



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CAMPUS FLORIANÓPOLIS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
AMBIENTAL

TÁSSIA MATTOS BRIGHENTI

USO DO MODELO SWAT E MODELOS DE CLIMA NA ANÁLISE DA
DISPONIBILIDADE HÍDRICA: UM ESTUDO COM BACIAS DE SANTA
CATARINA

FLORIANÓPOLIS

2019

Tássia Mattos Brighenti

USO DO MODELO SWAT E MODELOS DE CLIMA NA ANÁLISE DA
DISPONIBILIDADE HÍDRICA: UM ESTUDO COM BACIAS DE SANTA
CATARINA

Tese submetida ao Programa de Pós-Graduação em Engenharia Ambiental da Universidade Federal de Santa Catarina para a obtenção do título de doutor em Engenharia Ambiental.

Orientador: Profa. Dra. Nadia Bernardi Bonumá

Coorientador: Prof. Dr. Pedro Luiz Borges Chaffe

Florianópolis

2019

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Brighenti, Tássia
USO DO MODELO SWAT E MODELOS DE CLIMA NA ANÁLISE DA
DISPONIBILIDADE HÍDRICA: UM ESTUDO COM BACIAS DE SANTA
CATARINA / Tássia Brighenti ; orientador, Nadia Bonumá,
coorientador, Pedro Chaffe, 2019.
103 p.

Tese (doutorado) - Universidade Federal de Santa
Catarina, Centro Tecnológico, Programa de Pós-Graduação em
Engenharia Ambiental, Florianópolis, 2019.

Inclui referências.

1. Engenharia Ambiental. 2. Hidrologia Aplicada. I.
Bonumá, Nadia. II. Chaffe, Pedro. III. Universidade
Federal de Santa Catarina. Programa de Pós-Graduação em
Engenharia Ambiental. IV. Título.

Tássia Mattos Brighenti

USO DO MODELO SWAT E MODELOS DE CLIMA NA ANÁLISE DA
DISPONIBILIDADE HÍDRICA: UM ESTUDO COM BACIAS DE SANTA
CATARINA

O presente trabalho em nível de doutorado foi avaliado e aprovado por banca
examinadora composta pelos seguintes membros:

Prof. Davide Franco, Dr.

Universidade Federal de Santa Catarina

Luis Hamilton P. Garbossa, Dr.

EPAGRI/CIRAM

Pablo Borges de Amorim, Dr.

Universidade Federal de Santa Catarina

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi
julgado adequado para obtenção do título de doutor em Engenharia Ambiental.

Prof. Dr.(a) Maria Eliza Nagel Hassemer

Coordenador(a) do Programa

Prof. Dr.(a) Nadia Bernardi Bonumá

Orientador(a)

Florianópolis, 18 de dezembro de 2019.

AGRADECIMENTOS

Ao universo e minha admirável boa sorte!

Agradeço à Universidade Federal de Santa Catarina, por me proporcionar uma educação pública e de qualidade. Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo auxílio financeiro durante os quatro anos de doutorado, incluindo meu período no exterior.

Aos meus orientadores Nadia e Pedro, agradeço por esses sete anos de caminhada. Por compartilharem comigo seu tempo e conhecimentos. Por me permitirem fazer parte da inspiradora equipe LabHidro.

Aos membros da banca, Professor Davide Franco, Luis Garbossa e Pablo Borges pela contribuição na melhoria da qualidade deste trabalho.

Aos meus pais, Rosy e Humberto, por todo o apoio e investimento na minha educação. Aos meus irmãos Lívia e Luiz por estarem sempre emocionalmente disponíveis. A família Brighenti pela paixão pelo conhecimento.

Aos meus amigos que tornaram essa jornada possível. A todos que fizeram e fazem parte do meu dia-a-dia, a todos que estão na minha vida. Por compartilharem experiências, ciência e sentimentos.

À Veronica, o ser mais extraordinário que tive a oportunidade de conhecer.

“The important thing in science is not so much to obtain new facts as to discover new ways to think about them.” (Willian Lawrence Bragg)

RESUMO

Este estudo fornece uma estrutura abrangente e uma avaliação atualizada das abordagens necessárias para realização de estudos que visam o cálculo das disponibilidades hídricas atuais e futuras em uma região específica. O modelo *Soil and Water Assessment Tool* (SWAT) juntamente com modelos de clima (*General Circulation Models* – GCMs) foram aplicados em nove bacias do estado de Santa Catarina objetivando o cálculo das variáveis hidrológicas no passado e futuro. Especificamente, a abordagem foi baseada na identificação da resolução ideal dos dados de chuva; calibração e validação do modelo SWAT; redução da quantidade de GCMs utilizados na aplicação das projeções futuras; correção da evapotranspiração; e integração do SWAT (parâmetros calibrados) com os GCMs (dados de precipitação e temperatura). Na investigação da resolução espacial dos dados de chuva e sua influência na resposta hidrológica do modelo SWAT, os resultados confirmam a importância de uma representação confiável da variabilidade espacial da chuva, e que para anos secos, o detalhamento da rede de monitoramento deve ser mais preciso. O SWAT foi calibrado e validado de maneira eficiente, e obteve bons resultados para dois métodos de cálculo da evapotranspiração potencial, com o método de Penam-Monteith apresentando pequena melhora em relação ao de Hargreaves. Para a representação das condições futuras de precipitação e temperatura no estado de Santa Catarina, foram selecionados oito GCMs que apresentam diferença menor que 50% entre as distribuições estatísticas dos dados observados e a rodada histórica. Embora os dados brutos e corrigidos dos GCMs apresentem a mesma relação de aumento ou diminuição do volume de chuva em relação à média anual observada, os dados corrigidos apontam melhora significativa, na representação das séries históricas, quando aplicado um método de correção de viés. As projeções futuras indicam que a produção de água para as bacias estudadas aumentará durante a estação úmida e diminuirá durante a estação seca.

Palavras-chave: Resolução espacial da chuva. Evapotranspiração. Correção de viés.

ABSTRACT

This study provides a comprehensive framework and an up-to-date assessment of the approaches needed to conduct studies that aimed the water availability future projections in a specific region. I applied the Soil and Water Assessment Tool (SWAT) model together with Global Circulation Models (GCMs) to nine watersheds in Santa Catarina state, in order to calculate the hydrological variables for past and future. Specifically, the approach was based on identifying optimal rainfall data resolution; SWAT calibration and validation; reducing the amount of GCMs used for future projections; evapotranspiration correction; and integrating SWAT (calibrated parameters) with GCMs (precipitation and temperature data). In the investigation of the spatial resolution of the rainfall data and its influence on the hydrological response of the SWAT model, the results confirm the importance of a reliable representation of the spatial variability of the rainfall, and that for some periods, such as dry years, the detailing of the water network. Rain must be more accurate. The SWAT was efficiently calibrated and validated and yielded good results for two potential evapotranspiration calculation methods, with the Penam-Monteith method showing slight improvement over Hargreaves. To represent future precipitation and temperature conditions in the state of Santa Catarina, eight GCMs were selected with a difference of less than 50% between statistical distribution in the observed data and the historical round. Although the raw and corrected GCMs data show the same ratio of increase or decrease in rainfall volume compared to the observed annual average, the corrected data show significant improvement in the representation of historical series, when a bias correction method is applied. Future projections indicate that water production for the studied basins will increase during the wet season and decrease during the dry season.

Keywords: Rainfall data resolution. Evapotranspiration. Bias correction.

LISTA DE FIGURAS

Figura 1 - Aplicações do modelo SWAT distribuídas pelo mundo. O sombreamento indica o número de estudos por país, que usam dados subdiários. O pontilhado indica os locais revisados por Gassman et al., (2007, 2014). Fonte: Brighenti et al., (2019b).....	20
Figura 2 - Demonstração da divisão da série histórica de vazões para o <i>Split-Sample Test</i>	25
Figura 3 - Modelo <i>family tree</i> CMIP3 e CMIP5 (marcado com *) Fonte: (Knutti et al., 2013).....	31
Figura 4 - Representação metodológica da proposta deste trabalho. Os processos assinalados com * são ilustrados nas Figuras 8 (seção 3.3) e 10 (seção 3.5.8).	33
Figura 5 - Localização das bacias hidrográficas, pontos de monitoramento de chuva e vazão, captação de água, pequenas centrais hidrelétricas (PCHs), e usinas hidrelétricas (UHEs) no estado de Santa Catarina. No decorrer do texto, as bacias hidrográficas são nomeadas de acordo com os códigos (e.g. das Almas) descritos no exutório de cada bacia apresentados na figura.	35
Figura 6 - (a) tipo de solo e (b) uso da terra, utilizados nas simulações com o modelo SWAT.	35
Figura 7 – Passos para a configuração do modelo <i>Soil and Water Assessment Tool</i> - SWAT.	38
Figura 8 – Representação do arranjo espacial de estações pluviométricas após a interpolação IDW. Os pontos azuis são a estações de chuva originais e os pontos laranja-azul são as novas estações de precipitação com dados interpolados para o centro de cada grade.	43
Figura 9 - Procedimento na realização do DM. Esquerda: A distribuição Gamma da precipitação diária simulada foi deslocada para a distribuição Gamma das observações (círculos pretos). Direita: A distribuição Gaussiana da temperatura média diária simulada por foi deslocada em direção à distribuição Gaussiana das observações (círculos pretos). Fonte: Teutschbein e Seibert, (2012).	49
Figura 10 – Passo-a-passo para a realização do processo de correção da evapotranspiração.	50
Figura 11 - Histograma para os 29 anos (1985-2013) de chuva média mensal, referentes a cada bacia simulada.....	52

<p>Figura 12 - Resultados mensais da vazão durante o ano mais seco de cada bacia, separados para as cinco entradas diferentes (original, 5 km, 10 km, 30 km e 90 km). Curva de probabilidade cumulativa (CP) para cada cenário apresentando os valores de NS e sua classificação. A escala de cores na CP representam a classificação das simulações proposta por Ritter e Muñoz-Carpena, (2013), variando de muito bom, verde escuro, à branco para insatisfatório.), porcentagem de simulações dentro de cada faixa pode ser encontrada no APÊNDICE A.</p>	54
<p>Figura 13 - Melhores parâmetros obtidos para as calibrações com Hargreaves e Penman-Monteith. O eixo x corresponde ao intervalo dos valores usados na calibração do modelo SWAT descritos na Tabela 4.....</p>	56
<p>Figura 14 – Valores médios mensais não calibrados de evapotranspiração (ET) e produção de água (WYLD) para os 29 anos simulados. As colunas representam ET (H - Hargreaves e PM - Penman-Monteith) e as linhas são representativas dos valores de WYLD.....</p>	58
<p>Figura 15 - Melhores parâmetros obtidos para as calibrações com Hargreaves e Penman-Monteith para todas as bacias hidrográficas. O eixo x corresponde ao intervalo dos valores usados na calibração do modelo SWAT descritos na Tabela 4.</p>	60
<p>Figura 16 - Espacialização das estações para os quais são fornecidos os dados das variáveis dos modelos de clima. Os quadros marcados são referentes aos modelos selecionados para a aplicação com o modelo SWAT.</p>	61
<p>Figura 17 – Parâmetros <i>shape</i> e <i>scale</i> para cada um dos GCMs escolhidos já corrigidos pelo método DM. A linha azul representa dos dados observados de precipitação e a linha vermelha representa os dados da rodada histórica dos modelos de clima.....</p>	63
<p>Figura 18 – Comparação entre os resultados obtidos a partir das simulações realizadas com os dados observados e as simulações com os dados da rodada histórica, brutos e corrigidos, dos GCMs, para a bacia hidrográfica das Almas.</p>	65
<p>Figura 19 - Resultado das variáveis precipitação, produção de água e evapotranspiração para as simulações dos cenários futuros rcp4.5 e rcp 8.4. A linha pontilhada no eixo da precipitação representa os valores históricos observados (2000 – 2004).</p>	66
<p>Figura 20 - Precipitação para os cenários rcp4.5 e rcp8.5 e para os modelos escolhidos nas bacias hidrográficas das Almas e Itajaí-Açu. O resultado para o restante das bacias estudadas pode ser encontrado no Apêndice D.....</p>	68

<p>Figura 21 - Valores para a produção de água (a) e evapotranspiração (b) para as bacias hidrográficas estudadas. As linhas tracejadas representam os valores médios para os dados observados (1985-2013), as linhas e colunas em cor laranja são para o cenário rcp4.5 e as em cor verde ao cenário rcp 8.5.</p>	69
<p>Figura 23 – Distribuição espacial da média anual de chuvas para o período de 1985 - 2013.....</p>	89
<p>Figura 24 - Distribuição espacial da chuva mensal para o arranjo original das estações e diferentes tamanhos de grade (5 km, 10 km, 30 km, 90 km), para o ano mais seco avaliado.....</p>	89
<p>Figura 25 - Precipitação para os cenários rcp4.5 e rcp8.5 e para os modelos escolhidos para cada bacias hidrográficas.....</p>	92
<p>Figura 27 – Representação do período de calibração e validação para cada um dos exutórios analisados. Cada coluna representa um ano e cada linha um mês. Em verde o período total de dados de vazão disponíveis, com linhas o período usado na calibração e pontilhado o período usado na validação.....</p>	94

LISTA DE TABELAS

Tabela 1 - Relação de trabalhos que utilizam dados de chuva provenientes de GCMs com o uso do modelo SWAT.	30
Tabela 2 – Descrição do uso da terra atribuído para agricultura em cada uma das bacias hidrográficas analisadas, área das bacias, e código de identificação utilizado na Figura 5 e no decorrer do texto.	36
Tabela 3 – Resumo quantidade de estações de chuva utilizadas no processo de simulação. Nome da bacia hidrográfica, área, quantidade e área média de cada subbacia.	43
Tabela 4 - Relação dos parâmetros utilizados no processo de calibração, bem como suas descrições, e intervalo dos valores máximos e mínimos.	44
Tabela 5 - Anos usados nos processos de calibração e validação do modelo SWAT.	45
Tabela 6 – Modelos referentes ao pacote CMIP5 usados na obtenção dos dados de precipitação e temperatura, centros de pesquisa e resolução espacial.	48
Tabela 7 - Valores mensais de Nash-Sutcliffe para vazão, sem a distinção entre anos médios, secos e úmidos. O boxplot ao lado mostra a representação da distribuição de valores.	53
Tabela 8 – Valores mensais de NS e RMSE para os valores de vazão. Os valores foram calculados através da ferramenta disponível em Ritter and Muñoz-Carpena, (2013).	55
Tabela 9 - Valores de <i>p-factor</i> e <i>r-factor</i> para calibração do modelo SWAT para os diferentes tamanhos de grade. Tabela para valores calibrados e não calibrados de vazão. Valores de <i>p-factor</i> e <i>r-factor</i> para calibração do modelo SWAT para os diferentes tamanhos de grade.	56
Tabela 10 – Calibração do modelo SWAT com os métodos de Penman-Monteith e Hargreaves.	59
Tabela 11 – Diferença em % das distribuições estatísticas para os parâmetros <i>shape</i> e <i>scale</i> dos dados observados de precipitação e rodada histórica dos GCMs. Os modelos de mesma família são marcados na tabela com o mesmo número.	62
Tabela 12 – Diferença em % para os valores de temperatura máxima e mínima entre valores observados e da rodada histórica.	64
Tabela 13 – Desempenho dos modelos de clima na bacia hidrográfica das Almas. O coeficiente Pbias é apresentado para uma simulação de cinco anos (2000 -	

2004), para as variáveis precipitação (prec.), produção de água na bacia (WYLD) e evapotranspiração (ET).....	64
Tabela 14 - Porcentagens das simulações apresentas na Figura 12 para as respectivas curvas de Probabilidade Cumulativa. Segundo a classificação de Ritter e Muñoz-Carpena, (2013).....	88
Tabela 15 – Diferença em % entre as distribuições dos parâmetros <i>shape</i> e <i>scale</i> para os dados observados e da rodada histórica dos modelos de circulação global.....	91

LISTA DE ABREVIATURAS E SIGLAS

ANA - Agencia Nacional de Águas

ASCE – Sociedade Americana de Engenharia Civil

BHRN – Bacia Hidrográfica do Rio Negrinho

CANMAX - Quantidade de água interceptada

CEAP - Projeto de Avaliação dos Efeitos da Conservação

CH_N1 - Coeficiente de Manning para os canais tributários

CH_N2 - Coeficiente de Manning para o canal principal

CH_K1 - Condutividade efetiva dos canais tributários

CH_K2 - Condutividade efetiva do canal

CIRAM - Centro de Informações de Recursos Ambientais e de Hidrometeorologia de Santa Catarina

CN – Curva número

CN2 - Curva Número inicial para condição de umidade do solo II

DEM - Modelo Numérico do Terreno

EPAGRI - Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina

ESCO - Coeficiente de compensação de evaporação de água no solo

ET-H Evapotranspiração usando o método de Hargreaves

ET-PM – Evapotranspiração calculada usando o método e Penman-Monteith

GCM – *General Circulation Models*

GW_DELAY - Intervalo de tempo para recarga do aquífero

GW_QMN - Nível limite de água no aquífero livre para ocorrer o fluxo de retorno

GW_REVAP - Coeficiente de ascensão de água à zona de saturação

HidroWeb - Sistema de Informações Hidrológicas

HRU – Unidade de Resposta Hidrológica

IBGE – Instituto Brasileiro de Geografia e Estatística

LATTIME - Escoamento lateral

logNSE – Função logarítmica do Coeficiente de Eficiência de Nash-Sutcliffe

NES – Coeficiente de Eficiência de Nash-Sutcliffe

Pbias – Percent Bias

PET - Evapotranspiração Potencial

RCHRG_DP - Coeficiente de percolação da água para o aquífero profundo

REF-ET - Reference Evapotranspiration Calculation Software

SCS - Soil Conservation Service

SLSOIL - Comprimento da declividade para o escoamento subsuperficial

SOL_AWC - Armazenamento de água no solo

SUFI2 – Sequential Uncertainty Fitting

SURLAG - Coeficiente de retardamento do escoamento superficial direto

SWAT – Soil and Water Assessment Tool

SWAT CUP - SWAT Calibration and Uncertainty Procedures

USDA - Serviço de Pesquisas Agrícolas

USEPA - Agência de Proteção Ambiental dos Estados Unidos

LISTA DE SÍMBOLOS

Símbol	Descrição
o	
\bar{d}	distância entre os limites superior e inferior de 95PPU
E_a	evapotranspiração total diária no dia t (mm)
ET_o	evapotranspiração potencial (mm/dia)
I_a	abstração inicial que abrange o armazenamento, a interceptação e a infiltração no solo antes de iniciar o escoamento superficial (mm)
K_{time}	constante que depende da escala de tempo utilizada
k	o número de pontos de dados observados
n	constante
Q	vazão (m ³ /s)
qt	valor filtrado da vazão no tempo t (m ³ /s)
Qt	vazão no tempo t (m ³ /s);
Q_{gw}	vazão de retorno no dia t (mm)
Q^{mean}	média da vazão observada, para as três equações (m ³ /s)
Q_i^{obs}	vazão observa (m ³ /s)
Q_i^{sim}	vazão simulada (m ³ /s)
Q_{sup}	escoamento superficial total (mm)
$r(x)$	valores residuais
R_{day}	precipitação total diária no dia t (mm)
S	parâmetro de retenção (mm)
SW_t	quantidade final de água no solo (mm)
SW_o	quantidade inicial de água no solo (mm)
t	tempo (dias)
X_u	percentil correspondente a 97,5% da distribuição cumulativa de cada ponto simulado
W_{seep}	quantidade de água que entra e é armazenada no solo (mm)
σ_x	desvio padrão da variável medida x
$\lambda_i^{ks}(x)$	pesos obtidos da resolução do sistema de krigagem

SUMÁRIO

1	INTRODUÇÃO	15
1.1	OBJETIVO GERAL.....	17
1.1.1	Objetivos Específicos	17
2	REVISÃO BIBLIOGRÁFICA	19
2.1	O MODELO SWAT.....	19
2.1.1	Uso em diferentes escalas de tempo	20
2.1.2	Resolução espacial da chuva	21
2.1.3	Estimativa da evapotranspiração	22
2.2	CALIBRAÇÃO, VALIDAÇÃO, E ANÁLISE DE INCERTEZA DE MODELOS HIDROLÓGICOS	23
2.2.1	Avaliação de modelos hidrológicos	26
2.2.2	SWAT-CUP e o algoritmo SUFI2	27
2.3	MODELOS DE CLIMA.....	29
3	MATERIAIS E MÉTODOS	33
3.1	ÁREA DE ESTUDO	34
3.2	O MODELO SWAT.....	36
3.2.1	O algoritmo SUFI2	38
3.3	RESOLUÇÃO ESPACIAL DA CHUVA PARA O MODELO SWAT	42
3.3.1	O Método IDW	43
3.4	CALIBRAÇÃO e VALIDAÇÃO DO MODELO SWAT	44
3.5	MODELOS DE CLIMA COMO ENTRADA NO SWAT	47
3.5.1	Correção de viés	48
3.5.2	Correção da evapotranspiração	50
4	RESULTADOS E DISCUSSÃO	51
4.1	EFEITO DA RESOLUÇÃO ESPACIAL DA CHUVA NAS SIMULAÇÕES	51
4.2	CALIBRAÇÃO E VALIDAÇÃO DO MODELO SWAT	55
4.2.1	Calibração para os diferentes tamanhos de grade	55

4.2.2	Diferenças no cálculo da evapotranspiração	57
4.3	ESCOLHA DOS MODELOS DE CLIMA	60
4.4	INTREGRAÇÃO MODELO SWAT E MODELOS DE CLIMA.....	67
5	CONCLUSÃO	73
	REFERÊNCIAS	75
	APÊNDICE A.....	88
	APÊNDICE B.....	89
	APÊNDICE C.....	91
	APÊNDICE D.....	92
	APÊNDICE E.....	94

1 INTRODUÇÃO

A preocupação dos gestores públicos em relação a água é baseada em satisfazer as demandas populacionais atuais e em como enfrentar problemas associados a secas ou inundações. No Brasil a disponibilidade de água depende em grande parte do clima. Recentemente, mudanças na precipitação e temperatura, foram observadas como possíveis causas dos problemas que afetam a disponibilidade da água (Marengo, 2008).

