	Resultados e discussão	74
4.3.1	Análise de sensibilidade	74
4.3.2	Calibração/Avaliação do modelo.....	76
4.3.3	O modelo está “acertando pelos motivos certos”?	81
4.4	Conclusões	83
CAPÍTULO 5. Considerações finais.....		85
Referências		87
ANEXO 1		106
ANEXO 2		127
ANEXO 3		129
ANEXO 4		130
ANEXO 5		132
ANEXO 6		134

CAPÍTULO 1. **Introdução**

1.1 Motivação

Modelagem hidrológica é uma importante ferramenta para complementar observações de variáveis hidrológicas, isto é, trata-se de uma forma de extrapolar informações no espaço (e.g., de bacias hidrográficas com monitoramento para bacias hidrográficas não monitoradas) e no tempo (e.g., estimar dados hidrológicos no futuro com base em dados medidos no presente), ou para testar hipóteses sobre processos hidrológicos.

Modelos hidrológicos têm sido utilizados com sucesso em: sistemas de previsão hidrológica (e.g., Chang et al., 2019; Fan et al., 2017), mapeamento de áreas com risco de inundação (e.g., Ahmadisharaf et al., 2018; Pappenberger et al., 2012), simulação da qualidade da água em corpos hídricos (e.g., Hongxing Liu et al., 2019; Quinn & Yang, 2019), simulação do impacto nos recursos hídricos de cenários de mudanças climáticas (e.g., Krysanova et al., 2018; Sorribas et al., 2016), ou de mudanças no uso e ocupação no solo (e.g., Bosmans et al., 2017; Guzha et al., 2018), como ferramenta de compreensão de processos hidrológicos (e.g., Beven, 2012; Kittel et al., 2018; Paiva et al., 2013), entre outros.

Mesmo que modificados e aprimorados continuamente, modelos hidrológicos estão sempre sujeitos a incertezas (e.g., Engeland et al., 2016; Teweldebrhan et al., 2018; Zhang et al., 2016). Causas para essas incertezas incluem a deficiente representação de processos físicos, a dificuldade de especificação de condições de contorno e condições iniciais, incertezas nas medições dos dados utilizados para calibração dos parâmetros do modelo (Beven, 2012), ou dificuldades na implementação de esquemas numéricos robustos (Clark & Kavetski, 2010).

Tradicionalmente, dados de vazão medidos em estações fluviométricas são utilizados para calibração de modelos. O processo de calibração está sujeito à equifinalidade de parâmetros, isto é, são muitas as combinações de conjuntos de parâmetros capazes de reproduzir o comportamento da variável observada, que é, em geral, a vazão, para modelos hidrológicos (Beven, 2006; Gupta et al., 1998). Em modelos de grande escala, existe um desafio ainda maior para a regionalização de parâmetros estimados localmente (Samaniego et al., 2017).

Conjuntos de parâmetros que visem acertar apenas uma variável (e.g., vazão) podem comprometer a correta representação de outras variáveis de saída do modelo, em função de compensações nos parâmetros (Alley, 1984), já que uma saída de água do modelo por evapotranspiração, por exemplo, pode ser erroneamente representada pela percolação para o aquífero.

Uma alternativa para tratar a equifinalidade de parâmetros em modelos hidrológicos, bem como para a correta representação de processos físicos em modelos hidrológicos, é apresentada já por Beven & Binley (1992), que apontam a existência de valor adicional na acurácia do modelo quando mais de uma variável é utilizada para calibração. No entanto, a principal limitação para esta prática é a escassez de monitoramento de outras variáveis além de vazão.

Missões de sensoriamento remoto têm se destacado por suas contribuições crescentes para o monitoramento contínuo e representativo de variáveis hidrológicas em grandes bacias. São vantagens e potencialidades sua larga cobertura espacial e temporal, contemplando variáveis hidrológicas como altimetria, umidade do solo, evapotranspiração, precipitação, anomalias no armazenamento de água terrestre e extensão de áreas inundadas (Lettenmaier et al., 2015). Este monitoramento remoto é especialmente relevante em regiões com escassez de observações in-situ, por isso é importante o desenvolvimento de estratégias de utilização das observações de sensoriamento remoto da forma mais eficiente possível (Sivapalan et al., 2003). No entanto, existem também limitações no uso do SR em modelos hidrológicos, em função das incertezas nas estimativas de algumas variáveis: por exemplo, em regiões de florestas, a densidade da vegetação pode comprometer estimativas de umidade do solo (Karthikeyan et al., 2017b); ou variações de níveis em rios na ordem de centímetros podem não ser representadas por missões de altimetria cuja incerteza é na ordem de centímetros também (Jarihani et al., 2013).

Observações de sensoriamento remoto vêm sendo utilizadas na modelagem hidrológica de grandes bacias de diversas formas:

- (1) dados de entrada, como por exemplo precipitação estimada por SR como forçante de modelos hidrológicos (e.g., B. Collischonn et al., 2008; Guetter et al., 1996).
- (2) validação de modelos, em que variáveis de saída do modelo (e.g., evapotranspiração, níveis d'água) são comparadas as suas estimativas por SR (e.g., Kittel et al., 2018; Paiva et al., 2013; Siqueira et al., 2018).

- (3) calibração de modelos, em que variáveis de saída do modelo são comparadas a variáveis estimadas por SR, implicando em um processo iterativo de atualização dos parâmetros do modelo buscando minimizar as diferenças entre variáveis simuladas e estimadas por SR. São exemplos os trabalhos de López et al. (2017) e Odusanya et al. (2019) (variável de calibração: evapotranspiração), ou os trabalhos de Wambura et al. (2018) e de Li et al. (2018) (variável de calibração: umidade do solo). Outros trabalhos, que fazem uso de outras variáveis de calibração (e.g., Dembélé et al., 2020; Nijzink et al., 2018; W. Sun et al., 2012; Zink et al., 2018) são revisitados em detalhe na Revisão Bibliográfica (Capítulo 3, sub-item 3.1.1: Literature review on calibration of hydrological models with RS data).
- (4) assimilação de dados, em que variáveis de saída do modelo são atualizadas de acordo com as suas estimativas por SR, porém não são ajustados os parâmetros do modelo (e.g., Wongchuig et al., 2019).

O presente estudo se propõe a focar em (2) e (3), i.e., na utilização de variáveis estimadas por SR para a calibração e validação de modelos. Na Revisão Bibliográfica (ANEXO 1), foram elencados 64 estudos que se utilizam de observações de sensoriamento remoto para calibração e validação de modelos hidrológicos, sendo que a maioria dos estudos é dos últimos anos, o que evidencia que se trata de um assunto no estado-da-arte da pesquisa em ciências hidrológicas.

Todos os estudos prévios elencados concluem que existe potencial a ser explorado na utilização de observações de SR para calibração de modelos hidrológicos, tanto para identificar erros na estrutura dos modelos, diminuir equifinalidade de parâmetros, melhorar a representação dos processos físicos no modelo, ou para estimativa de variáveis hidrológicas em regiões com pouco monitoramento in-situ. No entanto, a maioria dos estudos tem caráter de “prova de conceito”, e apresentam algumas limitações: são poucos os estudos que avaliam a calibração de modelos com observações de SR em áreas de estudo na América do Sul; a maioria dos estudos não utiliza de modelos de base física, que são capazes de simular a dinâmica hidráulica dos rios, por exemplo, dificultando comparação direta de variáveis como níveis d’água e áreas inundadas; em geral, o número de variáveis utilizadas para calibração ainda é limitado, com a maioria dos estudos abrangendo apenas duas variáveis. Além disso, a maioria dos resultados desses estudos focam na melhoria na estimativa da vazão, mas poucos avaliam o impacto do uso de variáveis estimadas por sensoriamento remoto na representação de outras variáveis.

O presente estudo se insere ainda no contexto da pergunta 20 dos 23 problemas não-solucionados na Hidrologia (Blöschl et al, 2019): “Como podemos desembaralhar e reduzir incertezas estruturais, na parametrização e nos dados de entrada nas previsões de modelos hidrológicos?” (tradução livre).

Neste estudo, propõe-se uma abordagem compreensiva sobre a contribuição de variáveis estimadas por sensoriamento remoto para a calibração e avaliação de modelos. São consideradas simultaneamente um número abrangente de variáveis hidrológicas (vazão, altimetria, anomalias no armazenamento terrestre, evapotranspiração, extensão de áreas inundadas, umidade do solo e evapotranspiração). São utilizados produtos de sensoriamento remoto, que, embora seja uma tecnologia sofisticada, são disponibilizados de forma pós-processada e gratuita pelas agências espaciais. São estudadas áreas da América do Sul (o que engloba grande variabilidade hidro-climática, que é relevante dado que o valor adicional das variáveis estimadas por SR podem ter impactos diferenciados dependendo de características hidro-climáticas regionais). Um modelo hidrológico-hidrodinâmico fortemente acoplado é utilizado. Ainda, objetiva-se ir além de interpretar a modelagem hidrológica como uma ferramenta para gerar dados de vazão, mas sim encará-la como uma ferramenta para compreensão dos diferentes compartimentos, fluxos e variáveis do ciclo hidrológico.

1.2 Objetivos

Objetivo geral

Avaliar o uso de múltiplas variáveis estimadas por sensoriamento remoto para a calibração e avaliação de modelos hidrológicos.

Objetivos específicos

- Avaliar sensibilidade entre variáveis e parâmetros em um modelo hidrológico de base física;
- Avaliar (do ponto de vista de múltiplas variáveis) o desempenho da calibração do modelo hidrológico-hidrodinâmico com variáveis estimadas por SR;
- Verificar se o método proposto se aplica (e com qual performance?) para diferentes condições hidro-climáticas;
- Verificar se a calibração com diferentes variáveis conduz aos mesmos conjuntos de parâmetros.

1.3 Organização do texto

No Capítulo 2, é apresentada uma revisão bibliográfica sobre modelagem hidrológica-hidrodinâmica, sensoriamento remoto aplicado ao ciclo hidrológico e calibração de modelos hidrológicos. No Capítulo 3, é apresentado um artigo intitulado “On the contribution of remote sensing-based calibration to model multiple hydrological variables” submetido ao periódico *Water Resources Research*, em que se apresenta uma revisão sistemática do tema e a metodologia de calibração proposta é aplicada para uma área de estudo (bacia hidrográfica do rio Purus, na Amazônia). No Capítulo 4, é apresentado um artigo em que a proposta de calibração é replicada para outras 3 bacias hidrográficas em diferentes regimes hidro-climáticos na América do Sul. O Capítulo 5 apresenta as conclusões gerais, sugestões para trabalhos futuros e perspectivas.

CAPÍTULO 2. Fundamentos teóricos

2.1. Modelagem hidrológica

A modelagem hidrológica consiste na representação matemática do ciclo hidrológico. Segundo Freeze & Harlan (1969), modelos hidrológicos têm finalidade de estudar eventos hidrológicos passados, prever eventos hidrológicos futuros, avaliar efeitos antrópicos no regime hidrológico, e fornecer ferramentas para a compreensão de processos hidrológicos.

Esforços em modelar matematicamente o ciclo hidrológico datam de 1850, com o método racional proposto por Mulvany, passando pelo hidrograma unitário de Sherman na década de 30, por modelos conceituais que representam compartimentos do ciclo hidrológico na década de 60, chegando até o estado-da-arte em modelagem hidrológica, com os modelos distribuídos de base física (Todini, 2007), ou mesmo com os modelos empíricos robustos que utilizam técnicas como redes neurais artificiais.

Modelos hidrológicos podem ser classificados entre concentrados ou distribuídos; determinísticos ou estocásticos; estáticos ou dinâmicos; e, principalmente, podem ser empíricos, conceituais ou de base física. Além disso, também podem ser classificados de acordo com o processo ao qual é dada ênfase (e.g., modelos de água subterrânea, modelos de reservatórios, modelos de superfície, modelos hidrodinâmicos de rios); de acordo com a escala aos quais se aplicam; ou também podem ser classificados como modelos de eventos ou modelos de séries contínuas (Tucci, 1998; Beven, 2012; Devi et al., 2015).

Nesse contexto, *modelos hidrológicos de grande escala* abrangem regiões da ordem de dezenas a centenas de milhares de quilômetros quadrados (da Paz et al., 2011). *Modelos concentrados* não consideram a variabilidade espacial na bacia hidrográfica, ao passo que em *modelos distribuídos* a bacia hidrográfica é subdividida em unidades menores, o que proporciona variabilidade espacial de entradas, saídas e parâmetros do modelo. *Modelos determinísticos* apresentam as mesmas saídas para um determinado conjunto de dados de entrada, enquanto *modelos estocásticos* podem gerar diferentes saídas para um mesmo conjunto de dados de entrada. Entre estáticos ou dinâmicos, os modelos são classificados se consideram a mudança das variáveis no tempo (dinâmicos) ou não (modelos estáticos).

Modelos empíricos baseiam-se apenas em equações matemáticas para derivar as saídas do modelo a partir de um conjunto de dados de entrada, desconsiderando quaisquer

processos físicos ocorrentes na bacia hidrográfica, como por exemplo, redes neurais artificiais (Hsu et al., 1995). *Modelos conceituais* são baseados em conceitos físicos simplificados, regidos por equações semi-empíricas, com parâmetros estimados através de dados empíricos e de calibração. Exemplos incluem o Stanford Watershed Model IV (Crawford & Linsley, 1966), Soil Conservation Service (SCS) e Sacramento (Burnash et al., 1973).

Modelos de base física são aqueles que buscam adotar variáveis de estado que representem de forma fiel os processos físicos ocorrentes na bacia hidrográfica. Apesar de representarem de forma mais realística os processos hidrológicos, modelos de base física apresentam a limitação de necessitarem a especificação de um maior número de dados de entrada. São exemplos os modelos SHE (Abbott et al., 1986), TOPKAPI (Ciarapica & Todini, 2002), LISFLOOD (P. D. Bates & De Roo, 2000) e MGB (W. Collischonn et al., 2007).

Modelos hidrológicos geralmente possuem um módulo de propagação de vazões, que visa transportar o escoamento gerado ao longo da rede de drenagem. Alguns métodos de propagação são bastante simples, enquanto outros consideram equações de base física, como as equações 1D de Saint Venant para escoamento em canais (Equações (2-1) e (2-2)).

$$\frac{\partial A}{\partial t} + \frac{\partial Q}{\partial x} = q \quad (2-1)$$

$$\frac{\partial Q}{\partial t} + \frac{\partial}{\partial x} \left(\frac{Q^2}{A} \right) + gA \frac{\partial h}{\partial x} = gA(S_0 - S_t) \quad (2-2)$$

em que A é a área molhada da seção transversal do rio [m^2], t é o tempo [s], Q é a vazão [$\text{m}^3 \cdot \text{s}^{-1}$], x é a distância no sentido longitudinal do rio [m], q é a contribuição lateral [$\text{m}^2 \cdot \text{s}^{-1}$], g é a aceleração da gravidade [$\text{m} \cdot \text{s}^{-2}$], h é a profundidade da água no rio [m] e S_0 e S_t são as declividades do fundo do rio e da linha de energia, respectivamente [$\text{m} \cdot \text{m}^{-1}$].

A fim de diminuir o custo computacional de simulação, existem diversas simplificações das equações de Saint-Venant para a propagação do escoamento em rios, como por exemplo, o método de Muskingum-Cunge, método da Onda Cinemática (Fread, 1993), ou o recente modelo inercial, que é uma aproximação das equações de Saint-Venant, mas que despreza apenas o termo de inércia advectiva na equação dinâmica

(Bates et al., 2010), sendo portanto uma abordagem eficiente muito próxima da representação hidrodinâmica completa, porém com um custo computacional menor.

Alguns modelos hidrodinâmicos de base física que se destacam são LISFLOOD-FP (Bates & De Roo, 2000), CAMA-FLOOD (Yamazaki et al., 2011) e MGB (W. Collischonn et al., 2007).

2.2. Calibração de modelos hidrológicos

A calibração de parâmetros de um modelo visa que os valores das variáveis de saída do modelo sejam semelhantes aos valores dessas variáveis provenientes de medições na natureza, conforme representado esquematicamente na Figura 2-1. Em geral, na modelagem hidrológica, esta variável utilizada para a calibração dos parâmetros é a vazão (Hunger & Döll, 2008).

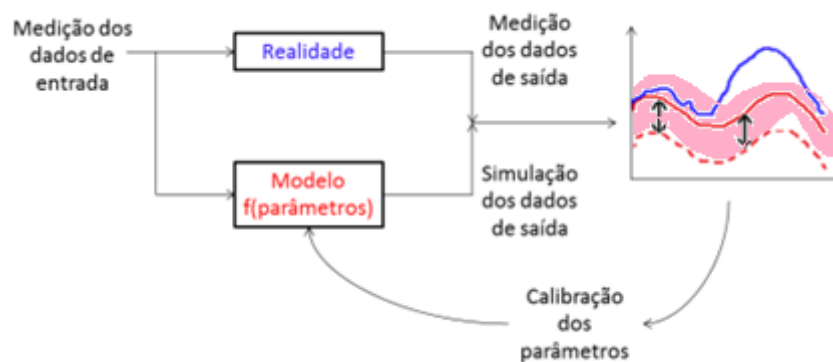


Figura 2-1. Representação esquemática da modelagem hidrológica, em que um modelo objetiva representar a realidade de um sistema, e a calibração dos parâmetros do modelo é realizada através da comparação entre as saídas do modelo e medições da natureza, a fim de reduzir a diferença entre essas séries (observada e simulada).

A calibração de modelos pode ser realizada de forma *manual* ou *automática*. A forma *manual* consiste no método de “tentativa e erro”, em que as séries históricas de vazões simuladas e observadas são comparadas, de forma que se altera os parâmetros conforme seu conhecimento do modelo, a fim de que as vazões simuladas reproduzam o comportamento das vazões observadas. Por outro lado, a *calibração automática* consiste na repetição de “tentativa e erro” em um número maior de vezes, porém não existe inspeção visual das séries históricas, de forma que o modelo é calibrado de acordo com métricas que avaliem a performance do modelo, que no contexto de calibração automática, são chamadas de “funções-objetivo”.

Exemplos de função-objetivo são a raiz do erro quadrático médio (RMSE), coeficiente de Nash-Sutcliffe (NSE, Nash & Sutcliffe, 1970), coeficiente de Kling-Gupta (KGE, Gupta et al., 2009), entre outros (Ferreira, 2017).

Para a calibração automática, existem métodos *mono-objetivo* ou *multi-objetivo*. Enquanto a calibração *mono-objetivo* procura um conjunto de parâmetros que otimizem uma função objetivo apenas, a calibração *multi-objetivo* procura vários conjuntos de parâmetros que otimizem duas ou mais funções-objetivo simultaneamente. Enquanto o método *mono-objetivo* fornece apenas uma resposta para o problema de otimização, o método *multi-objetivo* fornece diversas respostas igualmente ótimas, que constituem a chamada curva de Pareto, apresentada na Figura 2-2 (Madsen, 2000).




Figura 2-2. Representação gráfica da curva de Pareto. À esquerda, a região $S \subset \mathbb{R}^3$. À direita, sua imagem $z \subset \mathbb{R}^2$, em que a curva de Pareto (conjunto de soluções ótimas do sistema) aparece em negrito. O vetor z^* é um exemplo de uma das soluções ótimas do sistema. Fonte: Miettinen, 1999.

Gupta et al. (1998) e Yapo et al. (1998) apontam que experiências passadas revelam que a calibração *mono-objetivo* é insuficiente em representar corretamente as características dos dados observados. Por outro lado, a calibração *multi-objetivo*, mesmo que se utilize de funções-objetivo relacionadas a diferentes aspectos do hidrograma apenas (e.g., vazões médias, vazões mínimas, curva de permanência), resulta em melhores métricas de desempenho. A calibração *multi-objetivo* que considere ainda diferentes variáveis do modelo (e.g., vazão, evapotranspiração, umidade do solo) apresenta ainda melhores resultados. No entanto, essa abordagem é limitada pela disponibilidade e qualidade de dados observados dessas variáveis.

O processo de otimização de uma ou mais funções-objetivo pode ser realizado através de algoritmos de *busca local* ou de *busca global*, sendo que apenas os métodos de busca global são capazes de contornar ótimo locais. Exemplos de algoritmos mais simples de busca global são “busca exaustiva”, e de busca aleatória uniforme, e de busca local são o método univariacional e o Simplex (Nelder & Mead, 1965).

Existem também *algoritmos evolucionários*, que buscam ótimos das funções-objetivo com base em mecanismos de evolução de populações de seres vivos, como por exemplo o SCE-UA (mono-objetivo, apresentado por (Duan et al., 1992), ou os algoritmos multi-objetivo MOCOM-UA (Yapo et al., 1998), MOSCEM-UA (Vrugt et al., 2003) e NSGA-II (Deb et al., 2002).

Alternativamente, existem processos de calibração baseados em múltiplas simulações com diferentes conjuntos de parâmetros, especificados a priori a partir de valores aleatórios derivados de distribuições de probabilidades específicas. Um exemplo é o método GLUE (Beven & Binley, 1992), que é similar ao método de busca aleatória uniforme.

Embora os algoritmos de otimização tenham sido aprimorados ao longo dos anos, a calibração dos parâmetros ainda é fortemente limitada pela disponibilidade de dados observados: medições in-situ, embora acuradas, são escassas e pontuais para os locais de amostra. Nesse sentido, o sensoriamento remoto vem se destacando por apresentar um monitoramento contínuo e representativo de variáveis hidrológicas em grandes bacias.

2.3. Sensoriamento remoto aplicado à modelagem hidrológica

Sensoriamento remoto é “a medição ou aquisição de informações sobre alguma propriedade de algum objeto ou fenômeno, através de um instrumento que não está em contato físico ou próximo com o objeto ou fenômeno em estudo” (Colwell, 1983). Em geral, as informações são obtidas através da interação da radiação eletromagnética com um alvo, a um dado comprimento de onda (Lillesand & Kiefer, 1994).

A partir da década de 1990, com o advento do programa *Earth Observing System* (EOS), pela NASA, estão disponíveis à comunidade científica produtos de sensoriamento remoto de diversas variáveis ambientais (Purkis & Klemas, 2013).

O uso de sensoriamento remoto na hidrologia representa um importante avanço na compreensão científica de processos e variáveis hidrológicas, pois as abordagens dos estudos passaram de uma escala experimental para uma escala regional a global (Lettenmaier et al., 2015). Algumas das variáveis do ciclo hidrológico que apresentam monitoramento por sensoriamento remoto são precipitação, umidade do solo, evapotranspiração, anomalias no armazenamento de água, altimetria, vazão, extensão de corpos hídricos (Tang et al., 2009).

Nos parágrafos seguintes, são apresentados de forma breve os princípios físicos das observações de sensoriamento remoto de variáveis hidrológicas, exemplos de missões, e aplicações em modelagem hidrológica.

2.3.1. Precipitação

A precipitação é uma variável muito importante na modelagem hidrológica, pois trata-se da principal forçante do ciclo hidrológico terrestre. Seu monitoramento por sensoriamento remoto apresenta cobertura quase global, o que é relevante principalmente pois a distribuição de estações pluviométricas (in-situ) no globo é bastante desigual, sendo mais concentrada em países desenvolvidos (Huffman et al., 1997).

Existem sensores de precipitação nas faixas do visível, infra-vermelho e micro-ondas passivo, além do radar. Estimativas nas faixas do visível e infra-vermelho a bordo de satélites geostacionários são menos acuradas, mas possuem maior resolução espacial e temporal. Estimativas de micro-ondas passivo são mais acuradas, mas com menor resolução espaço-temporal. Medições de radar são mais acuradas, mas possuem menor abrangência espacial. Na prática, são disponibilizados produtos de precipitação que combinam observações de múltiplas missões e sensores de SR, observações in-situ e dados de reanálise, como por exemplo TRMM-TMPA, GPM e MSWEP. Kidd & Huffman (2011) apresentam uma revisão em detalhe sobre o sensoriamento remoto da precipitação.

Na modelagem hidrológica, produtos de SR de precipitação vem sendo usados como dados de entrada (e.g., B. Collischonn et al., 2008; Guetter et al., 1996; López et al., 2017), principalmente em regiões com baixo monitoramento in-situ.

2.3.2. Umidade do solo

O sensoriamento remoto de umidade do solo é realizado através de radiômetros (sensores passivos), que captam a radiação emitida na faixa do micro-ondas permitindo estimativa da temperatura de brilho; ou de sensores ativos/radares, que registram coeficiente de retroespalhamento. Essas informações são então relacionadas a estimativas de constante dielétrica do solo, que é muito sensível à presença de água, o que permite estimativas da umidade do solo (Karthikeyan et al., 2017a; Lettenmaier et al., 2015)

Limitações do sensoriamento remoto da umidade do solo estão associadas à profundidade de penetração do sinal, de forma que o produto final representa a umidade da camada superficial do solo apenas, e podem existir erros nas estimativas devido a

interferências da vegetação. Existem estudos que analisam alternativas para a extrapolação dos dados de SR da umidade do solo para toda a coluna de solo, como por exemplo o filtro temporal desenvolvido com base na equação de Richards proposto por (Albergel et al., 2008).

Karthikeyan et al. (2017a) apresenta uma revisão bibliográfica completa sobre o desenvolvimento do sensoriamento remoto (ativo e passivo) da umidade do solo, bem como análises comparativas entre 10 produtos disponíveis de umidade do solo, com resultados que apontam boas perspectivas para a utilização dos produtos SMOS (Soil Moisture Ocean Salinity) e SMAP (Soil Moisture Active Passive).

Na modelagem hidrológica, produtos de umidade do solo podem ser úteis para informar dados de entrada (e.g., Parrens et al., 2017), validação e calibração de modelos hidrológicos (e.g., Kundu et al., 2017; Li et al., 2018) ou assimilação de dados (e.g., Hirpa et al., 2014; Wanders et al., 2014).

2.3.3. Evapotranspiração

O sensoriamento remoto da evapotranspiração pode ser realizado por balanço de energia, a partir do monitoramento da temperatura de superfície (e.g., SEBAL, SEBS, ALEXI, METRIC); por equações de base física, adaptadas para o uso com índices de vegetação, como por exemplo NDVI ou LAI (e.g., MOD-16, GLEAM); e por modelos empíricos e/ou estatísticos, que se adequam a escalas locais e/ou regionais (Biggs et al., 2015).

Por se tratar de uma variável diretamente relacionada ao balanço de energia, a evapotranspiração estimada por SR tem sido muito utilizada em modelos hidrológicos, tanto para informar dados de entrada (e.g., Mendiguren et al., 2017; Stisen et al., 2008), para calibração (e.g., Kunnath-Poovakka et al., 2016; Vervoort et al., 2014) e validação (e.g., Ruhoff et al., 2013) de modelos, e para assimilação de dados (e.g., Dong et al., 2016).

Alguns autores descrevem a validação de produtos de sensoriamento remoto de evapotranspiração (Ruhoff et al., 2013; Saleska et al., 2013), bem como sua aplicação para compreensão do processo de evapotranspiração (Fisher et al., 2008, 2017), na agricultura (Anderson et al., 2016), e na validação de modelos hidrológicos (Chen et al., 2005; Ruhoff et al., 2013).

2.3.4. Altimetria

O nível d'água é uma variável hidrológica muito importante, pois pode ser relacionado com a vazão através de curvas-chave. No entanto, o monitoramento in-situ dos níveis nos rios é insuficiente (Pavelsky, 2014). Por outro lado, dados de altimetria de SR apresentam larga cobertura espacial, pois toda intersecção de um rio com a passagem de um satélite torna-se uma “estação virtual”, local em que é possível a obtenção de séries temporais das variações dos níveis d'água.

O sensoriamento remoto de altimetria ocorre através da emissão de um pulso à nadir (na faixa do visível, LiDAR; ou na faixa das micro-ondas, radar), que interage com o alvo e é então registrado o tempo de resposta. Com as informações de tempo de resposta e velocidade, é possível estimar a distância do sensor ao alvo. Limitações do sensoriamento remoto de altimetria envolvem a possível interferência de nuvens no caso do LiDAR, ou medições menos acuradas no caso do radar. Além disso, é necessário que os rios monitorados sejam largos o suficiente para captarem o sinal, e os dados necessitam de pós-processamento a fim de eliminar ruídos e captar apenas o sinal do dado bruto associado ao nível d'água (Calmant & Seyler, 2006).

Exemplos de missões de SR de altimetria por radar são o Envisat ou o Jason-2, que apresentam o *trade-off* de que o Envisat apresenta frequência temporal de 35 dias, enquanto o Jason-2 repete o ciclo a cada 10 dias. No entanto, a distância entre os traços do Envisat (~80km) é menor do que o Jason-2 (315km), o que permite que existam mais estações virtuais do Envisat. Em termos de acurácia da medição, esses dois produtos são equiparáveis, na ordem de 0.28m (Jarihani et al., 2013).

Observações de altimetria por SR são utilizadas em modelos hidrológicos para sua validação (e.g., Siqueira et al., 2018), calibração (e.g., Getirana et al., 2010; Sun et al., 2012) e assimilação de dados (e.g., Paiva et al., 2013; Santos da Silva et al., 2010).

2.3.5. Extensão de águas superficiais

A extensão de corpos d'água pode ser monitorada através de sensores tradicionais como Landsat, MODIS ou Sentinel, que monitoram a reflectância da superfície (bandas do infra-vermelho e do visível), ou através de sensores que operam na faixa das micro-ondas, que monitoram temperatura de brilho (radiômetros, passivos) ou índice de retroespalhamento da superfície, isto é, radares, chamados de sensores ativos (Schumann et al., 2015).

O uso dos produtos de sensoriamento remoto para detecção da extensão de águas superficiais requer, em geral, etapas de processamento e classificação dos dados, para correções do relevo, ou remoção de ruídos através de aplicação de filtros, por exemplo. Existem autores que disponibilizam bases de dados de áreas inundadas (e.g., Chapman et al., 2015; Hess et al., 2003; Pekel et al., 2016).

Observações de SR de extensão de águas superficiais podem ser utilizados para validação (e.g., Paiva et al., 2011; 2013) ou calibração de modelos hidrológicos (e.g., G. Liu et al., 2015; Mason et al., 2009).

2.3.6. Armazenamento de água terrestre (TWS)

As variações de armazenamento de água em uma bacia hidrográfica ocorrem em função do desequilíbrio entre entradas (e.g., precipitação) e saídas (e.g., evapotranspiração) do sistema. A água armazenada numa bacia pode estar no solo, nos aquíferos, no gelo, ou superficialmente (em rios e lagos, por exemplo).

Embora as variações no armazenamento de água terrestre não seja uma variável hidrológica convencional (como, por exemplo, vazão ou nível), ela vem se tornando interessante com o advento da missão GRACE (“Gravity Recovery and Climate Experiment”), que permite a derivação de estimativas de anomalias no armazenamento de água a partir das medições do potencial gravitacional terrestre. Esta missão foi lançada em 2002, e consiste em dois satélites que orbitam a superfície terrestre, identificando as variações do potencial gravitacional com resolução temporal de aproximadamente 30 dias (Swenson & Wahr, 2006).

Em modelagem hidrológica, observações da missão GRACE podem ser utilizadas para validação ou calibração (e.g., Werth & Güntner, 2010); e assimilação de dados (e.g., Tangdamrongsub et al., 2015) em modelos.

CAPÍTULO 3. **Contribuição de sensoriamento remoto para a calibração da modelagem de múltiplas variáveis hidrológicas**

O artigo apresentado neste capítulo foi submetido à Water Resources Research em janeiro de 2020.

On the contribution of remote sensing-based calibration to model multiple hydrological variables

A. M. Oliveira¹, A. S. Fleischmann¹, and R. C. D. Paiva¹

¹ Instituto de Pesquisas Hidráulicas (IPH), Universidade Federal do Rio Grande do Sul – UFRGS, Av. Bento Gonçalves, 9500, Porto Alegre 90050-260, RS, Brazil.

Corresponding author: Aline Meyer Oliveira (alinemey@gmail.com)

Key Points:

- Calibration/evaluation of a hydrological-hydrodynamic model with five remote sensing-based water cycle variables in a tropical region
- Different calibration strategies with remotely-sensed observations were able to improve water cycle representation
- Model calibration with multiple remotely sensed variables highlighted deficiencies in model structure and parameterization, and observations.

Abstract

The accuracy of hydrological model predictions is limited by uncertainties in model structure and parameterization, and observations used for calibration, validation and model forcing. Conventionally, calibration is performed with discharge estimates. However, the internal processes in the model might be misrepresented, i.e., the model might be getting the “right results for the wrong reasons”, which compromises model reliability. An alternative is to calibrate the model parameters with remote sensing (RS) observations of the water cycle. Previous studies highlighted the potential of RS-based calibration to improve discharge estimates, but put much less effort on investigating other variables of the water cycle. In this study, we analyzed in detail the contribution of five

different RS-based variables (water level (h) from Jason-2, flood extent (A) from ALOS-PALSAR, terrestrial water storage (TWS) anomalies from GRACE, evapotranspiration (ET) from MOD16 and soil moisture (W) from SMOS) to calibrate a hydrological-hydrodynamic model for a tropical study region with floodplains in the Amazon basin. Single-variable calibration experiments with all variables were able to improve discharge from around 6.1% to 52.9% KGE improvement compared to the a priori parameter sets. Multi-variable calibration experiments (all except Q ; $h+W$) resulted in around 1.7% to 59.9% KGE improvement for discharge estimates. Water cycle representation was also improved (e.g., calibration with h improved not only h estimates but also A , TWS and ET). By looking at multiple RS observations of the water cycle, we were able to find inconsistencies in model structure and parameterization, which would remain unknown if only discharge observations were considered.

Plain Language Summary

Hydrological models are important tools for many applications in water resources, such as natural hazards management, quantification of impacts of climate change or anthropogenic effects on the water cycle. However, there are uncertainties in these models, which might lead to inaccurate predictions. In many cases, they are related to calibrating parameters of the model by comparing in-situ streamflow observations with modeled streamflow estimates. Therefore, internal processes in the model might be misrepresented, i.e., the model might be getting the “right results for the wrong reasons”, which compromises model reliability and its estimates. An alternative is to calibrate the model parameters with remote sensing (RS) observations of the water cycle. In this study, we analyzed the contribution of five different RS-derived variables (water level, flood extent, anomalies in total terrestrial water storage, evapotranspiration, and soil moisture) to calibrate model parameters. We found that RS-based calibration was able to improve water cycle representation (e.g., calibration with water level was able to improve estimates of water level itself, but also flood extent, terrestrial water storage and evapotranspiration). Moreover, by looking at multiple RS observations of the water cycle, we were able to found inconsistencies in model structure and parameterization, which would remain unknown if only discharge observations were considered.

3.1 Introduction

The accurate representation of hydrologic processes in mathematical models remains a key challenge in water resources research and applications (Baroni et al., 2019; Clark et al., 2015; Kirchner, 2006; Nearing et al., 2016; Semanova & Beven, 2015) due to uncertainties in model structure (Wagener et al., 2003), parameterization (Gharari et al., 2014; Shafii & Tolson, 2015), and observations (Di Baldassarre & Montanari, 2009). These uncertainties might lead to inaccurate predictions of hydrological variables for many applications: water resources and natural hazards management (Grimaldi et al., 2019; Montanari & Koutsoyiannis, 2014), quantification of impacts of climate change and anthropogenic effects on the water cycle (Haddeland et al., 2006; Teutschbein & Seibert, 2012; C. Y. Xu et al., 2005).

Traditionally, hydrological models are calibrated against gauged streamflow data, which might hamper predictions in ungauged sites, and does not provide an accurate representation of internal model processes (Hrachowitz et al., 2013). Several solutions have been proposed to improve process representation and reduce uncertainty in model predictions, such as the generalized likelihood uncertainty estimation (Beven & Binley, 1992), dynamic identifiability analysis (Wagener et al., 2003), multiscale parameter regionalization (Samaniego et al., 2010), and multi-objective calibration (Yapo et al., 1998). Another alternative is the use of complementary datasets in addition to streamflow observations for model calibration (e.g., Crow et al., 2003; Franks et al., 1998; Lo et al., 2010; López et al., 2017; Rajib et al., 2016), data assimilation (e.g., Brêda et al., 2019; Houser et al., 1998; Mitchell et al., 2004; Paiva et al., 2013; Pathiraja et al., 2016; Reichle et al., 2002; Vrugt et al., 2005), or validation (e.g., Alkama et al., 2010; Motovilov et al., 1999; Neal et al., 2012; Siqueira et al., 2018).

The use of complementary datasets (i.e., observations of hydrological variables other than discharge) for model calibration has been demonstrated as a promising approach to improve representation of processes in hydrological models (Clark et al., 2015), to reduce uncertainty in hydrological predictions (Gharari et al., 2014), to address equifinality issues (Beven, 2006) and to do predictions in ungauged or poorly-gauged sites (Sivapalan et al., 2003). However, distributed data of complementary hydrological variables (e.g., evapotranspiration, soil moisture) are scarce, and in-situ measurements present poor spatial and temporal representativeness. As a consequence, calibration of

hydrological models based on other hydrological variables than streamflow is not a common practice.

In this context, remote sensing (RS) observations have stood out in the last decade because of their increasing spatial and temporal resolutions, free availability in many cases, and capability to record less monitored hydrological variables such as soil moisture, evapotranspiration, and terrestrial water storage (Lettenmaier et al., 2015). For instance, GRACE mission provided monthly estimates of changes in water storage on a global coverage with an accuracy of 2 cm when estimated uniformly over the land and ocean regions (Tapley et al., 2004). Missions such as SMOS, SMAP, AMSR-E and ASCAT were estimated to provide soil moisture data with a median RMSE of 0.06-0.10 m³/m³ for the CONUS (Karthikeyan et al., 2017). Altimeters such as Envisat, Jason-2 and ICESat-1 and ICESat-2 can yield water level data with an accuracy ranging from 0.04 m to 0.42 m, involving trade-offs between temporal resolution from 10 to 91 days, and cross-track separation from 15 to 315 km (Jarihani et al., 2013), and the future SWOT mission focuses on surface waters (Biancamaria et al., 2016).

Previous studies have analyzed the value of integrating RS data into hydrological modeling through calibration or data assimilation (see review by Xu et al., 2014 and Jiang & Wang, 2019). RS-based calibration of hydrological models is a promising approach, but it is novel and it has not been fully explored to its potential yet. Therefore, in the next section we present a literature review to identify what are directions and questions that would help us move forward in understating the contributions of RS-based calibration of hydrological models.

In this study, we evaluate the use of multiple RS products to calibrate model parameters, and analyze the redundancy and complementarity between different variables and processes. Therefore, we provide contributions to the literature on what we can learn from model limitations and inconsistencies by looking at multiple RS observations of the water cycle. A tropical region with extensive floodplains in the Amazon is adopted as a case study. We also provide insights on how RS-based calibration can improve discharge estimates, and on what is the added value of multi-variable calibration with RS observations.