Aproximadamente dois mil casos de secas e inundações foram relatados entre 2005 e 2015 no Banco de Dados de Desastres de Emergência (<<https://www.emdat.be/index.php>>). Para a América do Sul, relatórios do Painel Intergovernamental sobre Mudanças Climáticas (IPCC) sugerem um aumento de chuva de até 30% a cada década nas bacias do rio Prata e do rio Paraná, com a vazão seguindo a mesma tendência. Trabalhos como os de Bartiko et al., 2019, 2017 e Chagas e Chaffe, 2018, também relatam mudanças nos regimes históricos de chuvas e vazões na região Sul do Brasil. Portanto, a avaliação de possíveis cenários climático-hidrológicos pode ajudar na compreensão da disponibilidade de água para o futuro.

Para lidar com problemas referentes aos recursos hídricos e obter informações sobre disponibilidade de água, modelos hidrológicos se tornaram ferramentas necessárias e eficientes na compreensão desse sistema. Porém, na prática, este tipo de abordagem ainda enfrenta algumas limitações, tais como: a) capturar a heterogeneidade espaço-temporal da precipitação é um problema antigo de modeladores que ainda permanece em discussão (Kim e Kim, 2018; Zhang et al., 2018); b) a estimativa da disponibilidade total de água em várias escalas, com desempenho razoável para cada um dos componentes do ciclo hidrológico é um problema mais complexo e pouco abordado (Boutt e Iroume, 2017; Hall et al., 2014; Wood et al., 2011); c) a utilização de dados provenientes dos *General Circulation Models* (GCMs) ou modelos de clima tem avançado, porém ainda existem lacunas a serem preenchidas para sua eficiente utilização, como a realização ou não da correção de viés, e uso de técnicas como *downscaling* (Abbaspour et al., 2009; Mehta et al., 2016).

Mesmo com os avanços em tecnologias como as de sensoriamento remoto, dados de chuva pontuais de estações pluviométricas ainda são os mais usados nas aplicações com modelos hidrológicos (Sikorska e Seibert, 2018; Wang et al., 2018). Para que a representação dos processos naturais seja feita de maneira robusta, a escala espacial do monitoramento da precipitação deve ser compatível com as características dos processos naturais estudados

(Kim e Kim, 2018; Zhang et al., 2018). A compreensão equivocada da escala pode levar a esforços de monitoramento e modelagem desnecessários ou insuficientes. Entender a escala certa pode facilitar o uso de dados provenientes de GCMs (e.g. *Coupled Model Intercomparison Project Phase 5 - CMIP5*), uma vez que são gerados em grade para todo o globo, e supõe-se a necessidade de técnicas como o *downscaling* (Maraun et al., 2015; Xavier et al., 2016).

Além da correta representação da chuva no processo de modelagem, a credibilidade dos modelos hidrológicos é baseada na ideia de que são descritos de forma transparente, e que processos como a calibração sejam realizados. Esse processo está sempre condicionado à estrutura do modelo, aos dados disponíveis e aos algoritmos de verificação (Abbaspour et al., 2015; Yen et al., 2014). Um modelo calibrado para uma bacia hidrográfica pode ser usado para investigar diversas variáveis, entre elas: disponibilidade hídrica e vazão (Brighenti et al., 2016; Tuo et al., 2016); análise da produção de sedimentos em suspensão (Brighenti et al., 2019a; Stryker et al., 2017); carga de nutrientes (Van Griensven e Bauwens, 2005; Yang et al., 2018); e o efeito que mudanças no regime climático podem causar no balanço hídrico (Kundu et al., 2017; Shrestha et al., 2016). A integração das saídas dos modelos hidrológicos com modelos de clima é uma tarefa bastante desafiadora e uma avaliação coerente e robusta depende da finalidade do estudo (Maraun et al., 2015; Teutschbein e Seibert, 2012). Poucos estudos têm demonstrado sistematicamente a capacidade e limitação dos GCMs em representar condições de chuva para estudos hidrológicos na escala de regional (Borges e Chaffe, 2019; Chen et al., 2017).

O estado de Santa Catarina possui clima subtropical e está sujeito a alterações no clima, apresentando mudanças nos regimes de vazão, nas zonas pertencentes às bacias do Alto Uruguai, Iguaçu e Atlântico (Chagas e Chaffe, 2018; Saurral et al., 2008). Mesmo com um histórico de chuvas bem distribuídas durante o ano, o estado enfrenta conflitos em relação à disponibilidade hídrica. Já foi observado no estado, um aumento na média anual de vazões médias e máximas e de eventos extremos, como fortes chuvas e secas prolongadas (Bartiko et al., 2017; Chagas e Chaffe, 2018). Além disso, a elaboração do Plano Nacional de Adaptação às Mudanças do Clima (Portaria nº 150), que visa promover a redução da vulnerabilidade nacional à mudança do clima, fortalece a necessidade de estudos que objetivam a compreensão e gestão do risco associado a esse fenômeno.

A modelagem hidrológica na resolução mensal permite o estudo das diferentes contribuições do ciclo hidrológico, e a análise de longos período permite a investigação de

tendências e mudanças em variáveis como precipitação, evapotranspiração e quantidade de água. O modelo *Soil and Water Assessment Tool* (SWAT) (Arnold et al., 2012) foi a ferramenta utilizada neste trabalho para avaliação de nove bacias hidrográficas representativas do estado de Santa Catarina. O modelo é reconhecido como ferramenta integrada para estudos multidisciplinares em diversas escalas espaciais e temporais, em diferentes condições fisiográficas e climáticas de bacias hidrográficas. É considerado na atualidade, um dos modelos hidrológicos mais aplicados no mundo e possui seu código aberto (Krysanova e Srinivasan, 2015; Van Griensven et al., 2012). Neste trabalho, fez-se uso do modelo SWAT na análise das disponibilidades hídricas atuais e futuras com diversas aplicações no estado de Santa Catarina. Investigou-se a resolução ideal dos dados de precipitação, a calibração do modelo SWAT em diferentes cenários, e o uso integrado com dados de modelos de clima.

1.1 OBJETIVO GERAL

Analisar a disponibilidade hídrica de bacias hidrográficas de Santa Catarina através do uso combinado do modelo *Soil and Water Assessment Tool* (SWAT) e modelos de clima.

1.1.1 Objetivos Específicos

- a) Investigar como a resolução espacial dos dados de chuva influencia na resposta hidrológica do modelo SWAT.
- b) Testar como as diferenças na precipitação e no cálculo da evapotranspiração afetam os valores dos parâmetros do modelo SWAT durante o processo de calibração.
- c) Analisar como as possíveis escolhas no cálculo da evapotranspiração podem influenciar as simulações de disponibilidade hídrica.
- d) Selecionar os modelos de clima que melhor representam as condições de precipitação e temperatura para o estado de Santa Catarina.
- e) Testar como um método de correção da evapotranspiração pode ser usado na simulação de cenários futuros de disponibilidade hídrica.

2 REVISÃO BIBLIOGRÁFICA

2.1 O MODELO SWAT

O *Soil and Water Assessment Tool* (SWAT) (Arnold et al., 2012) é um modelo de bases físicas, semi-distribuído no espaço que funciona em escala de bacia hidrográfica. A popularidade do modelo pode ser atribuída ao seu código aberto e interface com plataforma GIS (Krysanova and Srinivasan, 2015; Van Griensven et al., 2012). O SWAT possui 5 versões oficiais, SWAT2000, SWAT2005, SWAT2009, SWAT2012, e SWAT+. A descrição detalhada do histórico do modelo pode ser encontrada em Arnold et al., (2012); as versões SWAT+, 2009, e 2005, foram revisadas por Bieger et al., (2017); Gassman et al., (2007); Tuppad et al., (2011).

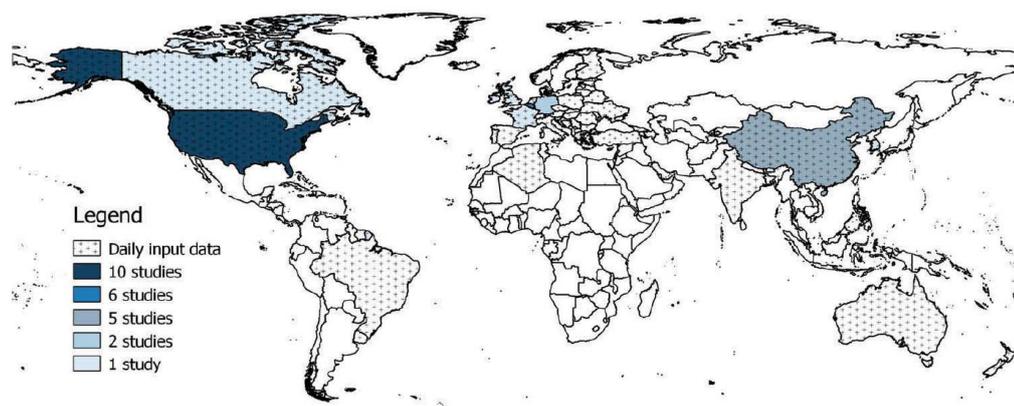
Os principais componentes do modelo são clima, hidrologia, temperatura do solo, plantações, erosão e sedimentação, nutrientes, pesticidas e manejo da terra. O SWAT é espacialmente discretizado em subbacias, que por sua vez são subdivididas em unidades de resposta hidrológica (HRU) compostas por um único tipo de solo, uso e declividade. A HRU é a unidade principal de cálculo do balanço hídrico (Arnold et al., 2012). Além disso, o modelo possui várias modificações que causaram novas extensões, tais como, SWAT-MODFLOW (Bailey et al., 2016); SWAT-VSA (Easton et al., 2008); SWIM (Krysanova et al., 1998); SWAT-LAG (Idhayachandhiran et al., 2019); e ESWAT (Van Griensven and Bauwens, 2001).

O SWAT possui uma série de revisões bibliográficas que discutem suas aplicações. Considerações sobre os aspectos gerais do modelo e diferentes tipos de aplicações podem ser encontradas em Arnold et al., (2012), Gassman et al., (2007, 2014), Krysanova e Arnold, (2008), e Krysanova e White, (2015). Os aspectos das aplicações do modelo no Brasil são discutidos por Bonumá et al., (2015); Bressiani et al., (2015). Temas mais específicos como mudanças no clima/uso da terra e uso de dados subdiários são discutidos por Krysanova e Srinivasan, (2015) e Brighenti et al., (2019b), respectivamente. Especificamente para o estado de Santa Catarina, o modelo apresenta 13 trabalhos publicados em revistas científicas entre os anos de 2011 e 2019, que podem ser acessados na plataforma de busca do próprio modelo (<https://www.card.iastate.edu/swat_articles/>).

2.1.1 Uso em diferentes escalas de tempo

A estrutura temporal do monitoramento da precipitação afeta a modelagem hidrológica como um todo. Portanto, é aconselhável que os padrões de precipitação estejam bem representados. O modelo SWAT pode realizar simulações que vão da escala de tempo diária a subdiária ($\Delta t \geq 1$ min), simulações com o uso do passo de tempo diário são mais comuns que simulações subdiárias (Brighenti et al., 2019b). A Figura 1 apresenta a distribuição espacial dos trabalhos que utilizam dados diários (Gassman et al., 2007 e 2014) e subdiários (Brighenti et al., 2019b).

Figura 1 - Aplicações do modelo SWAT distribuídas pelo mundo. O sombreado indica o número de estudos por país, que usam dados subdiários. O pontilhado indica os locais revisados por Gassman et al., (2007, 2014). Fonte: Brighenti et al., (2019b).



A maior diferença entre a simulação diária e subdiária no modelo SWAT ocorre na rotina de infiltração. O método Green-Ampt Mein-Larson (GAML) é usado para chuvas subdiárias, enquanto o *Curve Number* (CN - USDA Serviço de Conservação do Solo, 1972) é usado para chuvas diárias. Existem três tipos de ciclos de iteração no tempo, e há um loop de iteração para a discretização espacial (HRUs). escoamento superficial, vazão e armazenamento de reservatórios podem ser simulados no intervalo de tempo subdiário, porém o escoamento de base e a evapotranspiração são calculados na escala diária e são igualmente distribuídos para cada intervalo de tempo (Jeong et al., 2010).

Para Brighenti et al., (2019b) não existe consenso em qual aplicação, diária ou subdiária do modelo SWAT apresenta melhor ajuste a área de estudo. Os autores concluem que a escolha da melhor escala de tempo vai depender das finalidades de cada estudo. Como por exemplo: a) O método GAML apresentou melhor desempenho que o CN na análise do output diário, mas o desempenho foi pior na escala mensal, indicando limitações em

representar variações sazonais; b) o uso do método GAML melhora os resultados, principalmente na simulação dos picos dos hidrogramas; c) o uso de CN proporciona bom desempenho para vazões médias; d) o volume de inundação exportado foi melhor simulado com os módulos subsidiários do modelo.

2.1.2 Resolução espacial da chuva

A mudança na resposta dos modelos hidrológicos em relação variabilidade espacial dos dados de precipitação foi abordada de diferentes maneiras ao longo das últimas décadas. As metodologias disponíveis para esse tipo de investigação possuem uma variedade de categorias, divididas em: análise por entropia (Wang et al., 2018), abordagem bayesiana (Sikorska e Seibert, 2018), suposição por onda cinemática (Kim e Kim, 2018), momentos espaciais (Zoccatelli et al., 2011), cadeia de simulações (Emmanuel et al., 2015) e *upscaling* (Ahrens e Beck, 2008, Nicótina et al., 2008)

Para o modelo SWAT este tipo de análise também é recorrente, porém nenhum consenso foi atingido até o momento. Entre algumas das alternativas encontradas, temos as descritas por: (a) Rathjens et al., (2014) e Rathjens e Oppelt, (2012a, 2012b) utilizam uma abordagem grid-baseada para os dados de uso e tipo de solo, modelo numérico do terreno e declividade, sendo que o módulo da chuva permanece o mesmo da versão oficial, com o SWAT utilizando a estação de chuva mais próxima do centro da sub-bacia e para este caso, para o centro do grid. (b) Grusson et al., (2017) utilizam a versão oficial do modelo SWAT e testam diferentes resoluções de dados de chuva em formato de grid, são elas: estações pontuais de monitoramento, e produtos de reanálise dos sistemas CFSR (30 km) e SAFRAN (8, 16, 32, 64, e 128 km). Os desempenhos com 8 km são semelhantes aos das redes agregadas de SAFRAN de 16 e 32 km. O CFSR apresentou desempenho variado, devido aos pontos da grade onde a precipitação foi superestimada. O mesmo problema foi encontrado nas estações de monitoramento, onde os dados em algumas estações meteorológicas não pareciam ser representativos da respectiva sub-bacia. (c) Wagner et al., (2012) utiliza dados 16 pluviômetros em uma bacia de 2036 km² na comparação de sete métodos diferentes de interpolação, incluindo polígonos de Thiessen, abordagens estatísticas e geoestatísticas. Os resultados mostram que as interpolações que utilizam covariáveis têm melhor desempenho (e.g. *regression-inverse distance weighting* e *regression-kriging*). Porém, alertam que a

decisão interpolação adequada deve não apenas ser baseada na comparação com medições pontuais, mas também deve levar em conta a representatividade da rede de monitoramento.

No Brasil, Xavier et al., (2016) montou uma grade interpolada da rede de monitoramento disponível do país, para dados de chuva e variáveis climáticas. Os métodos IDW (*inverse distance weighting*) e ADW (*angular distance weighting*) apresentaram os resultados mais satisfatórios no processo de transformação da rede de monitoramento em uma grade de interpolada. Ao fim, os autores fixam a grade final, para todo o Brasil, de 28 km, o que para alguns estudos em escala de bacia hidrográfica pode ter resolução insuficiente.

Em uma análise prévia para Santa Catarina, Brighenti et al., (2019d) avaliou a influência da densidade da rede de monitoramento de chuva nas simulações com o modelo SWAT em doze bacias hidrográficas do estado. Os processos analisados foram evapotranspiração real e vazão, na escala mensal para um intervalo de 30 anos. Concluiu-se que as estações disponíveis são suficientes para análise do balanço hídrico em escala mensal. Mais especificamente, observou-se que: (i) a vazão é mais sensível que a evapotranspiração real em relação aos padrões espaciais de chuva; (iii) os padrões iniciais da precipitação nem sempre refletem na resposta das bacias hidrográficas; (iv) o erro total da vazão simulada é maior para as bacias menores e mais declivosas.

2.1.3 Estimativa da evapotranspiração

A evapotranspiração potencial (PET) pode ser informada diretamente para o modelo SWAT, a partir de séries de dados observados, ou calculada pelos dados meteorológicos. São oferecidas três metodologias de cálculo para a PET: Hargreaves (Hargreaves et al., 1985), Priestley-Taylor (Priestley e Taylor, 1972) e Penman-Monteith (Monteith, 1965, Allen et al., 1998). A evapotranspiração real (ET) é estimada a partir da água armazenada no dossel e disponível no solo. A água armazenada no dossel é evaporada primeiramente. Caso a evapotranspiração potencial seja superior ao volume armazenado no dossel, a demanda evaporativa restante é distribuída entre solo e plantas (NEITSCH et al., 2011).

Penman-Monteith é um dos métodos mais utilizados no cálculo da evapotranspiração potencial, pois apresenta uma formulação fisicamente baseada (Zhao et al., 2013). Vários estudos realizados no Brasil optam pelo uso do método de Penman-Monteith (e.g. Franco e Bonumá, 2017; Xavier et al., 2016). Porém, é um método que requer uma variedade de dados, e em situações onde as estações meteorológicas são escassas, opta-se por formulações mais simples, como a de Hargreaves, que necessita apenas dos dados máximos e mínimos de

temperatura diária (Oudin et al., 2005). Qual método é o mais adequado ainda é uma questão em aberto, e segundo (Oudin et al., 2005; Zhao et al., 2013) pode variar de acordo com as características de cada estudo.

2.2 CALIBRAÇÃO, VALIDAÇÃO, E ANÁLISE DE INCERTEZA DE MODELOS HIDROLÓGICOS

A calibração de modelos hidrológicos, bem como do modelo SWAT, é um processo que pode ser feito de forma manual ou automática, que busca melhorar um conjunto de parâmetros, com o auxílio de séries de dados observados. A validação consiste em rodar o modelo com os valores de parâmetros determinados na calibração, sendo que a série de validação não pode ser a mesma da calibração (Arnold et al., 2012; Daggupati et al., 2015). A calibração envolve a otimização dos parâmetros, para posterior comparação dos resultados das simulações com os dados observados. É necessário determinar valores iniciais para os parâmetros, os quais servem como ponto de partida para a calibração. Testes que determinam o grau de incerteza no modelo também são recomendados no uso de procedimentos automáticos de calibração (Gupta et al., 1999; Yapo et al., 1996).

A calibração de modelos hidrológicos é abordada de diferentes formas na literatura. Pode ser discutida a partir de metodologias como as propostas por Klemes (1986) e Andréassian (2005) que se preocupam com a transposição temporal e espacial dos modelos hidrológicos, propondo métodos para que essas exigências sejam atendidas. Esta ideia de transposição pode ser aplicada em diferentes escalas: sazonais onde o ajuste do modelo é baseado em anos secos e úmidos; ou em escala de um hidrograma, onde vazões altas e baixas são analisadas separadamente. Quando aplicamos a calibração automática, os diferentes algoritmos de otimização também são pontos avaliados no processo. Por exemplo, que evitam problemas de ótimos locais; quais são mais eficientes em tempo de processamento; e quais introduzem a possibilidade da análise de incerteza. A busca pelos melhores valores de parâmetros nestes algoritmos é dependente de funções objetivo, que medem a distância entre os valores observados e simulados. Cada função objetivo apresenta uma abordagem diferente e serve para avaliar diferentes casos (Daggupati et al., 2015; Folton et al., 2015; Kirchner, 2006; Nicolle et al., 2014; Yen et al., 2016).