3.1.1 Literature review on calibration of hydrological models with RS data

A comprehensive, yet non-exhaustive literature review of studies that used RS datasets for parameter estimation in hydrological models is presented in this section and summarized in Figure 3-1. A total of 62 research articles was found, which are listed in the Supporting Information (Table 3-S1). Most previous publications about calibrating hydrological models with RS products involved large study areas ($> 1000 \text{ km}^2$), which is expected because of the coarse resolution of RS products. Most studies used RS-derived evapotranspiration for model calibration, followed by soil moisture (Figure 3-1b), but there have been attempts for calibration of up to eight different RS-derived variables (Nijzink et al., 2018). This indicates a still existent knowledge gap regarding which RS-derived variables are more useful for model calibration. Indeed, many recent studies have investigated the added value of RS-derived information to calibrate hydrological models (Figure 3-1d; Table 3-S1).

Most of the studies (69.35%) used only one RS product for model calibration (Figure 3-1e, in black), while twelve studies (19.35%) used two products, and five studies (8.06%) used three products, e.g., Kittel et al. (2018) calibrated the parameters of a hydrological model with water level observations from Envisat and Jason-2, and TWS from GRACE. Only few studies used more than three RS products for model calibration (Demirel et al., 2019; Nijzink et al., 2018). Therefore, we identified a knowledge gap on the use of multiple RS products for hydrological model calibration, which would allow a better understanding of the redundancy and complementarity between variables observed by RS.

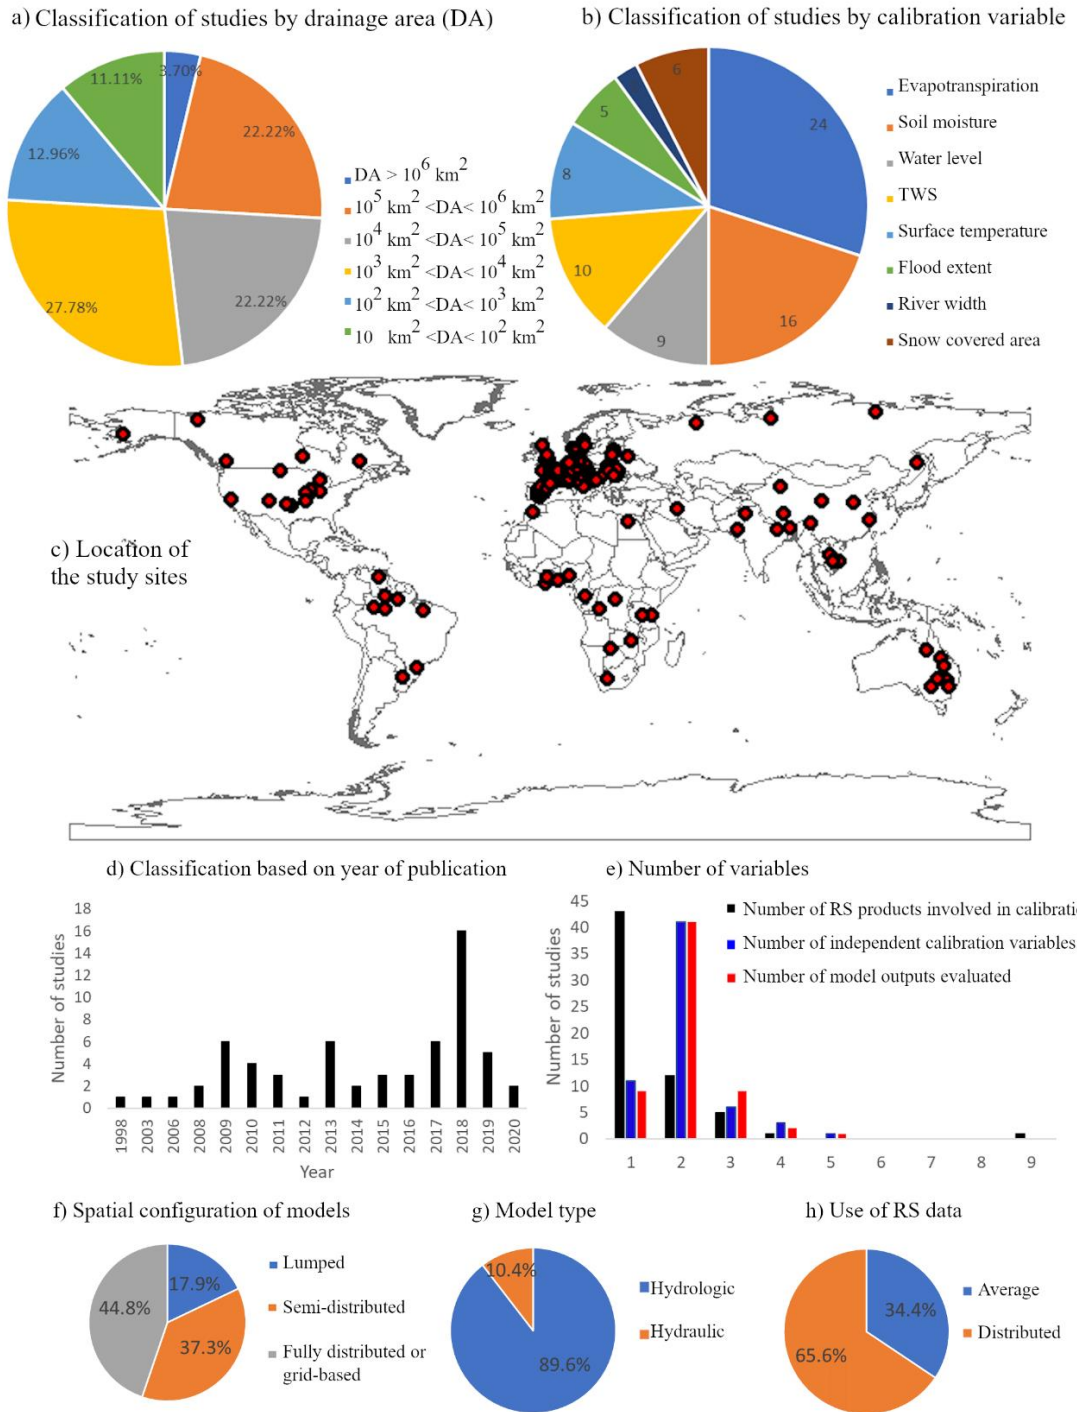


Figure 3-1. Summary of the literature review on 62 studies that incorporated RS datasets for parameter estimation in hydrological models (see Table 3-S1 in Supporting Information). (a) Classification of publications based on the drainage area of study sites (an average value was considered for publications that used multiple study sites); (b) distribution of studies based on the calibration variable; (c) geographical distribution of study sites; (d) number of publications per year; (e) number of RS products involved in calibration (in black), number of independent calibration variables (in blue), and number of model outputs evaluated (in red); (f) classification of models based on their spatial configuration; (g) model type; and (h) use of RS data.

Some studies addressed the use of RS data to estimate discharge in ungauged basins (e.g., Kittel et al., 2018; Sun et al., 2010), while others focused on narrowing the parameter search space, and thus equifinality reduction, by combining multiple variables for calibration (e.g., Nijzink et al., 2018; Pan et al., 2018). This is confirmed by Figure 3-1e (in blue), which demonstrates that the vast majority of researches used two variables for calibration (in general, discharge and a RS-derived variable). Within these studies, some analyzed model performance in terms of discharge only, while others considered different variables (Figure 3-1e, in red), providing a more comprehensive discussion on inconsistencies of hydrological models (e.g., Koch et al., 2018; Li et al., 2018). In this study, we attempt to address the latter approach, by analyzing model performance based on multiple variables.

Previous studies can also be classified based on how RS data are incorporated into the model calibration procedure (Figure 3-1h): 65.6% of the previous articles used RS-based spatially distributed information, thus calibrating the model with distributed objective functions (e.g., pixel-by-pixel or by sub-basin). Within these studies, bias-insensitive functions have been introduced (e.g., Koch et al., 2018; Demirel et al., 2018; Zink et al., 2018; Dembele et al., 2020), which is important for reducing the impact of RS data uncertainty on the parameter estimation procedure. The remaining publications (34.4%) incorporated RS data as an average for the whole basin. Here, we average RS data for calibration, but we additionally provide qualitative evaluation of spatial patterns. There is still a need for more studies in tropical regions (especially South America) (Figure 3-1c), which have particular hydro-climatic characteristics, thus leading to different requirements on model process representation (e.g., snow-related processes might not be so relevant in some tropical areas, whereas an accurate representation of floodplains might be).

Most studies used simple flood wave routing schemes such as Muskingum, usually adopted in rainfall-runoff models (Figure 3-1g). Only 10.4% of researches attempted to couple hydrologic and hydrodynamic models, which is especially relevant for representing flat regions with wetlands (Hodges, 2013; Neal et al., 2012; Pontes et al., 2017). Here, we used a tightly coupled hydrological-hydrodynamic model, based on the inertial formulation proposed by Bates et al. (2010), being the first study to analyze impacts of calibration of hydraulic parameters (i.e., Manning's coefficient, river width and depth) on hydrological variables (e.g., evapotranspiration and soil moisture). In

general, we identified a lack of researches that use a larger number of RS variables (more than 2) for model calibration, assessing its impacts on the water cycle representation.

3.2 Methods

3.2.1 Experimental design

A hydrological-hydrodynamic model (MGB; (Collischonn et al., 2007)) is set up for a case study in the Amazon (Purus River Basin) with a priori parameter sets based on their variability as reported in literature (references in Table 3-S2). The study is then divided into two steps.

Firstly, a sensitivity analysis is performed to understand parameter uncertainty and the correlation between model state variables.

Then, a calibration step is performed in which the model is calibrated with the well-known MOCOM-UA optimization algorithm considering six variables: (1) in-situ streamflow (one gauge at the basin outlet), and RS observations of (2) water level (one satellite altimetry virtual station), (3) flood extent (sum of flooded areas over the Lower Purus River Basin), (4) terrestrial water storage (TWS), (5) evapotranspiration, and (6) soil moisture. Variables (4), (5) and (6) are averaged over the whole basin. The calibration of each variable is performed individually (single-variable), and evaluated for all variables. All calibration experiments are repeated 3 times with differing initial parameter sets (to ensure that convergence is not dependent on the initial parameter sets), and we use state-of-the-art RS products that are freely available. Given limitations on the availability of simultaneous RS time coverage, the model is calibrated for one time period (2009-2011), and evaluated both for the same time period of calibration, but also with a different period (2006–2008 for discharge, flood extent, TWS, ET) and (2013–2014 for water level and soil moisture). A qualitative evaluation of spatial patterns is provided additionally. A final test is performed in which two multi-variable calibration experiments are conducted: (i) calibration with all analyzed variables, except discharge; and (ii) calibration with two complementary variables (water level and soil moisture), which are selected for simultaneous calibration.

3.2.2 Study area: Purus River Basin

The Purus River Basin (Figure 3-2) in Amazon presents a drainage area of approximately 236,000 km², and discharge values range from around 1,000 (June-December) to 12,000 m³/s (January-July) at Canutama gauge. Because of its large area, it is compatible with the spatial resolution of RS products (e.g., a pixel of GRACE presents spatial resolution of roughly 300-400 km). Purus river has a minor anthropogenic influence, which simplifies the modeling process. The climate is equatorial (Figure 3-2d), and mean annual rainfall is 2147 mm/year (according to in-situ gauges). Purus was selected because of its representativeness of tropical regions as the Amazon basin, which is the largest river in the world (Holeman, 1968), and it is characterized by extensive floodplains (Junk, 1997). For instance, on the lower Purus, the floodplain width is in the order of 30 km, which corresponds to approximately 30 times the main channel width (Paiva et al., 2011). These floodplains allow a satisfactory flood extent monitoring by RS image classification, which contributes to the suitability of Purus River Basin for this study.

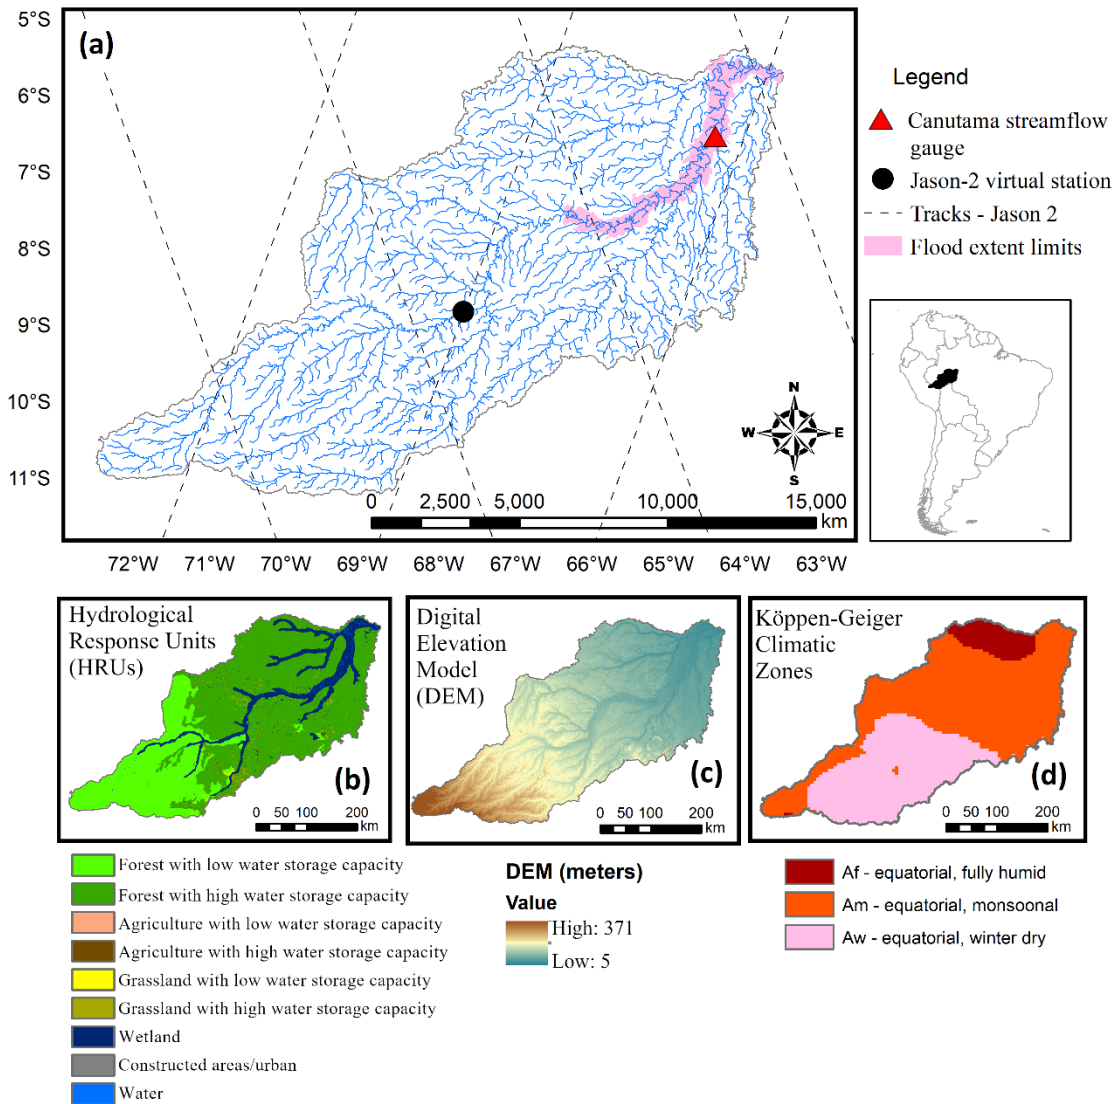


Figure 3-2. Study area: Purus River Basin. (a) drainage network (in blue), location of the discharge gauge (Canutama, triangle in red), tracks of the spatial altimetry mission Jason 2 (dashed black lines), location of the altimetry virtual station (circle, in black), and the area used for extraction of flood extent (Lower Purus, pink polygons); (b) Hydrological Response Units (Fan et al., 2015); (c) Bare Earth Digital Elevation Model (O’Loughlin et al., 2016); (d) Köppen-Geiger Climatic Zones (Kottek et al., 2006).

3.2.3 Hydrological-hydrodynamic model: MGB

The MGB (“Modelo de Grandes Bacias”, a Portuguese acronym for “Large Basin Model”) is a semi-distributed, hydrological-hydrodynamic model (Collischonn et al., 2007; Pontes et al., 2017). It was chosen for this study because (1) it has been widely and successfully applied in several South American basins (e.g., Paiva et al., 2013; Siqueira et al., 2018); (2) it is representative and similar to other conceptual hydrological models like VIC (Liang et al., 1994) and SWAT; and (3) the hydrological component is tightly

coupled to a hydrodynamic routing scheme, allowing the simulation of complex flat, tropical basins. Moreover, the source code of MGB is freely available at www.ufrgs.br/lsh.

Within the model structure, basins are discretized into unit-catchments, which are further divided into Hydrological Response Units (HRU's) based on soil type and land use. A vertical water balance is performed for each HRU, considering canopy interception, soil infiltration, evapotranspiration, and generation of surface, subsurface and groundwater flows. Soil is represented as a bucket model with a single layer. Flow generated in each HRU is routed to the outlet of the unit-catchment with linear reservoirs. Outflow from each unit-catchment is then propagated through the stream network by using a 1D hydrodynamic model based on the inertial approximation proposed by Bates et al. (2010). The stream network is derived from Digital Elevation Model (DEM) processing. The model has 19 parameters, which are further detailed in the next section. Other model inputs are precipitation, climate data, soil type and land use maps, which are further described in section 3.2.6 *Model Setup*.

3.2.4 A priori uncertainty of model parameters

Within MGB model, there are parameters related to vegetation cover (albedo, leaf area index, vegetation height and Penman-Monteith surface resistance), river hydraulics (Manning's roughness, and width and depth parameters related to geomorphological relationships), and conceptual parameters related to soil water budget (W_m , b , K_{bas} , K_{int} , XL , CAP , W_c , CI , CS , CB), which are further detailed in Supporting Information (Table 3-S2). Out of the 19 model parameters, 6 are fixed and 13 are calibrated.

The a priori uncertainty of MGB model parameters is estimated based on their variability as reported in literature (references in Table 3-S2). Supporting Information (Table 3-S2) presents the calibration parameters, their initial values, range, and the references that support these assumptions.

3.2.5 Sensitivity analysis

In order to understand parameter uncertainty in the MGB model, multiple model runs were conducted considering four uncalibrated model setups: (1) varying only soil parameters; (2) varying only vegetation parameters; (3) varying only hydraulic parameters; (4) varying all parameters together. One hundred runs were conducted, in triplicate, resulting in three hundred runs for each setup.

Parameters were varied considering a uniform distribution, and results were analyzed in terms of mean RMSD (root mean square deviation) of each variable, by comparing each run with a reference one (i.e., the initial run with the initial parameter set as defined in Table 3-S2 of the Supporting Information). This was performed in order to understand the sources of model uncertainties related to different sets of parameters (e.g., are flood extent estimates sensitive to vegetation parameters, or are ET estimates sensitive to hydraulic parameters?). The uncertainty of the model was also compared to uncertainty in the observations, as derived from literature.

The results from setup “(4) varying all parameters together” were also used to understand which variables are inter-related in the model. For that, the Kling-Gupta Efficiency (KGE; Gupta et al., (2009)) was computed by, instead of comparing simulation and observation, each run was compared to the reference one (i.e., run with the initial parameter set). This was done to evaluate whether two variables get improved or get worsened together, or whether a variable improvement impacts on the deterioration of another. In other words, this approach allows to evaluate the correlation between the variables. Therefore, the correlation between the KGE of all variables was computed with the Pearson coefficient (r). In this step, neither RS data nor discharge observations are incorporated into the model yet.

3.2.6 Model setup

The Bare Earth Digital Elevation Model (O’Loughlin et al., 2016) (Figure 3-2c) was used for stream network computation and basin discretization with the IPH-HydroTools GIS package (Siqueira et al., 2016). The digital elevation model has a resolution of 90m, which was resampled to 500m for processing. An upstream area threshold of 100 km² was adopted to delineate the drainage network, and unit-catchments were discretized by dividing the stream network into fixed reach length of 10 km, resulting in 2957 unit-catchments for the whole basin. Soil type and land cover maps were extracted from the HRU discretization developed by Fan et al. (2015) (Figure 3-2b): (1) deep and (2) shallow forested areas, (3) deep and (4) shallow agricultural areas, (5) deep and (6) shallow pasture, (7) wetlands, (8) semi-impervious areas, and (9) open water, where “deep soils” refer to soils with high water storage capacity, and “shallow soils” are those with low water storage capacity. In the Purus River Basin, 57.4% of the region is covered by forest with deep soils, 26.9% by forest with shallow soils, and 13.7% by wetlands (i.e., river floodplains). Daily precipitation data were derived from TMPA 3B42 (version 7), with

spatial resolution of $0.25^\circ \times 0.25^\circ$ (Huffman et al., 2007), available at: <<https://gpm.nasa.gov/data-access/downloads/trmm>> which were extracted and interpolated by the nearest neighbor method for the centroid of each unit-catchment. Long term climate averages for mean surface air temperature, relative humidity, insolation, wind speed and atmospheric pressure are from the Climatic Research Unit database (New et al., 2000), available at: <<http://www.cru.uea.ac.uk/data>>, at a spatial resolution of 10° , and interpolated with the nearest neighbor method.

3.2.7 Model calibration

The adopted calibration algorithm is MOCOM-UA (Yapo et al., 1998; Multi-objective global optimization for hydrologic models) due to its satisfactory performance when coupled with hydrological models (e.g., Collischonn et al., 2008; Maurer et al., 2009; Naz et al., 2014). MOCOM-UA is an evolutionary algorithm, based on SCE-UA (Duan et al., 1992), that simultaneously optimizes a model population with respect to different objective functions. The model population consists of randomly distributed points within the parameter search space, and it reflects the a priori uncertainty of model parameters. Here, the population size was set to 100 individuals. Varying model parameters and their ranges are described in Supporting Information (Table 3-S2). All calibration experiments are repeated 3 times with differing initial parameter sets (to ensure that convergence is not dependent on the initial parameter sets), and results with absolute mean values greater than 2 times the standard deviation values are reported and analyzed with confidence.

Objective functions to be optimized depend on the calibration setup (Table 3-1). In the single-variable calibration, for each variable, three objective functions (OF) that summarize the agreement between simulated and observed (RS) time-series are simultaneously optimized: Pearson correlation (r), ratio of averages (μ_{sim} / μ_{obs}), and ratio of standard deviations ($\sigma_{sim} / \sigma_{obs}$), which are associated to the individual terms of Kling-Gupta Efficiency (KGE, Gupta et al., 2009).

Then, for the multi-variable calibration, the objective functions are the KGE of each variable considered: firstly, five objective functions were considered (KGE of all variables except discharge); secondly, two objective functions were adopted (KGE of selected variable 1 (x), and KGE of selected variable 2 (y)).

Table 3-1. Objective functions adopted in the calibration strategies.

Single-variable	Q	$OF_1 = \left(\frac{\mu_{sim}}{\mu_{obs}} \right)_Q$; $OF_2 = \left(\frac{\sigma_{sim}}{\sigma_{obs}} \right)_Q$; $OF_3 = r_Q$
	h	$OF_1 = \left(\frac{\mu_{sim}}{\mu_{obs}} \right)_h$; $OF_2 = \left(\frac{\sigma_{sim}}{\sigma_{obs}} \right)_h$; $OF_3 = r_h$
	A	$OF_1 = \left(\frac{\mu_{sim}}{\mu_{obs}} \right)_A$; $OF_2 = \left(\frac{\sigma_{sim}}{\sigma_{obs}} \right)_A$; $OF_3 = r_A$
	TWS	$OF_1 = \left(\frac{\mu_{sim}}{\mu_{obs}} \right)_{TWS}$; $OF_2 = \left(\frac{\sigma_{sim}}{\sigma_{obs}} \right)_{TWS}$; $OF_3 = r_{TWS}$
	ET	$OF_1 = \left(\frac{\mu_{sim}}{\mu_{obs}} \right)_{ET}$; $OF_2 = \left(\frac{\sigma_{sim}}{\sigma_{obs}} \right)_{ET}$; $OF_3 = r_{ET}$
	W	$OF_1 = \left(\frac{\mu_{sim}}{\mu_{obs}} \right)_W$; $OF_2 = \left(\frac{\sigma_{sim}}{\sigma_{obs}} \right)_W$; $OF_3 = r_W$
Multi-variable	Case 1	$OF_1 = KGE_h$; $OF_2 = KGE_A$; $OF_3 = KGE_{TWS}$; $OF_4 = KGE_{ET}$; $OF_5 = KGE_W$
	Case 2	$OF_1 = KGE_x$; $OF_2 = KGE_y$

Results are expressed in terms of a Skill Score (S) (Equation 1; Zajac et al., 2017), in order to evaluate the improvement (or deterioration) in the representation of a variable when the model is calibrated with a given variable, compared to the uncalibrated setup.

$$S = \frac{KGE_{calibrated} - KGE_{initial}}{1 - KGE_{initial}} \quad (3 - 1)$$

$KGE_{calibrated}$ is the mean KGE resulting from running the model with the calibrated parameters. $KGE_{initial}$ is the mean KGE resulting from running the model with the a priori parameter sets.

3.2.8 Calibration/Evaluation Data

The following data were used for model calibration and evaluation:

In-situ discharge measurements were obtained from the Brazilian Water Agency Hidroweb database (available at <<http://www.snirh.gov.br/hidroweb/publico/apresentacao.jsf>>), at the gauge “Canutama” (code: 13880000; location: S ° 32' 20.04"; W 64° 23' 8.88"; drainage area: 236,000 km², period of available data: 1973 to 2016). Uncertainty in discharge observations can be

estimated as ranging from 6.2% to 42.8% at the 95% confidence level, with an average of 25.6% (Di Baldassarre & Montanari, 2009).

- *Remotely sensed water level data* were obtained from Jason-2 mission, which presents an orbit cycle of approximately 10 days, and tracks separated by approximately 300 km at the equator (Lambin et al., 2010). It presents an accuracy of approximately 0.28 m (Jarihani et al., 2013), and data are available since 2008. The virtual station presented in Figure 3-1 corresponds to Track 165. Processed data for this study were downloaded from the Hydroweb/Theia database (<<http://hydroweb.theia-land.fr>>). Simulated and RS water level data were compared in terms of anomaly (values subtracted from long term average).

- *Satellite flood extent data* were derived from ALOS-PALSAR imagery, which presents a ground resolution of 100 m (Rosenqvist et al., 2007). Images were downloaded from Alaska Satellite Facility (available at <<https://www.asf.alaska.edu/>>) in processing level 1.5, which already presents geometric and radiometric corrections. A 3 x 3 median filter was used to remove speckle noise (Lee et al., 2014). Images were classified into water (backscattering coefficient less than -14 dB), non-flooded forest (between -14 dB and -6.5 dB), and flooded forest (higher than -6.5 dB) classes, according to Hess et al. (2003) and Lee et al. (2014). The uncertainty of flood extent estimates was estimated based on the RMSE between the resulting classification of this study, and the dual-season mapping developed by Hess et al. (2003). Simulated and RS flood extent data were compared for the pink area depicted in Figure 3-1, in order to avoid spurious flood extent data in regions that are known to be not subject to flooding. ALOS-PALSAR presents a recurrence cycle of 46 days (from 2006 to 2011), so flood extent data were available and evaluated only for 21 days.

- *Satellite-based terrestrial water storage (TWS) anomalies* were extracted from GRACE mission, launched in March 2002. GRACE provides monthly TWS estimates based on anomalies in gravitational potential, at a resolution of 300-400km, with an uniform accuracy of 2 cm over the land and ocean regions (Tapley et al., 2004). TWS anomalies were retrieved from three processing centers - GFZ (Geoforschungs Zentrum Potsdam, Germany), CSR (Center for Space Research at University of Texas, USA), and JPL (Jet Propulsion Laboratory, USA), available at <<https://grace.jpl.nasa.gov/>>, and then the

mean value based on the 3 products was averaged for the whole basin. Simulated and RS TWS were compared in terms of anomaly (values subtracted from long term average).

- *Satellite-based evapotranspiration* estimates were retrieved from MOD16 product, derived by an algorithm presented by Mu et al. (2011) based on Penman-Monteith equation. The dataset covers the period from 2000-2010 with a spatial resolution of 1 km² for global vegetated land areas. Because of that, even though MGB evapotranspiration is calculated for flooded areas (main channel and floodplains) and vegetation for water balance purposes, only the vegetation-ET output was compared to MOD16. MOD16 products are provided in 8-days, monthly and annual intervals. Monthly intervals were used here and averaged for the whole basin (mm/month). Accuracy of MOD16 along the Amazon basin is estimated as 0.76 mm/day (Gomis-Cebolla et al., 2019). MOD16 data is available at: < <https://www.ntsg.umt.edu/project/modis/mod16.php>>.

- *Satellite-based soil moisture* is derived from SMOS mission (Kerr et al., 2001), processed by CATDS, and downloaded in processing level 4, which combines lower level products with data from other sensors and modeling/data assimilation techniques. Daily L4 root zone soil moisture at 0-1m (Al Bitar et al., 2013) were used (available at: <<https://www.catds.fr/Products/Available-products-from-CEC-SM/L4-Land-research-products>>, and data from ascending and descending orbits were averaged for the whole basin. Since MGB model represents the soil as a bucket (i.e., single soil layer), SMOS values were rescaled for the range 0 - 100% for comparison with the model based saturation degree, according to the Min/Max Correction method described by Tarpanelli et al. (2013), and applied by some studies (e.g., Rajib et al., 2016; Silvestro et al., 2015).

3.2.9 Model Outputs

The MGB model is simulated in a daily time-step. Evaluation of model outputs depends on the temporal resolution of RS products: discharge and soil moisture are evaluated in a daily basis. TWS and ET are temporally aggregated and evaluated in a monthly time-scale. For water level, evaluation is every 10 days, approximately. For flood extent, evaluation is every 46 days, approximately.

Discharge is a standard output in hydrological models. Water level and flood extent were computed as an advantage of using the hydrodynamic scheme for flood routing instead of the Muskingum simplification. TWS values were computed as the sum of water storage all hydrological compartments: river, floodplains, soil, groundwater and vegetation

canopy. Anomalies were retrieved as the changes in the TWS. This produces the same result as if TWS is computed as the precipitation subtracted by evapotranspiration and discharge. Evapotranspiration is computed in MGB model via Penman-Monteith equation, based on the climate input variables. The mass/water balance of a given HRU affects ET computation by increasing the surface resistance during water deficit periods. Besides, evaporation of canopy interception and open water evaporation are also considered in the model framework. Soil moisture as a saturation degree was computed as the water in the soil compartment divided by the maximum water capacity of the soil (W_m parameter). TWS, ET and soil moisture were averaged for the whole basin for comparison with RS data.

3.3 Results and discussion

Results are structured as follows. Firstly, the sensitivity analysis is presented with discussions on model uncertainties (Section 3.3.1). Then, results for model calibration are presented, with discussions on how RS-based model calibration can improve discharge and water cycle representation (Section 3.3.2).

3.3.1 Sensitivity analysis

A sensitivity analysis was carried out to understand the a priori uncertainty of the model parameters (Figure 3-3), by considering six output variables (discharge, water level, flood extent, TWS anomalies, vegetation ET, and soil moisture), and analyzing the dispersion provided by varying different parameter sets (hydraulic, soil, vegetation, all). These uncertainties are also compared with an estimate of the observations' uncertainties (values provided in section 3.2.8 *Calibration/Evaluation Data*). Figure 3-3 is commented in the subsequent sections.

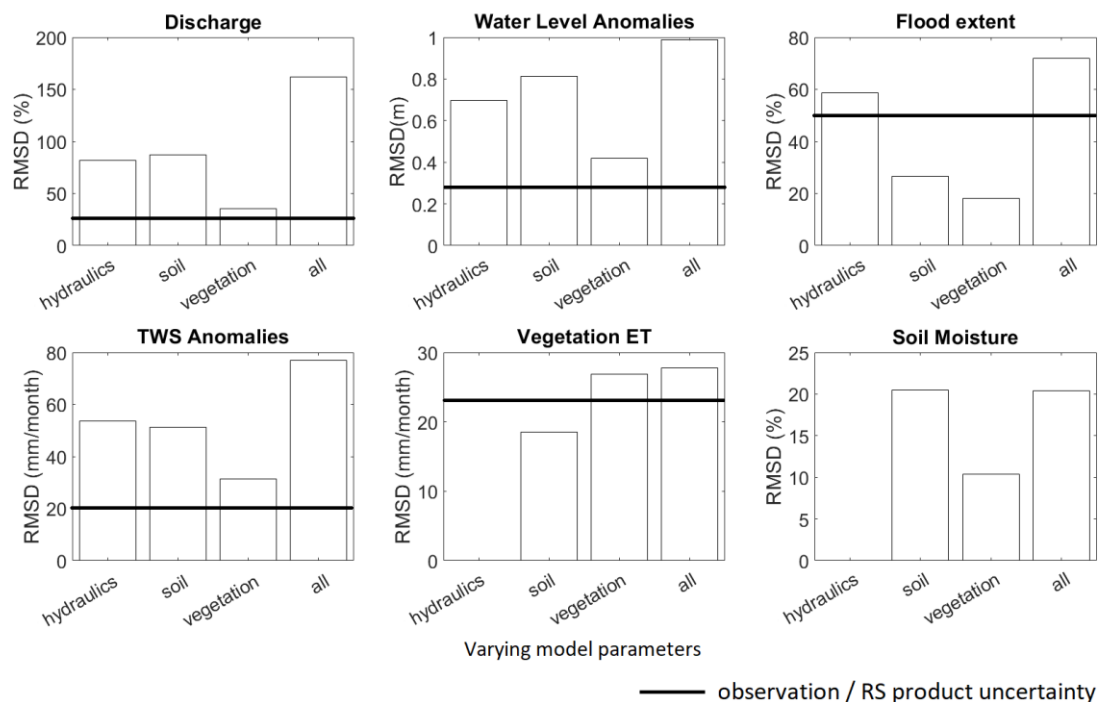


Figure 3-3. Sensitivity analysis of multiple model output variables to varying sets of parameters (hydraulics, soil, vegetation, overall). The a priori uncertainty of the model parameters, for each output variable, is compared to the reported uncertainty for the observation / RS product, previously described in the Cal/Eval data section (no uncertainty estimation is provided for the soil moisture root zone product given absence of this estimate for the Amazon region).

3.3.2 How do model uncertainties relate to uncertainties in observations?

Some variables present observations/RS products that have uncertainties significantly lower than the overall uncertainties of the model, e.g., 25 % for discharge observations, while model overall parameter uncertainty is ~160%. This pattern is also found for water level and TWS estimates, and implies that these observations might be useful to constrain the model. Nonetheless, uncertainties in RS products of flood extent (~50%) and vegetation ET (~23%) are in the same order of magnitude of model overall parameter uncertainty, which might hamper their contribution for model calibration, due to their high uncertainties.

3.3.3 Which sets of parameters are related to which variables?

The overall uncertainties in the model are related to different sets of parameters: discharge, water level, and TWS are more strongly related to hydraulics and soil parameters, and to a lesser extent to vegetation parameters. Flood extent estimates are strongly related to hydraulic parameters, and less to soil and vegetation. As expected, soil moisture and vegetation ET estimates relate to vertical water balance processes, therefore they are insensitive to hydraulic parameters. Soil moisture (W) is more sensitive to soil

parameters, while vegetation ET is more sensitive to vegetation parameters. Therefore, if model calibration with either of these variables (ET or W) is achieved through optimization of hydraulic parameters, it would highlight that the model would have “gotten the right results for the wrong reasons”.

3.3.4 Which variables are inter-related?

By varying all parameters, there is a high correlation (greater or equal to 0.4) between discharge and flood extent, water level and flood extent, flood extent and TWS, and ET and TWS (Figure 3-4). High correlations between discharge, water level and flood extent were expected because these variables are strongly associated through river transport processes. However, correlation between discharge and water level is not too high (0.30), and this is probably due to high uncertainties in hydraulic parameters, and to the large distance separating the virtual station for water level and the streamflow gauging point. Furthermore, high correlations between TWS and flood extent might be related to surface water storage dynamics which are specific for regions with floodplains.

In general, a high correlation between variables in Figure 3-4 should be reflected in positive results when calibrating with a given variable and evaluating with the other highly correlated variable (single-variable calibration). This may also indicate that observations of these variables are redundant if used simultaneously in a multi-calibration framework. However, high correlations in Figure 3-4 followed by deterioration after the single-variable calibration process might indicate structural errors in the model, or in the observations. However, this study did not attempt to quantify structural errors. Conversely, low correlations in Figure 3-4, followed by improvement in performances with the calibration with multiple variables, might indicate complementarity between variables.

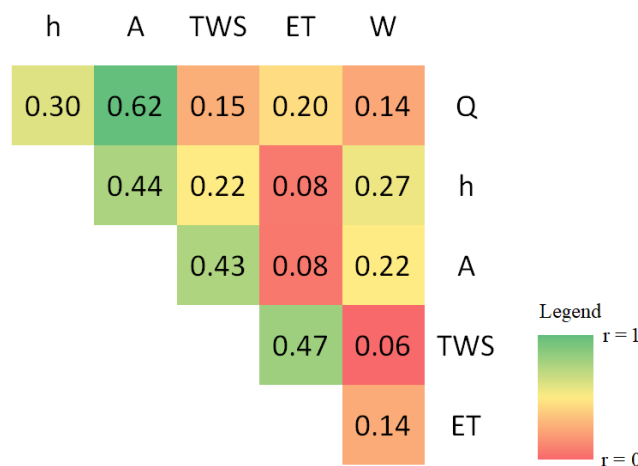


Figure 3-4. Correlation matrix (Pearson coefficient) between performance metrics (KGE) for the six analyzed variables, by varying all parameters together. KGE values are computed by comparing multiple runs with the reference simulation (i.e., the initial run with the initial parameter set as defined in Table 3-S2 of the Supporting Information). Q = discharge, h = water level, A = flood extent, TWS = total water storage anomalies, ET = vegetation evapotranspiration, W = soil moisture.

3.4 Model calibration

3.4.1 How RS-based model calibration improves discharge estimates?

For the evaluation time period (2006–2008 for discharge, flood extent, TWS, ET and 2013–2014 for water level and soil moisture), calibration with all RS products led to improvements in discharge estimates (Figure 3-5a). For the calibration time period (2009–2012), RS products TWS, ET and soil moisture also led to improvements in discharge estimates, but water level and flood extent led to overestimation of discharge estimates in wet periods (Figure 3-5a). This could be due to high uncertainties in the observations (Figure 3-3), but if this was the case, it would also be reflected in a poor performance for water level and flood extent when discharge is the target variable for calibration (Figure 3-5b), which does not occur. Therefore, calibration with discharge leads to reasonable parameter sets for the performance of discharge itself, and also water level and flood extent. However, it does not lead to the best hydraulic arrangement, which might be achieved more successfully when calibrating with water level or flood extent.

Nonetheless, both water level and flood extent observations are representative of a specific location in the basin (Figure 3-2), and calibration with these variables might lead to the best parameter arrangement for these locations, but not for the whole watershed. A more spatially-consistent use of these observations should improve their usability to constrain models and improve discharge estimates, such as the studies of Kittel et al. (2018), that used radar altimetry measurements at 12 locations in the basin, Schneider et al. (2017), that used data from 13 virtual stations, or Liu et al. (2015), that used water level measurements at 4 virtual stations, and flood extent for stream segments at different locations in the basin.

In spite of the limitations with water level and flood extent variables for discharge prediction in this study (for the calibration time period), other RS variables, such as TWS, ET, and soil moisture were able to improve discharge estimates by $S = 13.7\%$, $S = 52.9\%$, and $S = 27.0\%$ (Figure 3-6-I, calibration period) or $S = 27.4\%$, $S = 6.1\%$, $S = 12.3\%$ (Figure 3-6-II, evaluation period), which is especially relevant in the context of the Prediction in Ungauged Basins initiative (Hrachowitz et al., 2013; Sivapalan et al., 2003). These results

agree with previous studies, such as López et al. (2017) that found good performances in discharge estimates by model calibration with GLEAM ET and ESA CCI soil moisture, or Nijzink et al. (2018), that found improvements in discharge by using soil moisture products (AMSR-E, ASCAT) and TWS from GRACE.

The multi-variable calibration experiment considering all variables except discharge (Figure 3-6b) resulted in a Skill Score of $S = 17.4\%$ for discharge in the evaluation period. This is relevant for estimating discharge in poorly gauged basins. Nonetheless, for the calibration period, this Skill Score was $S = 1.7\%$, which is low, and might reflect some limitations when retrieving discharge measurements based on the calibration of RS-derived variables. This is probably because of the potential trade-offs between variables (Koppa et al., 2019). Moreover, all uncertainty from RS observations are incorporated into the calibration. An alternative to deal with uncertainties from RS observations in the calibration procedure would be the use of bias-insensitive metrics (e.g., Demirel et al., 2018; Zink et al., 2018; Dembele et al., 2020), or to explicitly include them into the objective functions (Aires, 2014; Croke, 2009; Foglia et al., 2009; Peña-Arancibia et al., 2015).

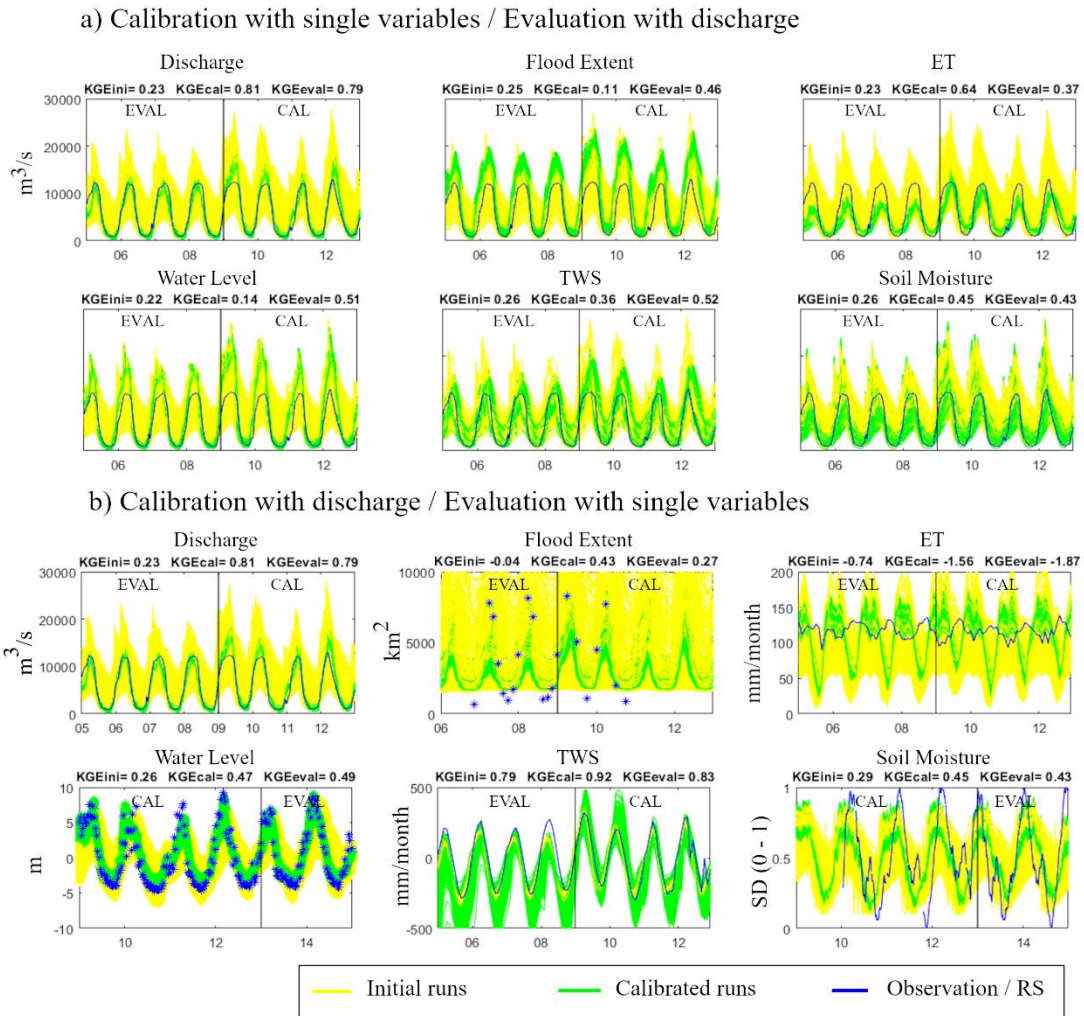
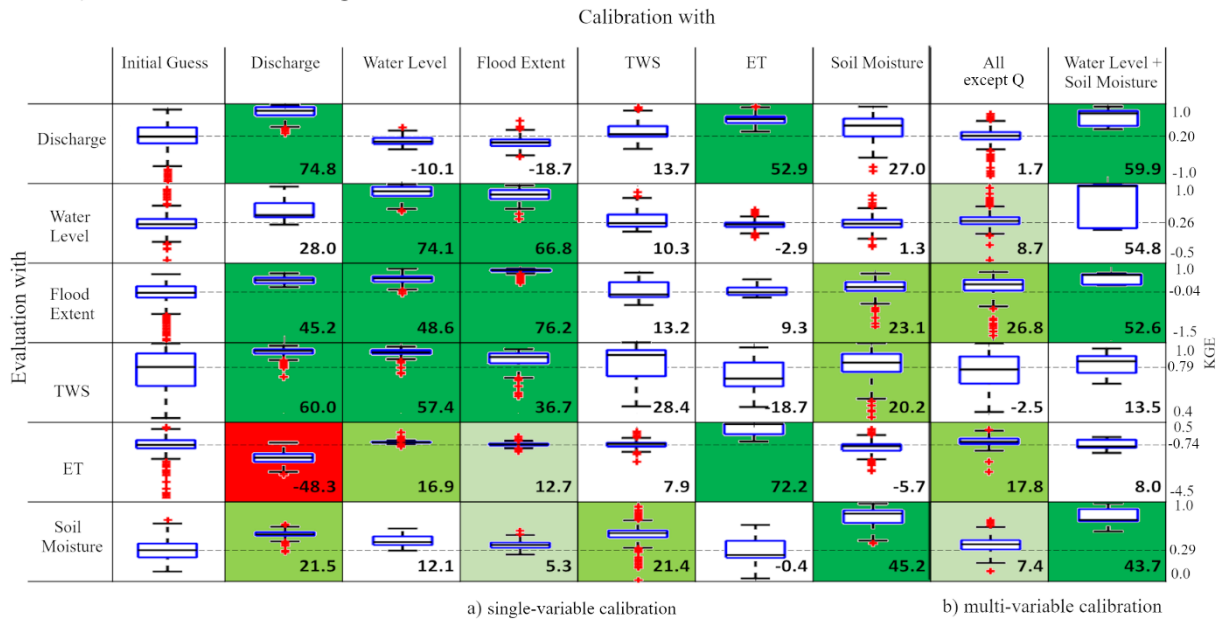


Figure 3-5. (a) Daily time series of discharge, when calibrating the model with six different variables. (b) Time series of the six variables when calibrating the model with discharge observations only (discharge, water level, flood extent and soil moisture are at a daily time step, while TWS and ET are at a monthly time step). *KGEini* is the mean KGE of initial runs, and *KGEeval* the mean KGE of calibrated runs. Time series for all variables by calibrating the model with all setups is presented in supporting information (Figure 3-S1).

I) Evaluation for the same period of calibration



II) Evaluation for a different period than calibration




Figure 3-6. Boxplots of mean KGE for the evaluation of multiple variables with different calibration strategies. (I) evaluation for the same period of calibration (2009 – 2012); (II) evaluation for a different period than calibration (2006 – 2008 for Q, A, TWS, ET; 2013 – 2014 for h and W). “Initial guess” refers to model runs with the a priori parameter sets. (a) single-variable (discharge, water level, flood extent, TWS, vegetation ET, soil moisture) and (b) multi-variable calibration (all except discharge, water level + soil moisture). The spread of the values in the boxplots stems from 300 model runs (100 for each calibration experiment). Numbers next to the boxplots represent skill score (%). Colors refer to classes of

skill score. Color white refers to cases when the results between the three experiments differ, i.e., when the absolute value of the mean skill score is less than two times the standard deviation computed for the 3 experiments. Please note that the KGE scales are different for each variable. Asterisks refer to cases when the evaluation period result did not fall into the same color category as the calibration period. Please note that Skill Score values are computed based on mean values, while the boxplots depict median values.

3.4.2 How RS-based model calibration improves representation of the water cycle?

When performing a single-variable calibration, the performance of the variable itself always improves, which is evidenced by the positive values in the main diagonal (Figure 3-6-I-a, for calibration period and Figure 3-6-II-a, for evaluation period). Calibration with water level was also able to improve estimates of flood extent, TWS and ET (cal period) / all variables (eval period). Calibration with flood extent improved water level, TWS, ET and soil moisture (cal/eval periods). Calibration with TWS improved soil moisture estimates (cal period) / discharge and soil moisture (eval period). Calibration with ET was able to improve discharge estimates (cal only). Calibration with soil moisture improved flood extent and TWS (cal period) / flood extent (eval period).

Results for calibration and evaluation periods agree (i.e., are into the same skill score color category) in 29 out of the 48 cases (60.4%). In the remaining cases (39.6%), results between calibration and evaluation periods differ.

In the best modeling scenario, calibration with any variable should improve the performance of all other variables. However, we have identified that this did not happen in our experiments. This can be due to uncertainties in model structure, in parameterization, or in the observations. Previous studies have also found significant advantages in using RS-based model calibration to identify structural model issues (e.g., Werth et al., 2009; Willem Vervoort et al., 2014; Winsemius et al., 2008), detect uncertainties in input data (e.g., Milzow et al., 2011), identify deficiencies in model parameterization (e.g., Franks et al., 1998; Koppa et al., 2019), or increase model reliability (e.g., Koch et al., 2018; Manfreda et al., 2018).

According to Figure 3-5b and supporting information (Figure 3-S1), calibration with discharge improved estimates of almost all variables. However, calibration with discharge deteriorated the performance for vegetation ET time series. Vegetation ET estimated by MOD16 varies at maximum 30mm/month, while MGB calibration with discharge observations led to variations of 100 mm/month in vegetation ET, reaching around 30

mm/month in the driest periods, while MOD16 estimates are limited to a minimum of 100 mm/month in these periods (time series in Figure 3-5b). However, one can notice that not even the seasonality between MGB and MOD16 time series agree. This could be due to relatively high uncertainties in vegetation ET estimates from MOD16 for the Amazon basin (around 23 mm/month, according to Gomis-Cebolla et al., 2019). Nonetheless, it could also be related to model structural and/or parameter deficiencies, in which case the model might be “right for the wrong reasons”. In order to identify the source of this ET inconsistency, we have compared MOD16 and MGB results to in-situ measurements of ET in Purus River Basin, provided by Gomis-Cebolla et al. (2019) and Maeda et al. (2017). We found a much stronger agreement both in seasonality and in amplitude of in-situ observations with MOD16 observations than with MGB model output. Hasler & Avissar (2007) have already warned about the overestimation of dry season water stress in hydrological models, probably related to the misrepresentation of soil water availability for plants. This was also found by Maeda et al. (2017), which highlighted that ET did not necessarily reach the lowest values during the driest periods, because of the plants’ access to deep soil water, which has also been previously documented by Nepstad et al. (1994). They found that, in the Southern Amazon ecotone, deep root water intake plays a key role in maintaining ecosystem productivity during dry season. MGB model is probably misrepresenting these processes, which would remain unknown if only discharge time series were observed.

Even though calibration with discharge observations was not able to represent ET estimates, calibration with the remaining variables (except for soil moisture) was able to improve ET estimates. For instance, in Figure 3-4, ET and water level presented low correlation ($r=0.08$), but calibration with water level improved ET estimates by $S = 16.9\%$ (cal period) / $S = 25.6\%$ (eval period). However, in Figure 3-4, ET and TWS presented high correlation ($r=0.47$), but calibration with TWS improved ET estimates by only $S = 7.9\%$ (cal period) / $S = 13.1\%$ (eval period).

In general, calibration with TWS did not present much influence on any of the variables. Consistently, TWS estimates got relatively easily improved by calibration with any variable (except ET, for cal period; or discharge, for eval period). These results for TWS contrast with previous work from Lo et al., 2010; Nijzink et al., 2018; Rakovec et al., 2016; Schumacher et al., 2018; and Werth & Güntner, 2010, which highlighted the valuable nature of GRACE data when incorporated into hydrological modeling. This can

be due to the high seasonality of Purus River Basin, in which TWS does not aggregate much information, biasing the calibration with high correlation values. Even for an uncalibrated setup TWS performances were very good: KGE values were around 0.8, while for all other variables, except for ET (for which KGE values were negative), KGE values were around 0.3 for the uncalibrated setup.

Flood extent and water level performances were improved by calibration with discharge, water level and flood extent, but it did not affect much ET (which actually was degraded with discharge calibration) and soil moisture. This is probably due to the relationship between water level and flood extent with river transport processes (e.g., flood routing and floodplain storage), while ET and soil moisture are more related to vertical hydrological processes (e.g., soil water balance). This highlights the complementarity between variables that relate to different processes.

Calibration with soil moisture improves performances of all variables (water level to a lesser extent), except for ET. Consistently, calibration with all variables (except ET) are able to improve soil moisture to some extent.

3.4.3 What is the added value of complementary RS observations?

By calibrating with all variables except Q (Figure 3-6b), we found improvements for almost all variables, with the most significant improvements for flood extent (Skill Score around $S = 25\%$ for cal and eval periods) and ET (Skill Score around $S = 20\%$ for cal and eval periods). For discharge, performance for the evaluation period was improved by $S = 17.4\%$, which is important for estimating discharge in poorly gauged basins. However, for the calibration period, Skill Score for discharge performance was $S = 1.7\%$, which might reflect some limitations in retrieving discharge measurements based on the calibration of the RS-derived variables (as discussed previously).

Therefore, we chose a specific arrangement of two complementary variables in order to check if this calibration setup might lead to better retrievals for discharge and the other variables. The chosen variables were soil moisture and water level, because of their complementarity. Based on the Skill Score values in Figure 3-6, calibration with water level improves all variables but discharge (and soil moisture to a lesser extent), while calibration with soil moisture improves all variables, but ET (and water level to a lesser extent).

The calibration arrangement of water level and soil moisture led to improvements not only to soil moisture and water level themselves, but also to all other variables (ET to a less extent). For instance, flood extent was improved by $S = 52.6\%$ and $S = 34.1\%$ (cal and eval period, respectively). Discharge was improved by $S = 59.9\%$, with a resulting mean $KGE = 0.70$ for the calibration period ($S = 45.0\%$ and mean $KGE = 0.35$ for evaluation period), which is relevant in the context of the PUB initiative (Hrachowitz et al., 2013; Sivapalan et al., 2003). These results agree with previous works that found an improvement in model performances by multi-variable calibration of: soil moisture and evapotranspiration (e.g., Koppa et al., 2019; López et al., 2017), discharge and evapotranspiration (e.g., Herman et al., 2018; Pan et al., 2018; Poméon et al., 2018), discharge and soil moisture (e.g., Li et al., 2018; Rajib et al., 2016), discharge and TWS (e.g., Rakovec et al., 2016; Schumacher et al., 2018; Werth & Güntner, 2010), and discharge and water level (e.g., Kittel et al., 2018; Schneider et al., 2017; W. Sun et al., 2012). However, it is difficult to compare this study to previous works, because most of them used discharge observations as constraints. In this study, we avoided the use of discharge observations for multi-variable calibration, in order to analyze the applicability of the RS-based calibration method for poorly-gauged regions.

Calibration with water level and soil moisture did not present much influence on ET performance, because of the specificities regarding ET in this watershed, i.e., given that the model setup does not represent deep root water intake during dry season, as discussed previously.

3.5 Are we getting the right results for the right sets of parameters?

When analyzing the dispersions of parameters before and after calibration with each variable (Figure 3-7 for a few selected parameters, Supporting Information (Figure 3-S2) for all calibrated parameters), it can be observed that the range of parameters vary largely depending on the calibration variable. For instance, W_m is a soil conceptual parameter that relates to maximum storage of water in the soil. In the calibration based on single variables except ET it converged to low values (300), while in the calibration with ET it reached high values (2000). This probably occurred in order to compensate, by parameterization, a structural error in the model, i.e., the model inability to represent deep root water uptake in dry season. These trade-offs between model parameters during calibration has also been reported and discussed by Koppa et al. (2019).

The surface resistance parameter also resulted in a wide range of values depending on the calibration target variable. When calibrated with water level, flood extent, or ‘all except Q’ experiments, it reached median values higher than 150 s/m, but calibration with h+W led to median values lower than 50 s/m. Surface resistance is a vegetation parameter directly related to ET dynamics, so it is important to note that calibration with ET was able to reduce the dispersion of this parameter, reaching a median value of about 80 s/m (similar to calibration with Q and W).

Another interesting result relates to channel Manning’s coefficient, which presented different values for each calibration exercise. This agrees previous findings about Manning parameter being often used as an effective parameter that compensates for neglected hydrodynamic processes as localized channel head losses, poor cross section representation, or non-represented 2D processes (Neal et al 2015).

Many previous studies have highlighted the use of multi-variable calibration to narrow parameters’ search space (Nijzink et al., 2018; W. Sun et al., 2018), but this was not observed in our results. Based on the limited multi-variable calibration experiments performed here (‘all except Q’ and h+W), no narrowing in parameters’ search space was found. For most parameters (except for Wm), calibration with ‘all except Q’ and h+W resulted in a wide range of values. This can be due to differing convergence sets of parameters between each of the triplicate runs. A more robust experiment comparing more multi-variable calibration strategies (e.g., Q+RS) might provide better understanding on this topic.




Figure 3-7. Boxplots of dispersion of three model parameters before (Initial) and after the single-variable calibration (Q – discharge; h – water level; A – flood extent; TWS – total water storage anomalies; ET - vegetation ET; W – soil moisture), and multi-variable calibration (All – variables except discharge; h+W – water level and soil moisture). The spread of the values in the boxplots stems from 300 model runs (100 for each calibration experiment). Description of parameters is

presented in Supporting Information (Table 3-S2). A complete figure with boxplots for all parameters is presented in Supporting Information (Figure 3-S2).

3.6 Spatial Evaluation

For model calibration, we used one streamflow gauge for discharge, one virtual station for water level, and averaged RS data for the whole basin for TWS, ET and soil moisture. However, there are many recent studies that investigated the potential for using RS spatially distributed information in model calibration, for instance with bias-insensitive metrics (Demirel et al., 2018; Zink et al., 2018; Dembele et al., 2020). Here we further analyze how the lumped calibration affected the simulated spatial patterns (Figure 3-8).

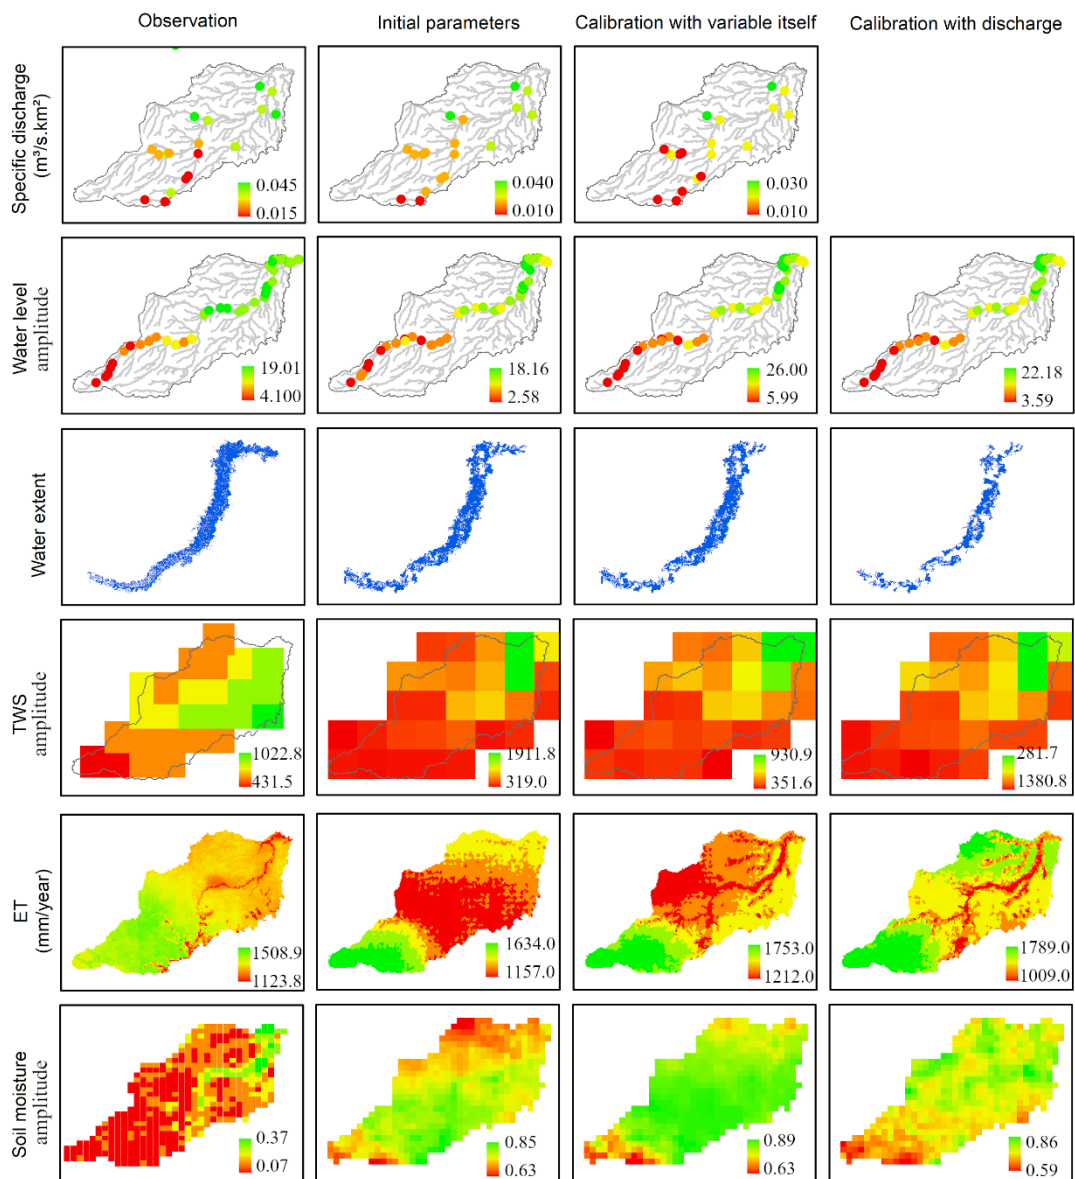


Figure 3-8. Spatial distribution of variables. Columns: observation, model run with the initial parameter set, model run with the best parameter set (calibrated for each variable), model run with the best parameter set (when calibrated with discharge).

For discharge, water level, flood extent and TWS, spatial patterns are well reproduced even when running the model with the initial parameter set, because the spatial patterns of these variables are determined by intrinsic characteristics of the basin. These characteristics are represented by model physics (e.g., water level amplitude increases from upstream to downstream), not much influenced by parameters. Nonetheless, for ET, the spatial patterns are completely different between the initial parameter set and the calibrated setup. In this case, the calibration with spatially aggregated ET was able to improve the model spatial representation of MOD16's ET observation. A similar result was found for soil moisture spatial representation by Demirel et al. (2019), that calibrated a model with spatially aggregated soil moisture and TWS data.

Results highlight the overall model capability to retrieve the ET spatial pattern even by using a lumped calibration approach. However, for other variables, the spatial pattern was not considerably affected by the differing model calibration strategies.

3.7 Conclusion

We calibrated and evaluated a hydrological-hydrodynamic model with five different RS-based observations of the water cycle: water levels (Jason-2), flood extent (ALOS-PALSAR), TWS (GRACE), vegetation ET (MOD16), and soil moisture (SMOS), for a study basin in a tropical region with floodplains (Purus River Basin in the Amazon), and analyzed the redundancy and complementarity between different variables and processes.

Results showed that calibration with current RS observations was able to improve discharge estimates. For instance, in the uncalibrated setup, average performances for discharge were around $KGE = 0.30$. By calibrating the model with ET from MOD16 (and evaluating for the same time period), discharge average performance was improved to $KGE = 0.64$, representing a Skill Score of $S = 52.9\%$. Also in the calibration period, a joint scheme of calibration with water level + soil moisture led to discharge improvements of $S = 59.9\%$. When evaluating for a different time period, discharge performance was improved by calibration with water level, TWS and a joint scheme of all RS-variables ($S = 25.9\%$, $S = 27.9\%$ and $S = 17.4\%$, respectively). We conclude that RS observations are

useful to predict discharge estimates, but the utility of each RS variable might depend on the study area characteristics and the time period considered.

Our results also showed that RS-based calibration led to an overall improvement of the water cycle representation. For instance, calibration with water level was able to improve estimates of water level itself, but also flood extent, TWS and ET; calibration with soil moisture was able to improve estimates of soil moisture itself, but also discharge, flood extent and TWS. This is especially relevant in the context of the PUB initiative (Hrachowitz et al., 2013; Sivapalan et al., 2003).

Moreover, calibration with multiple RS variables was able to highlight deficiencies that might be related to model structure, parameterization, and observations. In the context of model structure, for instance, calibration with ET highlighted the model inability to represent the root water intake in dry season in this region, thus compensating it by misrepresenting other variables. In the context of model parameterization, for instance, we found a wide range of different parameters by varying the calibration target variable.

Besides individual calibration with each RS variable, we conducted two multi-variable calibration experiments: calibration with all variables except discharge, and calibration with water level and soil moisture, that proved to be able to retrieve discharge and other variables estimates. Even though we used a lumped calibration approach, results highlighted the overall model capability to retrieve spatial pattern for most variables.

The main conclusions presented here are of great interest for the hydrological community, and agree with previous works in that RS-based calibration is useful to improve water cycle representation in hydrological models. To further investigate the potentiality of RS data, future developments should test the methodology presented here for multiple basins at contrasting hydro-climatic regions. Here, we assessed an Amazonian Equatorial basin, with particular climate and land cover characteristics and an overall spatial homogeneity of rainfall-runoff processes. Other basins with different hydroclimatic regimes could be also assessed, e.g., in arid basins subject to long dry periods, more erratic precipitation patterns, and different runoff generation mechanisms than the Amazon, which require different model structures.

Moreover, here we used one state-of-the-art RS product for each variable, but future developments should consider the use of different products for representing each variable

(e.g., ET could be represented by GLEAM, MODIS, SSEBop, SEBS, ALEXI, METRIC, etc., besides MOD16).

Acknowledgements

This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Finance Code 001, and the Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) – Grant Number 41161/2017-5. It was conducted in the context of the SWOT-MOD science team project from SWOT satellite mission. We would also like to thank colleagues from the Large Scale Hydrology Group (HGE/IPH) for general discussions about this study. Data presented in this study are available at <https://drive.google.com/open?id=1OEsqOjIGKM2vIwey6CaMOZg2O7TikK5K> (MGB code in FORTRAN, MGB Input folder, post-processing code in MATLAB).

CAPÍTULO 4. **Contribuição de sensoriamento remoto para a calibração da modelagem de múltiplas variáveis hidrológicas em diferentes condições hidro-climáticas**

Resumo. A correta representação de processos físicos em modelos hidrológicos tem se mostrado importante na estimativa de variáveis hidrológicas (além de vazão). Estudos anteriores investigaram a possibilidade de utilizar estimativas de variáveis hidrológicas por sensoriamento remoto (SR) para a calibração de modelos hidrológicos, a fim de gerar modelos mais realistas (que representem de forma mais acurada o ciclo hidrológico). No entanto, as variáveis e áreas de estudo analisadas são limitadas. Neste estudo, um modelo hidrológico-hidrodinâmico (MGB) foi calibrado com vazão, e com quatro variáveis estimadas por SR: níveis (Jason-2), anomalias no armazenamento terrestre (TWS, GRACE), evapotranspiração (ET, MOD16) e umidade do solo (SMOS), para quatro bacias representativas de diferentes regiões hidro-climáticas brasileiras: rio Purus na Amazônia, rio Araguaia no Cerrado, rio Piquiri na Mata Atlântica e rio Pardo na Caatinga, a fim de avaliar a contribuição das estimativas por SR para a modelagem de variáveis hidrológicas. Resultados indicam que em alguns casos a calibração com variáveis de SR melhorou estimativas de vazão, e que a ET foi a variável que ofereceu mais contribuições às estimativas de vazão. Para a estimativa de outras variáveis do ciclo hidrológico, em alguns casos a calibração com uma variável melhorou a estimativa de outras, mas nem sempre, indicando que observações apresentam incertezas, ou que a estrutura ou parametrização do modelo está incorreta. Dentre as quatro áreas de estudo, o estudo de caso mais consistente (i.e., calibração com uma variável resulta em melhora das outras) é o do rio Piquiri (Mata Atlântica), seguido pelo Purus (Amazônia), Araguaia (Cerrado) e Pardo (Caatinga). Em geral, o modelo convergiu para diferentes conjuntos de parâmetros, dependendo da variável de calibração. Isto salienta que, a depender da variável de calibração, o modelo “acerta por motivos diferentes”. A abordagem de utilizar diferentes variáveis estimadas por SR se mostrou útil para enriquecer a modelagem de variáveis hidrológicas (além de vazão).

Palavras-chave: modelagem hidrológica; calibração; sensoriamento remoto.

4.1 Introdução

A modelagem hidrológica é relevante para diversas aplicações: gestão de recursos hídricos (e.g., Refsgaard & Abbott, 1990), previsão de impacto nos recursos hídricos de mudanças climáticas (e.g., Sorribas et al., 2016) e/ou mudanças no uso e ocupação do solo (e.g., Bosmans et al., 2017), informar sistemas de previsão hidrológica (e.g., Chang et al., 2019), entre outros. Tipicamente, os parâmetros de modelos hidrológicos são calibrados com observações de vazão, em um processo iterativo de minimização das diferenças entre hidrogramas simulados pelos modelos e observados em postos fluviométricos (Van Beek et al., 2011; W. Collischonn et al., 2007; Döll et al., 2003). No entanto, esta abordagem não garante que os processos internos no modelo estejam sendo corretamente representados, já que podem haver compensações entre diferentes fluxos e compartimentos (e.g., Rakovec et al., 2016; Wanders et al., 2014). Dessa forma, a incorporação de outros fluxos do balanço hídrico na calibração de modelos se mostra como uma alternativa interessante para melhorar a representação dos processos hidrológicos e reduzir incertezas nas estimativas de modelos hidrológicos (Clark et al., 2015; Gharari et al., 2014; Koppa et al., 2019), embora melhorar a representação dos fluxos pode aumentar a incerteza total.

Considerando a escassez de medições in-situ de variáveis hidrológicas, as variáveis estimadas por sensoriamento remoto vêm se destacando em sua integração com modelagem, por exemplo variáveis como precipitação, altimetria, umidade do solo, entre outras (Lettenmaier et al., 2015). Alguns estudos abordaram as potencialidades e limitações do uso de variáveis estimadas por SR para a calibração de parâmetros em modelos hidrológicos (e.g., Dembélé et al., 2020; Demirel et al., 2019; Koch et al., 2018; López et al., 2017; Nijzink et al., 2018), elencados em detalhe na revisão bibliográfica apresentada por Meyer et al. (2020). A partir desta revisão, foram também identificadas algumas lacunas no conhecimento, como por exemplo o uso de um número limitado de variáveis, análises restritas para áreas de estudo no hemisfério norte, e esquemas de propagação do escoamento simplificados.

No trabalho de Meyer et al. (2020), também apresentado no Capítulo 3 da presente Dissertação, foi realizada a calibração dos parâmetros do modelo hidrológico-hidrodinâmico MGB para uma área de estudo na América do Sul (rio Purus, na Amazônia), considerando estimativas por sensoriamento remoto de altimetria (h); Jason-

2), áreas inundadas (A; ALOS-PALSAR), anomalias no armazenamento de água (TWS; GRACE), evapotranspiração (ET; MOD16) e umidade do solo (W; SMOS). No trabalho, a calibração com algumas variáveis estimadas por SR (TWS, ET, W e h+W) melhoraram estimativas de vazão na ordem de 6.1 a 52.9%. Ainda, a calibração com variáveis estimadas por SR melhorou a representação do ciclo hidrológico no modelo, sendo que analisando-se múltiplas variáveis do ciclo hidrológico, foi possível identificar inconsistências na estrutura e parametrização do modelo, que não seriam identificadas caso só observações de vazões fossem consideradas.

No entanto, as conclusões de Meyer et al. (2020) estão limitadas à área de estudo do rio Purus, na Amazônia, deixando em aberto a pergunta se essas mesmas conclusões seriam encontradas em outras bacias hidrográficas, com regimes hidro-climáticos diferentes. Sendo assim, o presente estudo se situa como uma continuação do trabalho apresentado no Capítulo 3, em que uma metodologia similar será replicada para quatro áreas de estudo representativas das características hidro-climáticas da América do Sul, a fim de identificar potencialidade e limitações de variáveis estimadas por sensoriamento remoto na calibração de modelos hidrológicos e de melhorar a representação de processos hidrológicos.

4.2 Métodos

4.2.1 Desenho experimental

O presente estudo investiga a melhora na representação do ciclo hidrológico na modelagem hidrológica através da calibração dos parâmetros do modelo com variáveis estimadas por sensoriamento remoto. Para isso, o modelo hidrológico-hidrodinâmico MGB foi testado para quatro bacias hidrográficas representativas de características hidro-climáticas da América do Sul. O conjunto de parâmetros iniciais é igual para todas as bacias, de acordo com sua variabilidade reportada na literatura. O estudo é então dividido em duas partes.

Primeiramente, é realizada uma análise de sensibilidade para entender as incertezas dos parâmetros e as correlações entre as variáveis de estado do modelo.

Depois, há a calibração do modelo com o algoritmo MOCOM-UA, considerando cinco variáveis: (1) vazão medida in-situ no exutório da bacia; e variáveis estimadas por sensoriamento remoto: (2) variações no nível (uma estação virtual de altimetria), (3)

anomalias no armazenamento de água (TWS); (4) evapotranspiração e (5) umidade do solo. As variáveis (3), (4) e (5) são consideradas como um valor médio para toda a bacia. A calibração para cada variável é realizada individualmente, e avaliada para todas as outras variáveis, conforme ilustrado na Figura 4-1. O modelo é calibrado e avaliado para o mesmo período (2009-2012), dadas as limitações na disponibilidade de observações de SR simultaneamente.

Diferentemente do estudo de Meyer et al. (2020), estimativas por sensoriamento remoto de Áreas Inundadas não foram utilizadas, em função da contribuição nula desta variável em regiões que não apresentam planícies de inundação.

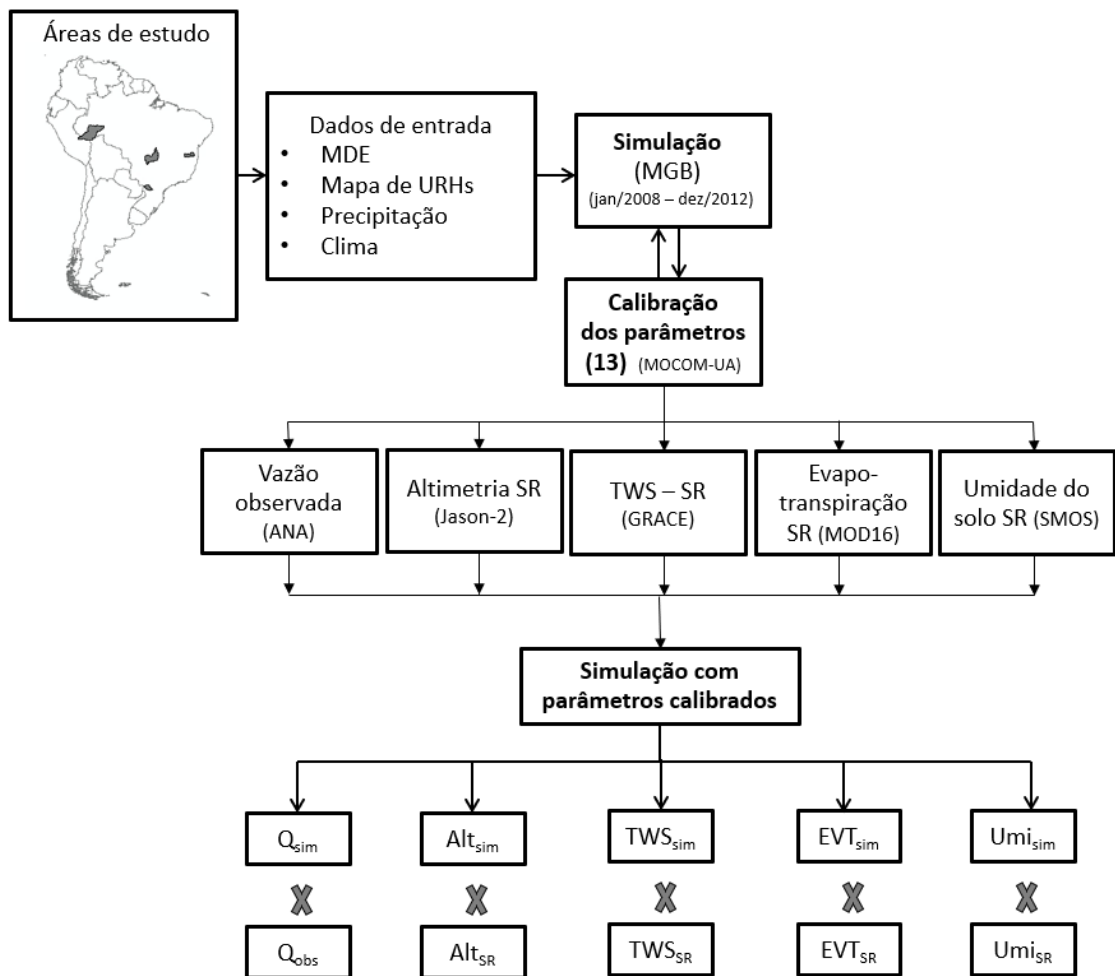


Figura 4-1. Esquema simplificado dos experimentos propostos para o presente estudo. O modelo MGB é alimentado com dados de entrada, gera saídas de diversas variáveis. Os parâmetros do modelo são calibrados com observações (in-situ, para vazão; de SR, para as demais variáveis). As saídas do modelo calibrado são validadas com base nas observações das diversas variáveis.