Entre as várias razões que podem justificar o mau desempenho do modelo, têm-se: 1) conceptualização inadequada dos processos; 2) estratégias de calibração inadequadas; 3)

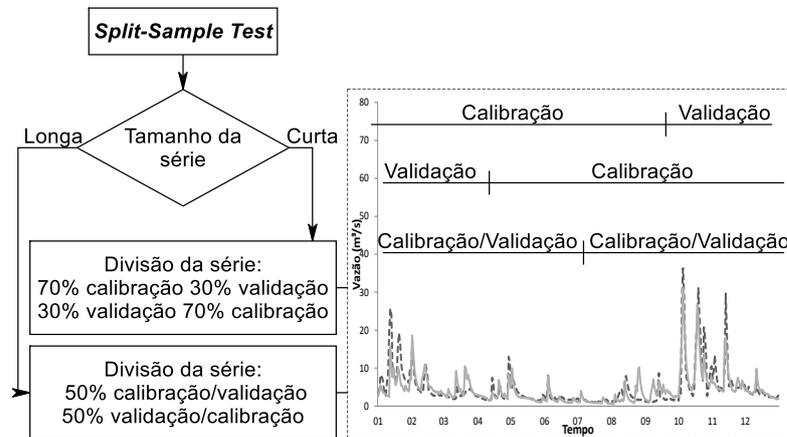
dados não confiáveis (e.g. curvas-chave mal elaboradas; mudança na seção transversal do rio). Enquanto o último problema está além do domínio do modelo, os dois primeiros são relacionados e dizem respeito a qualquer ação da modelagem (Boyle et al., 2000; Fenicia et al., 2006; Gupta et al., 1998). Na calibração de modelos com a proposta de transposição espacial e temporal, a metodologia proposta por Klemes (1986) apresenta uma estrutura hierárquica de testes complementares, o *Split-Sample Test*, *Differential Split-Sample Test*, *Proxy - Basin Test*, e o *Proxy-Basin Differential Split-Sample Test*.

O *Split-Sample Test*: é o teste clássico, onde a série de dados é dividida em dois segmentos, um para calibração e outro para validação. Se a série for suficientemente longa para representar as diferentes condições climáticas (anos secos e úmidos), então deve ser dividida em partes iguais (50/50) e cada parcela deve ser usada tanto para validação quanto para calibração. Porém se ela não for suficientemente longa, é conveniente adotar o seguinte procedimento: os primeiros 70% da série para calibração e os 30% finais para validação; e os últimos 70% para calibração e os 30% iniciais para validação. O modelo será julgado como válido para a área, somente se os dois resultados das calibrações forem similares e os resultados das validações aceitáveis (Figura 2). Para o *Differential Split-Sample Test*, o objetivo é verificar a capacidade do modelo em transitar entre os diferentes períodos climáticos, os anos úmidos devem ser calibrados separadamente, validados em anos secos, e vice-versa. O *Proxy-Basin Test* consiste em dar confiabilidade ao modelo em ser usado em uma bacia diferente daquela para a qual foi criado e/ou testado, dando maior validade geral ao uso do SWAT. Xu, (1999) ainda relata que o teste tem potencial de verificar a adequação do modelo em prever impactos na mudança do uso da terra. Neste, o modelo deve ser calibrado em uma bacia, e validado de maneira eficaz em outra de uso da terra semelhante.

O conceito de incerteza na modelagem pode ser definido de duas maneiras, uma é considerando sua definição a mesma de erro, e outra, é separando os dois conceitos. Segundo Daggupati et al., (2015) erro significa a diferença entre um valor simulado e observado, ou seja, o grau em que o modelo simula corretamente a variável de resposta. Incerteza é definida como o grau de concordância entre valor simulado e o observado, ou seja, a menor diferença nas variáveis de resposta que o modelo consegue diferenciar. Para Taylor (1997), o conceito de incerteza está relacionado ao sentido de probabilidade, uma vez que trata da variação nos resultados de um evento aleatório, dos distúrbios derivados de considerações erradas ou da distribuição de erros associados com as quantidades observadas ou estimadas. Harmel et al.,

(2006) adota em seu trabalho erro e incerteza como sinônimos, referindo-se a estes como variação estatística aleatória.

Figura 2 - Demonstração da divisão da série histórica de vazões para o *Split-Sample Test*.



Quando se realiza a análise de incerteza, algumas decisões prévias devem ser tomadas: 1) decidir os parâmetros e os dados de entrada que devem entrar na análise; 2) decidir qual metodologia de amostragem será utilizado; 3) quais medidas de probabilidade serão usadas para expressar o grau de veracidade do modelo; e 4) encontrar método que possa combinar funções de verossimilhança. Nenhuma dessas escolhas é simples, todas irão refletir de alguma maneira nos resultados. Assim, sugere-se que toda análise de incerteza deve estar associada a passos que possam ser conferidos e monitorados (Vrugt e Beven, 2016).

Quatro tipos de incertezas são geralmente reconhecidas: natural ou epistêmica (relativa ao próprio sistema); na coleta dos dados de entrada e nos de saída para comparação; na concepção do modelo; e as geradas pelo processo de calibração (parâmetros) (Beven, 2006; Beven e Binley, 1992; Gupta et al., 1998; Harmel et al., 2006; Kampf e Burges, 2010; McIntyre e Wheeler, 2004; Van Griensven et al., 2008).

Muitos dos erros no processo de modelagem não são os resultados de uma variação natural aleatória, mas resultado de uma falta de conhecimento sobre processos e condições de contorno, essas são as incertezas epistêmicas ou naturais. Incluindo medições deficientes, processos que deixamos de lado porque não são considerados importantes (ou para os quais não temos uma representação matemática embasada), e as características da bacia que não conhecemos (Beven e Alcock, 2012). As incertezas dos dados de entrada estão relacionadas com medições feitas nos períodos de monitoramento, para alimentar inicialmente o modelo (e.g. chuva e condutividade hidráulica do solo). Para Kampf and Burges, (2010); e Yen et al.,

(2015) erros aleatórios documentados entre pluviômetros, e a magnitude desses erros, podem variar de acordo com a intensidade da chuva e escala de tempo. No caso das variáveis medidas para comparação das saídas do modelo, as medições de vazão são geralmente realizadas medindo-se o nível do curso d'água de forma contínua, por dispositivos automáticos que medem a lâmina de água (sensores de pressão, sonoros ou flutuadores). Estes dados são convertidos em vazão, por uma relação com base na geometria do canal, nesta relação são reconhecidos diversos tipos de incerteza (Harmel et al., 2006).

Os parâmetros obtidos a partir da calibração automática, podem ser afetados por vários fatores: correlações; sensibilidade ou insensibilidade; escalas espaciais e temporais; e características estatísticas dos resíduos do modelo. As incertezas na concepção dos modelos, está ligada a formulações matemáticas simplificadas dos processos naturais. A incerteza nos parâmetros é resultado da falta de conhecimento de seus valores reais, seus intervalos, significado físico, variabilidade espacial e temporal (Harmel e Smith, 2007).

2.2.1 Avaliação de modelos hidrológicos

Funções objetivo são medidas de avaliação usadas para testar a validade de um modelo. Para este trabalho três funções objetivo (NS, KGE, Pbias) são utilizadas e cada função objetivo vai gerar um intervalo diferente, visto que a aproximação dos parâmetros é feita por diferentes equações. A escolha foi baseada em suas formulações, as quais possuem diferentes prioridades, na recomendação e uso difundido em literatura (Moriasi et al., 2007). As formulações para os coeficientes são descritas no item 3.4.

Nash-Sutcliffe (Nash and Sutcliffe, 1970) é a função objetivo mais utilizada na modelagem hidrológica, e sua prioridade para os valores altos da amostra é ponto comum entre autores (Asadzadeh et al., 2016; Gupta et al., 2009; Guse et al., 2017; Moriasi et al., 2007; Schaefli and Gupta, 2007). Além de suas recomendações técnicas em literatura (Moriasi et al., 2007), o uso difundido facilita a comparação entre trabalhos. Como é uma formulação muito utilizada, várias críticas e derivações são criadas.

O KGE (King-Gupta Efficiency) (Gupta et al., 2009) baseiam-se na decomposição do NS em três componentes (*alpha*, *beta* e *r*), que podem, se necessário, serem considerados separadamente para cada iteração. *Alpha* é a razão de variabilidade entre o desvio padrão dos valores medidos e modelados. O *r* representa o coeficiente de correlação de acordo com *Pearson*. *Beta* é a relação entre os valores médios simulados e observados (Asadzadeh et al., 2016; Guse et al., 2017; Kayastha et al., 2013; Magand et al., 2015; Nicolle et al., 2014;

Osuch et al., 2015). A formulação final do KGE vem como alternativa de uma função objetivo que não prioriza partes separadas do hidrograma, no processo de calibração todas as partes (altas, médias e baixas) têm mesmo peso (Gupta et al., 2009).

O *Percent bias* (Pbias), proposto por Gupta et al. (1999), avalia a tendência que a média dos valores simulados tem em relação aos observados. O valor ideal do Pbias é de 0 (zero), valores positivos indicam uma subestimação do modelo, e valores negativos superestimação (Moriasi et al., 2007).

2.2.2 SWAT-CUP e o algoritmo SUFI2

O modelo SWAT conta com o SWAT-CUP (*SWAT Calibration and Uncertainty Procedures*), ferramenta disponível para auxiliar a análise de sensibilidade, calibração, validação e análises de incerteza dos projetos gerados no SWAT. O programa integra cinco procedimentos de calibração e análise de incerteza semiautomáticos: Sequential Uncertainty Fitting (SUFI2) (Abbaspour et al., 2007, 2004); Generalized Likelihood Uncertainty Estimation (GLUE) (Beven e Binley, 1992); Parameter Solution (ParaSol) (van Griensven et al., 2006); Mark chain Monte Carlo (MCMC) (Kuczera et al., 1998); e Particle Swarm Optimization (PSO) (Kennedy e Eberhart, 1995). O SUFI2 é um método bastante difundido entre os usuários do modelo SWAT (Abbaspour et al., 2015; Bilondi et al., 2013; Brigode et al., 2014; Daggupati et al., 2016; Grusson et al., 2015; Habte et al., 2013; Monteiro et al., 2016; Price et al., 2012; Rouholahnejad et al., 2014, 2012; Yang et al., 2007); e foi o selecionado para a realização dos processos de calibração, validação e análise de incerteza deste estudo.

Segundo Beven (2001), as publicações relacionadas à metodologia e às técnicas de calibração e cálculo da incerteza possuem três vertentes: a) métodos de calibração que assumem ser possível encontrar uma combinação com valores ideais dos parâmetros e que ignoram a possibilidade de mensurar as incertezas de predição. Neste grupo a calibração é feita de forma manual ou automática, utilizando algoritmos de otimização; b) métodos de calibração que assumem ser possível encontrar uma combinação com valores ideais dos parâmetros, mas que fazem suposições em relação à superfície de resposta ao redor do ótimo global para mensurar as incertezas; c) métodos de calibração que rejeitam a ideia de que existe uma combinação com valores ideais dos parâmetros, os quais admitem que existam

diferentes combinações de valores para os parâmetros que podem fornecer simulações aceitáveis.

A quantidade de algoritmos de otimização é tão vasta quanto à de funções objetivo, visto que sua escolha, além das recomendações em literatura, está relacionada com as afinidades de cada modelador. Entre os trabalhos de Arnold et al. (2012), Kollat et al. (2012), Kayastha et al. (2013) e Osuch et al. (2015) cerca de dez tipos diferentes de algoritmos são citados. O *Sequential Uncertainty Fitting Procedure* (SUF12) proposto por Abbaspour et al. (2004). Uma vez que existem incertezas associadas em todo o processo de modelagem, a procura por valores únicos de parâmetros (solução única e ideal de um modelo) estão cada vez mais em descrença. O SUF12 é um algoritmo semiautomático de calibração, que leva em consideração no seu processamento todas as fontes de incerteza (e.g. dados de entrada, formulação do modelo, parâmetros do modelo). Junto a um número relativamente pequeno (1000) de iterações e uma plataforma amigável, faz com que seu uso seja quase unânime entre modeladores que usam o SWAT.

São disponibilizados onze tipos de funções objetivo para serem usadas prontamente no processo de calibração: Mult (forma multiplicativa do erro quadrado); Sum (somas do erro quadrado); r^2 (coeficiente de determinação); chi^2 , NS (Nash-Sutcliffe); br^2 (o coeficiente de determinação r^2 é multiplicado pelo coeficiente de regressão entre dados observados e simulados); SSQR (distribuições de frequência das séries observadas e simuladas); Pbias (Percent Bias), KGE (Kling-Gupta Efficiency); RSR (padronização do RMSE usando o desvio padrão dos dados observados); MNS (Nash-Sutcliffe Modificado).

O SUF12 utiliza elementos do *Generalized Likelihood Uncertainty Estimation* (GLUE) (Beven and Binley, 1992), porém, ao contrário do método, o SUF12 emprega uma abordagem em gradiente para permitir a busca global, e tem como saída o melhor intervalo de cada parâmetro. Consistindo em uma sequência de etapas em que a incerteza inicial nos parâmetros do modelo é progressivamente reduzida até que certos critérios de calibração sejam atendidos. O programa utiliza um método de amostragem Hipercubo Latino, juntamente com um algoritmo de busca global que examina o comportamento de uma função objetivo analisando as matrizes Jacobiana e Hessiana. Ao final da simulação o programa mostra o que chama de “envelope de incerteza”, que corresponde a 95% da incerteza de previsão (95PPU). O 95PPU é calculado entre 2,5% e 97,5% da distribuição cumulativa da variável de saída, obtida pelo Hipercubo Latino. Duas métricas são disponíveis para avaliar esse envelope: o *p-factor* e o *r-factor* (Abbaspour et al., 2015, 2004).

2.3 MODELOS DE CLIMA

O efeito estufa é um processo natural e emissões geradas por atividades humanas aumentam substancialmente a concentração dos gases que causam esse efeito na atmosfera, resultando em um aumento médio da temperatura global, incidência de temperaturas extremas, inundações e secas (IPCC, 2014). Modelos Climáticos Globais (GCMs) ou modelos de clima como os disponibilizados pelo *Coupled Model Intercomparison Project Phase 5* (CMIP5), são representações do sistema climático terrestre baseados nas leis de conservação de massa, energia e momento, e leis da termodinâmica e de radiação (Maraun et al., 2015). São divididos em simulações de cenários de um passado próximo, a rodada histórica (e.g. 1950 – 2005) e cenários futuros (e.g. 2020 – 2099), de variáveis climáticas como temperatura e precipitação (Pierce et al., 2009).

Mesmo com uma resolução grosseira, os GCMs podem fornecer informações importantes para estudos de impacto hidrológico na escala regional (Hewitson et al., 2014). A Figura 3 apresenta o esquema *family tree* para os modelos pertencentes aos CMIP3 e CMIP5, Knutti et al., (2013) apresentam os modelos com semelhanças óbvias em código ou produzidos pela mesma instituição são marcados com a mesma cor. Os modelos que aparecem no mesmo ramo são próximos e a similaridade é maior quanto mais à esquerda.

As simulações futuras apresentadas pelos modelos são chamadas de *Representative Concentration Pathways* (rcp), se baseiam em variações de crescimento populacional, estilo de vida e comportamento, uso da terra, tecnologia e políticas climáticas. Os rcps descrevem quatro diferentes possibilidades de emissões e concentrações atmosféricas. O cenário de mitigação mais rigorosa (rcp2.6), dois cenários intermediários (rcp4.5 e rcp6.0) e um cenário com altíssimas emissões de gases de efeito estufa (rcp8.5). Segundo estes quatro cenários, a temperatura global irá aumentar, os oceanos continuarão aquecendo e acidificando e o nível médio global dos mares irá subir. Também há grandes probabilidades de que ondas de calor e eventos de precipitações extremas se tornem mais frequentes em diversas regiões (IPCC, 2014).

Para Osei et al., (2018) e Teutschbein e Seibert, (2013, 2012) os dados simulados pelos GCMs, como temperatura e precipitação, devem ser utilizados com certa cautela, pois muitas vezes mostram vieses significativos. Algumas razões para tais vieses incluem erros de modelo causados por conceituação imperfeita, discretização e média espacial em resoluções muito grosseiras. Entre algumas soluções os autores recomendam utilizar-se de métodos de

correção de viés (*bias correction*). Processos de *downscaling* também são recomendados e tem a função de melhorar a escala espacial para aplicação dos modelos. Entretanto, deve-se ter cautela na correção do ruído, como por exemplo, interpretar a variabilidade interna da série como uma tendência do modelo (Clark et al., 2016).

Tabela 1 - Relação de trabalhos que utilizam dados de chuva provenientes de GCMs com o uso do modelo SWAT.

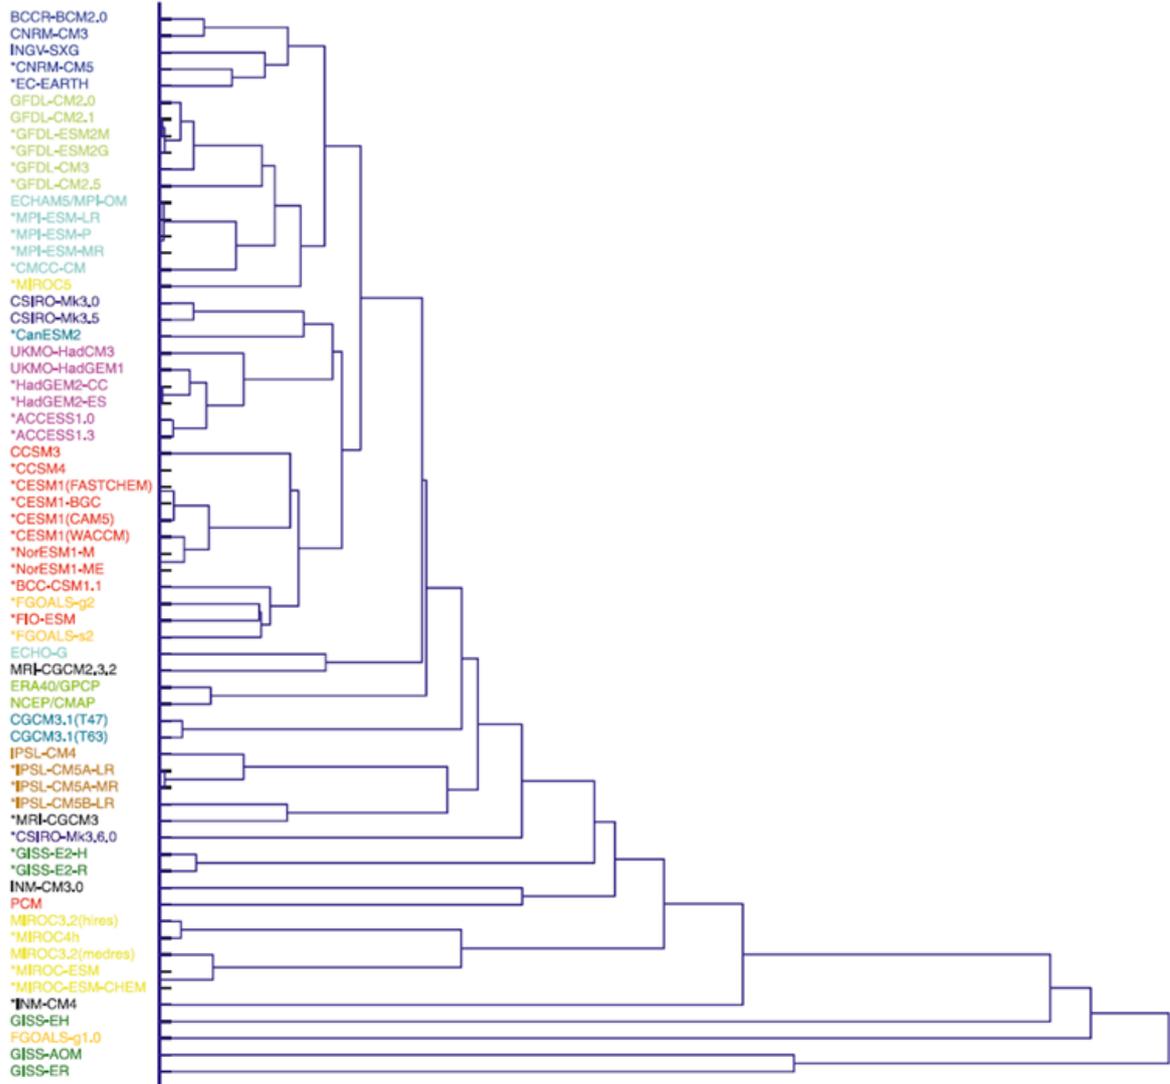
Autores	Produto	Área da bacia (km²)	País	Escala de tempo mínima
Abbaspour et al., (2009)	GCCM 3.1	1.648.000	Irã	Diária
Bekele e Knapp (2010)	GCMs	2.430	EUA	Diária
Raneesh e Thampi Santosh (2011)	GCMs	170	Índia	Diária
Zhang et al., (2014)	GCMs	55.600	China	Diária
(Wagner et al., 2015)	COSMO-CLM	2.036	Índia	Diária
Jha et al., (2013)	GCMs	492.000	EUA	Anual
Vaghefi et al., (2015)	Canadian GCM	51.000	Irã	Diária
Garee et al., (2017)	GCMs	13.567	Paquistão	Diária
Meaurio et al., (2017)	GCM - CMIP5	185	País Basco	Diária
Tan et al., (2017)	GCM - CMIP5	12.134	Malásia	Diária

Vários trabalhos que descrevem os impactos que as alterações climáticas causam nos recursos hídricos foram publicados recentemente utilizando o modelo SWAT. Os resultados das análises mostram uma dependência direta dos resultados em relação aos cenários de mudanças climáticas escolhidas (relativo às emissões dos gases de efeito estufa) aos GCM utilizados, e ao do tempo das simulações (Krysanova e White, 2015). Visto que, a base a desenvolvimento entre os GCMs é distinta, ou seja, alguns podem ser melhores que outros, para um determinado objetivo, existe a oportunidade de utilizar-se de métodos de seleção ou ponderação do peso dos modelos na tentativa de quantificação das incertezas associadas ao processo (Clark et al., 2016).