O modelo hidrológico-hidrodinâmico MGB (Collischonn et al., 2007; Pontes et al., 2017) é capaz de representar os processos hidrológicos em passo de tempo diário e discretização em unidades de resposta hidrológica (URHs), conforme características de tipo de solo e seu uso e ocupação. São consideradas diferentes áreas de estudo na América do Sul, a fim de abranger diferentes regiões hidro-climáticas.

4.2.2 Áreas de estudo

Para o presente estudo, foram escolhidas quatro bacias hidrográficas da América do Sul, a fim de abranger e representar diferentes regiões hidro-climáticas, com dinâmicas hidrológicas diferenciadas (e.g., com e sem planícies de inundação; regiões de clima equatorial, tropical, semi-árido; tipos e usos e ocupações do solo diversos; diferentes áreas de drenagem). Além disso, foram excluídas as bacias com forte influência antrópica, como por exemplo regiões com reservatórios que influenciam no regime dos rios. O terceiro critério de escolha das áreas de estudo foi a disponibilidade de estações fluviométricas com dados de vazão de 2009 a 2011, que são os anos em que há intersecção das séries temporais dos produtos de sensoriamento utilizados. Além disso, apenas bacias hidrográficas com área de drenagem maior que 20000 km² foram consideradas, pois trata-se de uma escala compatível com as observações de sensoriamento remoto.

De acordo com os critérios apresentados, foram escolhidas quatro bacias hidrográficas, são elas: as bacias do rio Purus, representativa do bioma *Amazônico*; a bacia do rio Araguaia, na região do *Cerrado*; o rio Pardo, em transição para a região árida do nordeste brasileiro (*Caatinga*); e o rio Piquiri no região sul do Brasil, no bioma de *Mata Atlântica*. A Figura 4-2 apresenta a localização das bacias hidrográficas consideradas no presente estudo, no contexto da classificação climática de Koeppen-Geiger (Kottek et al., 2006), com as respectivas caracterizações das bacias hidrográficas: áreas de drenagem (A), IA (índice de aridez), coeficiente de escoamento (C), precipitação total anual (P) e vazão média anual (Q). São também apresentados hidrogramas observados para o ano de 2009 (em mm/dia) nas estações fluviométricas consideradas em cada uma das bacias delimitadas (Tabela 4-1). Ainda na Figura 4-2, são apresentados os mapas de precipitação média anual, evapotranspiração potencial, índice de aridez, coeficiente de escoamento e biomas brasileiros espacializados no contexto da América do Sul.

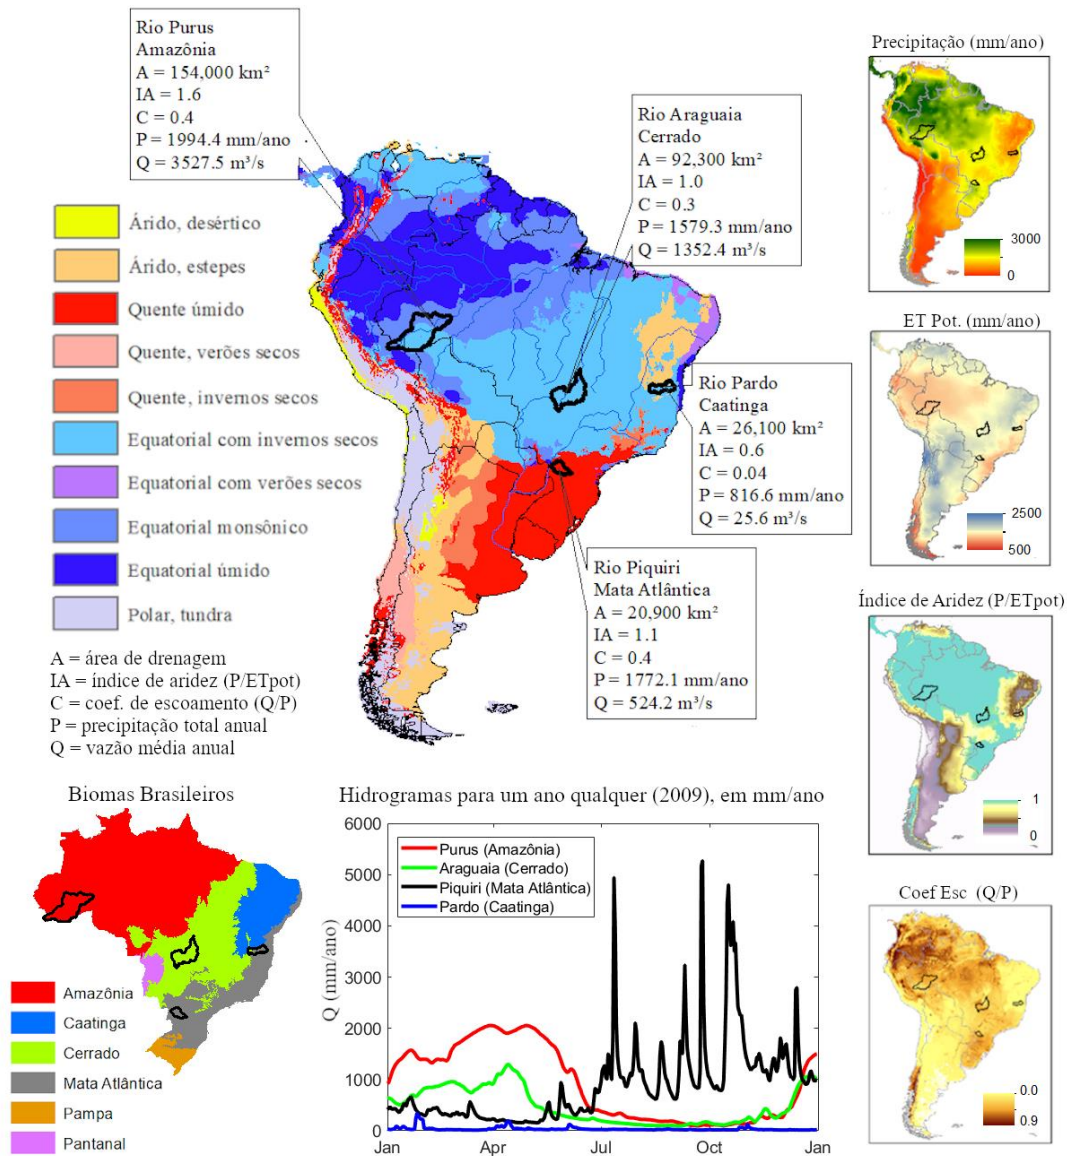


Figura 4-2. Caracterização das bacias hidrográficas consideradas no presente estudo (Purus - Amazônia, Araguaia - Cerrado, Pardo - Caatinga, Piquiri – Mata Atlântica). A = área de drenagem; IA = índice de aridez; C = coeficiente de escoamento; P = precipitação total anual; Q = vazão média anual. Mapa de classificação climática de Koeppen-Geiger (Kottek et al., 2006); precipitação total anual para a América do Sul (Fick & Hijmans, 2017); evapotranspiração potencial e índice de aridez (Zommer et al., 2008); coeficiente de escoamento com vazões simuladas por Siqueira et al. (2018); mapa de biomas brasileiros (IBGE). Hidrogramas observados para um ano qualquer (2009) nas estações fluviométricas especificadas na Tabela 4-1 (Hidroweb, ANA).

Os valores de área de drenagem (A) foram estimados em software de geoprocessamento, a partir da delimitação das bacias. Os valores de índice de aridez (IA) e de evapotranspiração potencial (PET) foram extraídos para as áreas de estudo a partir da base de dados “Global Aridity and PET Database”, com resolução espacial de 30 arc

segundos, disponibilizada por (Zomer et al., 2008). O índice de aridez (IA) é calculado como a precipitação anual média, dividida pela evapotranspiração potencial anual média ($IA = P/ET_{pot}$). Os valores de precipitação extraídos para as regiões de interesse foram obtidos através da interpolação das isoietas anuais, disponibilizadas no Atlas Pluviométrico do Brasil (Pinto et al., 2011). Os valores de coeficiente de escoamento, dado por $C = Q / P$, foram calculados a partir de séries históricas de vazão disponibilizados pela Agência Nacional das Águas (ANA), cujos valores de vazão média anual são também apresentados na caracterização das áreas de estudo.

As áreas de drenagem das bacias hidrográficas consideradas variam de 20900 km² (rio Piquiri) a 154000 km² (rio Purus); os valores de coeficiente de escoamento variam entre 0.04 (rio Pardo) e 0.4; os menores valores de vazão média (cerca de 25 m³/s) ocorrem também no rio Pardo, e os maiores valores de vazão média ocorrem no rio Purus, chegando a 3500 m³/s (Amazônia), o que evidencia diferentes magnitudes de vazão; o índice de aridez varia entre 0.6 (classificado como “seco sub-úmido”, no rio Pardo) e 1.6 (“úmido”, no rio Purus, na Amazônia). Valores de precipitação total anual seguem também este padrão, com o menor valor em cerca de 800 mm/ano para o rio Pardo, e cerca de 2000 mm/ano para o rio Purus. Os regimes hidrológicos são diferenciados, conforme ilustrado no hidrogramas da Figura 4-2, em que nos rios Purus e Araguaia existe uma sazonalidade bem definida, enquanto nos rios Piquiri e Pardo, existem vários picos ao longo do ano.

Com base nessa caracterização, verifica-se que as áreas de estudo abrangem diferentes dinâmicas hidrológicas e regiões hidro-climáticas da América do Sul: o rio Piquiri é representativo de bacias do sul do país, sem sazonalidade definida, vários picos no hidrogramas ao longo do ano, e alto coeficiente de escoamento (0.4), situados no bioma *Mapa Atlântica*, que sofre grande influência antrópica. Por outro lado, o rio Purus é representativo do bioma *amazônico*, com vegetação densa, baixa influência antrópica, sazonalidade bem definida, alta magnitude dos valores de vazão, e largas planícies de inundação. O rio Araguaia também apresenta planícies de inundação e sazonalidade bem definida, mas grande influência antrópica, característica do bioma *Cerrado*. O rio Pardo é representativo de bacias áridas, com baixo coeficiente de escoamento, e situa-se na transição entre outros biomas e a *Caatinga*.

4.2.3 O modelo MGB

Foi utilizado o modelo MGB (Modelo de Grandes Bacias), desenvolvido por Collischonn (2001), em sua versão mais atual aperfeiçoada por Pontes et al. (2017).

A escolha do modelo se deu principalmente em função de que o modelo já foi amplamente aplicado com sucesso em bacias hidrográficas da América do Sul (e.g., Siqueira et al., 2018), tem seu código disponibilizado livremente na página do grupo de Hidrologia de Grande Escala (“<https://www.ufrgs.br/hge/mgb-iph/>”), e em função da experiência do grupo de pesquisa em que o trabalho foi desenvolvido (Addor & Melsen, 2018).

O modelo MGB simula as etapas do ciclo hidrológico: balanço de água no solo, evapotranspiração, interceptação, geração de escoamento (superficial, sub-superficial e subterrâneo) e propagação de vazões na rede de drenagem. A bacia hidrográfica é discretizada em unidades menores de simulação (minibacias), as quais são sub-divididas em Unidades de Resposta Hidrológica (URHs), conforme características de uso e tipo de solo e de vegetação. Para cada URH, são computados os processos hidrológicos verticais, cujo resultado é propagado a jusante a nível de minibacia, conforme ilustrado na Figura 4-3.

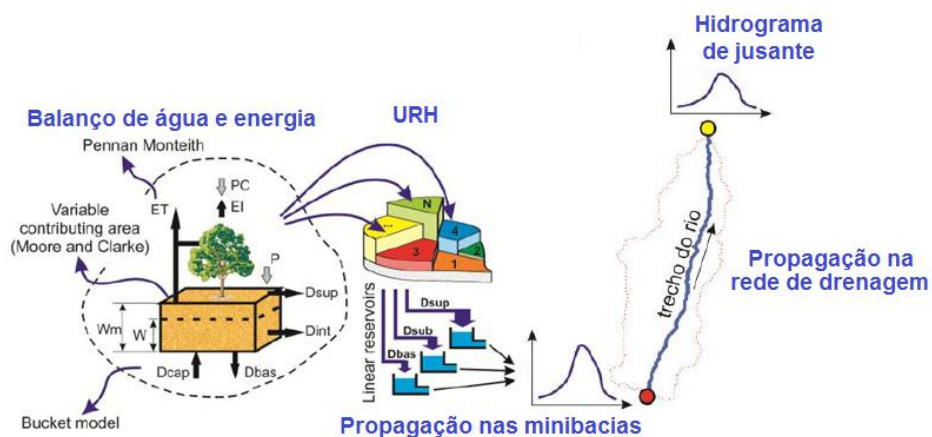


Figura 4-3. Panorama geral do modelo MGB-IPH. Fonte: adaptado de Paiva (2012) e Pontes et al. (2017).

Os processos hidrológicos verticais incluem balanço de água no solo, interceptação, evapotranspiração e geração de escoamento (superficial, sub-superficial e subterrâneo). A evapotranspiração é calculada pelo método de Penman-Monteith. A geração de escoamento considera um processo Dunniano, em que o escoamento é gerado apenas em áreas saturadas, sendo que o escoamento dentro de cada minibacia é propagado

pelo método de reservatórios lineares. O balanço hídrico no solo é apresentado na Equação (4-1).

$$W^t = W^{t-1} + (P - ET - D_{sup} - D_{int} - D_{bas} + D_{cap}) \quad (4-1)$$

Em que W [mm] é o volume de água armazenado no solo, P [mm] é a precipitação que chega ao solo, ET [mm] representa as perdas por evapotranspiração, D_{sup} [mm] é o escoamento superficial, D_{int} [mm] é o escoamento sub-superficial, D_{bas} [mm] é o escoamento subterrâneo e D_{cap} [mm] representa o fluxo ascendente do aquífero ao solo.

A propagação do escoamento na rede de drenagem, no MGB, pode ser realizada através do método Muskingum-Cunge ou do modelo inercial. Enquanto o método Muskingum-Cunge pode ser adequado em alguns casos e apresenta um custo computacional menor, o modelo inercial é mais acurado, especialmente em rios com baixa declividade, planícies de inundação ou efeitos de remanso (Pontes et al., 2017), fornecendo também estimativas de áreas inundadas ou de nível d'água, motivos pelos quais o modelo inercial foi adotado como método de propagação do escoamento no presente estudo. Para a aplicação do MGB, o modelo dispõe de interface gráfica em software livre (QGIS), que facilita a preparação do modelo e a visualização de seus resultados.

4.2.4 Incerteza a priori dos parâmetros do modelo

No modelo MGB, existem parâmetros relacionados a cobertura vegetal (índice de área foliar (IAF), altura da vegetação, resistência superficial), hidráulica (n de Manning, e parâmetros de largura e de profundidade dos rios relacionados através de relações geomorfológicas), e parâmetros conceituais relacionados ao solo (W_m , b , k_{bas} , k_{int} , CI , CS , CB), que são detalhados no material suplementar (Table 3-S2, ANEXO 2).

Neste estudo, cada bacia apresenta apenas um conjunto de parâmetros, que são sub-divididos em 9 Unidades de Resposta Hidrológica (URHs) (Figura 4-4). Parâmetros de solo são uniformes para todas as URHs, mas parâmetros de vegetação apresentam diferenças (altura de vegetação, IAF e resistência superficial são diferentes para as classes floresta e não-floresta).

A incerteza a priori dos parâmetros do modelo é estimada com base em sua variabilidade reportada na literatura A Tabela 3-S2 (ANEXO 2) apresenta os parâmetros

de calibração, seus valores iniciais, faixas, e as referências que suportam esses valores (e.g., Andreadis et al., 2013; Shuttleworth, 1989; Siqueira et al., 2018).

4.2.5 Análise de sensibilidade

Para entender a incerteza dos parâmetros, o modelo foi simulado 100 vezes, considerando quatro configurações: (1) variando apenas parâmetros do solo; (2) variando apenas parâmetros da vegetação; (3) variando apenas parâmetros hidráulicos; (4) variando todos os parâmetros. O intervalo escolhido para variação dos parâmetros é especificado na Tabela 3-S2.

Os parâmetros foram variados considerando uma distribuição uniforme, e os resultados foram analisados em termos de *RMSD* (“root mean square deviation”, ou raiz quadrada do erro médio) de cada variável, através da comparação de cada simulação com uma simulação de referência (conjunto inicial de parâmetros). Esse procedimento foi feito para entender as fontes das incertezas relacionadas a diferentes tipos de parâmetros (e.g., estimativas de nível d’água no rio são sensíveis a parâmetros de vegetação?).

4.2.6 Calibração do modelo

A calibração dos parâmetros no presente estudo é realizada de forma automática, através do algoritmo genético multi-objetivo MOCOM-UA, proposto por (Yapo et al., 1998), já implementado ao modelo MGB, em função de sua performance satisfatória quando acoplado a modelos hidrológicos (e.g., Collischonn et al., 2008; Maurer et al., 2009; Naz et al., 2014). Trata-se de um método que busca otimizar as funções-objetivo através de classificação e hierarquização das soluções por critérios de dominância e não dominância. O resultado da otimização é dado como um conjunto de indivíduos igualmente ótimos (curva de Pareto).

Inicialmente, devem ser informados valores iniciais para os parâmetros do modelo, bem como os seus limites mínimos e máximos, que estão relacionados na Tabela 3-S2 (ANEXO 2). Além disso, existem parâmetros da otimização que também devem ser especificados, como o número de indivíduos em cada geração (tamanho da população, que é de 100 indivíduos neste estudo), e as funções-objetivo a serem otimizadas.

A escolha das funções-objetivo se deu em função de sua aplicabilidade para a calibração das variáveis consideradas. Por exemplo, a métrica de Nash-Log não poderia ser utilizada, já que as séries de TWS e de altimetria apresentam valores negativos. Sendo assim, foram escolhidas a minimização de três funções-objetivo de mesmo peso:

$FO(1) = (r - 1)^2$, que leva em conta o coeficiente de correlação (r); $FO(2) = (\alpha - 1)^2$, que leva em conta a razão entre desvio padrão das variáveis simuladas e observadas (α), $FO(3) = (\beta - 1)^2$, que considera a razão entre suas médias (β), em que FO é função-objetivo. A otimização via termos do KGE foi também utilizada por Colossi et al. (2018), mas timidamente explorada na literatura científica. No entanto, a otimização de métricas como coeficiente de correlação, média e desvio padrão entre duas séries apresenta fundamentos lógicos para que as séries se aproximem.

Os três termos apresentados, $FO(1)$, $FO(2)$ e $FO(3)$, compõem a métrica chamada de coeficiente Kling-Gupta (KGE, Gupta et al., 2009), dada pela Equação (4-5). O KGE pode variar de valores negativos até 1, que representa seu valor ótimo.

$$KGE = 1 - \sqrt{(r - 1)^2 + (\alpha - 1)^2 + (\beta - 1)^2} \quad (4-5)$$

4.2.7 Dados de entrada do modelo

O modelo digital de elevação utilizado provém da missão *Shuttle Radar Topography Mission* (SRTM), de resolução espacial de 90 m, que foi utilizado para gerar a rede de drenagem e a discretização da bacia com o pacote IPH-HydroTools (Siqueira, et al., 2016). No pré-processamento, para geração de curva cota-área, no entanto, foi utilizado o MERIT DEM (Yamazaki et al., 2017).

Minibacias foram discretizadas através da segmentação da rede de drenagem em trechos de comprimentos fixos de 10 km, resultando em 2182 minibacias na bacia do rio Purus, 1527 minibacias para Araguaia, 1020 minibacias para Piquiri, e 1196, Pardo.

Tipos e usos do solo foram extraídos do Mapa de Unidades de Resposta Hidrológica da América do Sul desenvolvido por (Fan et al., 2015), que considera 9 tipos de unidades de resposta hidrológica, conforme apresentado na Figura 4-4 extraído para as áreas de estudo.

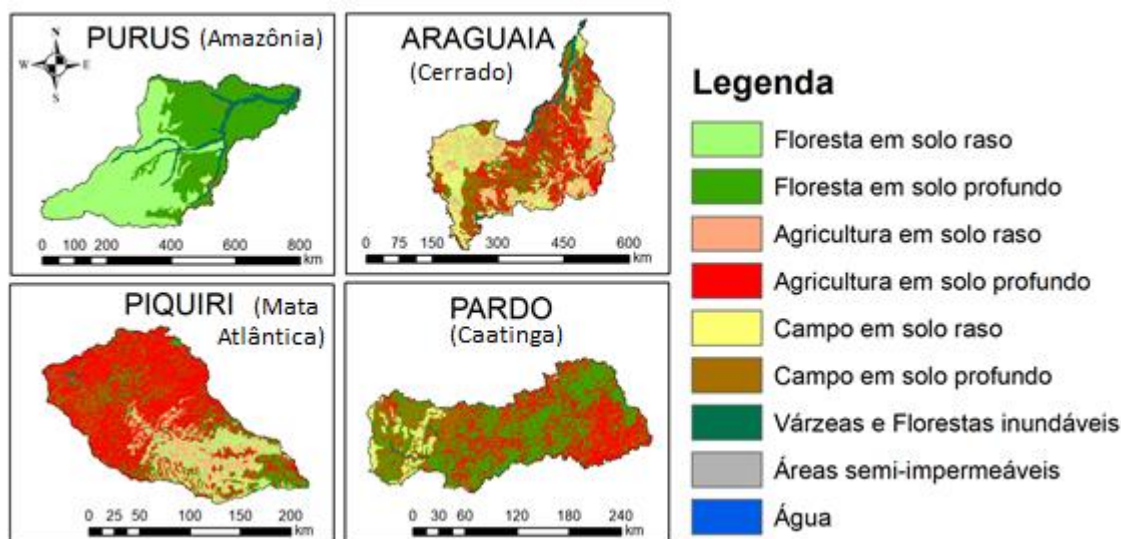


Figura 4-4. Mapa de Unidades de Resposta Hidrológica (URHs) das regiões de estudo.

Com base na análise da Figura 4-4, observa-se que na bacia do rio Purus existem várzeas, bem como predominância de florestas. Na bacia do rio Araguaia também existem várzeas, e não existe a predominância de alguma URH com relação às outras através de inspeção visual. A agricultura é pronunciada na bacia do rio Piquiri, também existindo na bacia do rio Pardo. No rio Pardo, ainda, destaca-se a predominância de solos profundos (mais de 90%), seguido pelo Piquiri (76% de solos profundos), enquanto que nas outras duas regiões não se destacam solos rasos ou profundos.

Dados de precipitação diários são provenientes do produto diário TMPA 3B42, em sua sétima versão, com resolução espacial de $0.25^\circ \times 0.25^\circ$ (Huffman et al., 2007), que foram extraídos e interpolados pelo método do inverso da distância ao quadrado, para o centroide de cada minibacia, através de ferramenta disponível no software MGB.

Dados de clima, tais como temperatura média do ar, umidade relativa do ar, insolação, velocidade do vento e pressão atmosférica, são provenientes da base de dados CRU (“Climatic Research Unit”), disponíveis em resolução espacial de intervalos de 10 arcminutos, obtidas a partir da interpolação para todo o globo de dados de estações meteorológicas adquiridos de 1961 a 1990 (New et al., 2000), foram inseridos como dados de entrada no modelo como normais climatológicas (médias mensais de longo período).

4.2.8 Dados de calibração/avaliação e compatibilização com o MGB

4.2.8.1 Vazão

Dados diários de vazão são provenientes das estações fluviométricas da Agência Nacional de Águas (ANA) relacionadas na Tabela 4-1, disponibilizadas no portal Hidroweb <<http://www.snirh.gov.br/hidroweb/publico/apresentacao.jsf>>,. A localização das estações fluviométricas é também apresentada na Figura 4-5. Na Figura 4-5, são também apresentadas estações virtuais de altimetria, que serão discutidas no item 4.2.8.2 *Altimetria espacial (Jason-2)*.

Tabela 4-1. Estações fluviométricas das áreas de estudo consideradas

Código	Nome	Rio	Bioma	Lat.	Lon.	Área (km ²)	Período com dados
13750000	Seringal Fortaleza	Purus	Amazônia	-7.71	-66.99	154,000	1967-2016
25700000	Bandeirantes	Araguaia	Cerrado	-13.68	-50.8	92,300	1974-2019
64830000	Balsa Santa Maria	Piquiri	Mata Atlântica	-24.18	-53.74	20,900	1969-2014
53790000	Couro Dantas	Pardo	Caatinga	-15.39	-40.06	26,100	1963-2019




Figura 4-5. Mapa das redes de drenagem das áreas de estudo, em que é apresentada a localização das estações fluviométricas e das estações virtuais para estimativa de nível d'água.

4.2.8.2 Altimetria espacial (Jason-2)

O altímetro Jason-2 foi escolhido por apresentar a melhor resolução temporal, de 10 dias. Apresenta distância entre os traços de aproximadamente 300km na linha do Equador (Lambin et al., 2010), séries temporais desde 2008, e uma acurácia de aproximadamente 0.28 m (Jarihani et al., 2013). Estações virtuais para as regiões de estudo são apresentadas na Figura 4-5, que mostra as intersecções dos traços dos altímetros com as redes hidrográficas.

As séries históricas de altimetria são provenientes do projeto Pistach, distribuído pela Aviso em parceria com o CNES (“<ftp://ftpsedr.cls.fr/pub/oceano/pistach/J2/IGDR/hydro/>”). Em rotina preparada no MATLAB, foram extraídos os dados das estações virtuais de interesse, e corrigidos de acordo com as recomendações presentes no “Coastal and Hydrology Altimetry product (PISTACH) handbook” (Mercier et al., 2010). Os números de órbitas correspondentes às estações virtuais são: Purus (165), Araguaia (228), Piquiri (076) e Pardo (024).

Para a compatibilização com o MGB, os valores de ambas as séries (x) foram padronizados através da subtração pelas suas médias (μ), em função de diferenças nos referenciais de nível.

4.2.8.3 Armazenamento de água terrestre (GRACE)

A missão GRACE (“Gravity Recovery and Climate Mission”), lançada em 2002, adquire informações do potencial gravitacional terrestre, que podem ser correlacionadas com o armazenamento de água terrestre (TWS) (Swenson, 2002). Apresenta resolução espacial de aproximadamente 333 km e resolução temporal de um mês, em geral.

No presente estudo, são utilizados produtos com resolução espacial de 100 km, disponibilizados pelas agências JPL, GFZ e CSR, disponíveis em (“<https://grace.jpl.nasa.gov/data/get-data/>”), extraídos para as bacias hidrográficas de interesse, com a multiplicação de fatores de escala recomendada por (Swenson & Wahr, 2006). Os valores estão computados em milímetros, em termos de anomalias relativas à média histórica de 2004 a 2009.

No MGB, para cada intervalo de tempo, os valores de anomalias no armazenamento foram acumulados, resultando em estimativas de volumes mensais. Os

volumes extraídos do MGB foram subtraídos de sua média, e divididos pela área da bacia, a fim de comparar as séries históricas em termos de anomalias em milímetros.

4.2.8.4 Evapotranspiração (MOD16)

O produto de evapotranspiração (MOD16) provém da aplicação de uma série de algoritmos baseados em índices de vegetação sobre as imagens do MODIS (“Moderate-Resolution Imaging Spectroradiometer”), acopladas a meteorologia de reanálise, além de outros produtos como classificação de uso da terra e diversas parametrizações (Mu et al., 2013).

O produto MOD16 utilizado apresenta resolução espacial de 1 km² e resolução temporal mensal, sendo disponibilizado pela Universidade de Montana (“<http://www.ntsug.umt.edu/project/modis/mod16.php>”). As séries históricas são extraídas para as bacias hidrográficas de interesse, em que é computado o valor médio de evapotranspiração para a bacia inteira. No entanto, a evapotranspiração proveniente do MOD16 corresponde apenas a áreas vegetadas (ou seja, evaporação de água aberta não é computada). Embora o MGB calcule evapotranspiração de áreas inundadas e da vegetação para realizar o balanço hídrico, apenas a evapotranspiração proveniente da vegetação foi comparada ao MOD-16. Os dados de evapotranspiração do MOD16 e do MGB foram comparados em milímetros, em valores absolutos mensais.

4.2.8.5 Umidade do Solo (SMOS)

A missão “Soil Moisture and Ocean Salinity” (SMOS) oferece informações de umidade do solo desde 2009, a nível global, com resolução espacial de aproximadamente 25km, para a camada superficial do solo, através de um radiômetro que registra a temperatura de brilho da superfície terrestre, que é relacionada com a umidade do solo através do algoritmo descrito em Kerr et al. (2012).

Foi adotado o produto de umidade do solo do SMOS disponibilizado pelo “*Centre Aval de Traitement des Données SMOS*” em Nível 4 de processamento, que corresponde ao produto diário de umidade do solo na “zona de raízes” (de 0 a 1m) (Bitar et al., 2013).

Os dados foram então extraídos para a região de interesse, em que é computado o valor médio de umidade do solo para a bacia inteira. Considerando que o MGB calcula o grau de saturação do solo (%), o produto de umidade do solo do SMOS foi reescalado para comparação com o MGB, através da equação 4-6, proposta por Tarpanelli et al.

(2013) e utilizada também em outros estudos (e.g., Rajib et al., 2016; Silvestro et al., 2015):

$$SM_{reescalado}(\%) = \frac{SM - SM_{MÍNIMO}}{SM_{MÁXIMO} - SM_{MÍNIMO}} \quad (4-6)$$

4.2.8.6 Sumário dos produtos de sensoriamento remoto

A Tabela 4-2 apresenta um resumo dos produtos de sensoriamento remoto utilizados no presente estudo e a respectiva variável de compatibilização com o MGB.

Tabela 4-2. Sumário dos produtos de sensoriamento remoto utilizados no estudo.

Produto	Variável Hidrológica	Descrição Geral	Res. Espacial	Res. Temporal	Período	Variável de compatibilização MGB	Link para download dos dados
Jason-2	Altimetria	Radar (micro-ondas), pulso à nadir	315 km*	9.9 dias	2008-atual	anomalias de valores instantâneos (x - u), metros.	ftp://ftpsedr.cls.fr/pub/oceano/pistach/J2/IGDR/hydro/
GRACE	Armazenamento de água	2 satélites, potencial gravitacional	100 km	~30 dias	2002-2017	Média para a bacia de anomalias mensais (x-u), mm.	https://grace.jpl.nasa.gov/data/get-data/
MOD-16	Evapotranspiração	Índices de vegetação	1 km	8 dias	2000-atual	Média para a bacia de totais mensais, mm.	http://www.nts.gov/modis/mod16.php
SMOS	Umidade do solo	Radiômetro (temperatura de brilho)	25 km	1 dia	2010-atual	Média para a bacia do grau de saturação do solo diário (%).	ftp://ext-catds-cecsm.catds2010@ftp.ifremer.fr/Land_products/L4_Root_Zone_Soil_Moisture/

*distância entre os traços

O presente estudo considera a simulação do ano de 2008 a 2011, com o ano de 2008 de “aquecimento” do modelo, em função da abrangência temporal em que há intersecção dos produtos de sensoriamento remoto.

4.2.9 Avaliação dos resultados

A performance das simulações do modelo com os parâmetros calibrados é avaliada através do coeficiente de Kling-Gupta (KGE), apresentado na Equação (4-5), em que são comparadas séries simuladas e observadas de cada uma das variáveis.

Para avaliação do desempenho da calibração com cada uma das variáveis, foi utilizado um “skill score” (em português, “índice de melhora”) (Zajak et al., 2017) apresentado na Equação 4-7.

$$S = \frac{KGE_{calibrado} - KGE_{não-calibrado}}{1 - KGE_{não-calibrado}} \quad (4-7)$$

Estudos futuros devem também considerar a possibilidade de avaliação dos resultados em comparação com o KGE resultante da calibração com a vazão, ao invés do KGE resultante da dispersão inicial dos parâmetros ($KGE_{não-calibrado}$).

4.3 Resultados e discussão

Nos próximos itens, são apresentados os resultados da análise de sensibilidade dos diferentes conjuntos de parâmetros do modelo e suas influências nas múltiplas variáveis analisadas (item 4.3.1. Análise de sensibilidade), e da calibração/avaliação do modelo com vazão, níveis, TWS, evapotranspiração e umidade do solo (item 4.3.2. Calibração/Avaliação do modelo), para as quatro áreas de estudo consideradas (Purus, representativa da *Amazônia*; Araguaia, representativo do *Cerrado*; Piquiri, representativo da *Mata Atlântica*; e Pardo, representativo da *Caatinga*).

4.3.1 Análise de sensibilidade

A Figura 4-6 apresenta os resultados da análise de sensibilidade para as quatro áreas de estudo.

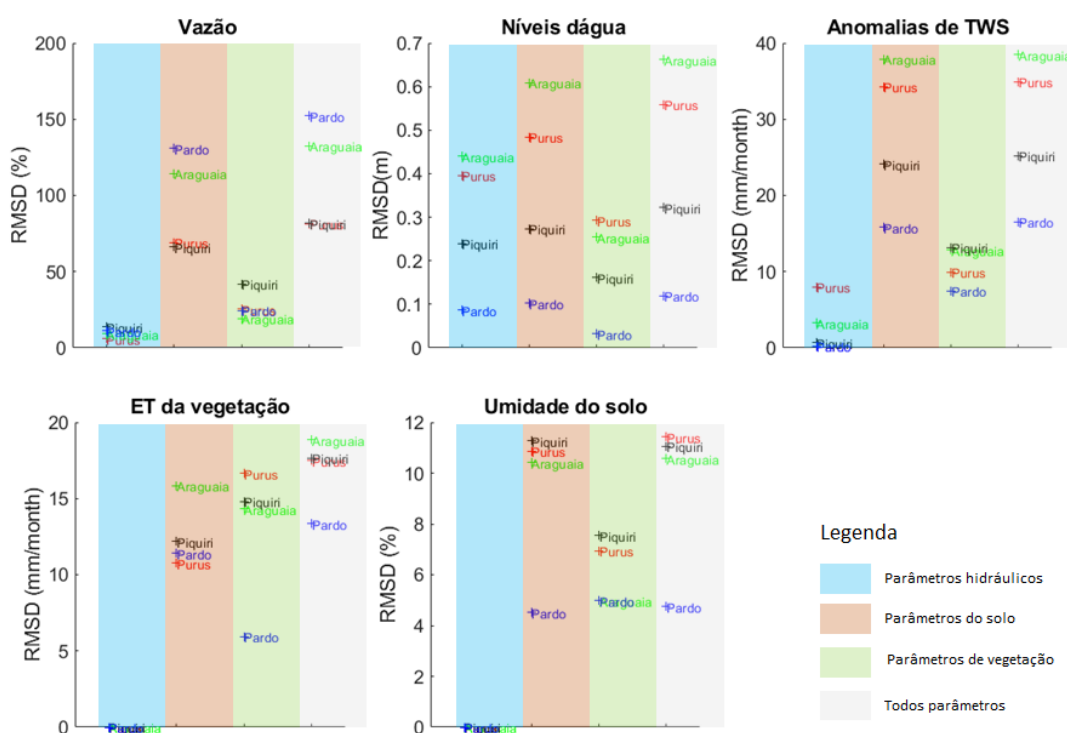


Figura 4-6. Análise de sensibilidade para diferentes saídas do modelo (vazão, níveis, TWS, ET e umidade do solo), considerando a variação de e diferentes conjuntos de parâmetros (hidráulicos, solo, vegetação, todos).

Estimativas de vazão e de TWS seguem o mesmo padrão para as quatro áreas de estudo: a sensibilidade total sofre maior influência de parâmetros de solo, seguido por parâmetros de vegetação e, por último, parâmetros hidráulicos. No entanto, para as estimativas de TWS, nos rios Piquiri e Pardo, a influência dos parâmetros hidráulicos é

quase nula, sendo mais pronunciada nos rios Purus e Araguaia. Isso pode ter relação com os rios Purus e Araguaia apresentarem planícies de inundação, em que a influência de parâmetros hidráulicos é maior.

Nas estimativas de nível d'água, os parâmetros hidráulicos também se destacam exatamente para os rios com planícies de inundação: Purus e Araguaia. Em geral, estimativas de variações nos níveis d'água seguem o mesmo padrão para todas as áreas: parâmetros de solo, seguido de parâmetros hidráulicos e, por último, parâmetros de vegetação.

Estimativas de evapotranspiração da vegetação e umidade do solo estão relacionados a processos hidrológicos verticais, por isso, não são sensíveis a parâmetros hidráulicos, como esperado. Além disso, estimativas de ET e umidade do solo não seguem o mesmo padrão para todas as áreas. Para a ET, Purus e Piquiri apresentam maior sensibilidade aos parâmetros de vegetação (como esperado), enquanto que Pardo e Araguaia apresentam maior sensibilidade a parâmetros de solo. Isso indica que, no Pardo e no Araguaia, a ET está sendo controlada por parâmetros relacionados à disponibilidade de água no solo, enquanto que no Purus e no Piquiri, a ET é mais fortemente controlada pelas características da vegetação.

Para a umidade do solo, Purus, Araguaia e Piquiri apresentam maior sensibilidade aos parâmetros de solo (como esperado). O rio Pardo apresenta aproximadamente a mesma sensibilidade aos parâmetros de solo e de vegetação.

Em comparação com o estudo de Meyer et al. (2020), para a bacia do rio Purus, os resultados da análise de sensibilidade são consistentes, com a única exceção de que, para vazão e TWS, a influência de parâmetros hidráulicos era maior no estudo de Meyer et al. (2020) do que neste. Isso se dá provavelmente em função de que a bacia do rio Purus delimitada no presente estudo é menor (154 mil km², em comparação com 236 mil km² no estudo anterior).

Em geral, a análise de sensibilidade realizada poderia contribuir com estratégias mais eficientes para a etapa de calibração dos parâmetros. Por exemplo, parâmetros hidráulicos não seriam calibrados com ET ou com umidade do solo. No entanto, neste estudo, a calibração proposta envolve todos os parâmetros, independentemente do resultado da análise de sensibilidade, a fim verificar posteriormente se a calibração

“acertou pelos motivos certos”, por exemplo, ou se acertou a evapotranspiração com a calibração de parâmetros hidráulicos (“acertar pelos motivos errados”).