A Tabela 1 mostra alguns trabalhos realizados com o modelo SWAT utilizando GCMs. O critério de seleção dos artigos foi baseado no número de citações e revista de alto impacto, para os anos de 2010 até 2017. O trabalho de Abbaspour et al., (2009) aparece na lista por ser uns dos mais citados pelos usuários do SWAT para esse assunto. A base de dados

utilizada para pesquisa foi a do próprio modelo (<<https://swat.tamu.edu/publications/>>). No Brasil, Borges e Chaffe, (2019) identificaram em uma revisão bibliográfica sobre a integração de GCMs e modelos hidrológicos, sete aplicações que utilizam o SWAT.

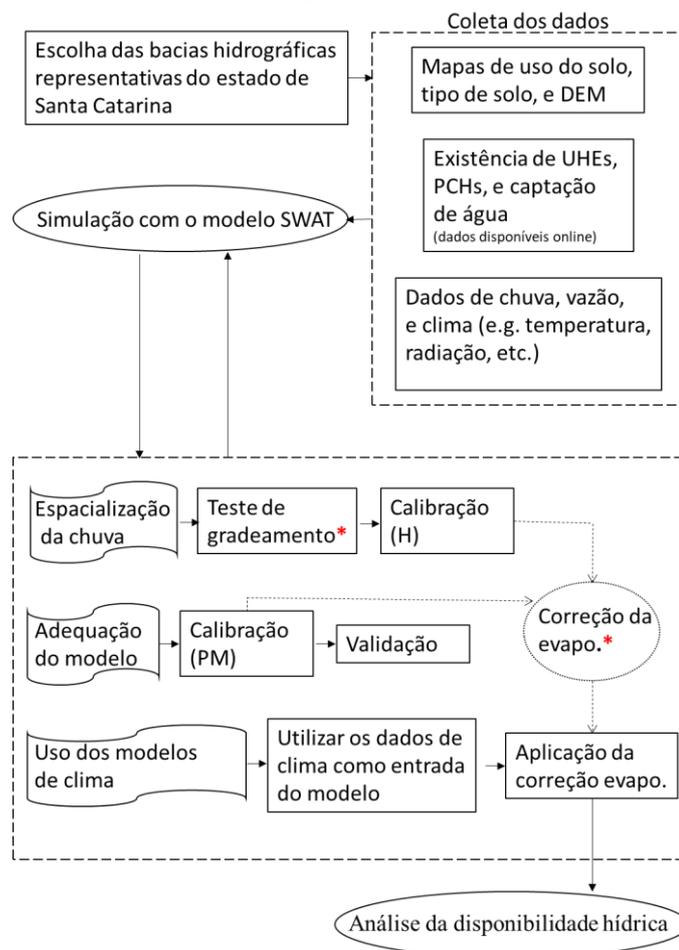
Figura 3 - Modelo *family tree* CMIP3 e CMIP5 (marcado com *) Fonte: (Knutti et al., 2013)



3 MATERIAIS E MÉTODOS

Os materiais e métodos são apresentados em relação à três abordagens principais realizadas neste trabalho: resolução espacial da chuva (objetivo específico (a)), adequação do modelo (objetivos específicos (b) e (c)), e modelos de clima como entrada no SWAT (objetivos específicos (d) e (e)). A Figura 4 mostra um fluxograma geral para a realização desse estudo. Os passos iniciais são a escolha das bacias hidrográficas, e coleta dos dados necessários para as simulações. A partir de diferentes metodologias (especialização da chuva, adequação do modelo, e uso dos modelos de clima) as simulações com o modelo SWAT são utilizadas na investigação da disponibilidade hídrica para o estado de Santa Catarina.

Figura 4 - Representação metodológica da proposta deste trabalho. Os processos assinalados com * são ilustrados nas Figuras 8 (seção 3.3) e 10 (seção 3.5.8).



3.1 ÁREA DE ESTUDO

O estado de Santa Catarina tem área de 95.738 km², distribuída por um total de 295 municípios. Possui clima subtropical e chuvas bem distribuídas durante o ano, com uma média anual de 1700 mm. Está localizado entre as latitudes 25°57'41" e 29°23'55" e longitudes 48°19'37" e 53°50'00", com altitudes que variam 0 a 1800 metros. A vegetação é originalmente formada pela Mata Atlântica, Floresta de Araucárias e campos. O estado possui duas principais vertentes hidrológicas, a vertente do Atlântico e a vertente do Prata; divididas pela Serra Geral e Serra do Mar. Nove bacias foram selecionadas para a aplicação deste trabalho. Rio das Almas (3654 km²); Rio Chapecó (9352 km²); Rio Canoas (15510 km²); Rio Itapocú (3160 km²); Rio Itajaí-Açu (14935 km²); Timbó (2693 km²); do Peixe (5165 km²); Cubatão (732 km²); e Iracema (304 km²) (Figura 5).

O estado de Santa Catarina possui rede de monitoramento de chuva e vazão, e os dados estão disponíveis no sistema HidroWeb gerenciado pela Agência Nacional de Águas (ANA). O número estações de monitoramento em funcionamento são cerca de 260 pluviométricas e 160 fluviométricas. Neste trabalho foram utilizadas um total de 96 estações de chuva, o critério de seleção baseou-se no intervalo de dados 1980 a 2013 e na quantidade de falhas, onde o ponto de corte foi possuir menos de 10% de falhas ao total. Um total de 16 pontos de monitoramento de vazão foram escolhidos e possuem o mesmo critério de seleção da chuva.

O modelo SWAT requer informações sobre a topografia (DEM - Modelo Digital de Elevação), tipo de solo, uso da terra e dados climáticos; os dados climáticos são compostos por precipitação, temperatura atmosférica, radiação solar, velocidade do vento e dados úmidos. O mapa do DEM foi obtido através da *Space Shuttle Radar Topography Mission* (SRTM) e tem resolução de 30 metros; o mapa de uso da terra (30 metros) foi obtido através do site MapBiomas (<<http://mapbiomas.org/>>), para o ano de 2013; o mapa de tipo de solo (90 metros) está disponível em <http://www.waterbase.org/download_data.html> e é produto da Organização das Nações Unidas para Alimentação e Agricultura (FAO) (Figuras 5 e 6).

Figura 5 - Localização das bacias hidrográficas, pontos de monitoramento de chuva e vazão, captação de água, pequenas centrais hidrelétricas (PCHs), e usinas hidrelétricas (UHEs) no estado de Santa Catarina. No decorrer do texto, as bacias hidrográficas são nomeadas de acordo com os códigos (e.g. das Almas) descritos no exutório de cada bacia apresentados na figura.

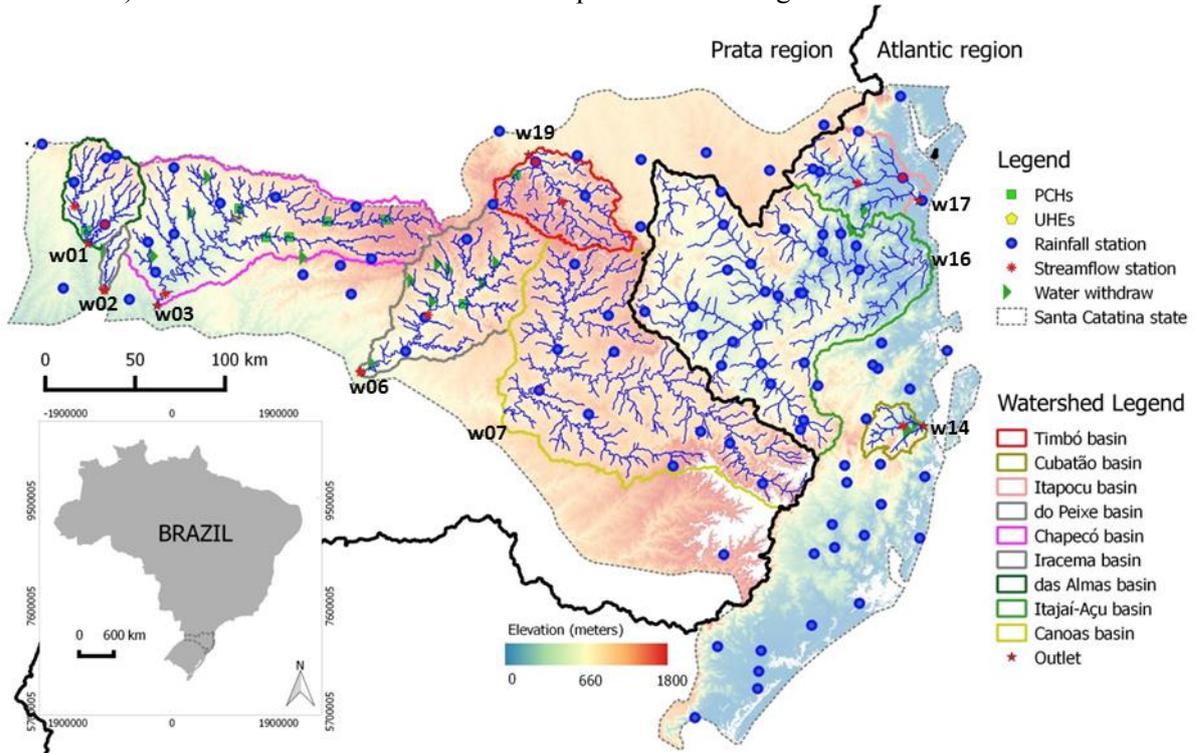
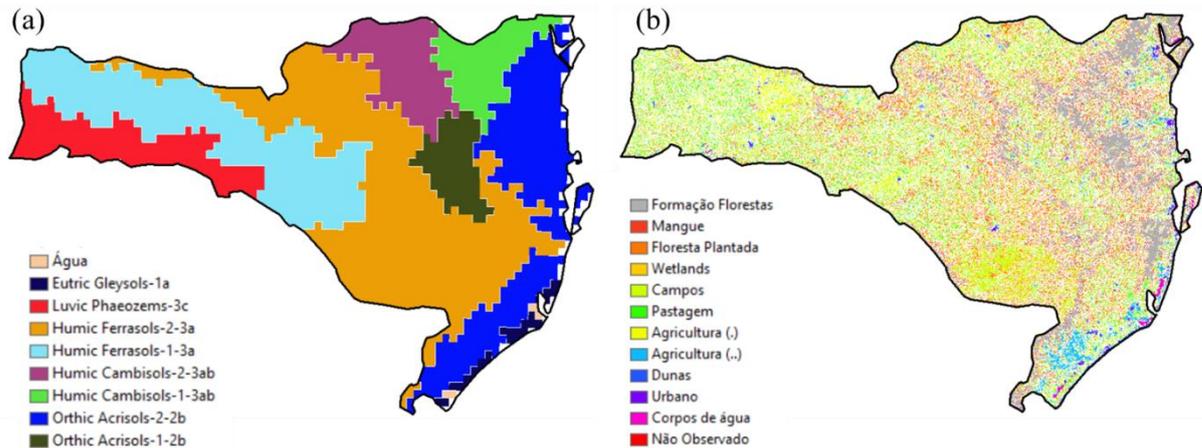


Figura 6 - (a) tipo de solo e (b) uso da terra, utilizados nas simulações com o modelo SWAT.



Para a definição da agricultura referente a cada bacia hidrográfica, foram selecionados os municípios que estão inseridos na bacia, e a partir dos dados disponíveis na plataforma digital do IBGE foram selecionados os tipos de cultura. Para cada bacia, os dois tipos de cultura agrícola com a maior porcentagem dentro da área da bacia foram selecionados (Tabela 2). Para o restante das atribuições de uso da terra, foram selecionados no modelo

SWAT os códigos para usos relacionados a florestas, pastagens, reflorestamento, urbano, água, e áreas úmidas. Um total de cinco (soja, milho, arroz, banana e cebola) tipos diferentes de agricultura são atribuídos ao modelo SWAT durante as simulações. Os dados para alimentar o estado inicial do modelo, referentes às UHEs, PCHs e captação de água foram coletados online a partir do que é disponibilizado pela ANA, governo do estado de Santa Catarina e Companhia Catarinense de Águas e Saneamento (CASAN).

Tabela 2 – Descrição do uso da terra atribuído para agricultura em cada uma das bacias hidrográficas analisadas, área das bacias, e código de identificação utilizado na Figura 5 e no decorrer do texto.

Bacia	Código	Área (km²)	Agricultura (.)	Agricultura (..)
das Almas	w01	1968,3	Soja	Milho
Iracema	w02	304,3	Soja	Milho
Chapécó	w03	8297,1	Soja	Milho
do Peixe	w06	5165,5	Soja	Milho
Canoas	w07	13364,7	Soja	Milho
Timbó	w19	2692,9	Soja	Milho
Cubatão	w14	732,6	Cebola	Milho
Itajaí-Açu	w16	14935,2	Arroz	Milho
Itapocú	w17	2696,6	Arroz	Banana

3.2 O MODELO SWAT

A Figura 7 apresenta os passos gerais para a configuração do modelo SWAT. Os dados de entrada necessários são o modelo numérico do terreno, mapas de uso e tipo de solo, e séries históricas dos dados climáticos (e.g. precipitação e temperatura). No processamento do modelo são definidas as subbacias, HRUs e assimilação dos dados climáticos a área de estudo. Após a simulação inicial, o modelo deve ter seus parâmetros ajustados a através do processo de calibração, e finalmente é feita a análise dos resultados.

Para o cálculo dos valores de evapotranspiração foram utilizadas duas abordagens (que dependem da fase do projeto), as equações de Hargreaves (usada no objetivo (b)) e Penman-Montieh (usada nos objetivos (a) e (c)). Para o cálculo da evapotranspiração pelo método de Hargreaves (Hargreaves et al., 1985), equação 1, foram inseridos os dados de temperatura no modelo. Os valores para a equação de Penman-Montieh (Allen et al., 1998), equação 2, foram retirados do trabalho de Xavier et al., (2016), e cada bacia apresenta apenas um valor para evapotranspiração no dia.

$$\lambda E_o = 0,0023H_0(T_{mx} - T_{mn})^{0,5}(\bar{T}_{av} + 17,8) \quad (1)$$

onde λ é o calor latente de vaporização (MJ kg⁻¹), E_o é a evapotranspiração potencial (mm d⁻¹), H_0 radiação solar extraterrestre (MJ m⁻² d⁻¹), T_{mx} temperatura máxima (°C), T_{mn} temperatura mínima (°C), e T_{av} média da temperatura no dia (°C).

$$ET_o = \left(\frac{\Delta(R_n - G) + k_{time}\rho_a c_p \frac{(e_s - e_a)}{r_a}}{\Delta + \gamma \left(1 + \frac{r_s}{r_a}\right)} \right) / \lambda \quad (2)$$

onde, ET_o é a evapotranspiração potencial (mm/dia); Δ é o gradiente de declividade da curva de pressão de vapor de saturação contra temperatura (kPa/°C); R_n é o saldo de radiação (MJ.m⁻²/dia); G é a densidade do fluxo de calor no solo (MJ.m⁻²/dia); K_{time} constante que depende da escala de tempo utilizada; ρ_a densidade média do ar em pressão constante (kg.m⁻³); c_p calor específico do ar (MJ.kg⁻¹/°C); $e_s - e_a$ é o déficit de pressão de vapor do ar para a altura de referência medida (kPa); r_a e r_s são as resistências totais da cobertura e aerodinâmica (sm⁻¹); γ constante psicrométrica (kPa°C⁻¹); λ é o calor latente de vaporização (MJ/kg).

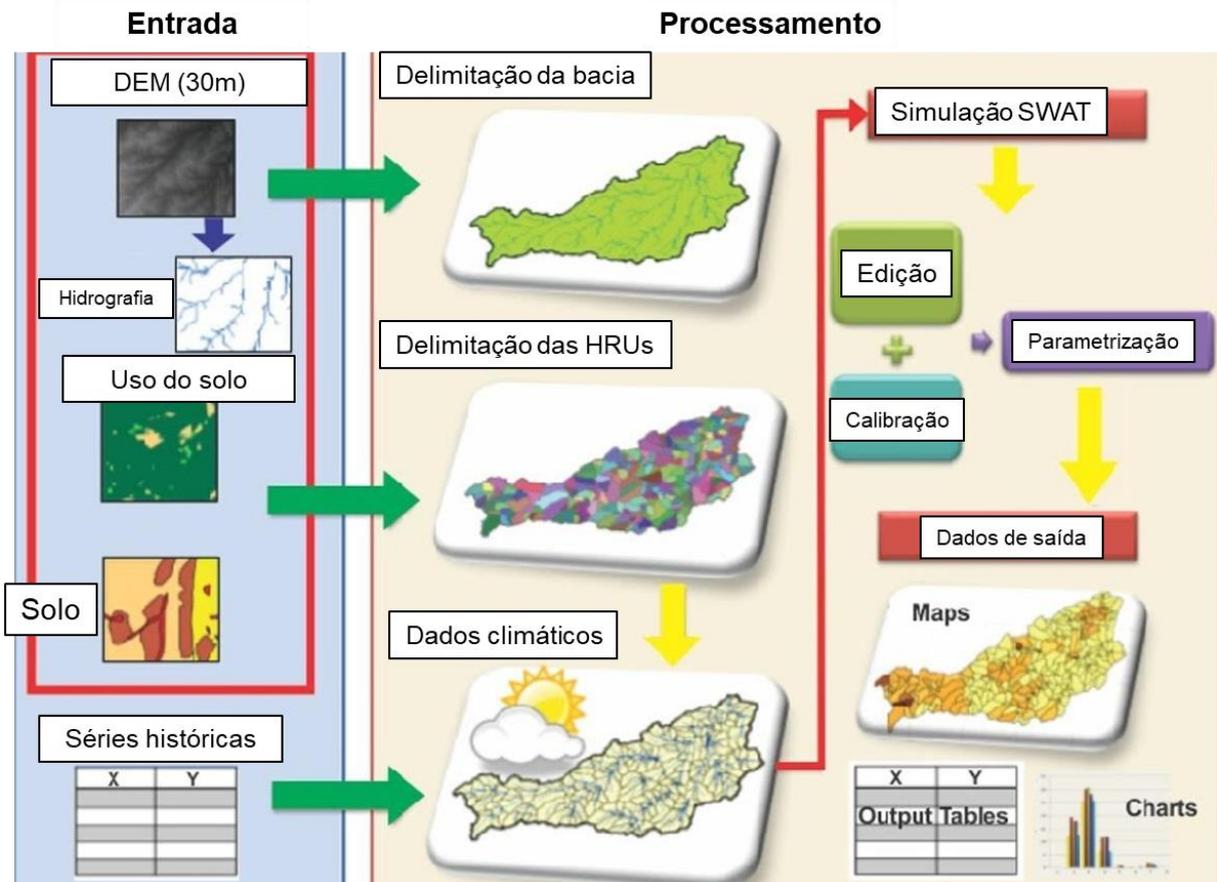
O SWAT permite utilizar camadas múltiplas de solo, porém neste estudo o solo tem apenas uma camada. A percolação ocorre somente quando a capacidade de campo do solo é excedida, e a camada logo abaixo não está saturada, o fluxo é influenciado pela condutividade hidráulica saturada. A água que percola para fora da camada de solo entra na zona vadosa e a partir do aquífero raso pode subir novamente para a zona não saturada, onde fica novamente disponível para evaporação, a água do aquífero raso também pode ser removida diretamente pelas plantas (Dams et al., 2015). O modelo foi simulado por um período de 29 anos (1985-2013), com cinco anos adicionais de aquecimento.

O escoamento superficial da água foi calculado pelo método Curva-Número (CN) e o fluxo no canal usando o método de Muskingum. As variações na altura do lençol freático são baseadas: na recarga, no fluxo, e na produção do sistema de águas subterrâneas (Neitsch et al., 2011). A fase terrestre do ciclo hidrológico simulado pelo SWAT é baseada na equação do balanço hídrico:

$$SW_t = SW_0 + \sum_{i=1}^t (R_{day} - Q_{sup} - E_a - W_{seep} - Q_{gw}) \quad (3)$$

onde, SW_t é a quantidade final de água no solo (mm), SW_0 é a quantidade inicial de água no solo (mm), t é o tempo (dias), R_{day} é a precipitação total diária no dia t (mm), Q_{sup} o escoamento superficial no dia t (mm), E_a é a evapotranspiração total diária no dia t (mm), W_{seep} é a quantidade de água que entra e é armazenada no solo no dia t , e Q_{gw} é a vazão de retorno no dia t (mm).

Figura 7 – Passos para a configuração do modelo *Soil and Water Assessment Tool* - SWAT.



3.2.1 O algoritmo SUFI2

A seguir será apresentado de forma resumida o passo-a-passo do algoritmo SUFI2, descrito em Abbaspour et al., (2004).

Passo 1: aqui é onde a função objetivo deve ser definida, o intervalo final dos parâmetros sempre está condicionado a escolha da função objetivo. Onde \mathbf{b} é o vetor do parâmetro; l é o total de compartimentos; e w_l é calculado pela equação 5.

$$g(\mathbf{b}) = \sum_{i=1}^l w_i \text{FunçãoObjetivo} \quad (4)$$

$$w_i = \frac{\text{avg}(\text{FunçãoObjetivo})_l}{\text{avg}(\text{FunçãoObjetivo})_i} \quad i = 1, \dots, l \quad (5)$$

Passo 2: esse passo estabelece significado físico as faixas máximas e mínimas dos parâmetros otimizados. Não existem bases teóricas de se excluir uma distribuição específica. Entretanto, pela inexistência de algumas informações, é assumido que os parâmetros têm uma distribuição normal, com a definição do intervalo máximo e mínimo.

$$b_j : b_{j,abs_min} \leq b_j \leq b_{j,abs_max} \quad j = 1, \dots, m \quad (6)$$

onde, b_j é o parâmetro j th; e m é o número de parâmetros a serem estimados.

Passo 3: esse passo envolve a análise de sensibilidade *one-at-a-time* dentro do algoritmo.

Passo 4: definida a faixa inicial de incerteza, para a primeira rodada da amostragem por Hipercubo Latino:

$$b_j : [b_{j,min} \leq b_j \leq b_{j,max}] \quad j = 1, m \quad (7)$$

Em geral, os intervalos acima são menores do que os intervalos absolutos dos parâmetros e são subjetivos, dependendo da experiência do modelador. A análise de sensibilidade no Passo 3 pode fornecer uma assistência na seleção dos intervalos apropriados. Embora sejam importantes, estas estimativas iniciais não são cruciais, uma vez que são atualizadas e permitidas dentro da faixa absoluta.

Passo 5: a amostragem por Hipercubo Latino resulta em uma combinação de n valores de parâmetros. Esse número deve ser definido pelo modelador, deve variar de 600 a 2000. O programa vai rodar n vezes, e produzirá um resultado para cada uma dessas n simulações.

Passo 6: como primeiro passo de avaliação da simulação a função objetivo é calculada.

Passo 7: nesta etapa, uma série de medidas é calculada para avaliar cada rodada amostrada. Primeiro, a matriz de sensibilidade ou Jacobiana de $g(\mathbf{b})$ é calculada usando:

$$J_{ij} = \frac{\Delta_{g_i}}{\Delta_{b_j}} \quad i = 1, \dots, C_2^n, j = 1, \dots, m \quad (8)$$

onde, C_2^n é o número de linhas na matriz Jacobiana (igual a todas as combinações possíveis de duas simulações), e j é o número de colunas (número de parâmetros). Seguindo o método de Gauss-Newton e negligenciando as derivadas de ordem superior da matriz de Hessina, \mathbf{H} , a matriz de Hessina de $g(\mathbf{b})$ é calculada como:

$$H = J^T J \quad (9)$$

De acordo com o teorema de Cramer-Rao, uma estimativa do limite inferior da matriz de covariância de parâmetros, \mathbf{C} , é calculada a partir de:

$$C = s_g^2 (J^T J)^{-1} \quad (10)$$

onde, s_g^2 é a variância da função objetivo. O desvio padrão estimado e o intervalo de confiança de 95% de um parâmetro b_j são calculados a partir da diagonal principal de \mathbf{C} :

$$s_j = \sqrt{C_{jj}} \quad (11)$$

$$b_{j,lower} = b_j^* - t_{v,0,025} s_j \quad (12)$$

$$b_{j,upper} = b_j^* + t_{v,0,025} s_j \quad (13)$$

onde, b_j é a melhor estimativa atual do parâmetro b (isto é, esse valor produz o melhor valor da função objetivo); e v são os graus de liberdade ($n-m$). As correlações dos parâmetros podem ser avaliadas usando diagonal principal e a diagonal secundária da matriz de covariância:

$$A_{ij} = \frac{C_{ij}}{\sqrt{C_{ii}} \sqrt{C_{jj}}} \quad (14)$$

É importante observar que a matriz de correlação \mathbf{A} , quantifica as mudanças como resultados dos parâmetros i , relativo às mudanças nos outros parâmetros j . As sensibilidades dos parâmetros S_j são calculados em seguida, pela média das colunas da matriz Jacobiana expressado por:

$$S_j = \bar{b}_j \frac{1}{C_2^n} \sum_{i=1}^{C_2^n} \left| \frac{\Delta g_i}{\Delta b_j} \right| \quad j = 1, \dots, m \quad (15)$$

onde, \bar{b}_j é a média d valor do parâmetro j th. É importante deixar claro que a análise de sensibilidade nesse passo é diferente da realizada no Passo 3. Aqui a análise de sensibilidade global é a realizada.

Passo 8: nesse passo o 95PPU de todas as variáveis preditas é computado usando as n simulações do Hipercubo Latino. A distribuição das variáveis não é sempre gaussiana e pode ser altamente distorcida. Assim, o cálculo usual dos limites de incerteza em função da variância dos valores não é aplicável. Portanto, a incerteza é representada como os percentis 2,5th (q_L) e 97,5th (q_U) da distribuição cumulativa de cada ponto simulado.

O melhor ajuste é calculado para cada variável q a partir da porcentagem de dados que estão dentro da região do 95PPU (envelope de incerteza). O r^2 entre os dados otimizados e observados, e as distancias médias \bar{d} entre os limites superiores e inferiores do 95PPU é determinado por:

$$\bar{d} = \frac{1}{K} \sum_{l=1}^k (q_U - q_L)_l \quad (16)$$

onde, l é o contorno; K é o total de observações por variável q .

Passo 9: em geral a faixa de incerteza é larga na primeira simulação, com um \bar{d} envolvendo praticamente 100% dos dados observados. Por isso, são necessárias novas rodadas de amostragem com intervalos de parâmetros atualizados, calculados a partir de:

$$b'_{j,min} = b_{j,lower} - \text{Max} \left[\frac{(b_{j,lower} - b_{j,min})}{2}, \frac{(b_{j,max} - b_{j,upper})}{2} \right] \quad (17)$$

$$b'_{j,max} = b_{j,upper} + \text{Max} \left[\frac{(b_{j,lower} - b_{j,min})}{2}, \frac{(b_{j,max} - b_{j,upper})}{2} \right] \quad (18)$$

onde, b' representa os valores atualizados.

Os critérios acima, ao mesmo tempo em que produzem intervalos de parâmetros menores, garantem que os intervalos de parâmetros atualizados estejam sempre centrados nas melhores estimativas atuais. Se as melhores estimativas estiverem próximas aos limites, os intervalos de parâmetros são aumentados sem exceder os limites absolutos. Na etapa final, os parâmetros são classificados de acordo com suas sensibilidades e os parâmetros altamente correlacionados são identificados.

3.3 RESOLUÇÃO ESPACIAL DA CHUVA PARA O MODELO SWAT

Para identificar a melhor resolução espacial para os dados de chuva, quando aplicados ao modelo SWAT, foi utilizado o método IDW de interpolação (Shepard, 1968). Para a realização do processo aplicou-se um gradeamento em toda área de estudo, que variou de 5 a 90 km, e cada ponto central da grade corresponde a uma nova estação de chuva. A entrada para a interpolação são os dados medidos das 96 estações selecionadas, os quais são interpolados para o centro de cada grade (Figura 8). Nesta etapa, apenas sete bacias foram utilizadas na análise dos resultados (Tabela 3).

O modelo SWAT atribui à estação pluviométrica mais próxima para cada subbacia, mesmo que se tenham várias estações de chuva dentro de uma mesma subbacia, o SWAT utilizará somente a única estação mais próxima ao centroide, todas as HRUs dentro da subbacia recebem a mesma estação de chuva. Nesta etapa, o modelo SWAT foi simulado com a equação de Hargreaves para o cálculo da evapotranspiração.

São apresentadas por fim, cinco resoluções espaciais para os dados de chuva; a formação original das estações, e os quatro gradeamentos oriundos do processo de interpolação (5, 10, 30 e 90 km). A interpolação para as regiões do Atlântico e do Prata foram feitas separadamente, de modo que os valores de precipitação medidos em cada um dos lados não se confundam, os dados são interpolados para os valores diários de chuva observada. A região do Atlântico é composta pelas bacias do Cubatão e Itapocú, e a região da Prata pelas bacias das Almas, Iracema, Chapecó, do Peixe e Timbó. A Tabela 3 resume o número de estações pluviométricas usadas pelo modelo SWAT para cada um dos arranjos utilizados, área das bacias, e quantidade e área das subbacias.

Figura 8 – Representação do arranjo espacial de estações pluviométricas após a interpolação IDW. Os pontos azuis são a estações de chuva originais e os pontos laranja-azul são as novas estações de precipitação com dados interpolados para o centro de cada grade.

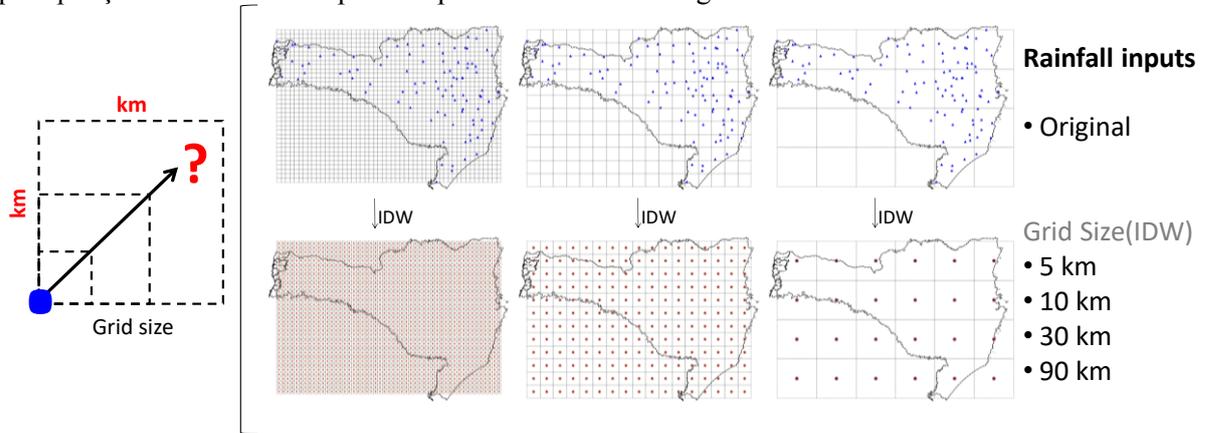


Tabela 3 – Resumo quantidade de estações de chuva utilizadas no processo de simulação. Nome da bacia hidrográfica, área, quantidade e área média de cada subbacia.

Bacias Hidrográficas				Número de estações por resolução espacial				
Nome	Área (km ²)	Quant. subbacias	Área média das subbacias (km ²)	Original	5km	10km	30km	90km
Iracema	304,3	7	43,5	3	5	4	2	2
Cubatão	732,6	39	18,8	4	22	11	4	2
das Almas	1968,3	80	24,6	5	58	25	5	1
Timbó	2692,9	140	19,2	6	83	33	6	2
Itapocú	2696,6	88	30,6	9	69	31	8	2
do Peixe	5165,6	141	36,6	7	120	57	11	4
Chapecó	8297,1	240	34,6	11	186	88	15	6

3.3.1 O Método IDW

O método IDW (*Inverse Distance Weighted*) (Shepard 1968) é comumente utilizado em sistemas de modelagem hidrológica distribuída, de fácil e rápida implementação. O método baseia-se nas funções das distâncias inversas nas quais os pesos são definidos pelo oposto da distância e normalizados para que sua soma seja igual a um, assume-se que as observações mais próximas umas das outras são mais parecidas do que aquelas mais distantes. Os pesos ponderados para cada ponto diminuem à medida que a distância do ponto a ser interpolado aumenta (Ly et al., 2013; Stisen and Tumbo, 2015; Zhang and Srinivasan, 2009).

$$Z(u) = \frac{1}{\sum_{i=1}^n \lambda_{ui}} \sum_{i=1}^n \lambda_{ui} Z(x_i), \quad \lambda_{ui} = \frac{1}{h_{ui}^p} \quad (19)$$

onde n representa o valor ds amostra em torno do local não amostrado; λ_{ui} indica o peso dos dados amostrados no local x_i ; p é o peso de h_{ui} ; $Z(u)$ é o valor interpolado; h_{ui} é a distância entre o local não amostrado e u ; e $Z(x_i)$ é o valor dos dados amostrados no local x_i .

3.4 CALIBRAÇÃO e VALIDAÇÃO DO MODELO SWAT

A calibração, validação e análise de incerteza são os processos necessários para adequar um modelo hidrológico a uma bacia hidrográfica específica, os processos foram feitos no algoritmo de calibração automático SUFI2. Foram realizadas 600 iterações para cada etapa de ajuste dos parâmetros e foi necessário apenas 1 rodada por bacia hidrográfica para que o modelo atingisse um conjunto aceitável de valores de parâmetros. A Tabela 4 apresenta os parâmetros e o intervalo inicial usado na calibração. Dentre os cenários propostos por Klemes, (1986) apresentados no item 2.2, foi realizado o *Split-Sample Test* de maneira simplificada. A série total foi dividida em dois períodos, e a calibração e validação foram realizadas apenas uma vez.

Tabela 4 - Relação dos parâmetros utilizados no processo de calibração, bem como suas descrições, e intervalo dos valores máximos e mínimos.

PARÂMETROS	INTERVALO	
	MIN.	MAX.
A_GWQMN.gw (limite de água do aquífero raso para ocorrer o fluxo de retorno – mm)	-1000	1000
V_GW_REVAP.gw (coeficiente de ascensão de água à zona de saturação)	0,020	0,20
A_RCHRG_DP.gw (percolação da água no aquífero profundo)	-0,05	0,05
A_GW_DELAY.gw (intervalo de tempo para a recarga do aquífero - dias)	-56,33	-8,45
R_CN2.mgt (curva número inicial para condição II de umidade no solo)	-0,15	0,15
V_LAT_TTIME.hru (escoamento lateral)	0	100
V_ESCO.hru (coeficiente de compensação de evaporação da água no solo)	0,7	0,95
R_SOL_BD.sol (densidade do bulbo úmido)	-0,15	0,15
V_ALPHA_BF.gw (fator do escoamento de base)	0	1
A_REVAPMN.gw (profundidade limite no aquífero raso para ocorrer o fluxo de retorno)	-750	750
R_SOL_AWC().sol (armazenamento da água no solo)	-0,05	0,05
R_SOL_K().sol (condutividade hidráulica saturada)	-0,15	0,15
R_SLSOIL.hru (comprimento da declividade para o escoamento subsuperficial)	-0,15	0,15
V_CANMX.hru _____FRST.PINE (máxima capacidade de armazenamento da copa)	0	25

*R: valor do parâmetro inicial é multiplicado por 1+(valor calibrado); V: o valor inicial é substituído pelo valor dado; A: o valor dado é somado ao valor inicial do parâmetro.

Todas as bacias hidrográficas foram simuladas para o mesmo intervalo de tempo, 1985-2013. Porém, o intervalo de calibração e validação varia para cada bacia (Tabela 5 e APÊNDICE E) de acordo com os dados disponíveis. Na média 10 anos são usados na calibração e 5 anos na validação. Os dados são coletados em escala de tempo diária e acumulados mensalmente para realização do processo. As bacias das Almas (das Almas_1 e das Almas_2), do Peixe (do Peixe_1 e do Peixe_2) e Timbó (Timbó_1 e Timbó_2) apresentam dois pontos de monitoramento de vazão.

Tabela 5 - Anos usados nos processos de calibração e validação do modelo SWAT.

Bacias	Calibração	Validação
das Almas_1	1997-2006	2008-2013
das Almas_2	2001-2011	2012-2013
Iracema	1994-2003	2008-2013
Chapecó	1995-2004	2008-2013
do Peixe_1	1990-1999	1985-1989
do Peixe_2	1994-2001	1985-1990
Canoas	1986-1995	2004-2009
Cubatão	1985-1994	1995-2001
Itajaí-Açu	1996-2005	1985-1990
Itapocú	1985-1995	1995-2000
Timbó_1	1985-1994	1995-2000
Timbó_2	1986-1995	1996-2001

O processo de calibração é dependente da função objetivo, e o KGE foi a função escolhida para o processo. A formulação baseia-se na decomposição do NS em três componentes (*alpha*, *beta* e *r*), que podem, se necessário, serem considerados separadamente para cada iteração. *Alpha* é a razão de variabilidade entre o desvio padrão dos valores medidos e modelados. O *r* representa o coeficiente de correlação de acordo com *Pearson*. *Beta* é a relação entre os valores médios simulados e observados (Asadzadeh et al., 2016; Guse et al., 2017; Kayastha et al., 2013; Magand et al., 2015; Nicolle et al., 2014; Osuch et al., 2015). A formulação final do KGE vem como alternativa de uma função objetivo que não

prioriza partes separadas do hidrograma, no processo de calibração, ou seja, todas as patres (altas, médias e baixas) têm mesmo peso (Gupta et al., 2009).

$$KGE = 1 - \sqrt{(r-1)^2 + (\alpha-1)^2 + (\beta-1)^2} \quad (20)$$

onde, α é a razão de variabilidade entre o desvio padrão dos valores medidos e simulados; r é o coeficiente de correlação; e β é a relação entre os valores médios simulados e observados.

Após a calibração do modelo, os valores dos parâmetros obtidos são usados na validação (valor único para cada parâmetro), seguindo os passos do *Split-Sample Test*. A análise de incerteza é realizada a partir do intervalo de parâmetros obtidos também na calibração. As métricas estatísticas usadas para avaliação da eficiência do modelo para estas três etapas são: NS, KGE, Pbias, *p-factor*, e *r-factor*.

Nash-Sutcliffe (Nash and Sutcliffe, 1970) é a função objetivo mais utilizada na modelagem hidrológica, e sua prioridade para os valores altos da amostra é ponto comum entre autores (Asadzadeh et al., 2016; Gupta et al., 2009; Guse et al., 2017; Moriasi et al., 2007; Schaefli and Gupta, 2007). Além de suas recomendações técnicas em literatura (Moriasi et al., 2007), o uso difundido facilita a comparação entre trabalhos. O *Percent bias*, proposto por Gupta et al., (1999), avalia a tendência que a média dos valores simulados tem em relação aos observados. O valor ideal do Pbias é de 0 (zero), valores positivos indicam uma subestimação do modelo, e valores negativos superestimação (Moriasi et al., 2007).

$$NS = 1 - \left[\frac{\sum_{i=1}^n (Q_i^{obs} - Q_i^{sim})^2}{\sum_{i=1}^n (Q_i^{obs} - Q^{mean})^2} \right] \quad (21)$$

$$Pbias = \left[\frac{\sum_{i=1}^n (Q_i^{obs} - Q_i^{sim})}{\sum_{i=1}^n (Q_i^{obs})} \right] * 100 \quad (22)$$

onde, Q_i^{obs} é a vazão observada; Q_i^{sim} é a vazão simulada; Q_i^{mean} é a vazão média.

A incerteza é definida pelo 95PPU que é calculado entre 2,5% e 97,5% da distribuição cumulativa da variável de saída. Duas métricas são disponíveis para avaliar esse envelope: o *p-factor* e o *r-factor*. O primeiro é referente à porcentagem de simulações que

ficaram dentro do envelope e pode variar de 0 a 1, o segundo é referente à espessura, e pode variar de 0 a infinito. Uma simulação onde o *p-factor* é igual a 1 e o *r-factor* é igual a 0, representaria uma simulação perfeita. Visto que isso é praticamente impossível em termos de incerteza na modelagem, valores de *p-factor* acima de 0,70 e *r-factor* a baixo de 1,5 podem ser consideradas simulações satisfatórias (Abbaspour et al., 2015, 2004).

$$r - factor = \frac{\left(\frac{1}{K} \sum_{l=1}^K (q_U - q_L)_l \right)}{\sigma_x} \quad (23)$$

$$p - factor = \frac{nX_{in}}{n} \quad (24)$$

onde, K é o número total de observações da variável q ; e σ_x o desvio padrão, n quantidade de dados observados, nX_{in} quantidade de dados observados no intervalo 95PPU.

3.5 MODELOS DE CLIMA COMO ENTRADA NO SWAT

A integração dos modelos acontece quando, os dados de saída dos GCMs (precipitação e temperatura), são utilizados como dados de entrada do modelo SWAT. Foram selecionados 22 modelos da rodada r1i1p1, pertencentes ao pacote CMIP5 (Tabela 6). Os dados para os modelos de clima podem ser encontrados em <<https://esgf-node.llnl.gov/projects/cmip5/>>. Aplicou-se o método *Distribution Mapping* (DM) (Teutschbein e Seibert, 2012) na correção de viés na rodada histórica dos 22 modelos CMIP5. Na correção são usados os anos de 1980 a 2013 dos dados observados de chuva das 96 estações disponíveis para o estado de Santa Catarina.

Para entrada no modelo SWAT foram selecionados apenas os GCMs que apresentam diferença menor que 50% nas distribuições estatísticas entre os valores observados e da rodada histórica. Após a escolha dos modelos que melhor representam as condições de precipitação para o estado de Santa Catarina, a correção de viés (precipitação e temperatura) também foi realizada para os cenários futuros rcp4.5 e rcp8.5. O modelo MIROC-ESM apresenta apenas o cenário rcp4.5, portanto o modelo não está representado nas análises do cenário rcp8.5. O processo de *downscaling* não foi realizado e os modelos permanecem com a resolução espacial original (Figura 16, item 4.3). Em resumo, o modelo SWAT é alimentado

com a chuva e temperatura de cada um dos cenários, os anos escolhido para as simulações são 2070 e 2071, com 1 ano adicional de aquecimento do modelo.