No estudo de Meyer et al. (2020), em figura análoga à Figura 4-6, foram apresentados os erros documentados para as estimativas de SR (e.g., TWS 20mm/mês, ou MOD16 23 mm/mês). No presente estudo, as incertezas das “observações” não foram consideradas de forma quantitativa, já que a acurácia das estimativas de SR pode variar em diferentes bacias, em função de interferência do tipo de vegetação, da escala da bacia, da largura do rio, do regime climático, entre outros fatores.

4.3.2 Calibração/Avaliação do modelo

Na Figura 4-7 e Figura 4-S1 (ANEXO 5), são apresentados os resultados da calibração/avaliação do modelo para múltiplas variáveis, nas quatro áreas de estudo.

4.3.2.1 A calibração com variáveis estimadas por SR melhora estimativas de vazão?

No Purus, bacia representativa da Amazônia, a calibração com TWS e ET melhoram as estimativas de vazão em 29.5% e 20.0%, respectivamente. Este resultado está de acordo com os resultados apresentados por Meyer et al. (2020), com exceção de que a umidade do solo também melhorou as estimativas de vazão no estudo prévio, enquanto neste estudo, a calibração com umidade do solo não apresentou melhora significativa nas estimativas de vazão.

No Araguaia, bacia representativa do Cerrado, nenhuma variável estimada por SR foi capaz de melhorar vazão. A calibração com as variáveis estimadas por SR superestimaram as vazões, principalmente nos períodos secos (Figura 4-S1, ANEXO 5). Este resultado pode indicar que a dinâmica do escoamento de base não está sendo corretamente representada na estruturação do modelo, ou que a parametrização a priori relativa ao escoamento de base situa-se muito distante da parametrização ideal para este tipo de bacia.

Na bacia do bioma Mata Atlântica (rio Piquiri), ET e umidade do solo melhoraram vazão (Skill Score em torno de 12%). Estimativas de níveis e de TWS, por outro lado, não se destacaram nem mesmo quando calibradas com suas próprias observações (i.e., calibração com nível não foi capaz de melhorar significativamente estimativas de nível, e o mesmo para TWS). Isso se dá provavelmente em função de que bacias da região sul apresentam comportamento não sazonal, de forma que estimativas de variações no TWS

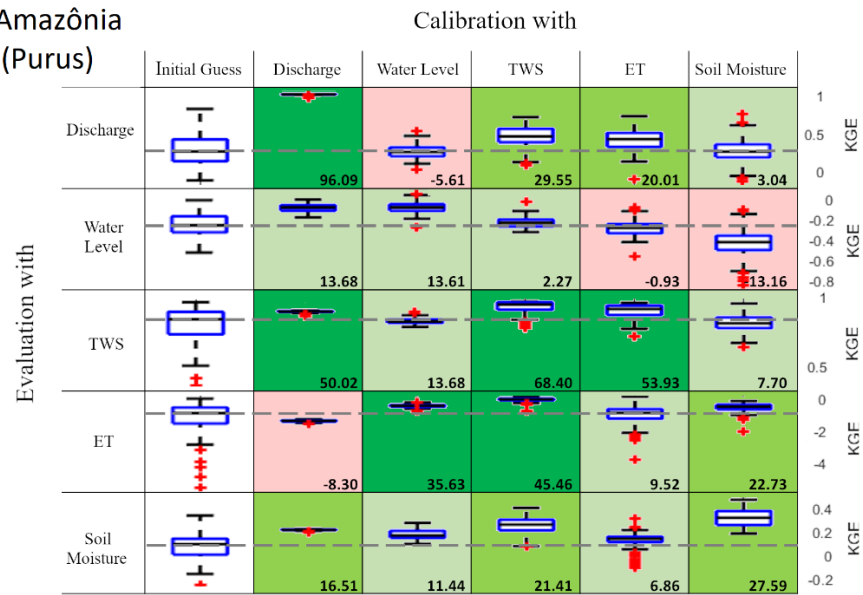
são muito pequenas, e esta informação não contribui efetivamente para a calibração do modelo. Ainda, bacias do bioma Mata Atlântica apresentam comportamento “rápido”, de forma que estimativas de nível a cada 10 dias podem não contribuir de forma efetiva para caracterização da dinâmica hidráulica.

Na bacia árida (rio Pardo), ET melhorou estimativas de vazão ($S = 33.6\%$). No entanto, na Figura 4-S1 (ANEXO 5), observa-se nos hidrogramas que nenhuma estimativa de SR é capaz de representar a ordem de grandeza de vazão corretamente. Isso se dá provavelmente em função de que a parametrização a priori do modelo situa-se muito distante da parametrização ideal para este tipo de bacia. Estudos futuros devem considerar estimativas a priori dos parâmetros variáveis conforme características hidro-climáticas específicas de cada bacia.

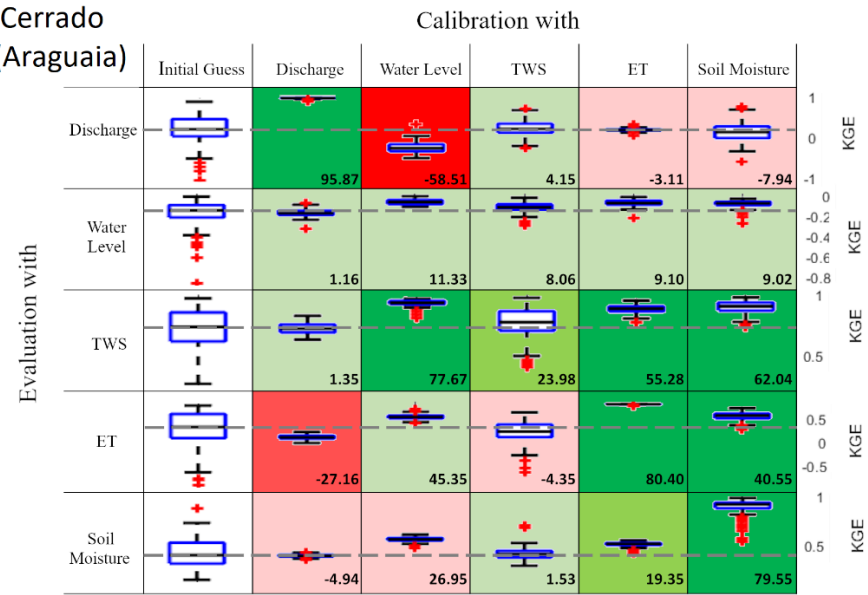
Em alguns casos, no entanto, estimativas de SR não contribuíram para melhorar as estimativas de vazão, o que pode ser em função de incertezas nas observações ou inconsistências estruturais ou na parametrização do modelo. Estes resultados são coerentes com o estudo de Dembele et al. (2020), por exemplo, que mostra que a melhora em estimativas de umidade do solo e evapotranspiração é acompanhada de uma degradação nas estimativas de vazão e de TWS.

Em outros casos as estimativas de SR de variáveis como ET, umidade do solo e TWS implicaram em melhoras nas estimativas de vazão. Este resultado concorda com estudos prévios de López et al. (2017) ou Nijzink et al. (2018), que encontraram boas performances de vazão através da calibração com ET e umidade do solo, e umidade do solo e TWS, respectivamente. De forma geral, a variável que mais se destacou na melhora das estimativas de vazão para as quatro bacias analisadas foi a evapotranspiração estimada pelo MOD-16. Estes resultados são especialmente relevantes no contexto da iniciativa de “Prediction in Ungauged Basins” (Hrachowitz et al., 2013; Sivapalan et al., 2003).


Amazônia (Purus)



Cerrado (Araguaia)



Mata Atlântica (Piquiri)



Caatinga (Pardo)


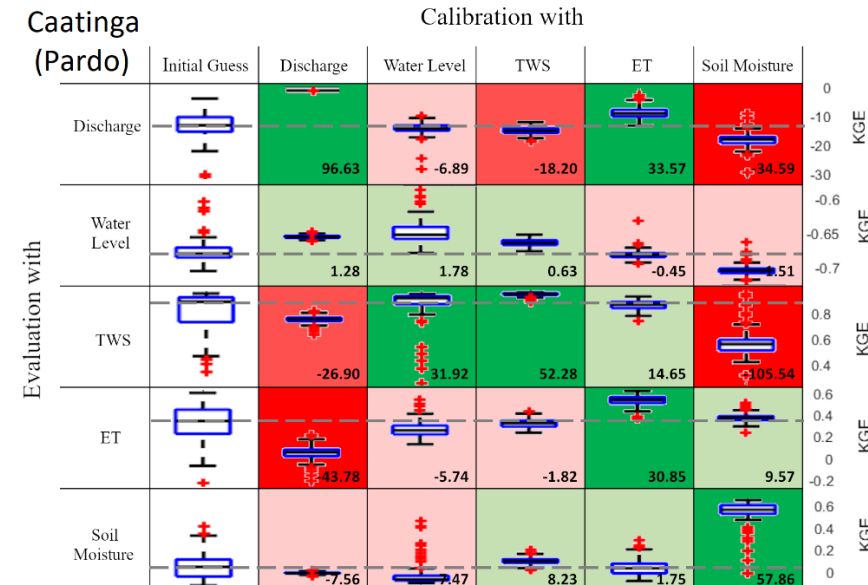


Figura 4-7. Boxplots dos valores de KGE, acompanhados do “skill scores” (S) para as diferentes variáveis de calibração/avaliação. As cores referem-se a classes de “skill score” (S). As escalas de KGE são diferentes para cada variável.

4.3.2.2 A calibração com variáveis estimadas por SR melhora as estimativas de outras variáveis do ciclo hidrológico?

Em um cenário em que os modelos fossem estruturalmente perfeitos, as parametrizações corretas, e as observações não tivessem incertezas, a calibração com uma variável deveria sempre melhorar as estimativas de outras variáveis. No entanto, não é isso que ocorre. Dentre as quatro áreas de estudo analisadas, a bacia da Mata Atlântica (Piquiri) é a que apresenta melhores índices de desempenho, seguido da bacia representativa da Amazônia (Purus), Cerrado (Araguaia) e, por último, Caatinga (Pardo).

No caso da bacia da Amazônia (Purus), estimativas de TWS se destacam como capazes de melhorar não apenas TWS, mas também vazão, ET e umidade do solo. Este resultado contrasta com o que foi encontrado por Meyer et al. (2020), para o rio Purus delimitado até uma área de drenagem maior, em que TWS não piorava as estimativas de outras variáveis, mas também não era relevante para melhorar estas estimativas.

Ainda no rio Purus, calibração com ET e umidade do solo melhoraram estimativas de outras variáveis, mas pioraram estimativas de nível. A calibração com nível degradou as estimativas de vazão, mas melhorou as estimativas de todas as outras variáveis, o que está de acordo com o que foi encontrado por Meyer et al. (2020). Esta inconsistência entre calibração de nível e vazão ocorre também nos rios Araguaia e Pardo, e pode ser em função de que a calibração com nível é específica para a localização da estação virtual, de forma que seria vantajoso fazer uso de mais estações virtuais (como os estudos de Kittel et al., 2018; Schneider et al., 2017), em função de que a calibração com vazão não leva a ajustes satisfatórios para os parâmetros hidráulicos do modelo, ou em função de incertezas nas estimativas de nível do presente estudo (que os dados de altimetria foram extraídos, porém as séries temporais não foram filtradas).

No rio Purus, a calibração com vazão melhorou estimativas de outras variáveis, com exceção de ET, resultado que já havia sido apresentado por Meyer et al. (2020), provavelmente em função de que o modelo não representa o acesso profundo das raízes das árvores na estação seca, de forma que a calibração com vazão não possibilita estimativas satisfatórias de ET.

No caso do bioma Mata Atlântica, na bacia do rio Piquiri, a principal contribuição de estimativas de SR é de umidade do solo, que melhora as estimativas de todas as outras variáveis (provavelmente em função de ser uma bacia predominantemente de solos

profundos). Embora a calibração com nível pareça melhorar as estimativas de nível e de outras variáveis também, provavelmente não é confiável, em função de que o KGE mediano após a calibração ainda é baixo (- 0.47). A calibração com nível nesta bacia provavelmente não é efetiva em função de seu comportamento “rápido”. TWS também não contribui significativamente para a calibração do modelo, provavelmente em função de que as variações de armazenamento na bacia são muito baixas.

No caso da bacia representativa do Cerrado (Araguaia), destacam-se as variáveis ET e umidade do solo, que melhoram as estimativas uma da outra, mas também de TWS. No entanto, trata-se de um modelo que parece ter alguma inconsistência estrutural, ou erros significativos nas estimativas de SR, já que a calibração com ET, nível e umidade do solo pioram estimativas de vazão, bem como as validações com ET e umidade do solo parecem discordar do restante das observações.

No caso da bacia árida (rio Pardo), ou o modelo está estruturalmente incorreto, ou as estimativas de SR não são confiáveis. Como é um rio menor, há maior probabilidade de que as observações de SR não sejam suficientemente acuradas para esta escala de aplicação. Apesar disso, calibração com ET foi capaz de melhorar vazão ($S = 33\%$), provavelmente em função de que em bacias áridas, o fluxo de evapotranspiração parece exercer grande influência nas vazões.

Dentre as quatro áreas de estudo, o modelo mais consistente (i.e., calibração com uma variável resulta em melhora das outras) é o da bacia representativa da Mata Atlântica (Piquiri), enquanto os outros modelos parecem apresentar alguma deficiência estrutural ou na parametrização. Uma alternativa para que os modelos apresentem melhores usos das informações de SR seria uma estimativa de parâmetros a priori mais acurada de acordo com as características hidro-climáticas das bacias: no caso da bacia amazônica, capacidades de armazenamento de água no solo mais altas; no caso da bacia do Cerrado, diminuição do parâmetro relacionado ao escoamento de base; no caso da bacia mais seca, ajuste de parâmetros que permitam valores mais altos de evapotranspiração.

Estudos futuros devem também explorar a possibilidade de eliminar os conjuntos de parâmetros que não melhorem as estimativas das outras variáveis, de forma que, através de uma calibração sequencial, possa-se encontrar um conjunto de parâmetros que seja ótimo para todas as variáveis.

4.3.2.3 O modelo está “acertando pelos motivos certos”?

Na Figura 4-8 e Figura 4-S2 (ANEXO 6), são apresentados os resultados da dispersão dos parâmetros antes e depois da calibração com múltiplas variáveis.

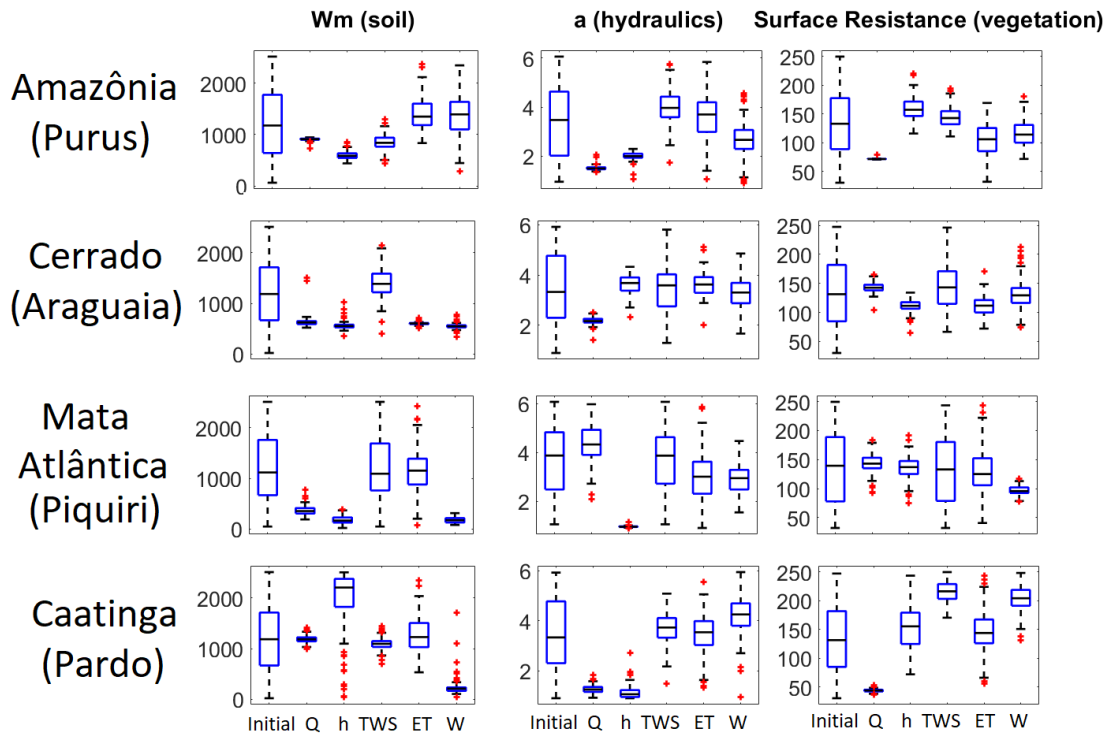


Figura 4-8. Boxplots dos parâmetros.

Na maioria dos casos, com a calibração, a dispersão dos parâmetros é menor do que a dispersão inicial. Com relação ao W_m (capacidade máxima de armazenamento de água no solo), no Purus a calibração com vazão, nível e TWS convergiu para valores mais baixos, enquanto a calibração com ET e umidade do solo convergiu para valores mais altos. No Araguaia, a calibração com TWS convergiu para valores de W_m mais altos, mas as outras calibrações convergiram para valores próximos. Valores próximos também foram encontrados para W_m no Piquiri com a calibração de vazão, nível e umidade do solo. E para o Pardo, vazão e TWS. Em geral, valores altos de W_m foram encontrados na bacia do rio Purus, o que é consistente com seu alto percentual de solos profundos; valores altos de W_m também foram encontrados para a bacia do rio Purus, a fim de compensar o acesso às raízes profundas na região amazônica.

O mesmo tipo de análise poderia ser conduzido para os outros parâmetros do modelo, mas são muitos parâmetros, variáveis e fatores que interagem. O que pode ser analisado, de forma geral, é que os parâmetros resultantes de diferentes calibrações muitas

vezes divergem, de forma que em muitos casos o modelo “acerta pelos motivos errados”, mesmo que não tenhamos certeza de qual é o certo e qual é o errado, podemos afirmar pelo menos que o modelo, dependendo da estratégia de calibração, “acerta por motivos diferentes”. É interessante observar que a diferença nos parâmetros entre calibrações com diferentes variáveis é até mesmo maior que a diferença entre as diferentes regiões de estudo.

A calibração com variáveis como vazão, nível e TWS influenciam na dispersão dos parâmetros hidráulicos. No rio Piquiri, por exemplo, o parâmetro “*a*” (multiplicador da largura na relação geomorfológica), quando calibrado com nível, conduz a valores de “*a*” na ordem de 0.5, mas a calibração com outras variáveis conduz a valores de “*a*” maiores que 2.0. Os resultados para parâmetros hidráulicos e de vegetação são especialmente relevantes, pois na maior parte das aplicações do MGB, eles são estimados a priori. Desta forma, é interessante comparar qual seria a estimativa a priori com o resultado da calibração com diferentes variáveis. De forma preliminar, na Figura 4-9, é apresentada esta comparação para o rio Purus apenas, considerando os valores da mediana das relações geomorfológicas resultantes da calibração, e as relações documentadas por Paiva (2013). Em estudos futuros, devem ser comparadas as relações geomorfológicas para outras áreas de estudo, bem como devem ser comparadas as estimativas dos parâmetros de vegetação.




Figura 4-9. Relações geomorfológicas (largura e profundidade em função da área de drenagem) calibradas (Q, h, TWS, ET, W) e estimadas in-situ para o rio Purus

Para a bacia do rio Purus, todas as calibrações superestimam as larguras dos rios, sendo que a calibração com vazão (seguida por nível) são as que mais se aproximam da estimativa in-situ. Em um ponto da bacia com área de drenagem de 100,000 km², por exemplo, a largura estimada in-situ é cerca de 236m, a largura mediana estimada com a

calibração com dados de vazão é aproximadamente 374m, e a calibração com dados de nível converge para 500m, enquanto a calibração com estimativas de ET e TWS convergem para larguras medianas de cerca de 1000m. Para as profundidades, a calibração com dados de níveis é a que mais se aproxima das estimativas in-situ, sendo que a um ponto a 100,000 km² de área de drenagem, a profundidade estimada na pior calibração (TWS) é de aproximadamente 8m, na melhor calibração (nível) é de cerca de 11m, e a estimativa in-situ é de 15m. No entanto, a uma área de drenagem de aproximadamente 400,000km², as profundidades estimadas in-situ e pela calibração com nível concordam (18m).

4.4 Conclusões

Um modelo hidrológico-hidrodinâmico (MGB) foi calibrado com vazão, e com quatro variáveis estimadas por sensoriamento remoto (SR): níveis (Jason-2), anomalias no armazenamento terrestre (TWS, GRACE), evapotranspiração (ET, MOD16) e umidade do solo (SMOS), para quatro bacias hidrográficas representativas de diferentes regiões hidro-climáticas brasileiras: Amazônia (Purus), Cerrado (Araguaia), Mata Atlântica (Piquiri) e Caatinga (Pardo), a fim de avaliar a contribuição das estimativas por SR para a modelagem de variáveis hidrológicas.

Resultados indicam que em alguns casos a calibração com variáveis de SR melhorou estimativas de vazão: calibração com TWS e ET na bacia do bioma amazônico; calibração com umidade do solo e ET na Mata Atlântica; calibração com ET na bacia árida. De forma geral, a variável ET, estimada pelo MOD-16, foi a que ofereceu mais contribuições às estimativas de vazão, o que é relevante no contexto de Predição de Vazões em Bacias Não Monitoradas (Prediction in Ungauged Basins, PUB).

Para a estimativa de outras variáveis do ciclo hidrológico, alguns resultados são positivos: calibração com umidade do solo em geral melhora evapotranspiração, calibração com níveis em geral melhora TWS, entre outros. No entanto, a calibração com uma variável nem sempre implica na melhora de outra, o que indica que as observações apresentam incertezas, ou que a estruturação ou parametrização do modelo está incorreta. Dentre as quatro áreas de estudo, o modelo mais consistente (i.e., calibração com uma variável resulta em melhora das outras) é o da bacia representativa da Mata Atlântica

(Piquiri), seguido pela bacia da Amazônia (Purus), Cerrado (Araguaia) e Caatinga (Pardo). Estudos futuros devem investigar o impacto na consistência dos modelos considerando uma estimativa a priori de parâmetros mais acurada de acordo com as características hidro-climáticas de cada região.

Em geral, o modelo convergiu para diferentes conjuntos de parâmetros, dependendo da variável de calibração. Isto salienta que, a depender da variável de calibração, o modelo “acerta por motivos diferentes”, embora não seja possível ter certeza qual das variáveis conduz a “motivos certos” ou a “motivos errados”. A abordagem de utilizar diferentes variáveis estimadas por SR se mostrou útil para melhorar a representação na modelagem de variáveis hidrológicas (além de vazão).

CAPÍTULO 5. **Considerações finais**

Este estudo avaliou as potencialidades e limitações do uso de variáveis hidrológicas estimadas por sensoriamento remoto para a calibração e avaliação de modelos hidrológicos, a fim de torná-los mais realistas. Para isso, foi realizada uma revisão bibliográfica na literatura científica, em que foram identificados 64 estudos que se utilizaram de sensoriamento remoto para a calibração de modelos hidrológicos. Nos estudos prévios, poucos analisaram a contribuição de múltiplas variáveis para a calibração (em geral duas ou três variáveis), ou verificaram o impacto da metodologia proposta para a estimativa de outras variáveis do ciclo hidrológico (além de vazão). Sendo assim, o presente estudo se propôs a preencher estas lacunas no conhecimento, através da consideração de um número expressivo de variáveis (i.e., vazão, níveis, área inundada, TWS, evapotranspiração e umidade do solo). A metodologia foi testada para uma área de estudo no rio Purus, na Amazônia, e depois replicada de forma simplificada para bacias representativas de diferentes condições hidro-climáticas na América do Sul.

No estudo com o rio Purus, o método proposto melhorou as estimativas de vazão de 16% a 48%, com observações de SR de TWS, ET e umidade do solo; bem como melhorar estimativas de outras variáveis do ciclo hidrológico (e.g., calibração com níveis melhorou estimativas de níveis, mas também áreas inundadas, TWS e ET). Além disso, foi possível salientar inconsistências na estruturação e na parametrização do modelo, que passariam despercebidas, se apenas observações de vazão fossem consideradas para a calibração do modelo. Sendo assim, a abordagem proposta se mostrou útil para uma modelagem mais realista de variáveis hidrológicas (além de vazão). Em um estudo mais amplo, com outras 3 bacias representativas de diferentes regiões hidro-climáticas, foram ratificadas as potencialidades do uso de observações de SR para melhorar a representação do ciclo hidrológico em modelos, embora a contribuição de cada variável seja diferente entre as bacias analisadas. No geral, a variável que mais se destacou foi a evapotranspiração.

Neste estudo, diversas questões científicas e operacionais foram levantadas, que não foram exploradas em todo o seu potencial, como por exemplo: calibração de parâmetros de vegetação ou de parâmetros hidráulicos das relações geomorfológicas; estimativas a priori de parâmetros mais acuradas de acordo com características das bacias; utilização de séries temporais mais extensas, e de períodos diferentes para calibração e avaliação; calibração considerando métricas espaciais; outros algoritmos de otimização mais eficientes; funções-objetivo diferentes em função da variável considerada; consideração

explícita das incertezas das observações no processo de calibração; calibração multi-variável; entre outros. Estes são tópicos de relevância para estudos futuros.

De forma geral, o estudo realizado contemplou dois grandes eixos de pesquisa: representação de processos hidrológicos em modelos; e observações da superfície terrestre por satélites (*Earth Observation from Space*). A intersecção destes dois eixos revelou potencialidades para uma melhor compreensão do ciclo hidrológico, estimativa de vazões em bacias não monitoradas, bem como contribuições do sensoriamento remoto para a modelagem hidrológica. Os métodos, resultados e conclusões apresentados revelam oportunidades para avanços científicos na compreensão de processos hidrológicos através da calibração de modelos com variáveis estimadas por sensoriamento remoto.

Referências

- Abbott, M. B., Bathurst, J. C., Cunge, J. A., O'Connell, P. E., & Rasmussen, J. (1986). An introduction to the European Hydrological System - Systeme Hydrologique Europeen, "SHE", 1: History and philosophy of a physically-based, distributed modelling system. *Journal of Hydrology*. [https://doi.org/10.1016/0022-1694\(86\)90114-9](https://doi.org/10.1016/0022-1694(86)90114-9)
- Addor, N. & Melsen, L.A. (2018). Legacy, rather than adequacy, drives the selection of hydrological models. *Water Resources Research*. <https://doi.org/10.1029/2018WR022958>
- Ahmadisharaf, E., Kalyanapu, A. J., & Bates, P. D. (2018). A probabilistic framework for floodplain mapping using hydrological modeling and unsteady hydraulic modeling. *Hydrological Sciences Journal*. <https://doi.org/10.1080/02626667.2018.1525615>
- Aires, F. (2014). Combining Datasets of Satellite-Retrieved Products. Part I: Methodology and Water Budget Closure. *Journal of Hydrometeorology*. <https://doi.org/10.1175/jhm-d-13-0148.1>
- Albergel, C., Rüdiger, C., Pellarin, T., Calvet, J. C., Fritz, N., Froissard, F., et al. (2008). From near-surface to root-zone soil moisture using an exponential filter: An assessment of the method based on in-situ observations and model simulations. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-12-1323-2008>
- Alkama, R., Decharme, B., Douville, H., Becker, M., Cazenave, A., Sheffield, J., et al. (2010). Global evaluation of the ISBA-TRIP continental hydrological system. Part I: Comparison to GRACE terrestrial water storage estimates and in situ river discharges. *Journal of Hydrometeorology*. <https://doi.org/10.1175/2010JHM1211.1>
- Alley, W. M. (1984). On the Treatment of Evapotranspiration, Soil Moisture Accounting, and Aquifer Recharge in Monthly Water Balance Models. *Water Resources Research*. <https://doi.org/10.1029/WR020i008p01137>
- Anderson, M. C., Zolin, C. A., Sentelhas, P. C., Hain, C. R., Semmens, K., Tugrul Yilmaz, M., et al. (2016). The Evaporative Stress Index as an indicator of agricultural drought in Brazil: An assessment based on crop yield impacts. *Remote Sensing of Environment*. <https://doi.org/10.1016/j.rse.2015.11.034>
- Andreadis, K. M., Schumann, G. J. P., & Pavelsky, T. (2013). A simple global river bankfull width and depth database. *Water Resources Research*. <https://doi.org/10.1002/wrcr.20440>
- Arnold, J. G., Moriasi, D. N., Gassman, P. W., Abbaspour, K. C., White, M. J., Srinivasan, R., et al. (2012). SWAT: Model use, calibration, and validation. *Transactions of the ASABE*. <https://doi.org/10.13031/2013.42259>
- Asadzadeh Jarihani, A., Callow, J. N., Johansen, K., & Gouweleeuw, B. (2013). Evaluation of multiple satellite altimetry data for studying inland water bodies and river floods. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2013.09.010>

- Di Baldassarre, G., & Montanari, A. (2009). Uncertainty in river discharge observations: A quantitative analysis. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-13-913-2009>
- Baroni, G., Schalge, B., Rakovec, O., Kumar, R., Schüler, L., Samaniego, L., et al. (2019). A Comprehensive Distributed Hydrological Modeling Intercomparison to Support Process Representation and Data Collection Strategies. *Water Resources Research*. <https://doi.org/10.1029/2018WR023941>
- Bates, P. D., & De Roo, A. P. J. (2000). A simple raster-based model for flood inundation simulation. *Journal of Hydrology*. [https://doi.org/10.1016/S0022-1694\(00\)00278-X](https://doi.org/10.1016/S0022-1694(00)00278-X)
- Bates, Paul D., Horritt, M. S., & Fewtrell, T. J. (2010). A simple inertial formulation of the shallow water equations for efficient two-dimensional flood inundation modelling. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2010.03.027>
- Becker, R., Koppa, A., Schulz, S., Usman, M., aus der Beek, T., & Schüth, C. (2019). Spatially distributed model calibration of a highly managed hydrological system using remote sensing-derived ET data. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2019.123944>
- Van Beek, L. P. H., Wada, Y., & Bierkens, M. F. P. (2011). Global monthly water stress: 1. Water balance and water availability. *Water Resources Research*. <https://doi.org/10.1029/2010WR009791>
- Beven, K. (2006). A manifesto for the equifinality thesis. In *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2005.07.007>
- Beven, K. (2012). *Rainfall-Runoff Modelling: The Primer: Second Edition*. *Rainfall-Runoff Modelling: The Primer: Second Edition*. <https://doi.org/10.1002/9781119951001>
- Beven, K., & Binley, A. (1992). The future of distributed models: Model calibration and uncertainty prediction. *Hydrological Processes*. <https://doi.org/10.1002/hyp.3360060305>
- Biggs, T. W., Petropoulos, G. P., Velpuri, N. M., Marshall, M., Glenn, E. P., Nagler, P., & Messina, A. (2015). Remote sensing of actual evapotranspiration from croplands. In *Remote Sensing of Water Resources, Disasters, and Urban Studies*. <https://doi.org/10.1201/b19321>
- Bitar, A.A. et al. The global SMOS Level 3 daily soil moisture and brightness temperature maps. *Earth System Science Data*, 9(1), pp.293-315. 2017.
- Bosmans, J. H. C., Van Beek, L. P. H., Sutanudjaja, E. H., & Bierkens, M. F. P. (2017). Hydrological impacts of global land cover change and human water use. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-21-5603-2017>
- Brêda, J. P. L. F., Paiva, R. C. D., Bravo, J. M., Passaia, O. A., & Moreira, D. M. (2019). Assimilation of Satellite Altimetry Data for Effective River Bathymetry. *Water Resources Research*. <https://doi.org/10.1029/2018wr024010>
- Burnash, Robert JC, R. Larry Ferral, and Robert A. McGuire. A generalized streamflow simulation system: Conceptual modeling for digital computers. US Department of

Commerce, National Weather Service, and State of California, Department of Water Resources, 1973.

- Calmant, S., & Seyler, F. (2006). Continental surface waters from satellite altimetry. *Comptes Rendus - Geoscience*. <https://doi.org/10.1016/j.crte.2006.05.012>
- Campo, L., Caparrini, F., & Castelli, F. (2006). Use of multi-platform, multi-temporal remote-sensing data for calibration of a distributed hydrological model: An application in the Arno basin, Italy. *Hydrological Processes*. <https://doi.org/10.1002/hyp.6061>
- Chang, C. H., Lee, H., Hossain, F., Basnayake, S., Jayasinghe, S., Chishtie, F., et al. (2019). A model-aided satellite-altimetry-based flood forecasting system for the Mekong River. *Environmental Modelling and Software*. <https://doi.org/10.1016/j.envsoft.2018.11.017>
- Chapman, B., McDonald, K., Shimada, M., Rosenqvist, A., Schroeder, R., & Hess, L. (2015). Mapping regional inundation with spaceborne L-Band SAR. *Remote Sensing*. <https://doi.org/10.3390/rs70505440>
- Chen, J. M., Chen, X., Ju, W., & Geng, X. (2005). Distributed hydrological model for mapping evapotranspiration using remote sensing inputs. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2004.08.029>
- Chow, V. T. (1959). *Open-Channel Hydraulics*. Ven Te Chow. McGraw-Hill, New York, 1959. xviii + 680 pp. Illus. \$17. Science.
- Ciarapica, L., & Todini, E. (2002). TOPKAPI: A model for the representation of the rainfall-runoff process at different scales. *Hydrological Processes*. <https://doi.org/10.1002/hyp.342>
- Clark, M. P., & Kavetski, D. (2010). Ancient numerical demons of conceptual hydrological modeling: 1. Fidelity and efficiency of time stepping schemes. *Water Resources Research*. <https://doi.org/10.1029/2009WR008894>
- Clark, M. P., Fan, Y., Lawrence, D. M., Adam, J. C., Bolster, D., Gochis, D. J., et al. (2015). Improving the representation of hydrologic processes in Earth System Models. *Water Resources Research*. <https://doi.org/10.1002/2015WR017096>
- Collischonn, W. Simulação Hidrológica de Grandes Bacias. Tese (Doutorado em Recursos Hídricos) - Curso de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental, Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2001.
- Collischonn, B., Collischonn, W., & Tucci, C. E. M. (2008). Daily hydrological modeling in the Amazon basin using TRMM rainfall estimates. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2008.07.032>
- Collischonn, W., Allasia, D., da Silva, B. C., & Tucci, C. E. M. (2007). The MGB-IPH model for large-scale rainfall-runoff modelling. *Hydrological Sciences Journal*. <https://doi.org/10.1623/hysj.52.5.878>

- Colossi, B. et al. Using SMOS for validation and parameter estimation of a large scale hydrological model in Paraná river basin. In EGU General Assembly Conference Abstracts, Viena, Áustria, 2017. p. 9360.
- Colwell, R. (1983). *Manual of Remote Sensing*. 2nd. *Edition, Falls*.
- Corbari, C., & Mancini, M. (2014). Calibration and validation of a distributed energy-water balance model using satellite data of land surface temperature and ground discharge measurements. *Journal of Hydrometeorology*. <https://doi.org/10.1175/JHM-D-12-0173.1>
- Crawford, N. H., & Linsley, R. K. (1966). Digital simulation in hydrology: Stanford Watershed Model IV. *Contemporary Hydrology*.
- Croke, B. F. W. (2009). Representing uncertainty in objective functions: Extension to include the influence of serial correlation. In *18th World IMACS Congress and MODSIM09 International Congress on Modelling and Simulation: Interfacing Modelling and Simulation with Mathematical and Computational Sciences, Proceedings*.
- Da Paz, A. R. et al. Discretização de modelos hidrológicos de grande escala: grade regular x mini-bacias. In: XIX Simpósio Brasileiro de Recursos Hídricos, Maceió, AL, 2011.
- Crow, W. T., Wood, E. F., & Pan, M. (2003). Multiobjective calibration of land surface model evapotranspiration predictions using streamflow observations and spaceborne surface radiometric temperature retrievals. *Journal of Geophysical Research D: Atmospheres*.
- Deb, K., Pratap, A., Agarwal, S., & Meyarivan, T. (2002). A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*. <https://doi.org/10.1109/4235.996017>
- Dembélé, M., Hrachowitz, M., Savenije, H. H. G., Mariéthoz, G., & Schaefli, B. (2020). Improving the Predictive Skill of a Distributed Hydrological Model by Calibration on Spatial Patterns With Multiple Satellite Data Sets. *Water Resources Research*. <https://doi.org/10.1029/2019WR026085>
- Demirel, Mehmet C., Mai, J., Mendiguren, G., Koch, J., Samaniego, L., & Stisen, S. (2018). Combining satellite data and appropriate objective functions for improved spatial pattern performance of a distributed hydrologic model. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-22-1299-2018>
- Demirel, Mehmet Cüneyd, Özen, A., Orta, S., Toker, E., Demir, H. K., Ekmekcioğlu, Ö., et al. (2019). Additional value of using satellite-based soil moisture and two sources of groundwater data for hydrological model calibration. *Water (Switzerland)*. <https://doi.org/10.3390/w11102083>
- Devia, G. K., Ganasri, B. P., & Dwarakish, G. S. (2015). A Review on Hydrological Models. *Aquatic Procedia*. <https://doi.org/10.1016/j.aqpro.2015.02.126>
- Döll, P., Kaspar, F., & Lehner, B. (2003). A global hydrological model for deriving water availability indicators: Model tuning and validation. *Journal of Hydrology*. [https://doi.org/10.1016/S0022-1694\(02\)00283-4](https://doi.org/10.1016/S0022-1694(02)00283-4)