Tabela 6 – Modelos referentes ao pacote CMIP5 usados na obtenção dos dados de precipitação e temperatura, centros de pesquisa e resolução espacial.

Modelos CMIP5	Centro de pesquisa	Resolução (°lat. x °long.)
ACCESS1,3 ACCESS1-0	Commonwealth Scientific and Industrial Research Organization/ Bureau of Meteorology (Australia)	1,2 x 1,9
bcc-csm1-1 bcc-csm1-1-m	Beijing Climate Center (China)	2,8 x 2,8
BNU-ESM	Beijing Normal University (China)	2,8 x 2,8
CCSM4	National Center for Atmospheric Research (USA)	0,9 x 1,2
CMCC-CESM CMCC-CM CMCC-CMS	Centro Euro-Mediterraneo sui Cambiamenti Climatici (Itália)	3,4 x 3,8 0,7 x 0,8 3,7 x 3,8
CNRM-CM5	Centre National de Recherches Météorologiques, Centre Européen de Recherche et de Formation Avancée en Calcul Scientifique (Fraça)	1,4 x 1,4
CSIRO-Mk3-6-0	Commonwealth Scientific and Industrial Research Organization/ Queensland Climate Change Centre of Excellence (Australia)	1,9 x 1,9
FGOALS_g2	Institute of Atmospheric Physics, Chinese Academy of Sciences (China)	2,8 x 2,8
GFDL-ESM2G GFDL-ESM2M	Geophysical Fluid Dynamics Laboratory (USA)	2,0 x 2,5
GISS-E2-H	NASA/GISS (Goddard Institute for Space Studies) (USA)	2,0 x 2,5
inmcm4	Russian Academy of Sciences, Institute of Numerical Mathematics (Russia)	1,5 x 2,0
MIROC4h MIROC-ESM MIROC-ESM-CHEM	Atmosphere and Ocean Research Institute (The University of Tokyo), National Institute for Environmental Studies, and Japan Agency for Marine-Earth Science and Technology (Japão)	0,6 x 0,6 2,8 x 2,8 2,8 x 2,8
MRI-CGCM3 MRI-ESM1	Meteorological Research Institute (Japão)	1,1 x 1,1
NorESM1-M	Bjerknes Centre for Climate Research, Norwegian Meteorological Institute (Noruega)	1,9 x 2,5

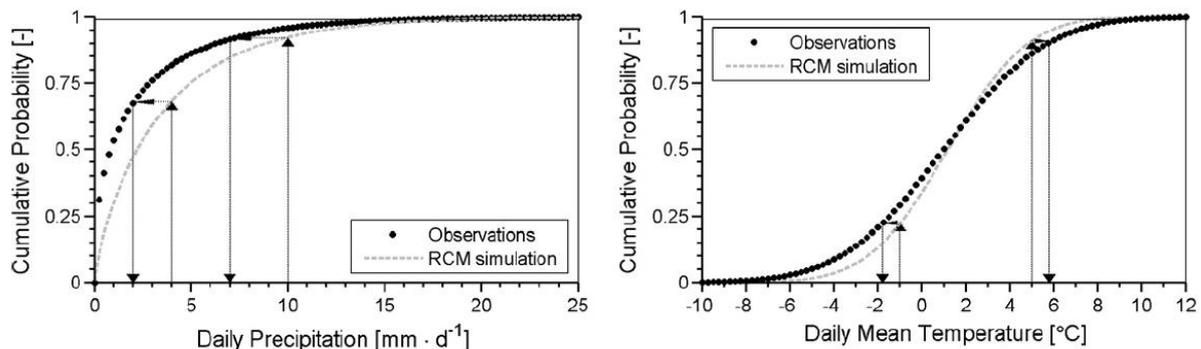
3.5.1 Correção de viés

A finalidade do *Distribution Mapping* (DM) (Teutschbein e Seibert, 2013, 2012) é corrigir a função de distribuição estatística dos valores simulados pelos GCMs a partir da função de distribuição dos dados observados (Figura 9). Para esta mesma abordagem vários nomes podem ser encontrados em literatura. Tais como: *probability mapping*, *quantile-quantile mapping*, *statistical downscaling*, ou *histogram equalization*.

A distribuição Gamma com os parâmetros *shape*, que controla o perfil da distribuição, e *scale*, que determina a dispersão da distribuição, é considerada adequada para eventos de precipitação. Para os dados de temperatura a distribuição Gaussiana geralmente tem o melhor ajuste. Estas duas distribuições foram utilizadas para correção dos valores obtidos pelas saídas dos modelos de clima.

Para o parâmetro *shape*, ou forma, um valor de *shape* < 1 indica uma distribuição Gamma de forma exponencial que é assintótica em ambos os eixos, *shape* = 1 caracteriza uma distribuição exponencial, e *shape* > 1 forma uma curva de distribuição unimodal inclinada. Quando o parâmetro *scale*, ou escala, é baixo indica a menores probabilidades de eventos extremos, quando o *scale* é maior, implica maiores probabilidades de eventos extremos. Entre as vantagens no uso do DM temos a correção da média, desvio padrão, frequências, intensidades de dias úmidos, e os eventos são ajustados de maneira não linear. Para informações mais detalhadas sobre o método consultar Teutschbein e Seibert, (2013, 2012).

Figura 9 - Procedimento na realização do DM. Esquerda: A distribuição Gamma da precipitação diária simulada foi deslocada para a distribuição Gamma das observações (círculos pretos). Direita: A distribuição Gaussiana da temperatura média diária simulada por foi deslocada em direção à distribuição Gaussiana das observações (círculos pretos). Fonte: Teutschbein e Seibert, (2012).



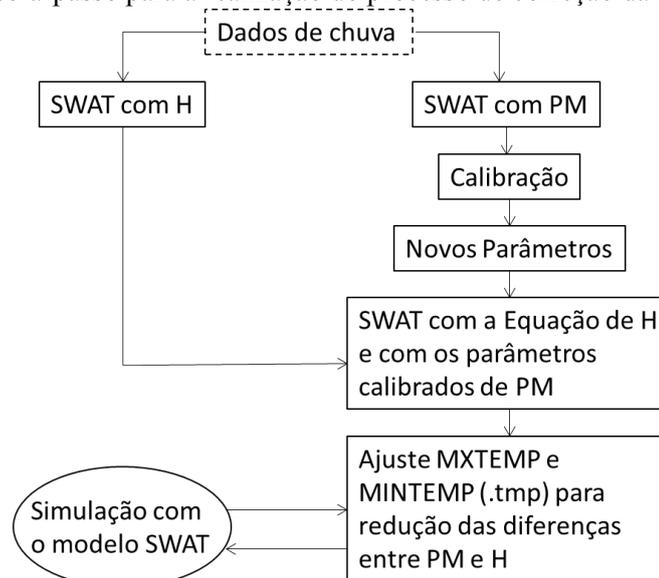
Para aplicação o DM nos dados de precipitação e temperatura disponíveis para o estado de Santa Catarina foi utilizado a plataforma CMhyd (Rathjens et al., 2016). O programa está disponível para download em <https://swat.tamu.edu/software/cmhyd/> e conta com oito métodos para correção de viés para dados de precipitação e temperatura.

3.5.2 Correção da evapotranspiração

A correção da evapotranspiração tem a finalidade de ajustar os valores das simulações futuras (cenários rcp4.5 e rcp8.5) que são calculados usando a equação de Hargreaves. Visto que alguns GCMs só possuem os dados de temperatura disponíveis, a evapotranspiração para as projeções futuras é calculada a partir do método Hargreaves, dentro do modelo SWAT. A correção é baseada nos resultados obtidos pelas calibrações dos dados históricos de monitoramento, e em ambos os cenários a entrada de chuva é o arranjo original com todos os parâmetros permanecendo os mesmos.

Primeiro, o modelo SWAT foi calibrado para cada bacia com a equação PM, onde se obtém um novo conjunto ótimo de parâmetros. O segundo passo, é substituir os parâmetros obtidos em ET-PM calibrado na simulação com ET-H, junto com um ajuste em % nos dados medidos de temperatura (máxima e mínima), e então rodar o modelo novamente. A comparação é feita com valores da evapotranspiração real que o modelo fornece como saída. A modificação na porcentagem é feita até se atingir o mínimo de diferença entre os valores evapotranspiração ET-PM e ET-H. Fixado a % de modificação da temperatura, esses valores são substituídos nas simulações com os cenários futuros (Figura 10).

Figura 10 – Passo-a-passo para a realização do processo de correção da evapotranspiração.



4 RESULTADOS E DISCUSSÃO

4.1 EFEITO DA RESOLUÇÃO ESPACIAL DA CHUVA NAS SIMULAÇÕES

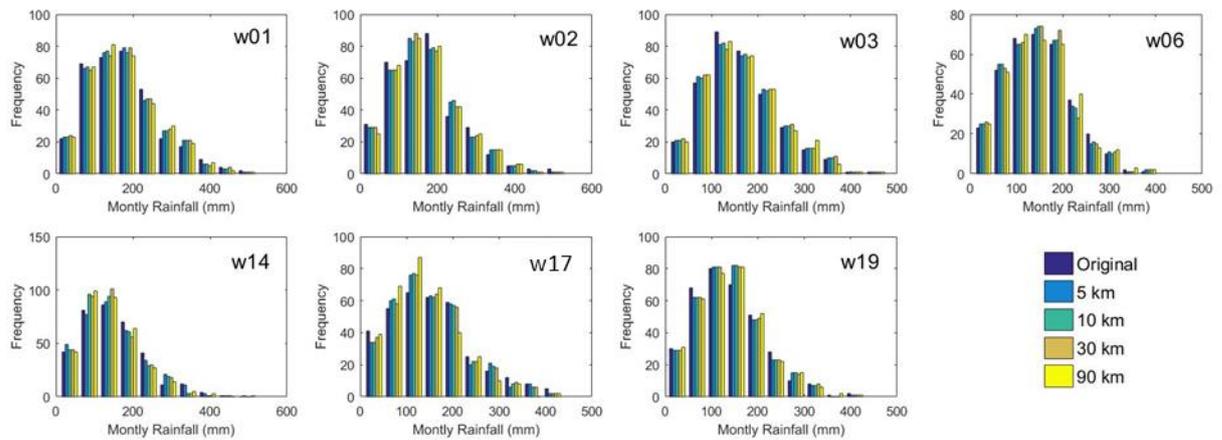
A chuva mensal acumulada para as sete bacias analisadas, apresentam comportamento distintos entre as regiões Prata e Atlântico. As bacias localizadas na região do Prata (das Almas, Iracema, Chapecó, do Peixe e Timbó), possuem o pico dos volumes de chuva mensal no mês de outubro e os meses mais secos variam entre agosto e março. Para as bacias localizadas na porção do Atlântico (Cubatão e Itapocú), os meses com a maior média mensal são janeiro e fevereiro, e os meses mais secos são junho e agosto.

A Figura 11 apresenta o histograma para as bacias nos 29 anos de chuvas, como esperado o processo de interpolação não modifica o formato dos hidrograma, porém diferenças podem ser observadas entre todos os gradeamentos. Vale lembrar que todos os processos são simulados na escala diária. Porém, os dados são analisados na escala mensal. Isso se justifica através das intenções nesta etapa do trabalho, que se resumem em entender como a variação espacial das chuvas afeta a hidrologia das bacias, e não processos que ocorrem em escalas menores de tempo como inundações.

Na avaliação dos resultados, foram adotados os valores de NS propostos Ritter and Muñoz-Carpena, (2013), onde: simulações muito boas são $\geq 0,91$; bom 0,90 - 0,81; aceitável/satisfatório 0,80 - 0,65; insatisfatório $<0,64$. É importante ressaltar que para alguns autores como Moriasi et al., (2007) simulações com modelo SWAT, com um NS de 0,50 pode ser considerada satisfatória.

A Tabela 7 mostra a primeira análise dos resultados de vazão realizada para a média mensal dos 29 anos simulados. Quando usamos o arranjo original das estações de chuva os resultados variam de bons a satisfatórios, em 6 das 10 simulações (das Almas, Chapecó, do Peixe_2, Itapocú e Timbó_2). Em relação às médias gerais, a interpolação IDW não melhorou significativamente as simulações de vazão. Embora existam pequenas variações nos valores acumulados de chuva, as cinco resoluções (original, 5 km, 10 km, 30 km e 90 km) estão próximas umas das outras em termos de desempenho, quando comparamos os valores de NS. A mediana entre as grades de 5 km, 10 km e 30 km é semelhante, e as medianas para os valores de NS, do arranjo original e de 90 km apresentam-se inferiores.

Figura 11 - Histograma para os 29 anos (1985-2013) de chuva média mensal, referentes a cada bacia simulada.

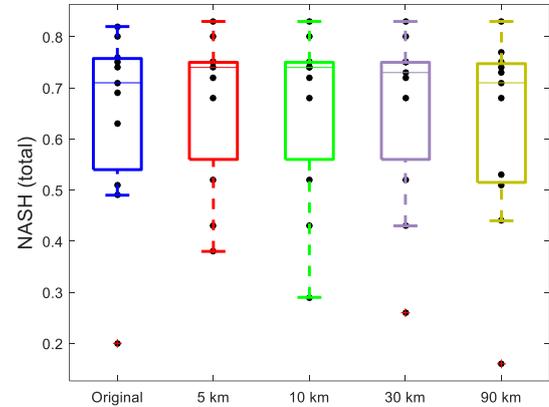


Visto que não existe variabilidade significativa entre os gradeamentos quando analisamos as médias para os 29 anos, o período total foi dividido em três categorias: (i) ano médio de precipitação; (ii) ano úmido; e (iii) ano seco. Após a divisão, concluiu-se que apenas o período mais seco tem melhoras significativas quando aplicamos a interpolação por gradeamento. Para o ano médio, houve melhora em 4 de 10 pontos e dos 4, apenas 2 são estatisticamente significativos. Para o ano mais chuvoso, se considerarmos a média total das simulações (todos os 10 pontos de monitoramento), o modelo passa para resultados insatisfatórios $NS = 0,63$ para uma faixa aceitável $NS = 0,70$. Porém, as melhoras são em apenas em 5 dos 10 pontos de vazão. Diante dos resultados, passamos a explorar, no decorrer deste tópico, apenas os resultados obtidos para o ano mais seco. O ano seco é obtido para cada bacia separadamente, e corresponde ao ano com menos chuva acumulada durante os 29 anos analisados.

Considerando o valor médio do NS, a grade de 5 km apresenta resultados mais satisfatórios, com NS médio de 0,71. O pior desempenho é dado pela grade de 90 km, com um NS médio de 0,44. No geral, a interpolação teve uma melhora em 8 dos 10 pontos de vazão. Para o ponto Cubatão a melhora foi significativa, onde se passou de -0,08 no arranjo original, para um NS de 0,43 na grade 5 km. Da mesma forma, das Almas_2 e do Peixe_2 mudaram de um NS insatisfatório de 0,21 e 0,32, para um valor aceitável de 0,76 e 0,78. Ao comparar as grades de 5 km, 10 km e 30 km, notasse um comportamento semelhante, sendo a grade de 5 km a mais eficiente.

Tabela 7 - Valores mensais de Nash-Sutcliffe para vazão, sem a distinção entre anos médios, secos e úmidos. O boxplot ao lado mostra a representação da distribuição de valores.

Bacias	Nash-Sutcliffe (total)				
	Original	5 km	10 km	30 km	90 km
das Almas_1	0,80	0,83	0,83	0,83	0,83
das Almas_2	0,71	0,74	0,74	0,73	0,71
Iracema	0,63	0,68	0,68	0,68	0,68
Chapecó	0,76	0,75	0,74	0,75	0,73
do Peixe_1	0,51	0,52	0,52	0,52	0,53
do Peixe_2	0,69	0,75	0,75	0,75	0,75
Cubatão	0,20	0,38	0,29	0,26	0,16
Itapocú	0,74	0,72	0,72	0,72	0,51
Timbó_1	0,49	0,43	0,43	0,43	0,44
Timbó_2	0,75	0,75	0,75	0,75	0,74



A Figura 12 mostra a distribuição mensal das vazões durante o ano mais seco para as cinco entradas diferentes de chuva, e também a curva de probabilidade cumulativa (CP) para cada cenário em relação aos valores de NS. As barras em tom de verde representam a classificação proposta por Ritter and Muñoz-Carpena, (2013), a porcentagem de simulação dentro de cada faixa pode ser encontrada no APÊNDICE A. A interpolação por grade mostrou-se ferramenta importante para melhorar as simulações do modelo SWAT, mesmo quando a grade de 90 km é aplicada e a variabilidade espacial parece estar perdida (ver APÊNDICE B), o modelo apresenta melhoras na simulação da vazão, exceto para a bacia do Peixe_1, em que a interpolação não teve melhora. A bacia do Cubatão, localizada na região do Atlântico, foi a bacia hidrográfica que apresenta o maior ganho em termos de valor NS após a interpolação para a grade de 5 km. De acordo com a classificação, os resultados de 5 km ainda são inaceitáveis, mas a melhora é evidente, e existe potencial para uma calibração eficiente. Nos pontos Itapocú e do Peixe_1, a interpolação não foi eficiente na simulação das vazões mais altas, causando diminuição nos valores de NS.

A necessidade de usar uma análise multiobjetiva na avaliação dos resultados de um modelo é discutida por Moriasi et al., (2007), Ritter e Muñoz-Carpena, (2013), e Brighenti et al., (2019). Os autores concordam que é importante analisar uma combinação de índices estatísticos e soluções gráficas, para reduzir a subjetividade comumente introduzida por apenas uma abordagem. O RMSE (Tabela 8) e as soluções gráficas (Figura 12) permitiram validar as conclusões encontradas pelo NS. O RMSE segue o mesmo padrão que o NS,

mostrando uma melhora após a interpolação em 8 dos 10 casos. O gráfico CP também aumenta a validade dos resultados. Por exemplo, há uma probabilidade 80% maior de uma simulação ser insatisfatória quanto o arranjo original é utilizado se compararmos com os resultados obtidos no gradeamento 5 km.

Figura 12 - Resultados mensais da vazão durante o ano mais seco de cada bacia, separados para as cinco entradas diferentes (original, 5 km, 10 km, 30 km e 90 km). Curva de probabilidade cumulativa (CP) para cada cenário apresentando os valores de NS e sua classificação. A escala de cores na CP representam a classificação das simulações proposta por Ritter e Muñoz-Carpena, (2013), variando de muito bom, verde escuro, à branco para insatisfatório.), porcentagem de simulações dentro de cada faixa pode ser encontrada no APÊNDICE A.