- Dong, Q., Zhan, C., Wang, H., Wang, F., & Zhu, M. (2016). A review on evapotranspiration data assimilation based on hydrological models. *Journal of Geographical Sciences*. <https://doi.org/10.1007/s11442-016-1265-4>
- Doughty, C. E., & Goulden, M. L. (2009). Seasonal patterns of tropical forest leaf area index and CO₂ exchange. *Journal of Geophysical Research: Biogeosciences*. <https://doi.org/10.1029/2007JG000590>
- Duan, Q., Sorooshian, S., & Gupta, V. (1992). Effective and efficient global optimization for conceptual rainfall-runoff models. *Water Resources Research*. <https://doi.org/10.1029/91WR02985>
- Engeland, K., Steinsland, I., Johansen, S. S., Petersen-Øverleir, A., & Kolberg, S. (2016). Effects of uncertainties in hydrological modelling. A case study of a mountainous catchment in Southern Norway. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2016.02.036>
- Fan, F. M., Buarque, D. C., Pontes, P. R. M., & Collischonn, W. (2015). Um mapa de Unidades de Resposta Hidrológica para a América do Sul. *XXI Simpósio Brasileiro de Recursos Hídricos*.
- Fan, F. M., Pontes, P. R. M., Buarque, D. C., & Collischonn, W. (2017). Evaluation of upper Uruguay river basin (Brazil) operational flood forecasts. *RBRH*. <https://doi.org/10.1590/2318-0331.0217160027>
- Ferreira, P. Influência da seleção das funções objetivo na calibração do modelo hidrológico distribuído MGB-IPH. Dissertação de Mestrado. – Programa de Pós-Graduação em Engenharia Civil e Ambiental, Universidade Federal da Paraíba, 2017.
- Fick, S. E., & Hijmans, R. J. (2017). WorldClim 2: new 1-km spatial resolution climate surfaces for global land areas. *International Journal of Climatology*. <https://doi.org/10.1002/joc.5086>
- Finger, D., Pellicciotti, F., Konz, M., Rimkus, S., & Burlando, P. (2011). The value of glacier mass balance, satellite snow cover images, and hourly discharge for improving the performance of a physically based distributed hydrological model. *Water Resources Research*. <https://doi.org/10.1029/2010WR009824>
- Finger, D., Vis, M., Huss, M., & Seibert, J. (2015). The value of multiple data set calibration versus model complexity for improving the performance of hydrological models in mountain catchments. *Water Resources Research*. <https://doi.org/10.1002/2014WR015712>
- Fisher, J. B., Tu, K. P., & Baldocchi, D. D. (2008). Global estimates of the land-atmosphere water flux based on monthly AVHRR and ISLSCP-II data, validated at 16 FLUXNET sites. *Remote Sensing of Environment*. <https://doi.org/10.1016/j.rse.2007.06.025>
- Fisher, J. B., Melton, F., Middleton, E., Hain, C., Anderson, M., Allen, R., et al. (2017). The future of evapotranspiration: Global requirements for ecosystem functioning, carbon and climate feedbacks, agricultural management, and water resources. *Water Resources Research*. <https://doi.org/10.1002/2016WR020175>

- Foglia, L., Hill, M. C., Mehl, S. W., & Burlando, P. (2009). Sensitivity analysis, calibration, and testing of a distributed hydrological model using error-based weighting and one objective function. *Water Resources Research*. <https://doi.org/10.1029/2008WR007255>
- Franco, A. C. L., & Bonumá, N. B. (2017). Multi-variable SWAT model calibration with remotely sensed evapotranspiration and observed flow. *RBRH*. <https://doi.org/10.1590/2318-0331.011716090>
- Franks, S. W., Gineste, P., Beven, K. J., & Merot, P. (1998). On constraining the predictions of a distributed model: The incorporation of fuzzy estimates of saturated areas into the calibration process. *Water Resources Research*. <https://doi.org/10.1029/97WR03041>
- Franz, K. J., & Karsten, L. R. (2013). Calibration of a distributed snow model using MODIS snow covered area data. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2013.04.026>
- Fread, D.L. (1993). Flow Routing in Handbook of Hydrology, ed. by DR Maidment.
- Freeze, R. A., & Harlan, R. L. (1969). Blueprint for a physically-based, digitally-simulated hydrologic response model. *Journal of Hydrology*. [https://doi.org/10.1016/0022-1694\(69\)90020-1](https://doi.org/10.1016/0022-1694(69)90020-1)
- Gao, Z. Q., Liu, C. S., Gao, W., & Chang, N. B. (2011). A coupled remote sensing and the Surface Energy Balance with Topography Algorithm (SEBTA) to estimate actual evapotranspiration over heterogeneous terrain. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-15-119-2011>
- Getirana, A. C.V., & Peters-Lidard, C. (2013). Estimating water discharge from large radar altimetry datasets. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-17-923-2013>
- Getirana, Augusto C.V. (2010). Integrating spatial altimetry data into the automatic calibration of hydrological models. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2010.04.013>
- Gharari, S., Shafiei, M., Hrachowitz, M., Kumar, R., Fenicia, F., Gupta, H. V., & Savenije, H. H. G. (2014). A constraint-based search algorithm for parameter identification of environmental models. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-18-4861-2014>
- Gomis-Cebolla, J., Jimenez, J. C., Sobrino, J. A., Corbari, C., & Mancini, M. (2019). Intercomparison of remote-sensing based evapotranspiration algorithms over amazonian forests. *International Journal of Applied Earth Observation and Geoinformation*. <https://doi.org/10.1016/j.jag.2019.04.009>
- Grimaldi, S., Schumann, G. J. P., Shokri, A., Walker, J. P., & Pauwels, V. R. N. (2019). Challenges, Opportunities, and Pitfalls for Global Coupled Hydrologic-Hydraulic Modeling of Floods. *Water Resources Research*. <https://doi.org/10.1029/2018WR024289>
- Guetter, A. K., Georgakakos, K. P., & Tsonis, A. A. (1996). Hydrologic applications of satellite data: 2. Flow simulation and soil water estimates. *Journal of Geophysical*

Research Atmospheres. <https://doi.org/10.1029/96jd01655>

- Gupta, H. V., Sorooshian, S., & Yapo, P. O. (1998). Toward improved calibration of hydrologic models: Multiple and noncommensurable measures of information. *Water Resources Research*. <https://doi.org/10.1029/97WR03495>
- Gupta, H. V., Kling, H., Yilmaz, K. K., & Martinez, G. F. (2009). Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2009.08.003>
- Guzha, A. C., Rufino, M. C., Okoth, S., Jacobs, S., & Nóbrega, R. L. B. (2018). Impacts of land use and land cover change on surface runoff, discharge and low flows: Evidence from East Africa. *Journal of Hydrology: Regional Studies*. <https://doi.org/10.1016/j.ejrh.2017.11.005>
- Ha, L. T., Bastiaanssen, W. G. M., van Griensven, A., van Dijk, A. I. J. M., & Senay, G. B. (2018). Calibration of spatially distributed hydrological processes and model parameters in SWAT using remote sensing data and an auto-calibration procedure: A case study in a Vietnamese river basin. *Water (Switzerland)*. <https://doi.org/10.3390/w10020212>
- Haddeland, I., Skaugen, T., & Lettenmaier, D. P. (2006). Anthropogenic impacts on continental surface water fluxes. *Geophysical Research Letters*. <https://doi.org/10.1029/2006GL026047>
- Hasler, N., & Avissar, R. (2007). What controls evapotranspiration in the Amazon basin? *Journal of Hydrometeorology*. <https://doi.org/10.1175/JHM587.1>
- Herman, M. R., Nejadhashemi, A. P., Abouali, M., Hernandez-suarez, S., Daneshvar, F., Zhang, Z., et al. (2017). Evaluating the Role of Evapotranspiration Remote Sensing Data in Improving Hydrological Modeling Predictability. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2017.11.009>
- Herman, M. R., Nejadhashemi, A. P., Abouali, M., Hernandez-Suarez, J. S., Daneshvar, F., Zhang, Z., et al. (2018). Evaluating the role of evapotranspiration remote sensing data in improving hydrological modeling predictability. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2017.11.009>
- Hess, L. L., Melack, J. M., Novo, E. M. L. M., Barbosa, C. C. F., & Gastil, M. (2003). Dual-season mapping of wetland inundation and vegetation for the central Amazon basin. *Remote Sensing of Environment*. <https://doi.org/10.1016/j.rse.2003.04.001>
- Hirpa, F. A., Gebremichael, M., Hopson, T. M., Wojick, R., & Lee, H. (2014). Assimilation of Satellite Soil Moisture Retrievals into a Hydrologic Model for Improving River Discharge. In *Remote Sensing of the Terrestrial Water Cycle*. <https://doi.org/10.1002/9781118872086.ch19>
- Hodges, B. R. (2013). Challenges in continental river dynamics. *Environmental Modelling and Software*. <https://doi.org/10.1016/j.envsoft.2013.08.010>
- Holeman, J. N. (1968). The Sediment Yield of Major Rivers of the World. *Water Resources Research*. <https://doi.org/10.1029/WR004i004p00737>

- Houser, P. R., Shuttleworth, W. J., Famiglietti, J. S., Gupta, H. V., Syed, K. H., & Goodrich, D. C. (1998). Integration of soil moisture remote sensing and hydrologic modeling using data assimilation. *Water Resources Research*. <https://doi.org/10.1029/1998WR900001>
- Hrachowitz, M., Savenije, H. H. G., Blöschl, G., McDonnell, J. J., Sivapalan, M., Pomeroy, J. W., et al. (2013). A decade of Predictions in Ungauged Basins (PUB)-a review. *Hydrological Sciences Journal*. <https://doi.org/10.1080/02626667.2013.803183>
- Hsu, K. -l, Gupta, H. V., & Sorooshian, S. (1995). Artificial Neural Network Modeling of the Rainfall-Runoff Process. *Water Resources Research*. <https://doi.org/10.1029/95WR01955>
- Huffman, G. J., Adler, R. F., Arkin, P., Chang, A., Ferraro, R., Gruber, A., et al. (1997). The Global Precipitation Climatology Project (GPCP) Combined Precipitation Dataset. *Bulletin of the American Meteorological Society*. [https://doi.org/10.1175/1520-0477\(1997\)078<0005:TGPCPG>2.0.CO;2](https://doi.org/10.1175/1520-0477(1997)078<0005:TGPCPG>2.0.CO;2)
- Huffman, G. J., Adler, R. F., Bolvin, D. T., Gu, G., Nelkin, E. J., Bowman, K. P., et al. (2007). The TRMM Multisatellite Precipitation Analysis (TMPA): Quasi-global, multiyear, combined-sensor precipitation estimates at fine scales. *Journal of Hydrometeorology*. <https://doi.org/10.1175/JHM560.1>
- Hunger, M., & Döll, P. (2008). Value of river discharge data for global-scale hydrological modeling. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-12-841-2008>
- Immerzeel, W. W., & Droogers, P. (2008). Calibration of a distributed hydrological model based on satellite evapotranspiration. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2007.11.017>
- Irmak, S., & Mutiibwa, D. (2010). On the dynamics of canopy resistance: Generalized linear estimation and relationships with primary micrometeorological variables. *Water Resources Research*. <https://doi.org/10.1029/2009WR008484>
- Jeffrey C. Neal a, †, Nicholas A. Odoni a, b, Mark A. Trigg a, Jim E. Freer a, Javier Garcia-Pintado c, d, David C. Mason e, et al. (2015). Efficient incorporation of channel cross-section geometry uncertainty into regional and global scale flood inundation models. *Journal of Hydrology*.
- Jiang, D., & Wang, K. (2019). The Role of Satellite-Based Remote Sensing in Improving Simulated Streamflow: A Review. *Water*. <https://doi.org/10.3390/w11081615>
- Junk, W. J. (1997). General Aspects of Floodplain Ecology with Special Reference to Amazonian Floodplains. https://doi.org/10.1007/978-3-662-03416-3_1
- Karthikeyan, L., Pan, M., Wanders, N., Kumar, D. N., & Wood, E. F. (2017a). Four decades of microwave satellite soil moisture observations: Part 1. A review of retrieval algorithms. *Advances in Water Resources*. <https://doi.org/10.1016/j.advwatres.2017.09.006>
- Karthikeyan, L., Pan, M., Wanders, N., Kumar, D. N., & Wood, E. F. (2017b). Four decades of microwave satellite soil moisture observations: Part 2. Product validation

- and inter-satellite comparisons. *Advances in Water Resources*. <https://doi.org/10.1016/j.advwatres.2017.09.010>
- Kerr, Y. H., Waldteufel, P., Wigneron, J. P., Martinuzzi, J. M., Font, J., & Berger, M. (2001). Soil moisture retrieval from space: The Soil Moisture and Ocean Salinity (SMOS) mission. *IEEE Transactions on Geoscience and Remote Sensing*. <https://doi.org/10.1109/36.942551>
- Kidd, C., & Huffman, G. (2011). Global precipitation measurement. *Meteorological Applications*. <https://doi.org/10.1002/met.284>
- Kirchner, J. W. (2006). Getting the right answers for the right reasons: Linking measurements, analyses, and models to advance the science of hydrology. *Water Resources Research*. <https://doi.org/10.1029/2005WR004362>
- Kittel, C., Nielsen, K., Tøttrup, C., & Bauer-Gottwein, P. (2018). Informing a hydrological model of the Ogooué with multi-mission remote sensing data. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-22-1453-2018>
- Koch, J., Demirel, M. C., & Stisen, S. (2018). The SPAtial EFficiency metric (SPAEF): Multiple-component evaluation of spatial patterns for optimization of hydrological models. *Geoscientific Model Development*. <https://doi.org/10.5194/gmd-11-1873-2018>
- Koppa, A., Gebremichael, M., & Yeh, W. W. G. (2019). Multivariate calibration of large scale hydrologic models: The necessity and value of a Pareto optimal approach. *Advances in Water Resources*. <https://doi.org/10.1016/j.advwatres.2019.06.005>
- Kottek, M., Grieser, J., Beck, C., Rudolf, B., & Rubel, F. (2006). World map of the Köppen-Geiger climate classification updated. *Meteorologische Zeitschrift*. <https://doi.org/10.1127/0941-2948/2006/0130>
- Krysanova, V., Donnelly, C., Gelfan, A., Gerten, D., Arheimer, B., Hattermann, F., & Kundzewicz, Z. W. (2018). How the performance of hydrological models relates to credibility of projections under climate change. *Hydrological Sciences Journal*. <https://doi.org/10.1080/02626667.2018.1446214>
- Kundu, D., Vervoort, R. W., & van Ogtrop, F. F. (2017). The value of remotely sensed surface soil moisture for model calibration using SWAT. *Hydrological Processes*. <https://doi.org/10.1002/hyp.11219>
- Kunnath-Poovakka, A., Ryu, D., Renzullo, L. J., & George, B. (2016). The efficacy of calibrating hydrologic model using remotely sensed evapotranspiration and soil moisture for streamflow prediction. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2016.02.018>
- Lambin, J., Morrow, R., Fu, L. L., Willis, J. K., Bonekamp, H., Lillibridge, J., et al. (2010). The OSTM/Jason-2 Mission. *Marine Geodesy*. <https://doi.org/10.1080/01490419.2010.491030>
- Lee, H., Jung, H. C., Yuan, T., Beighley, R. E., & Duan, J. (2014). Controls of Terrestrial Water Storage Changes Over the Central Congo Basin Determined by Integrating PALSAR ScanSAR, Envisat Altimetry, and GRACE Data. In *Remote Sensing of the Terrestrial Water Cycle*. <https://doi.org/10.1002/9781118872086.ch7>

- Lettenmaier, D. P., Alsdorf, D., Dozier, J., Huffman, G. J., Pan, M., & Wood, E. F. (2015). Inroads of remote sensing into hydrologic science during the WRR era. *Water Resources Research*. <https://doi.org/10.1002/2015WR017616>
- Li, H. T., Brunner, P., Kinzelbach, W., Li, W. P., & Dong, X. G. (2009). Calibration of a groundwater model using pattern information from remote sensing data. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2009.08.012>
- Li, Y., Grimaldi, S., Pauwels, V. R. N., & Walker, J. P. (2018). Hydrologic model calibration using remotely sensed soil moisture and discharge measurements: The impact on predictions at gauged and ungauged locations. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2018.01.013>
- Liang, X., Lettenmaier, D. P., Wood, E. F., & Burges, S. J. (1994). A simple hydrologically based model of land surface water and energy fluxes for general circulation models. *Journal of Geophysical Research*. <https://doi.org/10.1029/94jd00483>
- Lillesand, T. M., & Kiefer, R. W. (1994). Remote sensing and image interpretation. 3rd edition. *Remote Sensing and Image Interpretation. 3rd Edition*.
- Liu, G., Schwartz, F. W., Tseng, K. H., & Shum, C. K. (2015). Discharge and water-depth estimates for ungauged rivers: Combining hydrologic, hydraulic, and inverse modeling with stage and water-area measurements from satellites. *Water Resources Research*. <https://doi.org/10.1002/2015WR016971>
- Liu, Hongxing, Gopalakrishnan, S., Browning, D., & Sivandran, G. (2019). Valuing water quality change using a coupled economic-hydrological model. *Ecological Economics*. <https://doi.org/10.1016/j.ecolecon.2019.03.006>
- Liu, Hui, Gleason, S. M., Hao, G., Hua, L., He, P., Goldstein, G., & Ye, Q. (2019). Hydraulic traits are coordinated with maximum plant height at the global scale. *Science Advances*. <https://doi.org/10.1126/sciadv.aav1332>
- Lo, M. H., Famiglietti, J. S., Yeh, P. J. F., & Syed, T. H. (2010). Improving parameter estimation and water table depth simulation in a land surface model using GRACE water storage and estimated base flow data. *Water Resources Research*. <https://doi.org/10.1029/2009WR007855>
- López, P. L., Sutanudjaja, E. H., Schellekens, J., Sterk, G., & Bierkens, M. F. P. (2017). Calibration of a large-scale hydrological model using satellite-based soil moisture and evapotranspiration products. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-21-3125-2017>
- Madsen, H. (2000). Automatic calibration of a conceptual rainfall-runoff model using multiple objectives. *Journal of Hydrology*. [https://doi.org/10.1016/S0022-1694\(00\)00279-1](https://doi.org/10.1016/S0022-1694(00)00279-1)
- Maeda, E. E., Ma, X., Wagner, F. H., Kim, H., Oki, T., Eamus, D., & Huete, A. (2017). Evapotranspiration seasonality across the Amazon Basin. *Earth System Dynamics*. <https://doi.org/10.5194/esd-8-439-2017>
- Manfreda, S., Mita, L., Dal Sasso, S. F., Samela, C., & Mancusi, L. (2018). Exploiting the use of physical information for the calibration of a lumped hydrological model.

Hydrological Processes. <https://doi.org/10.1002/hyp.11501>

- Mason, D. C., Bates, P. D., & Dall' Amico, J. T. (2009). Calibration of uncertain flood inundation models using remotely sensed water levels. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2009.02.034>
- Maurer, E. P., Adam, J. C., & Wood, A. W. (2009). Climate model based consensus on the hydrologic impacts of climate change to the Rio Lempa basin of Central America. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-13-183-2009>
- Mendiguren, G., Koch, J., & Stisen, S. (2017). Spatial pattern evaluation of a calibrated national hydrological model - A remote-sensing-based diagnostic approach. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-21-5987-2017>
- Meyer, A., Fleischmann, A., & Paiva, R. (2020). *On the contribution of remote sensing-based calibration to model multiple hydrological variables*. Porto Alegre. <https://doi.org/https://doi.org/10.1002/essoar.10502160.1>
- Mercier, F., Rosmorduc, V., Carrere, L. and Thibaut, P., 2010. Coastal and Hydrology Altimetry product (PISTACH) handbook. Centre National d'Études Spatiales (CNES), Paris, France, 4.
- Miettinen K (1999) Nonlinear multiobjective optimization. Kluwer, Boston.
- Milzow, C., Krogh, P. E., & Bauer-Gottwein, P. (2011). Combining satellite radar altimetry, SAR surface soil moisture and GRACE total storage changes for hydrological model calibration in a large poorly gauged catchment. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-15-1729-2011>
- Mitchell, K. E., Lohmann, D., Houser, P. R., Wood, E. F., Schaake, J. C., Robock, A., et al. (2004). The multi-institution North American Land Data Assimilation System (NLDAS): Utilizing multiple GCIP products and partners in a continental distributed hydrological modeling system. *Journal of Geophysical Research D: Atmospheres*.
- Montanari, A., & Koutsoyiannis, D. (2014). Modeling and mitigating natural hazards: Stationarity is immortal! *Water Resources Research*. <https://doi.org/10.1002/2014WR016092>
- Montanari, M., Hostache, R., Matgen, P., Schumann, G., Pfister, L., & Hoffmann, L. (2009). Calibration and sequential updating of a coupled hydrologic-hydraulic model using remote sensing-derived water stages. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-13-367-2009>
- Motovilov, Y. G., Gottschalk, L., Engeland, K., & Rodhe, A. (1999). Validation of a distributed hydrological model against spatial observations. *Agricultural and Forest Meteorology*. [https://doi.org/10.1016/S0168-1923\(99\)00102-1](https://doi.org/10.1016/S0168-1923(99)00102-1)
- Mu, Q., Zhao, M., & Running, S. W. (2011). Improvements to a MODIS global terrestrial evapotranspiration algorithm. *Remote Sensing of Environment*. <https://doi.org/10.1016/j.rse.2011.02.019>
- Nash, J. E., & Sutcliffe, J. V. (1970). River flow forecasting through conceptual models part I - A discussion of principles. *Journal of Hydrology*.

[https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6)

- Naz, B. S., Frans, C. D., Clarke, G. K. C., Burns, P., & Lettenmaier, D. P. (2014). Modeling the effect of glacier recession on streamflow response using a coupled glacio-hydrological model. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-18-787-2014>
- Neal, J., Schumann, G., & Bates, P. (2012). A subgrid channel model for simulating river hydraulics and floodplain inundation over large and data sparse areas. *Water Resources Research*. <https://doi.org/10.1029/2012WR012514>
- Nearing, G. S., Tian, Y., Gupta, H. V., Clark, M. P., Harrison, K. W., & Weijs, S. V. (2016). A philosophical basis for hydrological uncertainty. *Hydrological Sciences Journal*. <https://doi.org/10.1080/02626667.2016.1183009>
- Negrón Juárez, R. I., da Rocha, H. R., e Figueira, A. M. S., Goulden, M. L., & Miller, S. D. (2009). An improved estimate of leaf area index based on the histogram analysis of hemispherical photographs. *Agricultural and Forest Meteorology*. <https://doi.org/10.1016/j.agrformet.2008.11.012>
- Nelder, J. A., & Mead, R. (1965). A Simplex Method for Function Minimization. *The Computer Journal*. <https://doi.org/10.1093/comjnl/7.4.308>
- Nepstad, D. C., De Carvalho, C. R., Davidson, E. A., Jipp, P. H., Lefebvre, P. A., Negreiros, G. H., et al. (1994). The role of deep roots in the hydrological and carbon cycles of Amazonian forests and pastures. *Nature*. <https://doi.org/10.1038/372666a0>
- New, M., Hulme, M., & Jones, P. (2000). Representing twentieth-century space-time climate variability. Part II: Development of 1901-96 monthly grids of terrestrial surface climate. *Journal of Climate*. [https://doi.org/10.1175/1520-0442\(2000\)013<2217:RTCSTC>2.0.CO;2](https://doi.org/10.1175/1520-0442(2000)013<2217:RTCSTC>2.0.CO;2)
- Nijzink, R. C., Almeida, S., Pechlivanidis, I. G., Capell, R., Gustafssons, D., Arheimer, B., et al. (2018). Constraining Conceptual Hydrological Models With Multiple Information Sources. *Water Resources Research*. <https://doi.org/10.1029/2017WR021895>
- O'Loughlin, F. E., Paiva, R. C. D., Durand, M., Alsdorf, D. E., & Bates, P. D. (2016). A multi-sensor approach towards a global vegetation corrected SRTM DEM product. *Remote Sensing of Environment*. <https://doi.org/10.1016/j.rse.2016.04.018>
- Odusanya, A. E., Mehdi, B., Schürz, C., Oke, A. O., Awokola, O. S., Awomeso, J. A., et al. (2019). Multi-site calibration and validation of SWAT with satellite-based evapotranspiration in a data-sparse catchment in southwestern Nigeria. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-23-1113-2019>
- Paiva, R. C.D., Collischonn, W., Bonnet, M. P., De Gonçalves, L. G. G., Calmant, S., Getirana, A., & Santos Da Silva, J. (2013). Assimilating in situ and radar altimetry data into a large-scale hydrologic-hydrodynamic model for streamflow forecast in the Amazon. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-17-2929-2013>
- Paiva, Rodrigo C.D., Collischonn, W., & Tucci, C. E. M. (2011). Large scale hydrologic and hydrodynamic modeling using limited data and a GIS based approach. *Journal*

of Hydrology. <https://doi.org/10.1016/j.jhydrol.2011.06.007>

- Paiva, Rodrigo C.D., Collischonn, W., & Buarque, D. C. (2013). Validation of a full hydrodynamic model for large-scale hydrologic modelling in the Amazon. *Hydrological Processes*. <https://doi.org/10.1002/hyp.8425>
- De Paiva, Rodrigo Cauduro Dias, Buarque, D. C., Collischonn, W., Bonnet, M. P., Frappart, F., Calmant, S., & Bulhões Mendes, C. A. (2013). Large-scale hydrologic and hydrodynamic modeling of the Amazon River basin. *Water Resources Research*. <https://doi.org/10.1002/wrcr.20067>
- Pan, M., & Wood, E. F. (2006). Data assimilation for estimating the terrestrial water budget using a constrained ensemble Kalman filter. *Journal of Hydrometeorology*. <https://doi.org/10.1175/JHM495.1>
- Pan, S., Liu, L., Bai, Z., & Xu, Y. P. (2018). Integration of remote sensing evapotranspiration into multi-objective calibration of distributed hydrology-soil-vegetation model (DHSVM) in a humid region of China. *Water (Switzerland)*. <https://doi.org/10.3390/w10121841>
- Pappenberger, F., Dutra, E., Wetterhall, F., & Cloke, H. L. (2012). Deriving global flood hazard maps of fluvial floods through a physical model cascade. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-16-4143-2012>
- Parajka, J., Naeimi, V., Blöschl, G., & Komma, J. (2009). Matching ERS scatterometer based soil moisture patterns with simulations of a conceptual dual layer hydrologic model over Austria. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-13-259-2009>
- Parajuli, P. B., Jayakody, P., & Ouyang, Y. (2018). Evaluation of Using Remote Sensing Evapotranspiration Data in SWAT. *Water Resources Management*. <https://doi.org/10.1007/s11269-017-1850-z>
- Parrens, M., Wigneron, J. P., Richaume, P., Al Bitar, A., Mialon, A., Fernandez-Moran, R., et al. (2017). Considering combined or separated roughness and vegetation effects in soil moisture retrievals. *International Journal of Applied Earth Observation and Geoinformation*. <https://doi.org/10.1016/j.jag.2016.11.001>
- Pathiraja, S., Marshall, L., Sharma, A., & Moradkhani, H. (2016). Hydrologic modeling in dynamic catchments: A data assimilation approach. *Water Resources Research*. <https://doi.org/10.1002/2015WR017192>
- Pavelsky, T. M. (2014). Using width-based rating curves from spatially discontinuous satellite imagery to monitor river discharge. *Hydrological Processes*. <https://doi.org/10.1002/hyp.10157>
- Pekel, J. F., Cottam, A., Gorelick, N., & Belward, A. S. (2016). High-resolution mapping of global surface water and its long-term changes. *Nature*. <https://doi.org/10.1038/nature20584>
- Pellet, V., Aires, F., Munier, S., Fernández Prieto, D., Jordá, G., Arnoud Dorigo, W., et al. (2019). Integrating multiple satellite observations into a coherent dataset to monitor the full water cycle - Application to the Mediterranean region. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-23-465-2019>

- Peña-Arancibia, J. L., Zhang, Y., Pagendam, D. E., Viney, N. R., Lerat, J., van Dijk, A. I. J. M., et al. (2015). Streamflow rating uncertainty: Characterisation and impacts on model calibration and performance. *Environmental Modelling and Software*. <https://doi.org/10.1016/j.envsoft.2014.09.011>
- Pinto, EJ de A. et al. (2011). Atlas pluviométrico do Brasil: isoietas mensais, isoietas trimestrais, isoietas anuais, meses mais secos, meses mais chuvosos, trimestres mais secos, trimestres mais chuvosos. Brasília: CPRM 1.
- Poméon, T., Diekkrüger, B., & Kumar, R. (2018). Computationally efficient multivariate calibration and validation of a grid-based hydrologic model in sparsely gauged West African river basins. *Water (Switzerland)*. <https://doi.org/10.3390/w10101418>
- Pontes, P. R. M., Fan, F. M., Fleischmann, A. S., de Paiva, R. C. D., Buarque, D. C., Siqueira, V. A., et al. (2017). MGB-IPH model for hydrological and hydraulic simulation of large floodplain river systems coupled with open source GIS. *Environmental Modelling and Software*. <https://doi.org/10.1016/j.envsoft.2017.03.029>
- Purkis, S. J., & Klemas, V. V. (2013). *Remote Sensing and Global Environmental Change*. *Remote Sensing and Global Environmental Change*. <https://doi.org/10.1002/9781118687659>
- Quinn, N. W. T., & Yang, Z.-L. (2019). Review of Hydrodynamics and Water Quality: Modeling Rivers, Lakes, and Estuaries by Zhen-Gang Ji. Second edition. *Environmental Modelling & Software*. <https://doi.org/10.1016/j.envsoft.2019.02.004>
- Rajib, A., Evenson, G. R., Golden, H. E., & Lane, C. R. (2018). Hydrologic model predictability improves with spatially explicit calibration using remotely sensed evapotranspiration and biophysical parameters. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2018.10.024>
- Rajib, M. A., Merwade, V., & Yu, Z. (2016). Multi-objective calibration of a hydrologic model using spatially distributed remotely sensed/in-situ soil moisture. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2016.02.037>
- Rakovec, O., Kumar, R., Attinger, S., & Samaniego, L. (2016). Improving the realism of hydrologic model functioning through multivariate parameter estimation. *Water Resources Research*. <https://doi.org/10.1002/2016WR019430>
- Refsgaard, J. C., & Abbott, M. B. (1990). The Role of Distributed Hydrological Modelling in Water Resources Management. https://doi.org/10.1007/978-94-009-0257-2_1
- Reichle, R. H., McLaughlin, D. B., & Entekhabi, D. (2002). Hydrologic data assimilation with the ensemble Kalman filter. *Monthly Weather Review*. [https://doi.org/10.1175/1520-0493\(2002\)130<0103:HDAWTE>2.0.CO;2](https://doi.org/10.1175/1520-0493(2002)130<0103:HDAWTE>2.0.CO;2)
- Rientjes, T. H. M., Muthuwatta, L. P., Bos, M. G., Booij, M. J., & Bhatti, H. A. (2013). Multi-variable calibration of a semi-distributed hydrological model using streamflow data and satellite-based evapotranspiration. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2013.10.006>

- Rosenqvist, A., Shimada, M., Ito, N., & Watanabe, M. (2007). ALOS PALSAR: A pathfinder mission for global-scale monitoring of the environment. In *IEEE Transactions on Geoscience and Remote Sensing*. <https://doi.org/10.1109/TGRS.2007.901027>
- Ruhoff, A. L., Paz, A. R., Aragao, L. E. O. C., Mu, Q., Malhi, Y., Collischonn, W., et al. (2013). Assessment of the MODIS global evapotranspiration algorithm using eddy covariance measurements and hydrological modelling in the Rio Grande basin. *Hydrological Sciences Journal*. <https://doi.org/10.1080/02626667.2013.837578>
- Saleska, S., Da Rocha, H., Kruijt, B., & Nobre, A. (2013). Ecosystem Carbon Fluxes and Amazonian Forest Metabolism. In *Amazonia and Global Change*. <https://doi.org/10.1029/2008GM000739>
- Samaniego, L., Kumar, R., & Attinger, S. (2010). Multiscale parameter regionalization of a grid-based hydrologic model at the mesoscale. *Water Resources Research*. <https://doi.org/10.1029/2008WR007327>
- Samaniego, L., Kumar, R., Thober, S., Rakovec, O., Zink, M., Wanders, N., et al. (2017). Toward seamless hydrologic predictions across spatial scales. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-21-4323-2017>
- Santos da Silva, J., Calmant, S., Seyler, F., Rotunno Filho, O. C., Cochonneau, G., & Mansur, W. J. (2010). Water levels in the Amazon basin derived from the ERS 2 and ENVISAT radar altimetry missions. *Remote Sensing of Environment*. <https://doi.org/10.1016/j.rse.2010.04.020>
- Schneider, R., Nygaard Godiksen, P., Villadsen, H., Madsen, H., & Bauer-Gottwein, P. (2017). Application of CryoSat-2 altimetry data for river analysis and modelling. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-21-751-2017>
- Schumacher, M., Forootan, E., van Dijk, A. I. J. M., Müller Schmied, H., Crosbie, R. S., Kusche, J., & Döll, P. (2018). Improving drought simulations within the Murray-Darling Basin by combined calibration/assimilation of GRACE data into the WaterGAP Global Hydrology Model. *Remote Sensing of Environment*. <https://doi.org/10.1016/j.rse.2017.10.029>
- Schumann, G. J. P., Bates, P. D., Neal, J. C., & Andreadis, K. M. (2015). Measuring and Mapping Flood Processes. In *Hydro-Meteorological Hazards, Risks, and Disasters*. <https://doi.org/10.1016/B978-0-12-394846-5.00002-3>
- Scurlock, J. M. O., Asner, G. P., & Gower, S. T. (2001). Global Leaf Area Index from Field Measurements, 1932-2000. *Oak Ridge National Laboratory Distributed Active Archive Center, Oak Ridge, Tennessee, U.S.A.* <https://doi.org/doi:10.3334/ORNLDAAAC/584>.
- Semenova, O., & Beven, K. (2015). Barriers to progress in distributed hydrological modelling. *Hydrological Processes*. <https://doi.org/10.1002/hyp.10434>
- Shafii, M., & Tolson, B. A. (2015). Optimizing hydrological consistency by incorporating hydrological signatures into model calibration objectives. *Water Resources Research*. <https://doi.org/10.1002/2014WR016520>
- Shuttleworth, W. J. (1989). Micrometeorology of temperate and tropical forest.

- Silvestro, F., Gabellani, S., Delogu, F., Rudari, R., & Boni, G. (2013). Exploiting remote sensing land surface temperature in distributed hydrological modelling: The example of the Continuum model. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-17-39-2013>
- Silvestro, F., Gabellani, S., Rudari, R., Delogu, F., Laiolo, P., & Boni, G. (2015). Uncertainty reduction and parameter estimation of a distributed hydrological model with ground and remote-sensing data. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-19-1727-2015>
- Siqueira, V., Fleischmann, A., Jardim, P., Fan, F., & Collischonn, W. (2016). IPH-Hydro Tools: a GIS coupled tool for watershed topology acquisition in an open-source environment. *Revista Brasileira de Recursos Hídricos*. <https://doi.org/10.21168/rbrh.v21n1.p274-287>
- Siqueira, V. A., Paiva, R. C. D., Fleischmann, A. S., Fan, F. M., Ruhoff, A. L., Pontes, P. R. M., et al. (2018). Toward continental hydrologic-hydrodynamic modeling in South America. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-22-4815-2018>
- Sivapalan, M., Takeuchi, K., Franks, S. W., Gupta, V. K., Karambiri, H., Lakshmi, V., et al. (2003). IAHS Decade on Predictions in Ungauged Basins (PUB), 2003-2012: Shaping an exciting future for the hydrological sciences. *Hydrological Sciences Journal*. <https://doi.org/10.1623/hysj.48.6.857.51421>
- Sorribas, M. V., Paiva, R. C. D., Melack, J. M., Bravo, J. M., Jones, C., Carvalho, L., et al. (2016). Projections of climate change effects on discharge and inundation in the Amazon basin. *Climatic Change*. <https://doi.org/10.1007/s10584-016-1640-2>
- Stisen, S., Sandholt, I., Nørgaard, A., Fensholt, R., & Jensen, K. H. (2008). Combining the triangle method with thermal inertia to estimate regional evapotranspiration - Applied to MSG-SEVIRI data in the Senegal River basin. *Remote Sensing of Environment*. <https://doi.org/10.1016/j.rse.2007.08.013>
- Stisen, S., McCabe, M. F., Refsgaard, J. C., Lerer, S., & Butts, M. B. (2011). Model parameter analysis using remotely sensed pattern information in a multi-constraint framework. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2011.08.030>
- Stisen, S., Koch, J., Sonnenborg, T. O., Refsgaard, J. C., Bircher, S., Ringgaard, R., & Jensen, K. H. (2018). Moving beyond run-off calibration—Multivariable optimization of a surface–subsurface–atmosphere model. *Hydrological Processes*. <https://doi.org/10.1002/hyp.13177>
- Sun, W., Ishidaira, H., & Bastola, S. (2012a). Calibration of hydrological models in ungauged basins based on satellite radar altimetry observations of river water level. *Hydrological Processes*. <https://doi.org/10.1002/hyp.8429>
- Sun, W., Ishidaira, H., & Bastola, S. (2012b). Prospects for calibrating rainfall-runoff models using satellite observations of river hydraulic variables as surrogates for in situ river discharge measurements. *Hydrological Processes*.

<https://doi.org/10.1002/hyp.8301>

- Sun, W., Fan, J., Wang, G., Ishidaira, H., Bastola, S., Yu, J., et al. (2018). Calibrating a hydrological model in a regional river of the Qinghai–Tibet plateau using river water width determined from high spatial resolution satellite images. *Remote Sensing of Environment*. <https://doi.org/10.1016/j.rse.2018.05.020>
- Sun, W. C., Ishidaira, H., & Bastola, S. (2010). Towards improving river discharge estimation in ungauged basins: Calibration of rainfall-runoff models based on satellite observations of river flow width at basin outlet. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-14-2011-2010>
- Sutanudjaja, E. H., Van Beek, L. P. H., De Jong, S. M., Van Geer, F. C., & Bierkens, M. F. P. (2014). Calibrating a large-extent high-resolution coupled groundwater-land surface model using soil moisture and discharge data. *Water Resources Research*. <https://doi.org/10.1002/2013WR013807>
- Swenson, S., & Wahr, J. (2006). Post-processing removal of correlated errors in GRACE data. *Geophysical Research Letters*. <https://doi.org/10.1029/2005GL025285>
- Tang, Q., Gao, H., Lu, H., & Lettenmaier, D. P. (2009). Remote sensing: Hydrology. *Progress in Physical Geography*. <https://doi.org/10.1177/0309133309346650>
- Tangdamrongsub, N., Steele-Dunne, S. C., Gunter, B. C., Ditmar, P. G., & Weerts, A. H. (2015). Data assimilation of GRACE terrestrial water storage estimates into a regional hydrological model of the Rhine River basin. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-19-2079-2015>
- Tapley, B. D., Bettadpur, S., Ries, J. C., Thompson, P. F., & Watkins, M. M. (2004). GRACE measurements of mass variability in the Earth system. *Science*. <https://doi.org/10.1126/science.1099192>
- Tarpanelli, A., Brocca, L., Melone, F., & Moramarco, T. (2013). Hydraulic modelling calibration in small rivers by using coarse resolution synthetic aperture radar imagery. *Hydrological Processes*. <https://doi.org/10.1002/hyp.9550>
- Teutschbein, C., & Seibert, J. (2012). Bias correction of regional climate model simulations for hydrological climate-change impact studies: Review and evaluation of different methods. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2012.05.052>
- Teweldebrhan, A. T., Burkhart, J. F., & Schuler, T. V. (2018). Parameter uncertainty analysis for an operational hydrological model using residual-based and limits of acceptability approaches. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/he-22-5021-2018>
- Tobin, K. J., & Bennett, M. E. (2017). Constraining SWAT Calibration with Remotely Sensed Evapotranspiration Data. *Journal of the American Water Resources Association*. <https://doi.org/10.1111/1752-1688.12516>
- Todini, E. (2007). Hydrological catchment modelling: Past, present and future. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-11-468-2007>
- Tucci, CEM. "Modelos Hidrológicos. 2ª edição." da UFRGS/Associação Brasileira de

Recursos Hídricos (1998).