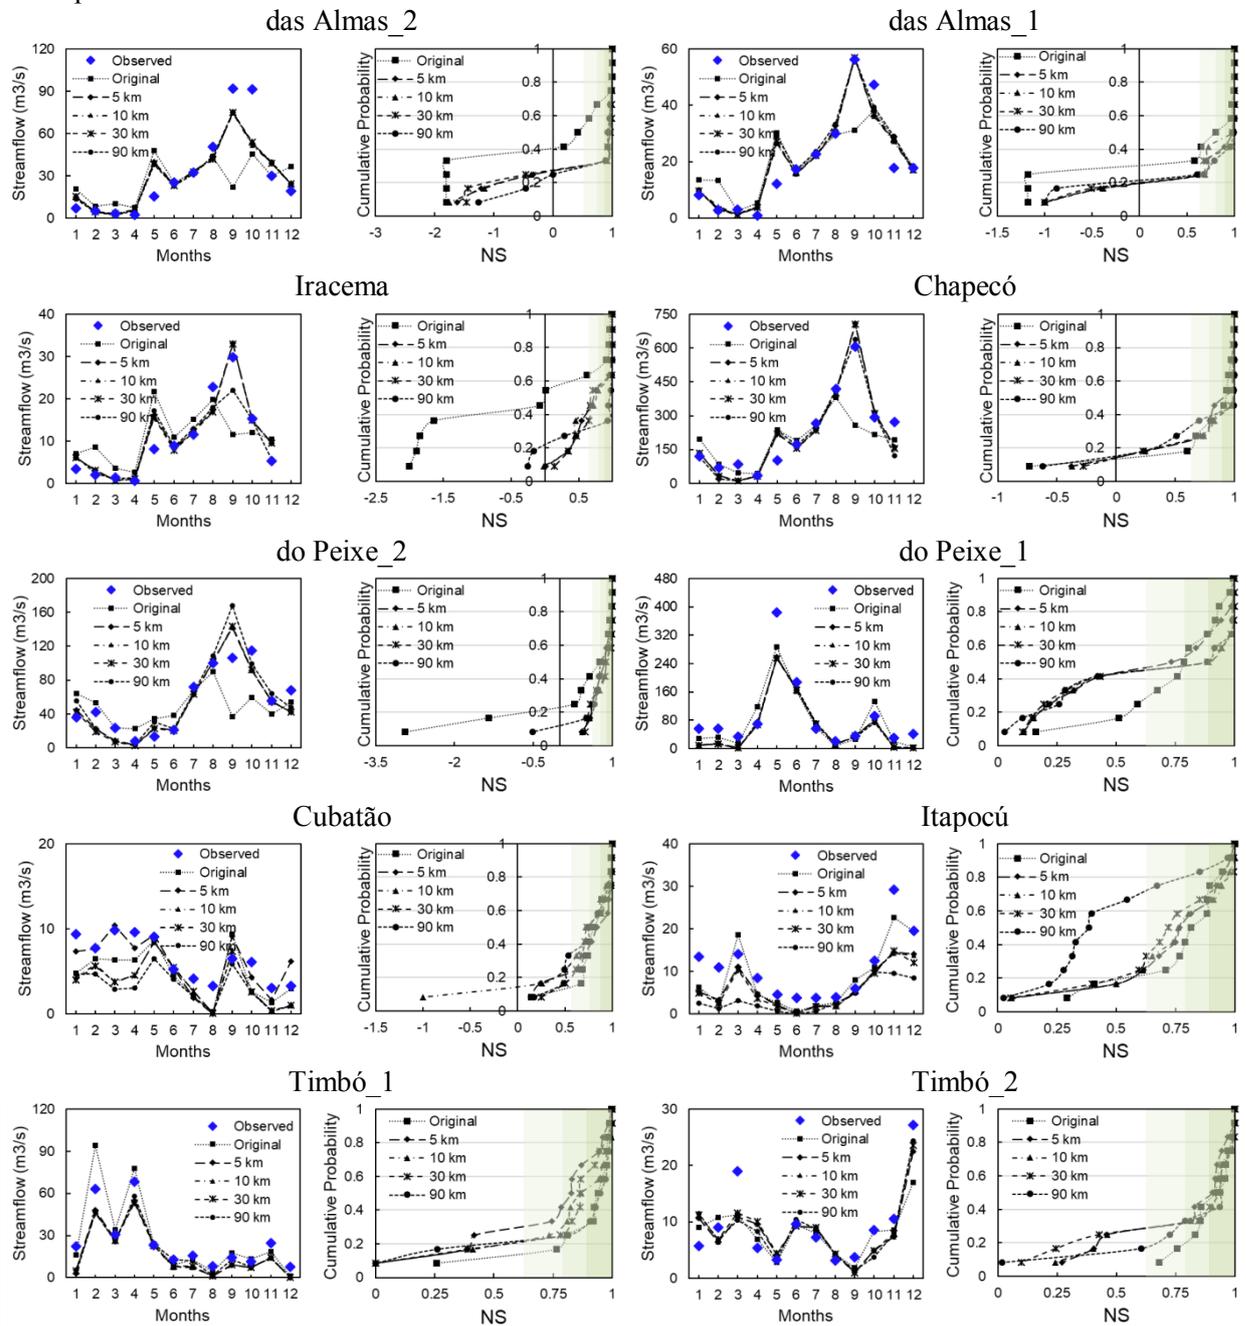


Tabela 8 – Valores mensais de NS e RMSE para os valores de vazão. Os valores foram calculados através da ferramenta disponível em Ritter and Muñoz-Carpena, (2013).

Bacia	Original		5 km		10 km		30 km		90 km	
	NS	RMSE	NS	RMSE	NS	RMSE	NS	RMSE	NS	RMSE
das Almas_1	0,61	10,4	0,87	6,1	0,87	6,1	0,86	6,1	0,85	6,4
das Almas_2	0,21	26,9	0,76	14,8	0,75	15,2	0,77	14,5	0,77	14,4
Iracema	0,27	7,7	0,85	3,5	0,85	3,5	0,85	3,4	0,80	4,0
Chapecó	0,46	120,9	0,84	65,1	0,85	64,7	0,85	65,0	0,84	66,8
do Peixe_1	0,85	38,6	0,80	44,5	0,79	44,9	0,79	45,2	0,79	45,7
do Peixe_2	0,32	29,4	0,78	16,8	0,78	16,8	0,76	17,5	0,61	22,3
Cubatão	-0,08	2,6	0,43	1,9	-0,67	3,3	-0,73	3,3	-1,22	3,8
Itapocú	0,65	4,4	0,34	6,0	0,32	6,1	0,26	6,3	-0,44	8,9
Timbó_1	0,66	4,0	0,69	3,8	0,69	3,8	0,71	3,6	0,69	3,8
Timbó_2	0,73	10,0	0,76	9,5	0,76	9,6	0,73	10,0	0,77	9,3

Os resultados apresentados nesta etapa confirmam a importância de uma representação confiável da variabilidade espacial da chuva durante os anos secos. Essa descoberta pode ajudar usuários do modelo a lidar com simulações em períodos/regiões secos, visto que existem trabalhos que relatam o fraco desempenho do modelo para esse período e.g. Liew et al., (2007); Pilgrim et al., (1988); Rahbeh et al., (2011). Fato que está provavelmente relacionado à falta de variabilidade espacial das chuvas e não às equações do modelo.

4.2 CALIBRAÇÃO E VALIDAÇÃO DO MODELO SWAT

A adequação do modelo SWAT é baseada na aplicação e análise dos processos de calibração, validação e análise de incerteza. A calibração foi feita para dois cenários distintos, um considerando a chuva de entrada (arranjo original, 5 km, 10 km, 30 km, 90 km) e outro para dois métodos de cálculo da evapotranspiração (Hargreaves e Peanman-Monteith), para o segundo caso, o arranjo de chuva utilizado é o original. Na análise dos resultados são utilizados os coeficientes KGE, *p-factor*, *r-factor* e soluções gráficas.

4.2.1 Calibração para os diferentes tamanhos de grade

Para processo calibração do modelo SWAT para os diferentes tamanhos de grade (original, 5 km, 10 km, 30 km e 90 km), não foi feita a distinção entre anos secos e úmidos, e foi realizado para o período total apresentado na Tabela 5. Os resultados seguem o mesmo

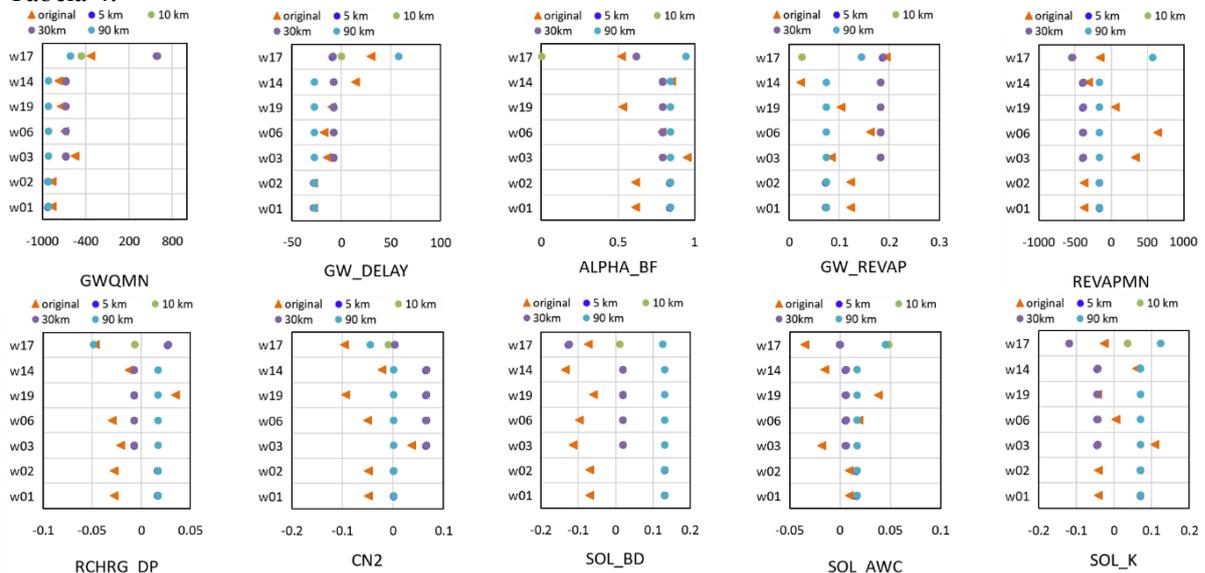
padrão do modelo não calibrado, e não apresentam diferença significativa entre os resultados obtidos pelo arranjo original, 5 km, 10 km e 30 km. A grade 90 km apresentou o pior desempenho, tanto para os valores de KGE como *p-factor* e *r-factor*.

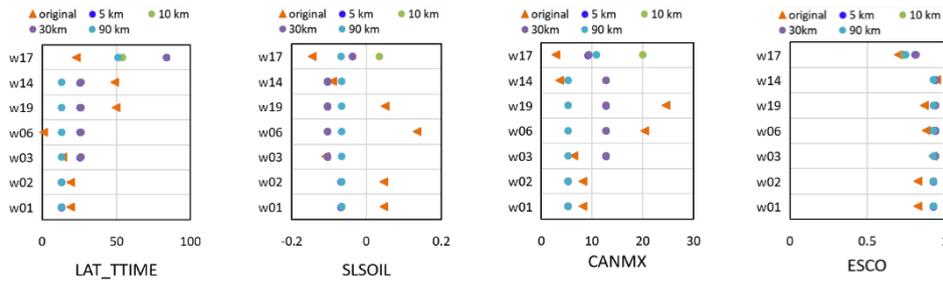
Quando avaliamos o modelo segundo dois intervalos de eficiência diferentes, a partir de Moriasi et al., (2007) ($KGE \geq 0,50$) ou Ritter e Muñoz-Carpena, (2013) ($KGE \geq 0,65$) os padrões de eficiência do modelo também não se modificam. A Tabela 9 apresenta os valores obtidos na calibração do modelo para as seis bacias hidrográficas discutidas no tópico anterior. A Figura 13 apresenta os intervalos dos parâmetros obtidos após o processo de calibração. As grades 5 km, 10 km e 30 km apresentam os mesmos conjuntos de parâmetros, exceto para bacia Itapocú. O arranjo original e a grade 90 km, diferem entre si e entre os outros três gradeamentos.

Tabela 9 - Valores de *p-factor* e *r-factor* para calibração do modelo SWAT para os diferentes tamanhos de grade. Tabela para valores calibrados e não calibrados de vazão. Valores de *p-factor* e *r-factor* para calibração do modelo SWAT para os diferentes tamanhos de grade.

Bacias	Original			5 km			10 km			30 km			90 km		
	KGE	p-factor	r-factor	KGE	p-factor	r-factor	KGE	p-factor	r-factor	KGE	p-factor	r-factor	KGE	p-factor	r-factor
w01_1	0,93	0,75	0,52	0,92	0,68	0,54	0,92	0,68	0,54	0,92	0,70	0,54	0,91	0,70	0,54
w01_2	0,73	0,61	0,46	0,75	0,60	0,46	0,77	0,62	0,46	0,72	0,56	0,45	0,74	0,56	0,46
w02	0,92	0,75	0,53	0,92	0,76	0,61	0,92	0,76	0,61	0,45	0,22	0,35	0,44	0,22	0,35
w03_1	0,90	0,57	0,61	0,88	0,50	0,63	0,87	0,51	0,63	0,88	0,51	0,63	0,48	0,13	0,42
w03_2	0,91	0,69	0,71	0,87	0,52	0,68	0,87	0,52	0,68	0,86	0,54	0,68	0,47	0,08	0,45
w06_1	0,63	0,66	0,49	0,58	0,47	0,48	0,58	0,48	0,48	0,59	0,47	0,48	0,36	0,17	0,34
w06_2	0,79	0,57	0,70	0,81	0,53	0,68	0,80	0,52	0,68	0,81	0,53	0,68	0,74	0,45	0,65
w14	0,57	0,42	0,58	0,58	0,37	0,86	0,58	0,38	0,86	0,57	0,35	0,86	-0,44	0,00	0,03
w17	0,82	0,63	1,52	0,64	0,83	1,45	0,76	0,81	1,44	0,64	0,82	1,44	0,75	0,74	1,33
w19_1	0,52	0,60	0,53	0,50	0,36	0,51	0,48	0,32	0,50	0,48	0,33	0,51	-0,29	0,00	0,07
w19_2	0,87	0,85	0,96	0,9	0,71	0,92	0,90	0,70	0,90	0,92	0,73	0,92	-1	0,00	0,00

Figura 13 - Melhores parâmetros obtidos para as calibrações com Hargreaves e Penman-Monteith. O eixo x corresponde ao intervalo dos valores usados na calibração do modelo SWAT descritos na Tabela 4.





Os resultados apresentados em literatura são contrastantes, vários estudos concluíram que a inclusão de informações mais detalhadas sobre a distribuição espacial das chuvas melhora a simulação de descargas, enquanto outros estudos, mostraram uma falta de melhorias significativas (Lobligeois et al., 2014). Além disso, alguns autores sugerem que uma correta representação do volume de entrada de chuva é mais importante do que o próprio padrão espacial da chuva na simulação dos hidrogramas (Emmanuel et al., 2015).

Com os resultados encontrados nesta etapa e na etapa anterior (item 4.1), conseguimos concordar, mesmo que pareça contraditório, com as duas hipóteses levantadas acima. As condições para o qual o modelo não apresentou melhoras em relação a diferentes resoluções da entrada de chuva foram as condições médias, onde a série histórica é analisada em seu total, anos úmidos e anos de chuva média. Para anos secos o aumento a resolução espacial da chuva ocasionou ganhos positivos na análise das vazões de saída do modelo SWAT.

4.2.2 Diferenças no cálculo da evapotranspiração

Para a análise da diferença que os dois métodos de evapotranspiração causam nas saídas do modelo SWAT foram avaliados os valores de vazão para o modelo calibrado e não calibrado. Além das comparações entre os valores médios mensais para os 29 anos simulados para os resultados de evapotranspiração e produção de água (WYLD). O WYLD representa a produção de água total da bacia durante o período simulado, ou seja, o somatório do escoamento superficial, lateral e subterrâneo, diminuindo as perdas por transmissão e a água que fica retida em lagos e/ou depressões no terreno.

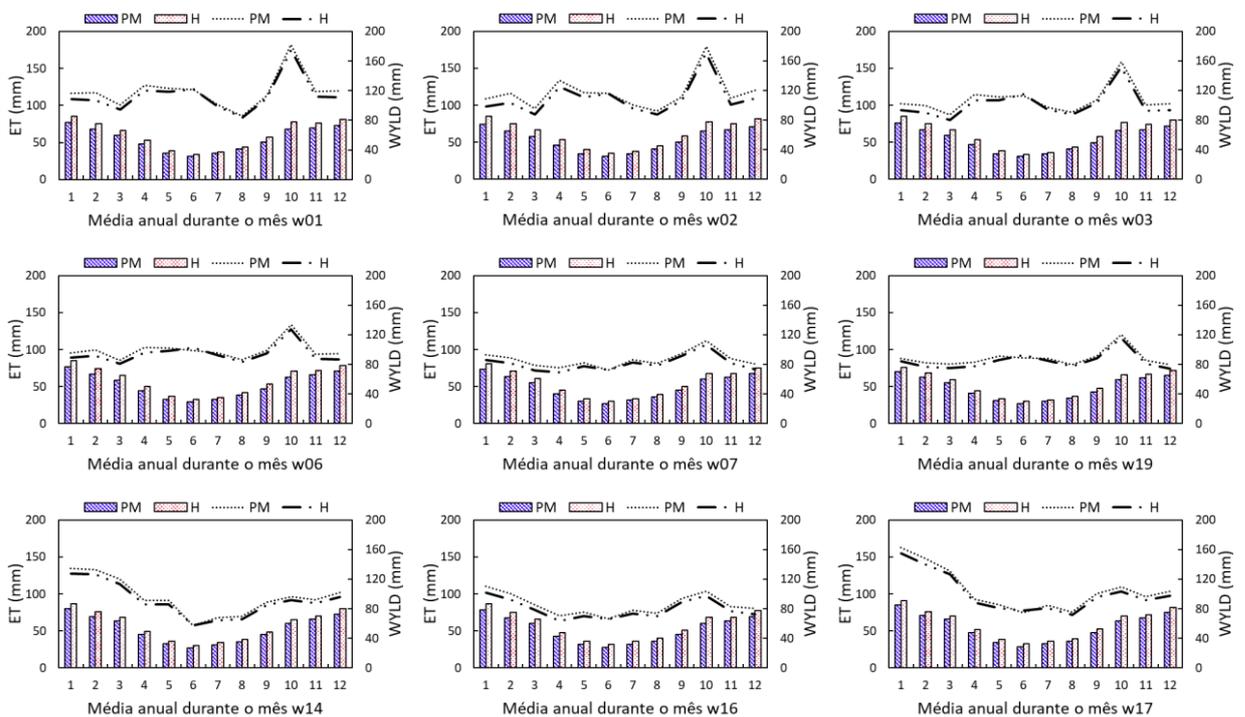
$$WYLD = SURQ + LATQ + GWG - TLOSS - PD \quad (25)$$

onde, SURQ é o escoamento superficial; LATQ é o escoamento lateral; é o escoamento subterrâneo; TLOSS são as perdas por transmissão; e PD é a água que fica retida em lagos e/ou depressões no terreno.

A Figura 14 apresenta os valores médios mensais não calibrados para ET e WYLD para os dois métodos utilizados. O volume médio de evaporação é superior em todas as bacias quando Hargreaves é utilizado. As diferenças nos volumes para o modelo não calibrado variam de 8 a 15% para evapotranspiração, e 4 a 7% para a produção de água.

A escolha do melhor método para o cálculo da evapotranspiração varia de acordo com a área estudada e com a escala de tempo utilizada na análise. Para o modelo não calibrado, Penman-Monteith possui simulações mais satisfatórias em 7 dos 13 exutórios para o coeficiente KGE. Para o Pbias, que expressa a relação entre os volumes, os dois métodos apresentam mesmo desempenho. É importante ressaltar que as simulações podem ser consideradas satisfatórias segundo os padrões estabelecidos por Moriasi et al., (2007) em 12 dos 13 casos, tanto para Penman-Monteith como para Hargreaves.

Figura 14 – Valores médios mensais não calibrados de evapotranspiração (ET) e produção de água (WYLD) para os 29 anos simulados. As colunas representam ET (H - Hargreaves e PM - Penman-Monteith) e as linhas são representativas dos valores de WYLD.



O modelo calibrado segue o mesmo padrão para os valores de KGE (Tabela 10). Na comparação do envelope de incerteza a por meio os coeficientes *p-factor* e *r-factor* o Penman-Monteith apresenta uma pequena melhora dos resultados em relação ao *p-factor*, ou seja, a quantidade dos dados observados que caem dentro do envelope é maior. A validação do modelo é considerada satisfatória para a maioria dos casos, exceto para ponto do Peixe_2 onde o valor de KGE é negativo para os dois métodos. A validação foi melhor em 6 dos 11 exutórios para o Penman-Monteith, em 3 de 11 para Hargreaves e, dois exutórios não apresentam nenhuma diferença entre os dois métodos. Mesmo que os resultados entre os dois métodos sejam muito similares, apenas o Penman-Monteith apresenta todas as simulações dentro das faixas estabelecidas como aceitáveis por Abbaspour et al., (2009) e Moriasi et al., (2007) durante o processo de calibração.

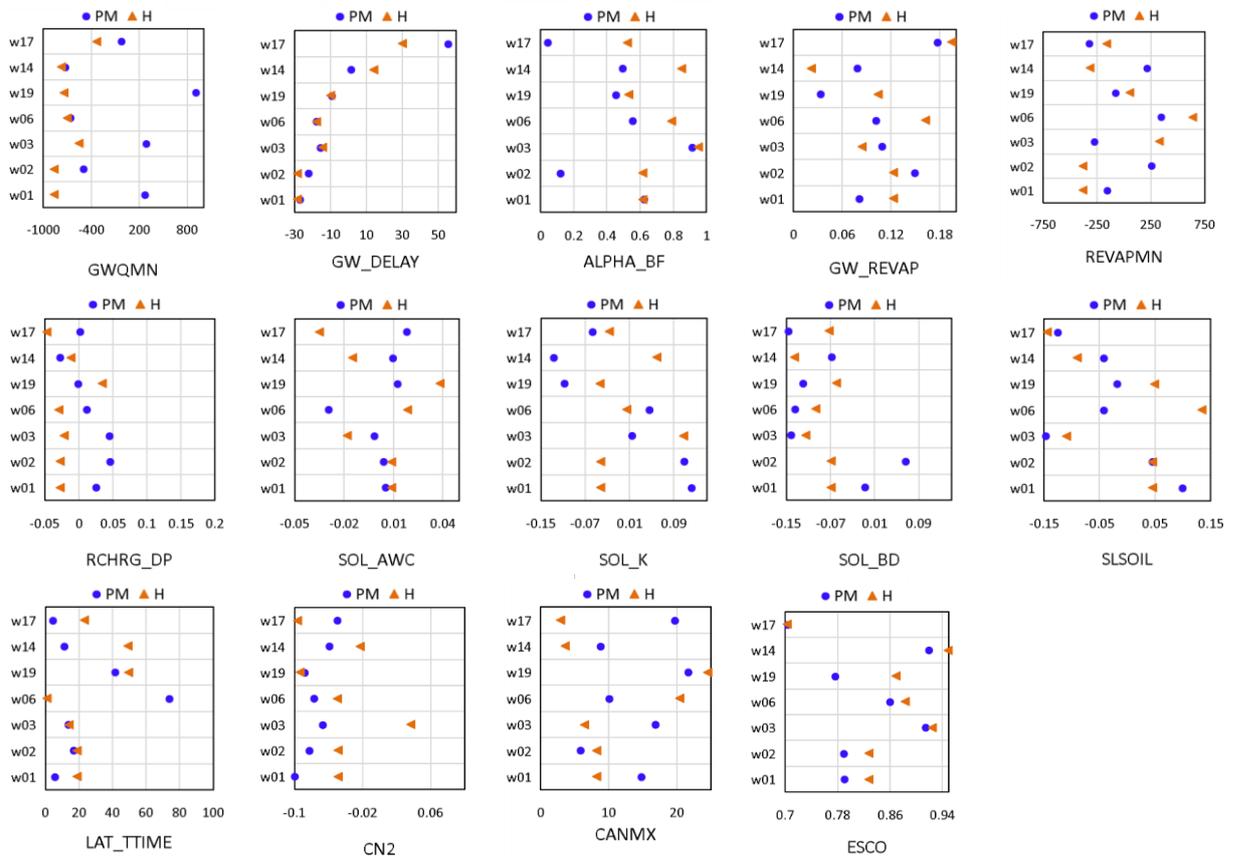
Tabela 10 – Calibração do modelo SWAT com os métodos de Penman-Monteith e Hargreaves.