- Vrugt, J. A., Gupta, H. V., Bastidas, L. A., Bouten, W., & Sorooshian, S. (2003). Effective and efficient algorithm for multiobjective optimization of hydrologic models. *Water Resources Research*. <https://doi.org/10.1029/2002WR001746>
- Vrugt, J. A., Diks, C. G. H., Gupta, H. V., Bouten, W., & Verstraten, J. M. (2005). Improved treatment of uncertainty in hydrologic modeling: Combining the strengths of global optimization and data assimilation. *Water Resources Research*. <https://doi.org/10.1029/2004WR003059>
- Wagener, T., McIntyre, N., Lees, M. J., Wheater, H. S., & Gupta, H. V. (2003). Towards reduced uncertainty in conceptual rainfall-runoff modelling: Dynamic identifiability analysis. *Hydrological Processes*. <https://doi.org/10.1002/hyp.1135>
- Wambura, F. J., Dietrich, O., & Lischeid, G. (2018). Improving a distributed hydrological model using evapotranspiration-related boundary conditions as additional constraints in a data-scarce river basin. *Hydrological Processes*. <https://doi.org/10.1002/hyp.11453>
- Wanders, N., Bierkens, M. F. P., de Jong, S. M., de Roo, A., & Karssenber, D. (2014). The benefits of using remotely sensed soil moisture in parameter identification of large-scale hydrological models. *Water Resources Research*. <https://doi.org/10.1002/2013WR014639>
- Werth, S., & Güntner, A. (2010). Calibration analysis for water storage variability of the global hydrological model WGHM. *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-14-59-2010>
- Werth, S., Güntner, A., Petrovic, S., & Schmidt, R. (2009). Integration of GRACE mass variations into a global hydrological model. *Earth and Planetary Science Letters*. <https://doi.org/10.1016/j.epsl.2008.10.021>
- Willem Vervoort, R., Miechels, S. F., van Ogtrop, F. F., & Guillaume, J. H. A. (2014). Remotely sensed evapotranspiration to calibrate a lumped conceptual model: Pitfalls and opportunities. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2014.10.034>
- Winsemius, H. C., G. Savenije, H. H., & M. Bastiaanssen, W. G. (2008). Constraining model parameters on remotely sensed evaporation: Justification for distribution in ungauged basins? *Hydrology and Earth System Sciences*. <https://doi.org/10.5194/hess-12-1403-2008>
- Wongchuig, S. C., de Paiva, R. C. D., Siqueira, V., & Collischonn, W. (2019). Hydrological reanalysis across the 20th century: A case study of the Amazon Basin. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2019.01.025>
- Xiong, L., & Zeng, L. (2019). Impacts of introducing remote sensing soil moisture in calibrating a distributed hydrological model for streamflow simulation. *Water (Switzerland)*. <https://doi.org/10.3390/w11040666>
- Xu, C. Y., Widén, E., & Halldin, S. (2005). Modelling hydrological consequences of climate change - Progress and challenges. *Advances in Atmospheric Sciences*. <https://doi.org/10.1007/BF02918679>

- Xu, X., Li, J., & Tolson, B. A. (2014). Progress in integrating remote sensing data and hydrologic modeling. *Progress in Physical Geography*. <https://doi.org/10.1177/0309133314536583>
- Yamazaki, D., Kanae, S., Kim, H., & Oki, T. (2011). A physically based description of floodplain inundation dynamics in a global river routing model. *Water Resources Research*. <https://doi.org/10.1029/2010WR009726>
- Yamazaki, D., Ikeshima, D., Tawatari, R., Yamaguchi, T., O'Loughlin, F., Neal, J. C., et al. (2017). A high-accuracy map of global terrain elevations. *Geophysical Research Letters*. <https://doi.org/10.1002/2017GL072874>
- Yapo, P. O., Gupta, H. V., & Sorooshian, S. (1998). Multi-objective global optimization for hydrologic models. *Journal of Hydrology*. [https://doi.org/10.1016/S0022-1694\(97\)00107-8](https://doi.org/10.1016/S0022-1694(97)00107-8)
- Zajac, Z., Revilla-Romero, B., Salamon, P., Burek, P., Hirpa, F., & Beck, H. (2017). The impact of lake and reservoir parameterization on global streamflow simulation. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2017.03.022>
- Zhang, J. L., Li, Y. P., Huang, G. H., Wang, C. X., & Cheng, G. H. (2016). Evaluation of uncertainties in input data and parameters of a hydrological model using a bayesian framework: A case study of a snowmelt-precipitation-driven watershed. *Journal of Hydrometeorology*. <https://doi.org/10.1175/JHM-D-15-0236.1>
- Zhang, Y., Chiew, F. H. S., Zhang, L., & Li, H. (2009). Use of remotely sensed actual evapotranspiration to improve rainfall-runoff modeling in Southeast Australia. *Journal of Hydrometeorology*. <https://doi.org/10.1175/2009JHM1061.1>
- Zhou, S., & Zhang, W. (2017). Calibration and validation of a semi-distributed hydrological model in the Amur River Basin using remote sensing data. <https://doi.org/10.1117/12.2278345>
- Zink, M., Mai, J., Cuntz, M., & Samaniego, L. (2018). Conditioning a Hydrologic Model Using Patterns of Remotely Sensed Land Surface Temperature. *Water Resources Research*. <https://doi.org/10.1002/2017WR021346>
- Zomer, R., Trabucco, A., Bossio, D., van Straaten, O., & Verchot, L. (2008). Global Aridity and PET Database.

ANEXO 1.

Table 3-S1. List of the 64 peer-reviewed studies that incorporated remote sensing datasets for parameter estimation in hydrological models. Search words on Scopus and Google Scholar were set to “ ((remote* sens* OR satellite) AND (hydrologic* model* OR rainfall-runoff) AND (calibration OR adjustment))”; there are presented only studies that evaluate calibration of parameters in hydrological models (data assimilation schemes are not included), and the list is limited to the following journals: WRR: Water Resources Research, HESS: Hydrology and Earth System Sciences, HP: Hydrological Processes, RSE: Remote Sensing of Environment, GMD: Geoscientific Model Development, AWR: Advances in Water Resources, JoH: Journal of Hydrology, WRM: Water Resources Management, JAWRA: Journal of the American Water Resources Association, JH: Journal of Hydrometeorology, EPSL: earth and Planetary Science Letters, JGR: Journal of Geophysical Research.

Authors / Journal	Model (lumped or distributed? / hydrologic or hydrodynamic?)	Number of independent calibration variables	"Observed"/RS variables (averaged or distributed?)	Remote sensing products	Study area	Optimization algorithm	Key findings
(Franks et al., 1998) / WRR	TOPMODEL (distributed / hydrologic)	2	Discharge and Saturated areas (distributed)	ERS-1 SAR	Naizin catchment (12 km ² , France)	GLUE	“The methodology can reject many previously acceptable parametrizations [...] (It) improved predictions of some discharge events.”

(Crow et al., 2003)/ JGR	VIC (distributed / hydrologic)	2	Discharge and Surface Temperature (averaged)	TOVS aboard NOAA-14 and GOES	Oklahoma, USA (> 2500 km ²)	SCE-UA	“Reduced error in model monthly evapotranspiration predictions by up to 20% relative to single-objective model calibration against streamflow alone”
(Campo et al., 2006) / HP	MOBIDIC (distributed / hydrologic)	2	Discharge and Soil Saturation (distributed)	ERS-2 SAR	Arno River (Italy), 8230 km ²	Nelder–Mead	“Good match between soil moisture predictions and remote sensing data, and also an enhancement of model performance in flow prediction with respect to a previous calibration with river discharge data only;
(Immerzeel & Droogers, 2008)/ JoH	SWAT (distributed / hydrologic)	1	Discharge or Evapotranspiration (distributed)	SEBAL	Upper Bhima catchment, in India (45.678 km ²)	PEST	“Correlation between monthly sub-basin simulated and measured actual evapotranspiration was increased from 0.40 to 0.81.”
(Winsemius et al., 2008)/ HESS	simplified version of 1-D HBV model (semi-distributed / hydrologic)	1	Evapotranspiration (distributed)	SEBAL	Luangwa river basin (150 000 km ²) in Zambia	Bayesian updating framework, with Monte Carlo sampling	The method revealed model structural deficiencies and it was able to condition model parameters.
(Werth et al., 2009)/ EPSL	WaterGAP (distributed / hydrologic)	2	Discharge and Total Water	GRACE	Amazon, Mississippi and Congo	ε-NSGAIL	“Improved simulation results with regard both objectives; {...} Results highlight the valuable nature of GRACE data when merged into large-scale hydrological

			Storage (averaged)		(>3 million km ²)		modeling. Furthermore, they reveal the utility of the multi-objective calibration framework for the integration of remote sensing data into hydrological models.”
(Mason et al., 2009)/ JoH	LISFLOOD-FP (hydrodynamic)	2	Waterlines (based on flood extent and altimetry) and Flood extent (distributed)	LiDAR, ERS-1 SAR	12km long reach, near Oxford, UK	Monte Carlo method	Waterlines are able to restrict the parameter range of acceptable model runs and hence reduce the number of runs necessary to generate a flood inundation uncertainty map.
(Parajka et al., 2009)/ HESS	modified HBV with dual soil layer (semi-distributed; hydrologic)	2	Discharge and Soil Moisture (distributed)	ERS-1, ERS-2, ASCAT	148 Austrian catchments varying from 25km ² to 9770 km ²	SCE-UA	“Using both ERS scatterometer based soil moisture and runoff for model calibration provides more robust model parameters than using either of these two sources of information.”
(M. Montanari et al., 2009)/ HESS	Nash model + HEC-RAS 1-D (lumped hydrologic + hydrodynamic)	1	Flooded areas + Altimetry (distributed)	ERS-2 SAR; Envisat	Alzette River basin, 356 km ² (Luxembourg)	Monte Carlo method	It provided valuable information for sequentially updating hydrologic-hydrodynamic (H-H) models, by updating the soil moisture module of the hydrologic model based on the comparison between remote sensing and H-H model output.

(Y. Zhang et al., 2009)/ JH	SimHYD (lumped / hydrologic)	2	Discharge and Evapotranspiration (averaged)	MODIS	120 catchments in Australia (from 50 to 2000 km ²)	Particle swarm optimization (PSO) toolbox in MATLAB	Calibration against both the observed streamflow and evapotranspiration produced better simulations of daily and monthly runoff in ungauged catchments compared to calibration against the observed streamflow data only.
(H. T. Li et al., 2009) / JoH	MODFLOW (groundwater / distributed)	2	Head data and Phreatic evaporation (distributed)	NOAA-AVHRR	Yanqi Basin (China)	PEST	The evaporation pattern can replace the head data in the model calibration process.
(Lo et al., 2010)/ WRR	Community Land Model 3.0 (hydrologic) coupled with a groundwater parametrization	2	Baseflow (distributed) and TWS (averaged)	GRACE	Illinois State, USA	Monte Carlo method	Improved parameter estimation and reduced the uncertainty of water table simulations in the model. It demonstrated the potential for the joint use of routinely available GRACE water storage data and streamflow records to constrain LSM simulations at the global scale.
(Augusto C.V. Getirana, 2010)/ JoH	MGB (hydrologic / distributed)	2	Discharge and Water level ("distributed" - many	Envisat	Branco river (Amazon),	MOCOM-UA	Results demonstrate that the combination of virtual stations along the river can provide reasonable parameters.

			gauging stations)		190.000 km ²		
(Werth & Güntner, 2010)/ HESS	WaterGAP (distributed / hydrologic)	2	Discharge and TWS (averaged)	GRACE	Global	ε-NSGAI	The results demonstrate the value of both the GRACE data and the multi-objective calibration approach for improving large-scale hydrological simulations, and they provide a starting-point for improving model structures.
(W. C. Sun et al., 2010) / HESS	HYMOD (hydrologic / distributed) + at-a-station hydraulic geometry	1	Discharge or River width (at basin outlet)	JERS-1	Mekong Basin (Asia, 795000 km ²)	GLUE	The method has potential for improving reliability of discharge estimates in ungauged basins.
(Milzow et al., 2011)/ HESS	SWAT (hydrologic / distributed)	4	Discharge, River stages, soil moisture, and TWS (averaged)	Envisat, GRACE	Okavango river, 170.000 km ²	Shuffled Complex Evolution Metropolis algorithm (SCEM-UA)	Soil moisture data was helpful in identifying errors in precipitation input; altimetry data were helpful to condition model parameters related to channel morphology; GRACE data were helpful to condition parameters related to various storage compartments of the model.
(Stisen et al., 2011)/ JoH	MIKE-SHE SW-ET (hydrologic / distributed)	2	Discharge and Surface temperature (distributed)	MODIS (MYD11A1)	Skjern River Basin, Denmark		When evaluated based on traditional objective functions, the method did not improve model performance. When evaluated based on objective functions that incorporate

					(2500 km ²)		RS surface temperature, spatial patterns were much better represented by using the proposed method.
(Finger et al., 2011) / WRR	TOPKAPI (hydrologic / distributed)	3	Discharge, Snow cover, glacier mass balance	MOD10A1. 5	Rhonegletscher basin (38.9 km ²)	Monte Carlo method	Combination of discharge and satellite snow cover images is best for improving model performance, because the volumetric information of discharge data and the spatial information of snow cover images are complementary.
(W. Sun et al., 2012a) / HP	HYMOD (hydrologic/distributed)+hydraulic module	2	Discharge and Water level ("distributed" - many gauging stations)	Topex/Poseidon	Upper Mississippi basin (247.600 km ²)	GLUE	The study contributes to improve streamflow estimation in ungauged basin and evaluate the value of remote sensing in hydrological modeling.
(W. Sun et al., 2012b) / HP	HYMOD (hydrologic/distributed)+hydraulic module	2	Discharge and Water level	-	Mekong basin (545.000 km ²)	NSGA II	"Using ground measurements with the possible error of satellite observations as calibration data, the maximum uncertainty was less than 20% of the mean daily discharge at Pakse station."
(Rientjes et al., 2013) / JoH	HBV (hydrologic / semi-distributed)	2	Discharge + Evapotranspiration (averaged for each sub-catchment)	SEBS, based on MODIS	Karkheh river (Iran), 51.000 km ²	Monte Carlo method	Catchment water balance is best reproduced when both discharge and satellite-based ET serve as calibration target.

(Corbari & Mancini, 2014)/ JH	FEST-EWB (hydrologic / distributed)	2	Discharge and Land surface temperature (distributed)	MODIS	Upper Po river (Italy 38000km ²)	"trial and error"	Improvements of about 10mm/8 days are obtained on evapotranspiration from the model calibrated with discharge and land surface temperature, with respect to the calibration based only on discharge.
(Tarpanelli et al., 2013)/ HP	MISD (hydrologic / semi-distributed) + Mike11 (hydraulic)	1	Flooded area (distributed)	SAR from Envisat	Tibet River (<100 km ² , Italy)	trial and error ?	This application on a small catchment contributes to strengthen the value of remote sensing data confirming the potential of SAR imagery to reduce uncertainties in hydraulic modelling calibration.
(Silvestro et al., 2013)/ HESS	Continuum (hydrologic / distributed)	2	Discharge and Land surface temperature (averaged and distributed)	LANDSAT	Orba basin (800km ² , Italy)	Monte Carlo method	The proposed methodology led to a parameter set that well reproduces both satellite land surface temperature and streamflow observations.
(Franz & Karsten, 2013)/ JoH	US NWS SNOW17 (snow model / distributed)	2	Discharge and Snow Covered Area (distributed)	MODIS SCA	North Fork of the American River Basin in California, USA (868 km ²)	SCE-UA	Calibration with SCA and discharge resulted in the most accurate spatial representation and discharge predictions, but not the best SCA summary statistics. Better SCA summary statistics does not coincide with more accurate discharge simulations.

(A. C.V. Getirana & Peters-Lidard, 2013)/ HESS	HyMAP (based CaMa-Flood+ISBA; hydrologic-hydrodynamic, distributed)	2	Rating curves - Discharge and Water level ("distributed" - many gauging stations)	Envisat	Amazon river (165501 km ²)		Instantaneous discharge estimates from large-scale radar altimetry datasets based on rating curves are feasible, but accuracy is highly sensitive to the quality of input data.
(Sutanudjaja et al., 2014)/ WRR	PCR-GLOBWB-MOD (distributed groundwater-land surface model)	2	Discharge and Soil Moisture (distributed)	European Remote Sensing (ERS) scatterometers	Rhine-Meuse basin (200.000 km ²)	Monte Carlo method	The stepwise approach introduced in this study, using both discharge and soil moisture data, can calibrate both discharge and soil moisture, as well as predicting groundwater head dynamics with acceptable accuracy.
(Willem Vervoort et al., 2014)/ JoH	IHACRES-CMD	2	Discharge and Evapotranspiration	MOD16	4 basins in Australia (from 146 to 2183 km ²)	Shuffled complex evolution	This study confirms that the calibration of models using multiple environmental timeseries (such as MOD16 evapotranspiration and Discharge) can be used to identify structural model issues.
(G. Liu et al., 2015)/ WRR	SWAT (distributed hydrologic) +	2	Water level and flood extent (distributed)	LANDSAT, ENVISAT	Red river (North America,	Genetic Algorithm framework	The integrated modeling approach is able to estimate discharge and water depth from space for larger ungauged rivers. This study also implies that in situ

	XSECT (hydraulic)				82129km ²)		discharge data may not be necessary for successful hydrologic model calibration.
(Silvestro et al., 2015)/ HESS	Continuum (hydrologic / distributed)	3	Discharge, Land surface temperature and Surface soil moisture (averaged)	LSA-SAF; ASCAT	Orba basin (800km ²) and Casentino basin (Italy)	"very simple brute-force calibration approach was used." ?	This study proves the usefulness of using both ground and satellite observations to constrain parameters in the calibration process and reduce the number of equifinal solutions, because of the model structure and the nature of hydrological processes, which may be weakly related to discharge observations.
(Finger et al., 2015)/ WRR	HBV-light (hydrologic / distributed)	3	Discharge, glacier mass balances, snow cover area (distributed)	MOD10A1.5	3 basins in Switzerland (from 39 to 103 km ²)	Monte Carlo method	Calibration against only discharge leads to unrealistic snow and glacier melt rates. Therefore, the use of multiple datasets is better to constrain the model parameters. Moreover, use of different datasets to calibrate hydrological models might be more important than model complexity to achieve realistic estimations of runoff composition.
(Kunnath-Poovakka et al., 2016)/ JoH	AWRA-L (hydrologic / distributed)	2	Discharge, Soil moisture and Evapotranspiration (averaged)	MODIS (CMRSET), AMSR-E	11 basins in Australia (from 55 km ² to 1028 km ²).	SCE-UA	The objective function containing the root mean square deviation of ET result in best streamflow predictions.

(M. A. Rajib et al., 2016)/ JoH	SWAT (distributed /hydrologic)	2	Discharge and Soil Moisture (distributed)	AMSR-E	2 basins in Indiana, USA: (18500 km ² and 700 km ²)	SUFI-2 (SWAT-CUP)	“Although application of remote sensing data in calibration improves surface soil moisture simulation, other hydrologic components such as streamflow, evapotranspiration (ET) and deeper layer {...} moisture content in SWAT remain less affected. While the results from this study show that root zone soil moisture can play a 3major role in SWAT calibration, more studies including various soil moisture data products are necessary to validate the proposed approach.”
(Rakovec et al., 2016)/ WRR	mHM (hydrologic / distributed)	2	Discharge and TWS (averaged)	GRACE	83 European basins, from 10 ⁴ to 10 ⁶ km ²	Dynamically Dimensioned Search (DDS) algorithm	“This study highlights the value for incorporating multiple data sources during parameter estimation to improve the overall realism of hydrologic models and their applications over large domains.”
(Kundu et al., 2017)/ HP	SWAT (distributed /hydrologic)	1	Soil moisture (distributed)	ESA_SM	Warrego river, Australia (~70000 km ²)	Particle swarm optimization	The results identified that calibration only on RS SM improved the general rainfall–runoff response simulation by introducing delays but cannot correct the overall routing effect. Furthermore, catchment characteristics (e.g., land use, elevation, soil types, and precipitation) regulating SM variation in different seasons highlighted by the

							model calibration are identified. This provides further opportunities to improve model parameterization.
(López et al., 2017). / HESS	PCR-GLOBWB (distributed / hydrologic)	2	Discharge, Evapotranspiration and Soil Moisture (averaged)	GLEAM, ESA CCI	Oum er Rbia River, Morrocco (38 025 km ²).	Monte Carlo method	“Results show that GLEAM evapotranspiration and ESA CCI soil moisture may be used for model calibration resulting in reasonable discharge estimates (NSE values from 0.5 to 0.75), although better model performance is achieved when the model is calibrated with in situ streamflow observations. Independent calibration based on only evapotranspiration or soil moisture observations improves model predictions to a lesser extent.”
(Schneider et al., 2017) / HESS	DHI MIKE HYDRO River software (hydrologic) / MIKE HYDRO River (hydrodinami c)	1	Water level (distributed - many stations)	CryoSat-2, Envisat	Brahmapu tra Basin in South Asia.	Genetic Algorithm framewor k	“They provide an opportunity to achieve forecasts of both discharge and water levels in a poorly gauged river system.”
(Franco & Bonumá, 2017)/ RBRH	SWAT (hydrologic / distributed)	2	Discharge and Evapotranspiration (averaged)	METRIC (based on MODIS)	Negro river (3453 km ²), in	SWAT-CUP	“Compared to conventional single-variable calibration (streamflow only), multi-variable calibration (streamflow and evapotranspiration, simultaneously) produce better streamflow performance, especially

					the south of Brazil		for low flow periods and daily step validation. Despite that, no evidence of reduction of streamflow prediction uncertainty was observed. SWAT model calibration using solely evapotranspiration still requires further studies.”
(Tobin & Bennett, 2017)/ JAWRA	SWAT (hydrologic / distributed)	2	Discharge and Evapotranspiration (averaged)	GLEAM	Little Washita River Experimental Watershed, in Oklahoma, USA.	SUFI-2	“Traditional objective metrics such as the Nash-Sutcliffe coefficients record no performance improvement after application of this method. However, there is a dramatic increase in the number of days with receding flow where simulations match observed streamflow.”
(Mendigurn et al., 2017)/ HESS	DK-model (hydrologic / distributed)	1	Discharge or Evapotranspiration (distributed)	MODIS (TSEB)	Denmark (42087 km ²)	PEST	“The Empirical Orthogonal Function (EOF) analysis shows that including remote-sensing-derived LAI, Root Depth and Kc in the distributed hydrological model adds spatial features found in the spatial pattern of remote-sensing-based ET.”
(Parajuli et al., 2018)/ WRM	SWAT (hydrologic / distributed)	2	Discharge and Evapotranspiration (averaged)	SEBAL (MODIS)	Big Sunflower River Watershed, in	SWAT-CUP - SUFI-2	“The results of this study demonstrated use of Modis-based remote sensing data to evaluate the SWAT model streamflow and ET calibration and validation, which can be applied in watersheds with the lack of meteorological data”

					Mississippi, USA		
(Wambura et al., 2018)/ HP	SWAT (distributed /hydrologic)	2	Discharge and Evapotranspiration (distributed)	MODIS	Wami River basin in Tanzania (41,170 km ²).	Latin hypercube sampling	“We conclude that additional constraints substantially reduce equifinality and prediction uncertainty in a distributed hydrological model.”
(Y. Li et al., 2018)/ JoH	GR models (modèle du Génie Rural); (hydrologic / lumped or distributed)	2	Discharge and Soil Moisture (distributed and averaged)	SMOS	2 basins in Australia (concentration time from 1 to 4-6 days)	SCE-UA	“The joint calibration scheme was found to slightly degrade the streamflow prediction at gauged sites during the calibration period compared with streamflow only calibration, but improvement was found at the same gauged sites during the independent validation period. A more consistent and statistically significant improvement was achieved at gauged sites not used in the calibration, due to the spatial information introduced by the remotely sensed soil moisture data. It was also found that the impact of using soil moisture for calibration tended to be stronger at the upstream and tributary sub-catchments than at the downstream sub-catchments.”
(Ha et al., 2018)/ Water	SWAT (distributed /hydrologic)	2	Evapotranspiration and LAI (distributed)	MOD15, MOD16	Day river, Vietnam	SUFI-2	“This outcome demonstrates the capability of SWAT model to obtain spatial and accurate simulation of eco-

					(6300 km ²)		hydrological processes, also when rivers are ungauged and the water withdrawal system is complex.”
(Zink et al., 2018)/ WRR	mHM (hydrologic / distributed)	2	Discharge and Land Surface Temperature (Distributed)	Meteosat Second Generation (MSG), processed by LSA-SAF	calibration in six distinct large German river basins and cross validation in 222 additional basins in Germany.	Dynamically Dimensioned Search algorithm (Tolson & Shoemaker, 2007)	“Our results show that patterns of Ts better constrain model parameters when considered in a calibration next to Q, which finally reduces parametric uncertainty.”
(Nijzink et al., 2018)/ WRR	HYPE, HYMOD, TUW, FLEX, FlexTopo (lumped/ hydrologic)	4	Soil moisture, Snow, Evapotranspiration and TWS	AMSR-E, ASCAT, NDII, SMOS,LSA - SAF,MOD16,GRACE, MOD10,MYD10	27 european basins (from 90 km ² to 1500 km ²).	Bayesian updating framework with Latin Hypercube Sampling	“Combining multiple (satellite) datasets for deriving posterior parameter ranges leads to a narrower parameter search space. Especially the soil moisture products of AMSR-E, ASCAT and the TWS anomalies from GRACE helped in determining feasible parameter sets with good performance in streamflow prediction.”

(S. Pan et al., 2018) / Water	Distributed Hydrology–Soil–Vegetation Model (DHSVM) (distributed / hydrologic)	2	Discharge and Evapotranspiration (averaged)	MODIS (SEBAL)	Jinhua river, China (5996 km ²)	ϵ -NSGAII	“The results show that runoff is simulated well in single objective calibration, whereas evapotranspiration is not. By considering more variables in multi-objective calibration, DHSVM provides more reasonable simulation for both runoff and evapotranspiration and great reduction of equifinality.”
(W. Sun et al., 2018)/ RSE	HYMOD (hydrologic) + at a station hydraulic geometry (AHG)	1	River widths (at station)	QuickBird, IKONOS, WorldView-1	Qinghai–Tibet river (33, 000km ²)	GLUE	“The accuracy of streamflow estimates for this regional river basin was satisfactory; {...} Incorporating narrower prior parameter ranges and hydrological signature information to constrain parameter space reduced simulation uncertainty.”
(Stisen et al., 2018)	MIKE SHE (distributed / hydrologic)	5	Discharge, hydraulic head, ET, soil moisture and Land surface temperature (distributed)	MODIS Aqua MYD11A1	Ahlergaard catchment, Denmark (1055 km ²)	PEST	“The multivariable calibration proved more robust, compared with calibration against Q and h only, during the validation period, even for Q and h. [...] Additionally, analysis showed that systematic spatial patterns in the errors of the LST maps could be a very valuable diagnostic tool for assessing deficiencies in the model structure, spatial parameterization, or process description.”

(Manfreda et al., 2018)/ HP	AD2 (hydrologic / lumped)	2	Discharge and Snow Covered Area (averaged)	MODIS (National Snow & Ice Data Center)	Aniene river, Italy (690 km ²)	Genetic Algorithm framework	“Results suggest that the use of physical information in the calibration procedure tends to increase model reliability with respect to approaches where the parameters are calibrated using an overall statistic based, considerably or exclusively, on streamflow data.”
(Kittel et al., 2018) / HESS	lumped conceptual rainfall–runoff model based on the Budyko framework and developed by Zhang et al. (2008), coupled to a cascade of linear reservoirs and a Muskingum	3	Discharge, water level, and TWS (distributed)	Envisat, Jason-2, GRACE	Ogooué river, Africa (224000 km ²)	SCE-UA	“By combining hydrological modeling with multimission remote sensing from 10 different satellite missions, we obtain new information on an otherwise unstudied basin.”

	routing compartment (Chow et al., 1988)						
(Schumacher et al., 2018)/ RSE	WaterGAP Global Hydrology Model (WGHM) (distributed / hydrologic)	2	Discharge and TWS (distributed)	GRACE	Murray-Darling basin (216673 km ² , Australia)	Ensemble Kalman filtering	Improved simulation of seasonality, trends of TWS, and individual water storage components. It does not improve discharge simulations, but increased correlations between river storage and river levels. “Using solutions from different GRACE data providers produces slightly different C/DA results.”
(A. Rajib et al., 2018)/ JoH	SWAT (distributed /hydrologic)	2	Discharge, ET (spatially distributed x lumped)	MOD16	~1670 km ² Pipestem Creek watershed in North Dakota, USA	SUFI-2 SWAT-CUP	“Results suggest that the inclusion of biophysical parameters involving vegetation dynamics and energy utilization mechanisms tend to increase model accuracy. Furthermore, we found that using a lumped, versus a spatially explicit, approach for integrating ET into model calibration produces a sub-optimal model state with no potential improvement in model performance across large spatial scales.”
(Poméon et al., 2018)/ Water	mHM (hydrologic / distributed)	2	Discharge and Evapotranspiration (distributed)	GLEAM 3.2a	10 river basins in West Africa	Dynamically Dimensioned	“The model performed reasonably well, with mean discharge KGE values of 0.53 (mHM Q) and 0.49 (mHM Q/ET) for the calibration. {...} Overall, our analysis highlights the worth of utilizing additional hydrologic variables (together with discharge) for the reliable

					(473,718 km ²)	Search (DDS),	application of a distributed hydrologic model in sparsely gauged West African river basins.”
(Herman et al., 2018)/ JoH	SWAT (distributed /hydrologic)	2	Discharge and Evapotranspiration (distributed)	SSEBop, ALEXI	Honeyoey Creek-Pine Creek, in Michigan (USA, 1100 km ²)	Multi-variable (NSGAI) and Genetic algorithm	Both calibration frameworks improve ET simulation. But calibration with Genetic Algorithm reduced model performance for streamflow prediction, while multi-variable calibration improved both streamflow and ET performances.
(Demirel et al., 2018) / HESS	mHM (hydrologic / distributed)	2	Discharge and Evapotranspiration (distributed)	MODIS	Skjern river, Denmark (2500 km ²)	SCE-UA	“The simulated spatial patterns of AET significantly improved when an objective function based on observed AET patterns and a novel spatial performance metric compared to traditional streamflow-only calibration were included.”
(Koch et al., 2018)/ GMD	mHM (hydrologic / distributed)	2	Discharge and Latent Heat (distributed)	LST MODIS - two-source energy balance model TSEB	Skjern River, Danish peninsula (2500 km ²)	PEST / SCE-UA	“Results suggest the importance of multiple-component metrics because stand-alone metrics tend to fail to provide holistic pattern information. {...} This study suggests applying bias insensitive metrics which further allow for a comparison of variables which are related but may differ in unit.”
(Odusanya et al.,	SWAT (distributed /hydrologic)	1	Evapotranspiration (distributed)	GLEAM_v3 .0a and MOD16	Ogun river (20 292	SWAT-CUP (SUFI-2)	“This study demonstrated the potential to use RS evapotranspiration data for hydrological model

2019)/ HESS					km ²), in Nigeria		calibration and validation in a sparsely gauged large river basin with reasonable accuracy.”
(Becker et al., 2019)/JoH	SWAT (distributed /hydrologic)	1	Evapotranspiration (distributed)	SEBAL	Chenab and Ravi rivers in Pakistan (15000 km ²)	Dynamically Dimensioned Search Algorithm (DDS)	“Results showed that the automated and spatially distributed model calibration was able to increase the model ET simulation performance from 0.04 to 0.27 KGE. [...] Using a modified remote sensing-derived ET product, which accounts for land-use class dependent ET characteristics, improved the overall calibration results to 0.40 KGE.”
(Xiong & Zeng, 2019)/Water	DEM-Based Distributed Rainfall-Runoff Model (DDRM – distributed / hydrologic)	2	Discharge and Soil moisture (distributed)	SMAP	Qujiang and Ganjiang catchments in China (38064 km ² and 81158 km ²)	SCE-UA	“The results show that different weights of soil moisture in the objective function can lead to very slight differences in simulation performance of soil moisture and streamflow. Besides, the joint calibration shows no apparent advantages in terms of streamflow simulation over the traditional calibration using streamflow data only. More studies including various remote sensing soil moisture products are necessary to access their effect on the joint calibration.”
(Koppa et al., 2019)/AWR	Noah-MP (distributed / hydrologic)	3	Discharge, Evapotranspiration and Soil Moisture (distributed)	GLEAM, ESA-CCI	Mississippi river basin (3.3 million km ²)	DREAM and AMALGRAM	“The results of the study show that incorporation of additional fluxes and soil moisture (a storage variable) is not always valuable due to significant trade-offs in accuracy among the model responses. In our experiments, only ET and SF could be simulated

							simultaneously to a reasonable degree of accuracy. In addition, we quantify the trade-offs in accuracy between the model responses using the concept of Pareto optimality. We find that combining ET with other fluxes entails higher trade-offs in accuracy compared to either SM or SF. Unlike deterministic calibration, with the developed framework we are able to identify deficiencies in model parameterization that lead to significant trade-offs in accuracy, especially between ET and SM. We find that the parameters which are insensitive to individual model responses can influence the trade-off relationship between them.”
(Mehmet Cüneyd Demirel et al., 2019) / Water	HBV	3	Discharge, soil moisture, TWS (lumped)	ESA-CCI, SMAP, AMSR-E, GRACE	Moselle River Basin in Germany and France (165,000 km ²)	Gradient-based Levenberg Marquardt, (SCE-UA), Covariance Matrix Adaptation Evolution	“The results of our multi-objective calibration reveal a substantial contribution of remote sensing products to the lumped model calibration, even if their spatially-distributed information is lost during the spatial aggregation. Inclusion of new observations, such as groundwater levels from wells and remotely sensed soil moisture to the calibration improves the model’s physical behavior, while it keeps a reasonable water balance that is the key objective of every hydrologic model.”

						Strategy (CMAES)	
(Schattan et al., 2020) / RSE	SES + HQsim models (snow hydrological model)	2	Discharge, snow (distributed)	MODIS, Landsat(7/8), Sentinel(1A/2A)	Upper Fagge basin, in Austria (52 km ²)	Monte Carlo method	The uncertainty in model calibration is reduced by two thirds when incorporating snow information, compared to calibration with discharge only.
(Dembélé et al., 2020)/ WRR	mHM	4	Discharge, soil moisture, evapotranspiration, TWS (distributed)	GLEAM, ESA CCI, GRACE	Volta river basin, in west Africa (415,600 km ²)	Dynamically dimensioned search algorithm (Tolson & Shoemaker, 2007)	“Results of the multivariate calibration show that the decrease in performance for streamflow (-7%) and terrestrial water storage (-6%) is counterbalanced with an increase in performance for soil moisture (+105%) and evaporation (+26%). These results demonstrate that there are benefits in using satellite data sets, when suitably integrated in a robust model parametrization scheme.”

ANEXO 2.

Table 3-S2. Parameters in MGB model, their initial value and range adopted in this study, and the references that support these values.

	Parameter	Initial value	Range	Reference
soil	Wm (maximum water storage capacity in the soil) [mm]	585	17.55 – 2515.5	(Siqueira et al., 2018)
	b (parameter related to variable infiltration curve) [-]	0.26	0.013 – 1.482	
	Kbas (percolation rate from soil to groundwater) [mm/day]	0.65	0.013 – 8.775	
	Kint (saturated hydraulic conductivity) [mm/day]	9.48	0.019 – 118.5	
	XL (controls the reduction in surface drainage) [-]	0.48	Fixed	
	CAP (capillarity from groundwater to soil) [mm/day]	0.0	Fixed	
	Wc (related to groundwater vertical flux) [mm]	0.1	Fixed	
	CS (related to surface flow propagation) [-]	15.6	1.092 – 40.56	
	CI (related to sub-surface flow propagation) [-]	105.7	21.14 – 401.66	
	CB (groundwater residence time) [days]	2547	483.9 - 10188	
	vegetation	Albedo [-]	0.08 – 0.23	
LAI (forest) [-]		6	2.70 – 10.20	(Doughty & Goulden, 2009)
LAI (agriculture / pasture) [-]		2	0.90 – 3.4	(Negrón Juárez et al., 2009)
LAI (wetlands) [-]		6.34	2.85 – 10.78	(Scurlock et al., 2001)
LAI (semi-impervious) [-]		1.5	0.68 – 2.55	(Scurlock et al., 2001)

	Veg. Height (forest) [m]	15	1.5 – 37.5	(Hui Liu et al., 2019)
	Veg. Height (other HRUs) [m]	0.7	0.07 – 1.75	(Gao et al., 2011)
	Surface Resistance [s/m]	100	30 – 250	(Irmak & Mutiibwa, 2010; Shuttleworth, 1989)
hydraulic	a [-], in $W = aA^b$, where W is bankfull width (m) and A is drainage area (km ²)	2.25	0.9 – 6.07	(Andreadis et al., 2013)
	b [-], in $W = aA^b$, where W is bankfull width (m) and A is drainage area (km ²)	0.48	Fixed	
	c [-], in $h = cA^d$, where h is bankfull depth (m) and A is drainage area (km ²)	0.11	0.0495 – 0.2475	
	d [-], in $h = cA^d$, where h is bankfull depth (m) and A is drainage area (km ²)	0.37	Fixed	
	n Manning [-]	0.03	0.024 – 0.060	(Chow, 1959)

ANEXO 3.

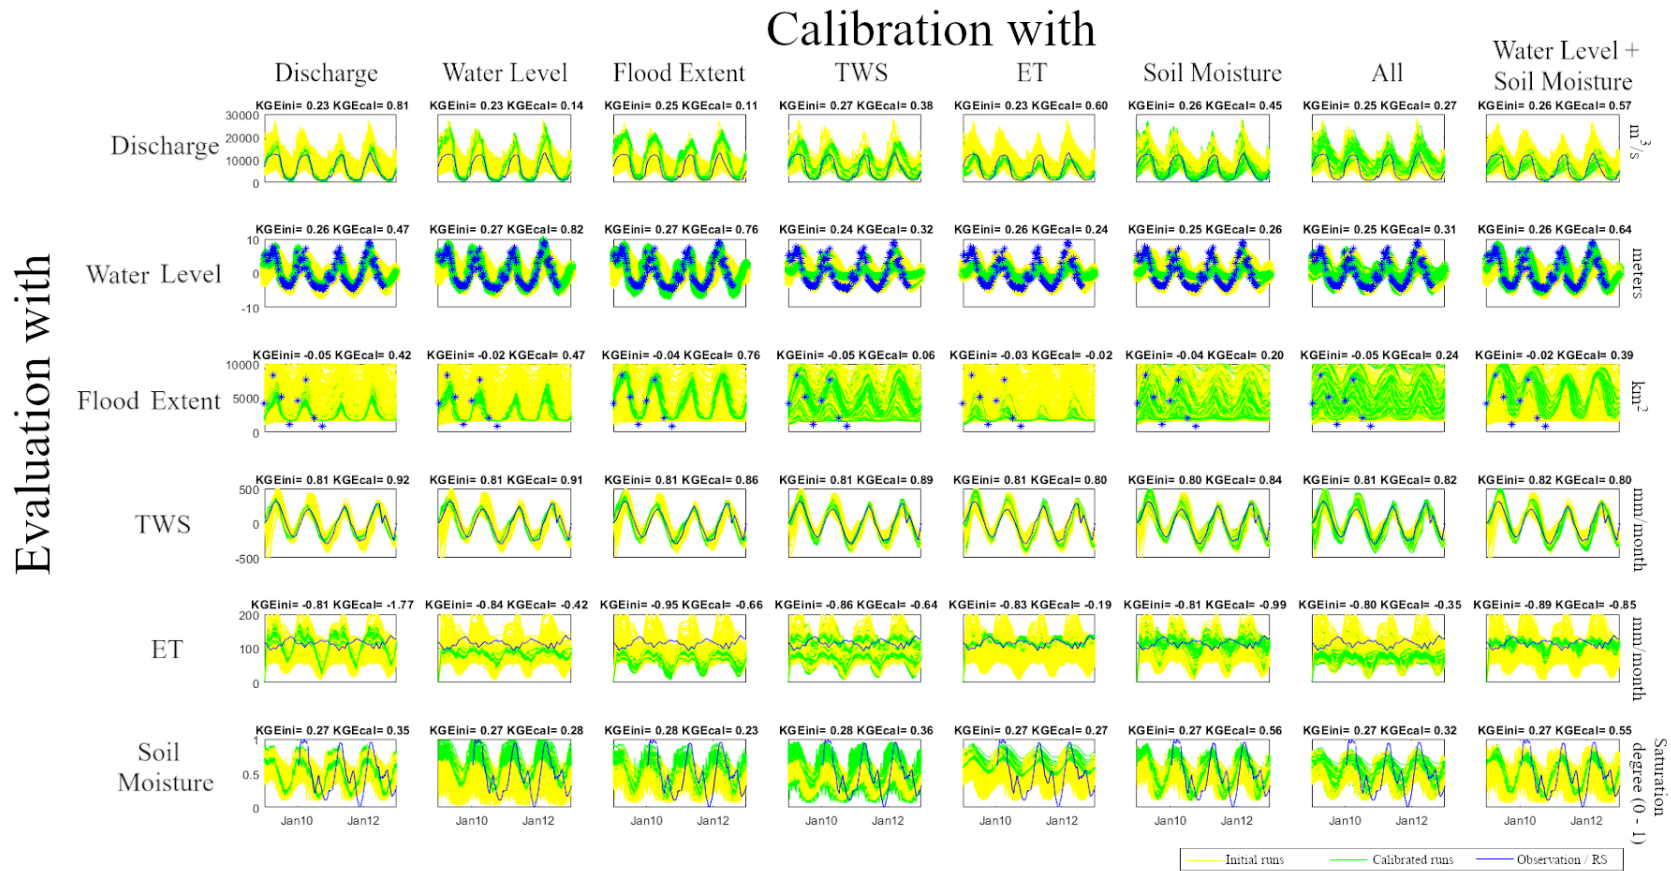



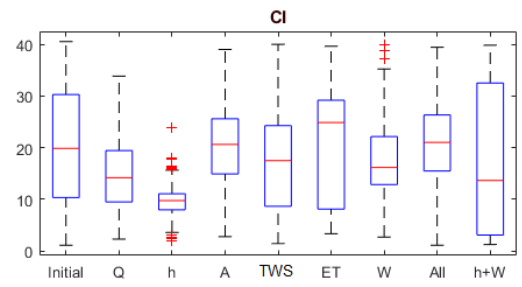



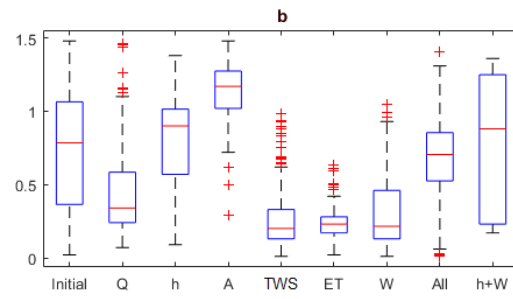



Figure 3-S1. Time series from 2009 to 2012 (calibration period) of all (six) analyzed variables, when calibrating the model with 8 different setups (six variables + all RS variables but discharge + water level and soil moisture). KGEini is the mean KGE of initial runs, and KGEcal the mean KGE of calibrated runs.

ANEXO 4.



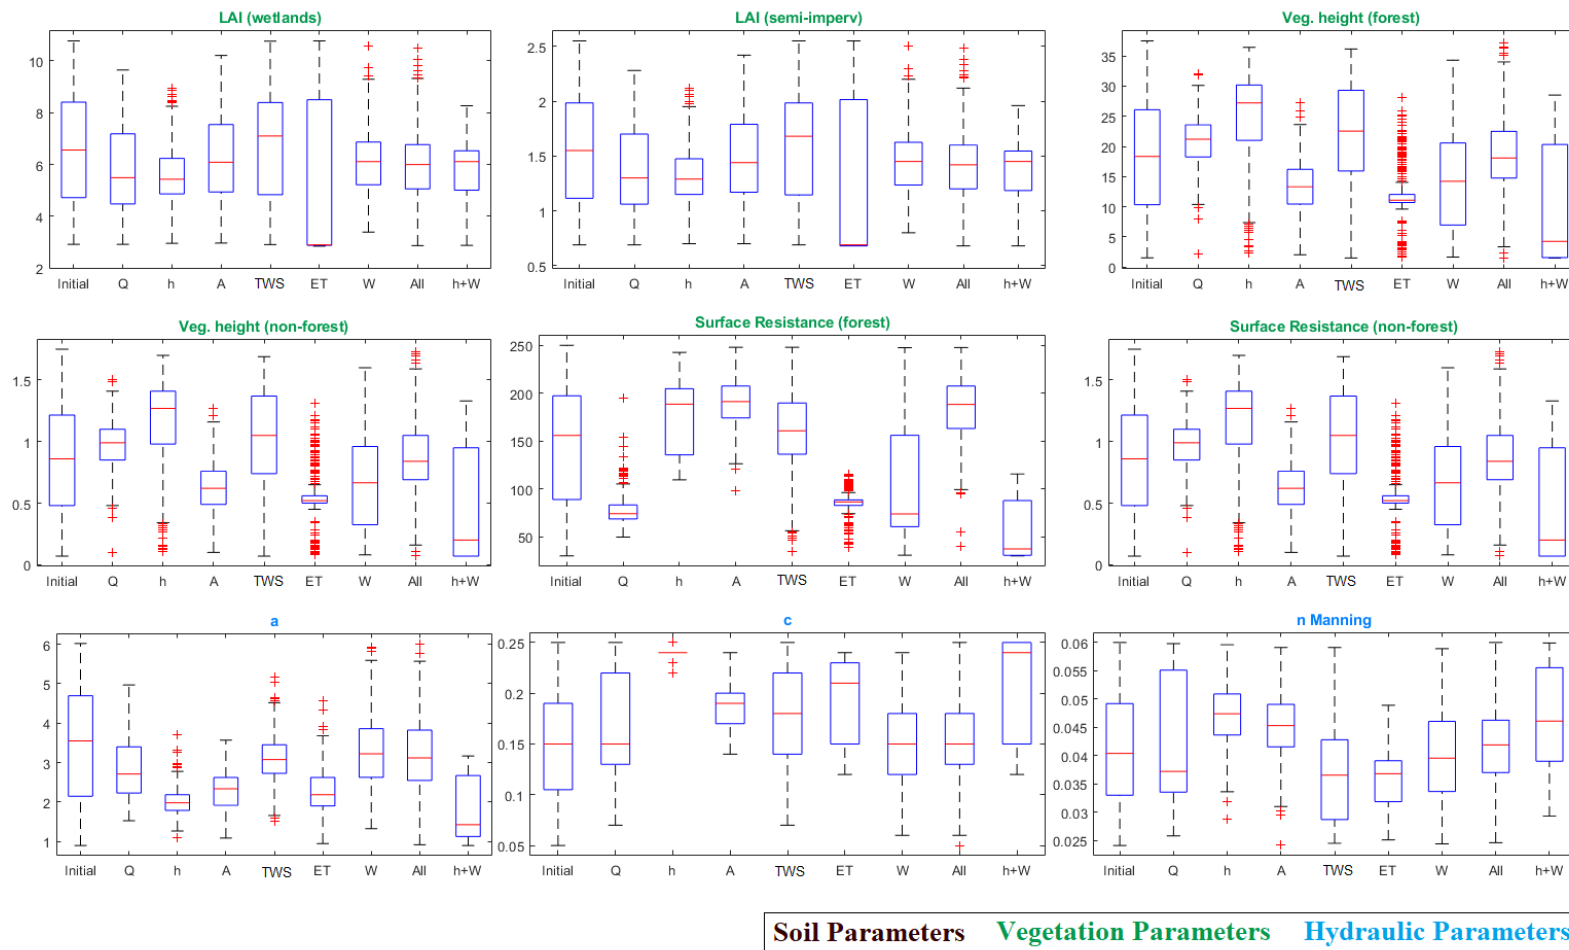
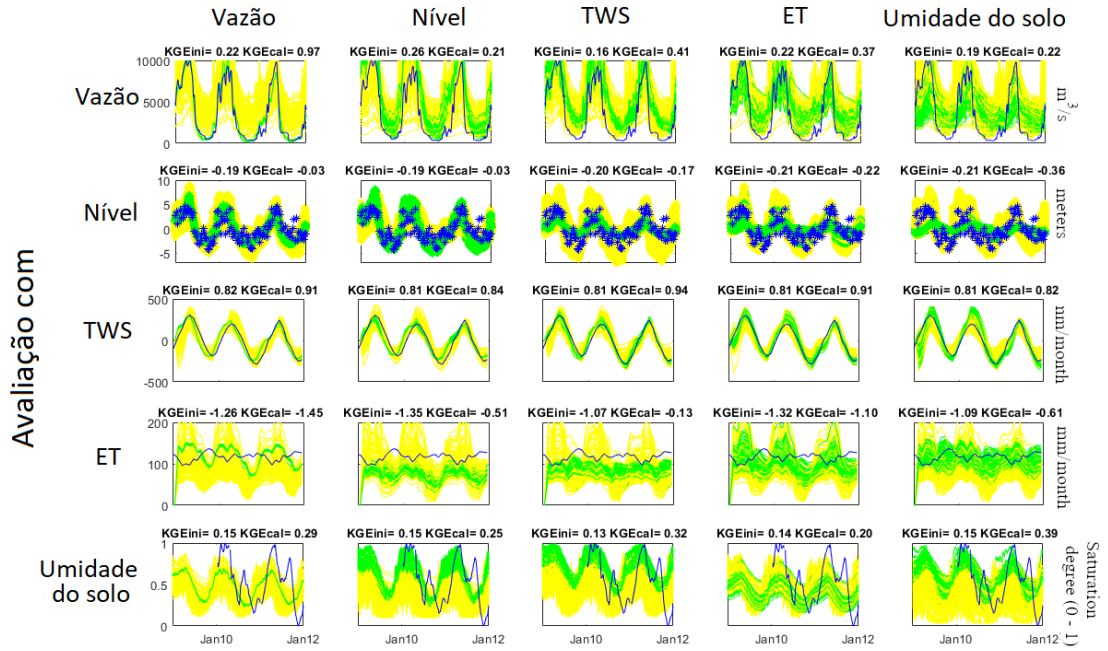


Figure 3-S2. Boxplots of dispersion of model parameters before (Initial), and after one-at-a-time calibration with each variable (Q – discharge; h – water level; A – flood extent; TWS – terrestrial water storage anomalies; ET - vegetation ET; W – soil moisture), and multi-variable experiments (All –variables except discharge; h+W –water level and soil moisture). Parameters are described in Supporting Information (Table 3-S2).

ANEXO 5.

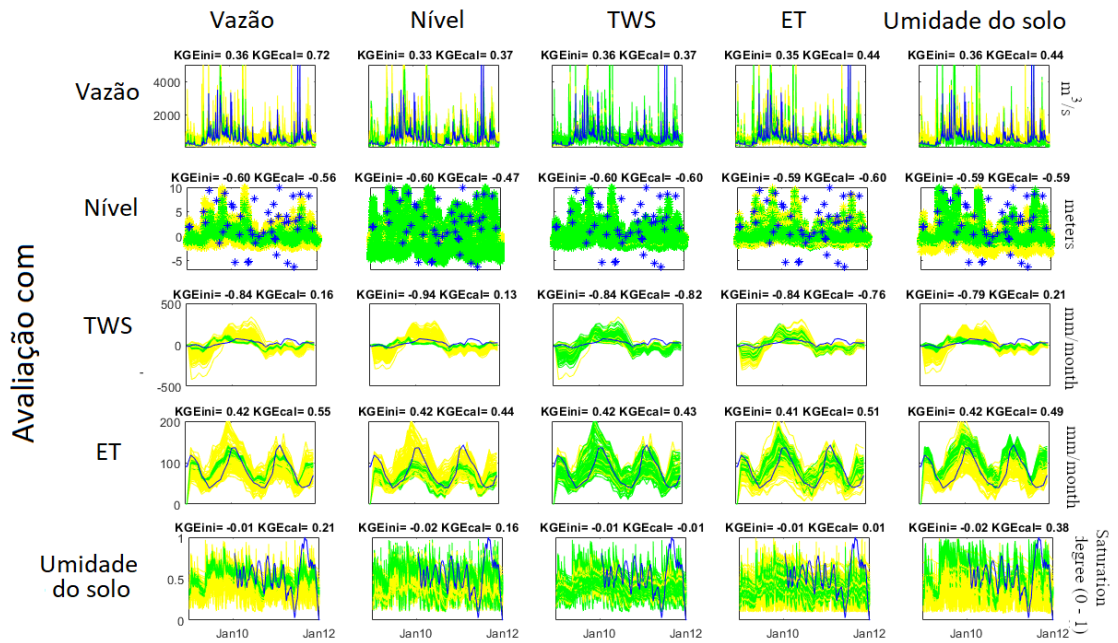
PURUS

Calibração com



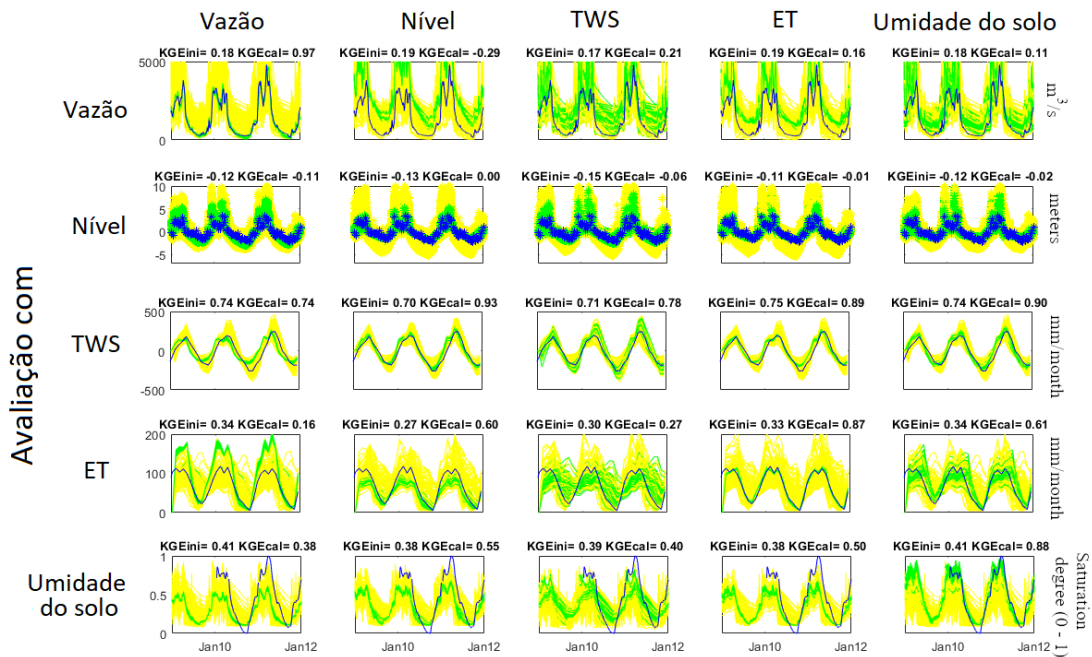
PIQUIRI

Calibração com



ARAGUAIA

Calibração com



PARDO

Calibração com

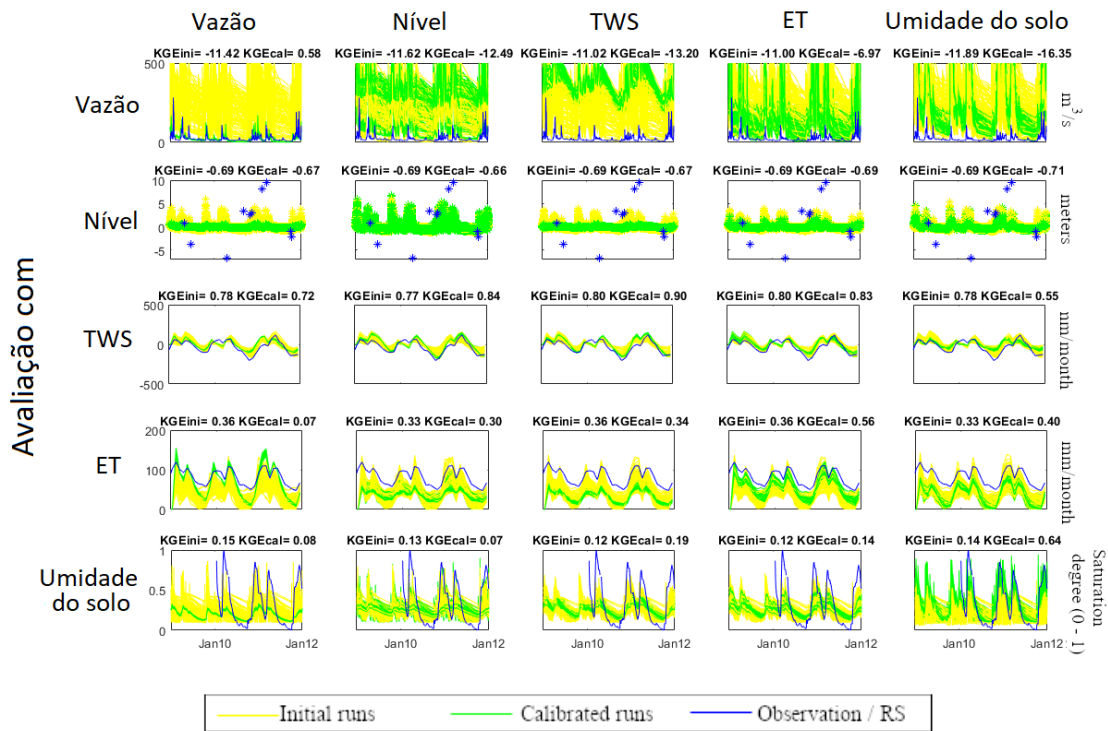


Figura 4-S1. Séries temporais das cinco variáveis analisadas (vazão, nível, TWS, ET e umidade do solo). KGEini refere-se à média dos resultados de KGE da primeira geração. KGEcal refere-se à média dos resultados de KGE da geração final.

ANEXO 6.

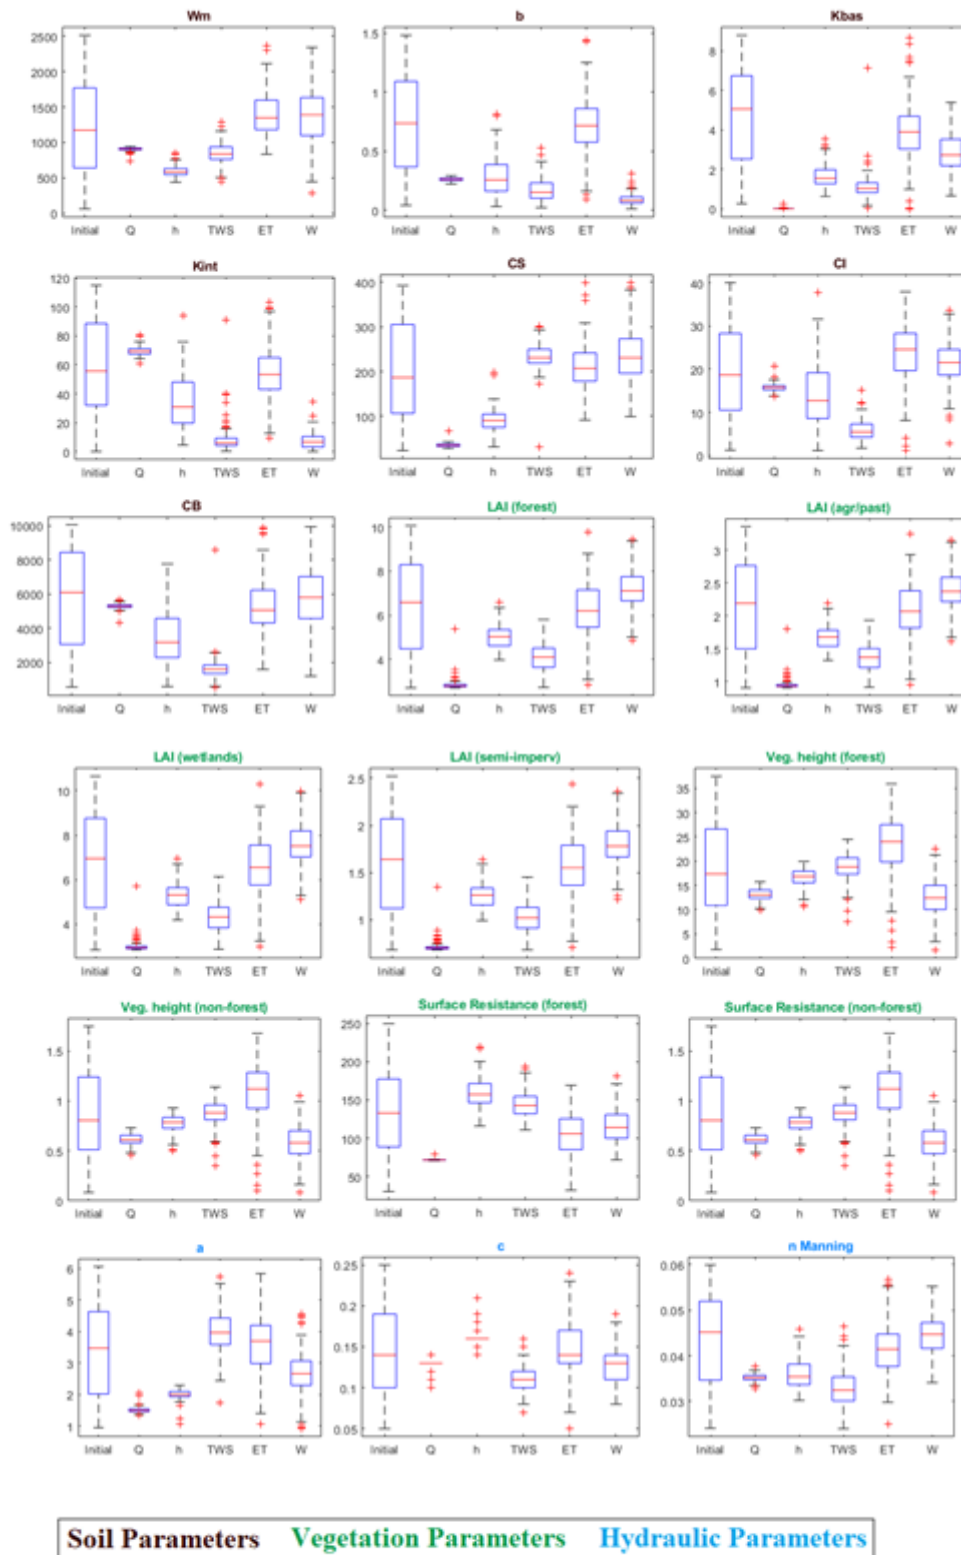
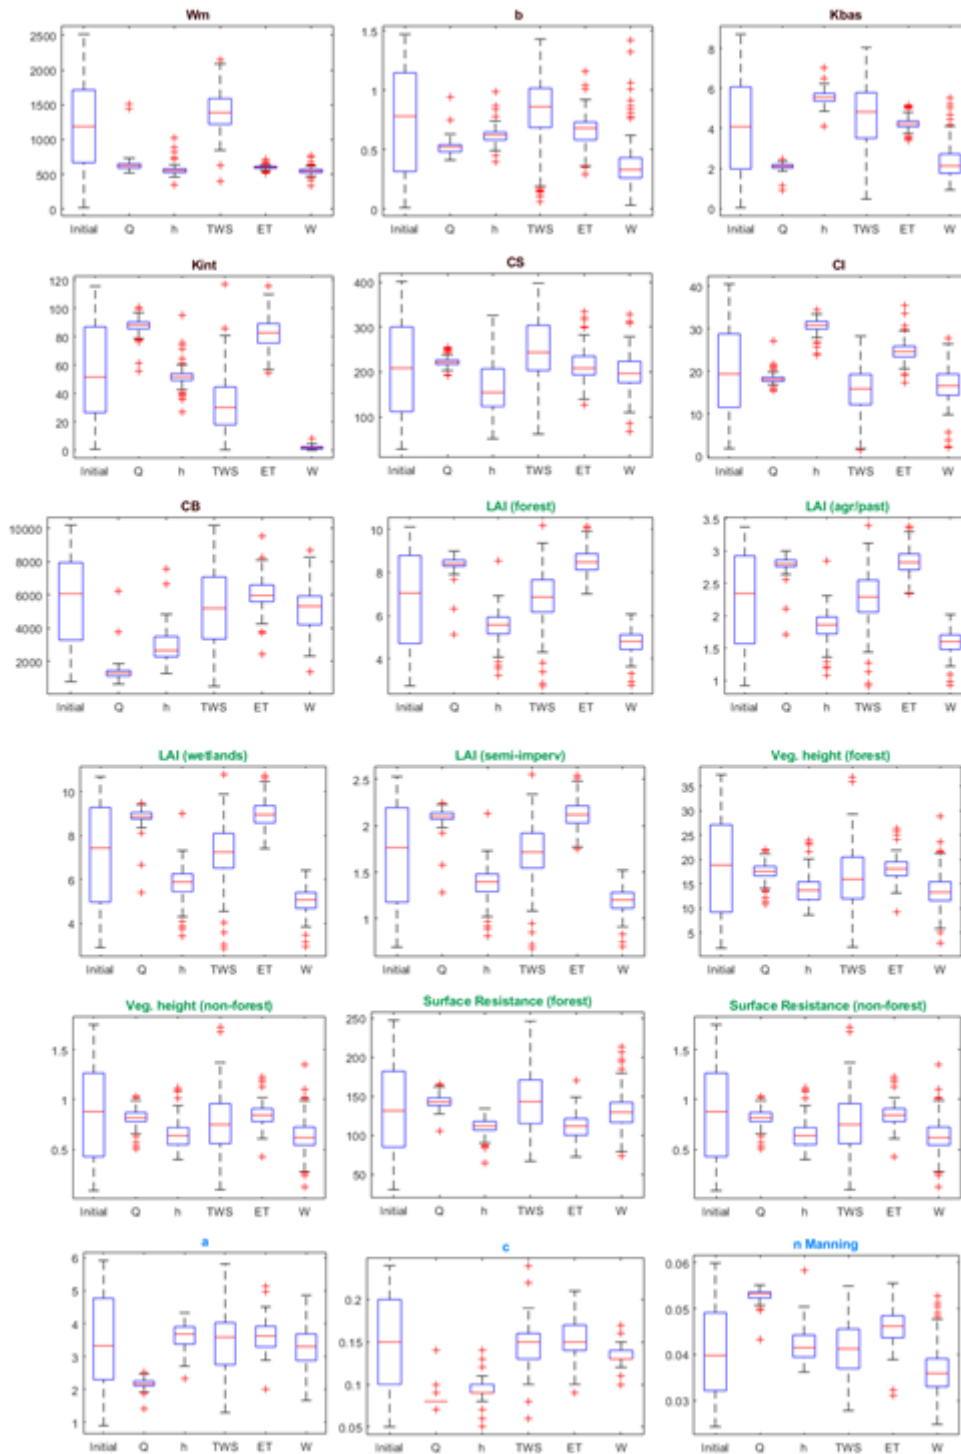
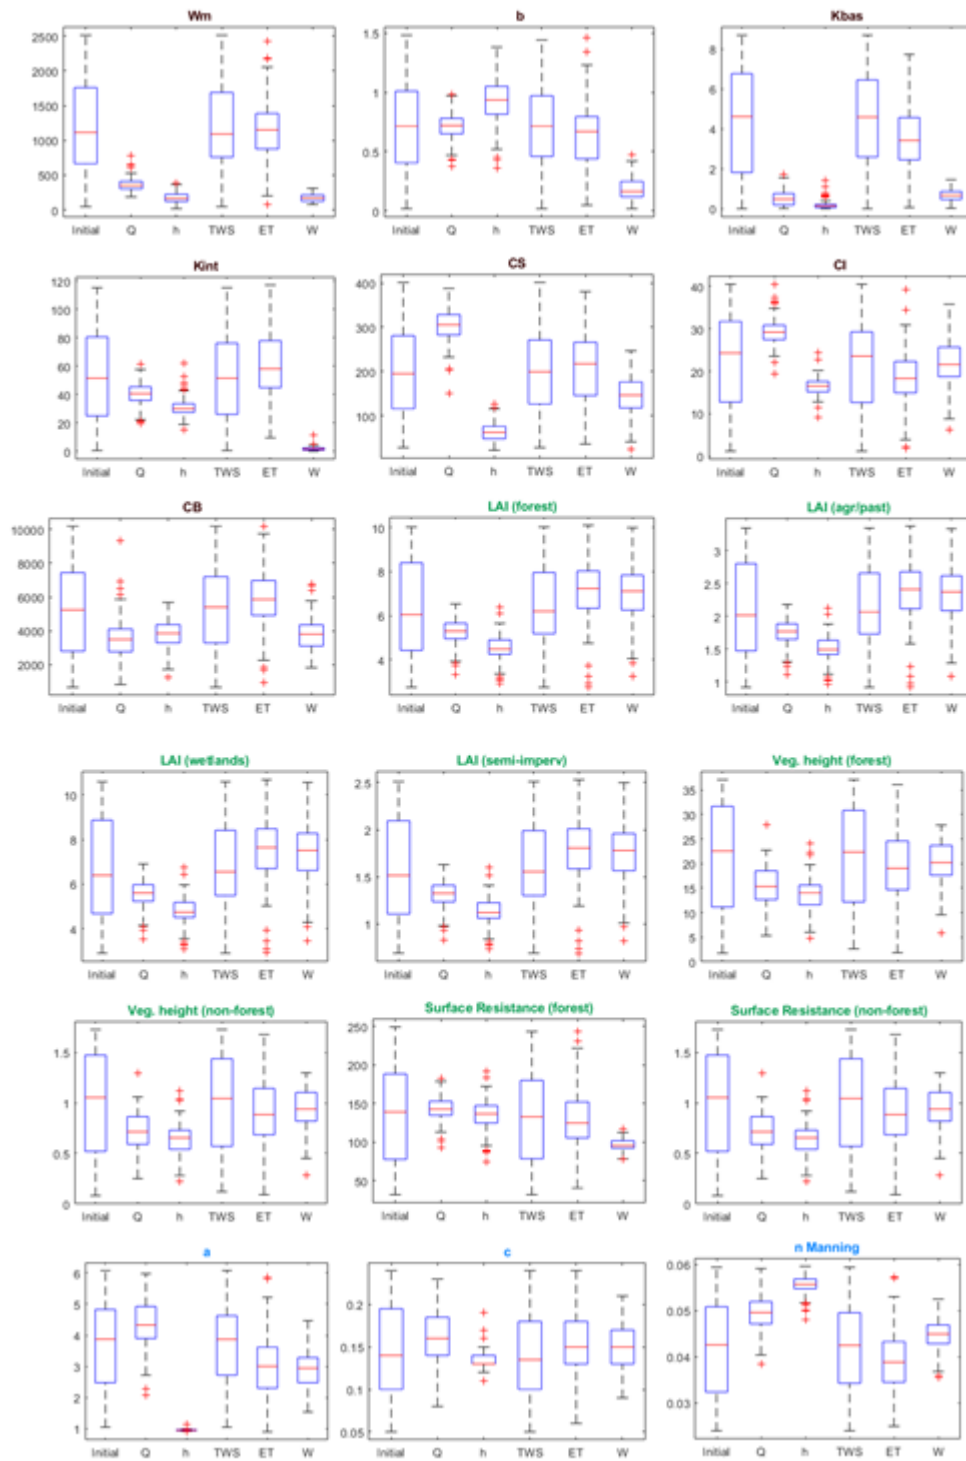


Figura 4-S2a. Boxplots da dispersão dos parâmetros antes da calibração (Initial), e depois da calibração com cada uma das variáveis (Q – vazão; h – nível; TWS – anomalias no armazenamento; ET – evapotranspiração; W – umidade do solo), para a bacia do rio Purus. Os parâmetros estão descritos no ANEXO 2 (Table 3-S2).



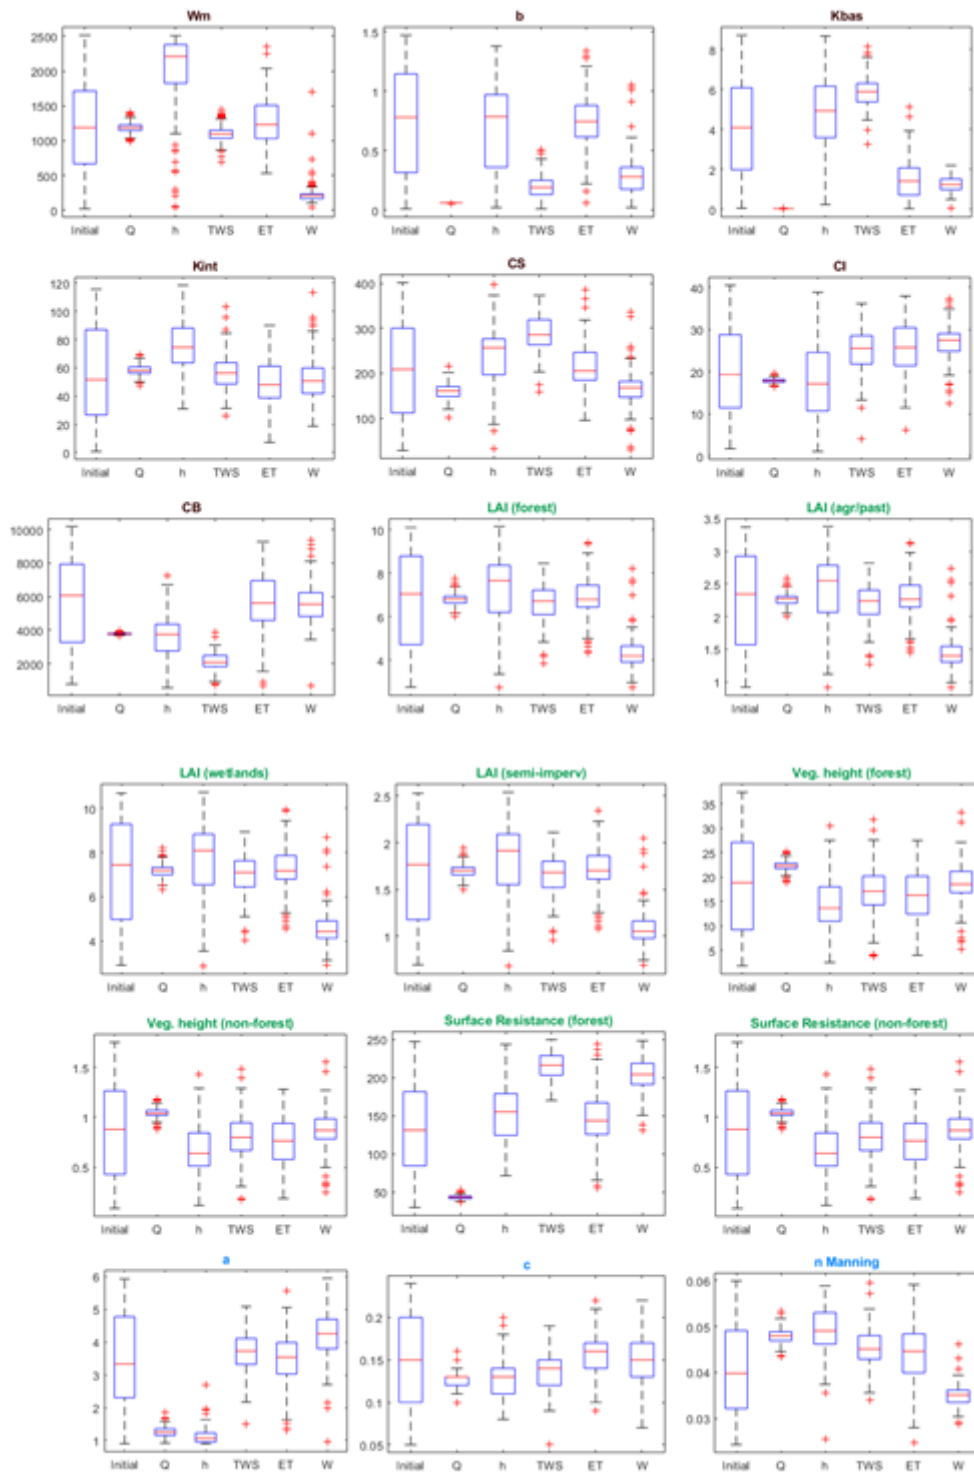
Soil Parameters **Vegetation Parameters** **Hydraulic Parameters**

Figura 4-S2b. Boxplots da dispersão dos parâmetros antes da calibração (Initial), e depois da calibração com cada uma das variáveis (Q – vazão; h – nível; TWS – anomalias no armazenamento; ET – evapotranspiração; W – umidade do solo), para a bacia do rio Araguaia. Os parâmetros estão descritos no ANEXO 2 (Table 3-S2).



Soil Parameters **Vegetation Parameters** **Hydraulic Parameters**

Figura 4-S2c. Boxplots da dispersão dos parâmetros antes da calibração (Initial), e depois da calibração com cada uma das variáveis (Q – vazão; h – nível; TWS – anomalias no armazenamento; ET – evapotranspiração; W – umidade do solo), para a bacia do rio Piquiri. Os parâmetros estão descritos no ANEXO 2 (Table 3-S2).



Soil Parameters **Vegetation Parameters** **Hydraulic Parameters**

Figura 4-S2d. Boxplots da dispersão dos parâmetros antes da calibração (Initial), e depois da calibração com cada uma das variáveis (Q – vazão; h – nível; TWS – anomalias no armazenamento; ET – evapotranspiração; W – umidade do solo), para a bacia do rio Pardo. Os parâmetros estão descritos no ANEXO 2 (Table 3-S2).