Bacias	Penman-Monteith				Hargreaves			
	KGE	<i>p-factor</i>	<i>r-factor</i>	KGE (val)	KGE	<i>p-factor</i>	<i>r-factor</i>	KGE (val)
das Almas_1	0,95	0,76	0,52	0,82	0,93	0,75	0,52	0,87
das Almas_2	0,72	0,68	0,45	0,62	0,73	0,61	0,46	0,57
Iracema	0,92	0,68	0,49	0,72	0,92	0,75	0,53	0,65
Chapecó	0,91	0,76	0,61	0,78	0,90	0,57	0,55	0,71
Chapecó	0,93	0,85	0,71	0,69	0,91	0,69	0,66	0,76
do Peixe_1	0,61	0,66	0,48	0,73	0,63	0,66	0,49	0,62
do Peixe_2	0,82	0,65	0,71	-0,17	0,79	0,57	0,70	-0,15
Cubatão	0,57	0,52	0,81	0,53	0,57	0,42	0,58	0,61
Itapocú	0,63	0,75	0,76	0,47	0,43	0,63	1,52	0,41
Timbó_1	0,52	0,73	0,54	0,45	0,52	0,60	0,53	0,44
Timbó_2	0,88	0,87	0,97	0,78	0,87	0,85	0,96	0,78

A Figura 15 apresenta os valores dos parâmetros obtidos no processo de calibração para os dois métodos. De maneira geral, os parâmetros apresentam grande variação, ou seja, com os melhores parâmetros ocupando quase todo o espaço do intervalo de calibração. Não foi encontrado relação clara entre a variação dos parâmetros e a região hidrológica a qual as bacias pertencem, Prata ou Atlântico, nem mesmo entre bacias vizinhas. Exceto para as bacias das Almas e Iracema usando o Hargreaves, os parâmetros apresentam-se sempre os mesmos. A grande variação dos parâmetros adicionado a pouca diferença nos resultados do modelo, indica sensibilidade dos parâmetros em relação ao método de evapotranspiração escolhido, porém o processo de calibração compensa as diferenças. Além a escala de tempo mensal,

outro palpite para a pouca variação é associado a resolução espacial dos dados de entrada, onde para Penman-Monteith foram utilizados um único valor de evapotranspiração potencial no dia para a toda a bacia, e no caso de Hargreaves foi utilizada uma grade de 25 km de valores máximos e mínimos de temperatura.

Figura 15 - Melhores parâmetros obtidos para as calibrações com Hargreaves e Penman-Monteith para todas as bacias hidrográficas. O eixo x corresponde ao intervalo dos valores usados na calibração do modelo SWAT descritos na Tabela 4.

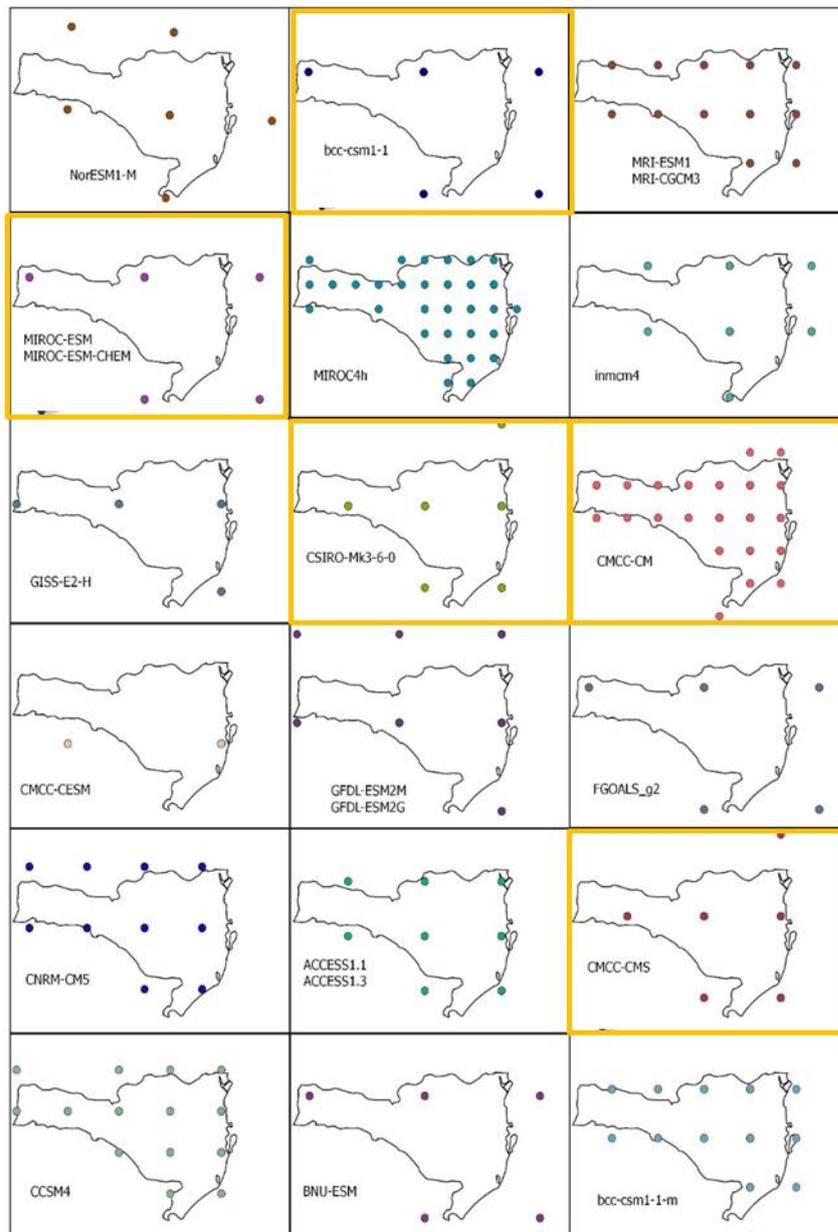


4.3 ESCOLHA DOS MODELOS DE CLIMA

A aplicação de métodos para correção do viés da precipitação e temperatura provenientes dos modelos de clima é procedimento recomendado em literatura (Teutschbein and Seibert, 2013, 2012). O *Distribution Mapping* (DM) pode ser entendido como a correção dos dados correspondentes aos GCMs em relação às estações de monitoramento disponíveis. O *downscaling* não foi realizado, e a resolução espacial das estações permaneceu a mesma que a resolução original de cada modelo (Figura 16). Mesmo que o processo seja comumente recomendado em literatura e sua realização seja considerada *default* neste tipo de estudo, é também de conhecimento, as incertezas que esse tipo de procedimento adiciona aos resultados

finais (Clark et al., 2016). Os resultados obtidos no item 4.1 dão apoio a escolha de não realizar o processo de *downscaling*, pois na análise dos dados mensais entre os diferentes tamanhos de grade testados, mesmo a grade mais grosseira, 90 km, teve a maioria de seus resultados satisfatórios.

Figura 16 - Espacialização das estações para os quais são fornecidos os dados das variáveis dos modelos de clima. Os quadros marcados são referentes aos modelos selecionados para a aplicação com o modelo SWAT.



Os dados de temperatura para os modelos bcc-csm1-1-m e MIROC4h não estavam disponíveis no *Earth System Grid Federation* (ESGF), portanto, estes dois modelos não foram

considerados nos próximos passos deste trabalho. Os dados de temperatura para os seis modelos foram corrigidos pelo método DM. A Tabela 12 mostra a diferença entre os valores de temperatura máxima e mínima. As saídas dos GCMs apresentaram melhores resultados para os dados de temperatura se comparados aos de precipitação, nas temperaturas o melhor ajuste foi para as máximas.

A escolha dos modelos que melhor representaram o clima para o estado de Santa Catarina são baseados nos valores de precipitação. Os valores observados de chuva para as 96 estações são comparados aos resultados da rodada histórica de cada um dos modelos, e o intervalo analisado foi de 1980 a 2005. Para a comparação entre as duas séries foram calculadas as diferenças entre os parâmetros *shape* e *scale* (APÊNCIDE C).

Oito foram os modelos que apresentaram diferença menor que 50% entre as funções de distribuição estatística dos dados observados e a rodada histórica dos GCMs (Tabela 11 e Figura 16). Visto que o regime de chuvas tem diferença entre as regiões do Atlântico e Prata (item 4.1), os modelos também foram corrigidos separadamente, ou seja, as bacias na região do Prata recebem os dados de chuva corrigidos apenas pelas estações de chuva localizadas nessa região, e vice-versa. A Tabela 11 e a Figura 17, apresentam a diferença entre os parâmetros *shape* e *scale* calculados para os dados observados e para a rodada histórica dos GCMs. Os oito modelos selecionados podem ser divididos em quatro famílias, as quais apresentam semelhanças em código e/ou são produzidos pela mesma instituição.

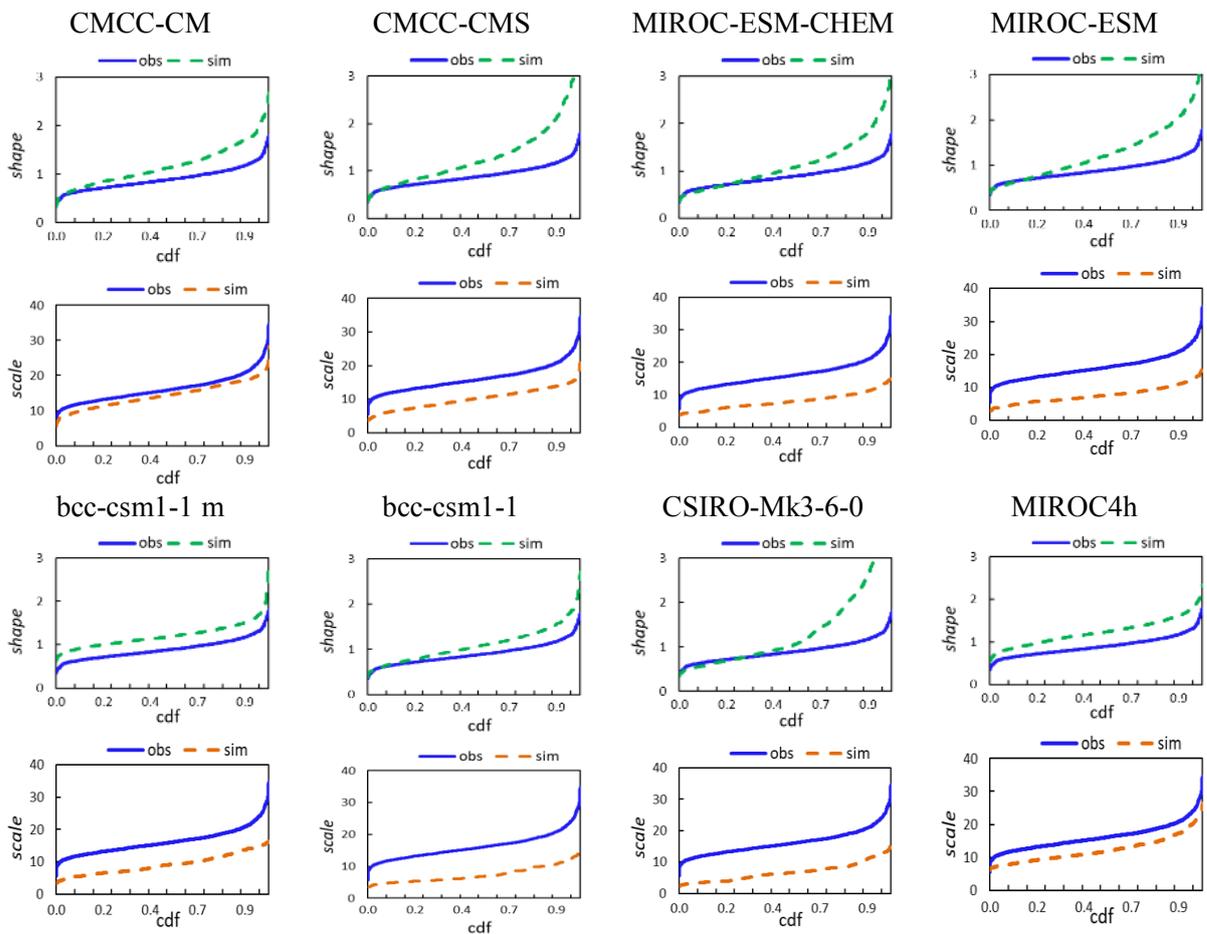
Tabela 11 – Diferença em % das distribuições estatísticas para os parâmetros *shape* e *scale* dos dados observados de precipitação e rodada histórica dos GCMs. Os modelos de mesma família são marcados na tabela com o mesmo número.

	Atlântico		Prata	
	<i>scale</i>	<i>shape</i>	<i>scale</i>	<i>shape</i>
CMCC-CM (1)	18,30	38,06	22,77	36,56
CMCC-CMS (1)	31,50	42,66	-	-
MIROC-ESM-CHEM (2)	44,30	36,14	-	-
MIROC-ESM (2)	45,52	45,12	-	-
MIROC4h (2)	-	-	23,88	36,89
CSIRO-Mk3-6-0 (3)	47,93	37,88	-	-
bcc-csm1-1 (4)	47,80	33,08	-	-
bcc-csm1-1-m (4)	38,89	46,74	47,65	38,18

Quando a eficiência dos modelos é comprada em relação as resoluções espaciais, mesmo que os dois modelos com resolução mais detalhada (CMCC-CM e MIROC4h) façam parte do grupo selecionado, modelos com resoluções mais finas nem sempre causam os

melhores resultados. Indicando que a eficiência dos modelos pode não estar apenas ligada a resolução espacial dos dados, mas também a formulação por trás dos cálculos.

Figura 17 – Parâmetros *shape* e *scale* para cada um dos GCMs escolhidos já corrigidos pelo método DM. A linha azul representa dos dados observados de precipitação e a linha vermelha representa os dados da rodada histórica dos modelos de clima.



A correção dos dados provenientes dos modelos de clima é aconselhada em literatura (Wang et al., 2019), e para identificar as diferenças entre os dados corrigidos e não corrigidos foi selecionado um modelo GCM de cada uma das quatro famílias, e aplicados na bacia das Almas. O modelo SWAT foi simulado para cinco anos da rodada histórica (2000-2004) e para dois anos de projeção futura. A Tabela 13 apresenta os valores do coeficiente Pbias para as variáveis precipitação, produção de água e evapotranspiração.

Tabela 12 – Diferença em % para os valores de temperatura máxima e mínima entre valores observados e da rodada histórica.

	Temp. Máx.	Temp. Min.
CMCC-CM	5,91	17,69
CMCC-CMS	7,81	24,27
MIROC-ESM-CHEM	8,02	18,91
MIROC-ESM	9,08	19,05
bcc-csm1-1	12,61	23,89
CSIRO-Mk3-6-0	12,24	22,25

No geral os valores corrigidos mostram melhora significativa na representação das séries históricas, e uma diferença pequena entre os dois cenários pode ser observada apenas no modelo CMCC-CM. O uso dos dados brutos gera uma subestimação nos valores de precipitação, produção de água e evapotranspiração em todos os casos, exceto para o modelo CSIRO-Mk3-6-0 para a variável ET. Para os dados corrigidos a precipitação é subestimada em três dos quatro modelos, a produção de água em dois e a evapotranspiração em apenas um modelo (Tabela 13).

O modelo bcc-csm1-1 apresenta a maior diferença entre os dados corrigidos e brutos comparados com o observado, os dados brutos estimam menos 1145 mm/ano de chuva que, e os dados corrigidos 7 mm/ano a menos. A menor diferença foi encontrada nos resultados do CMCC-CM, com 86 mm/ano a menos para os dados brutos e menos 66 mm/ano para os dados corrigidos (Figura 18).

Tabela 13 – Desempenho dos modelos de clima na bacia hidrográfica das Almas. O coeficiente Pbias é apresentado para uma simulação de cinco anos (2000 - 2004), para as variáveis precipitação (prec.), produção de água na bacia (WYLD) e evapotranspiração (ET).

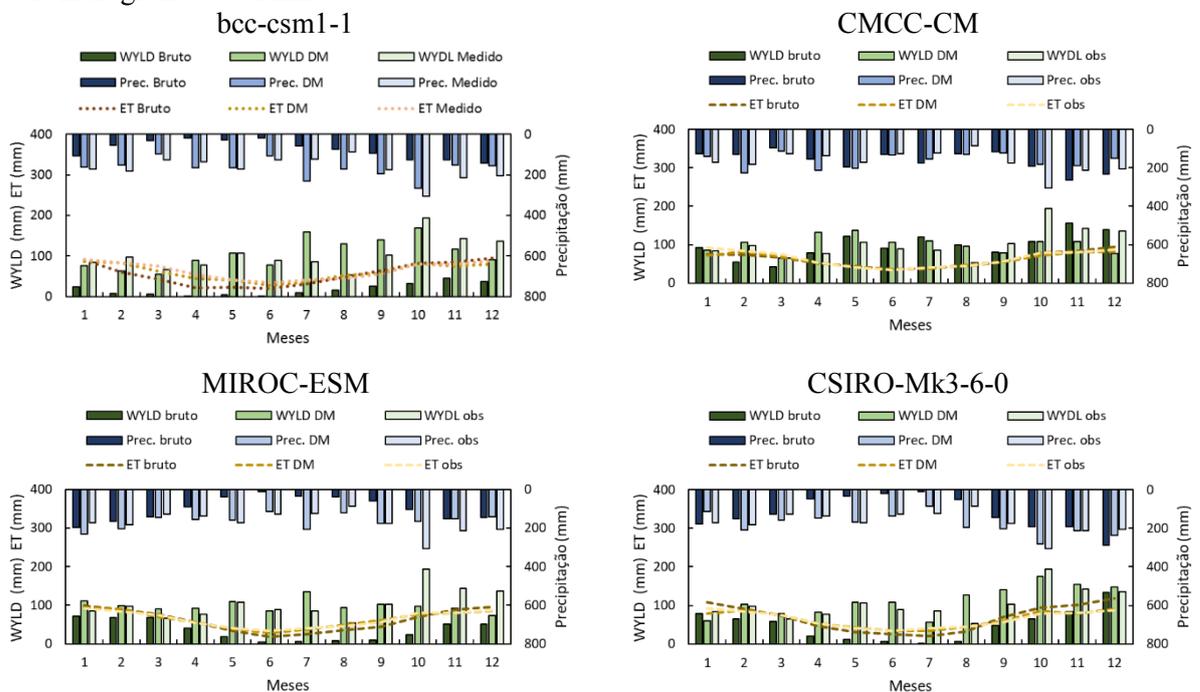
	Bruto			Corrigido (DM)		
	Prec.	WYLD	ET	Prec.	WYLD	ET
CMCC-CM	4,3	4,3	3,2	3,2	2,0	3,2
MIROC-ESM	42,1	66,3	4,6	2,6	4,5	-0,1
bcc-csm1-1	56,5	83,2	14,2	0,4	-3,0	5,2
CSIRO-Mk3-6-0	29,1	53,3	-5,9	-6,1	-8,4	0,4

Os valores apresentados na Figura 18 representam a média mensal para os cinco anos simulados. A evapotranspiração é a variável que apresenta melhor ajuste e menor diferença em relação aos dados observados, tanto para os dados brutos como para os dados corrigidos. Embora os dois cenários (bruto e corrigido) apresentem resultados bem distintos, com uma

diferença grande entre os valores de Pbias, principalmente para WYLD e precipitação, o formato das séries premisse o mesmo. Por exemplo, os maiores volumes de evapotranspiração estão sempre presentes nos meses de novembro, dezembro, janeiro e fevereiro, e menores volumes de maio a gosto.

A Figura 19 apresenta um exemplo para aplicação dos cenários futuros quando consideramos dados corrigidos ou não, os gráficos apresentam os valores médios mensais dos anos 2070 e 2071, na bacia hidrográfica das Almas, para os quatro modelos selecionados acima. O padrão observado na rodada histórica é repetido para os cenários futuros nos dois casos analisados, na maioria das vezes. Os volumes de precipitação para os dados brutos são menores que para os dados corrigidos, e conseqüentemente uma menor produção de água na bacia. Mesmo com as diferenças na precipitação, os valores de evapotranspiração permanecem muito próximos nas duas ocasiões. O modelo CMCC-CM foi o único que apresentou exceção em três dos quatro casos de chuva analisados, com os valores dos dados brutos estimando maior volume de chuva que os dados corrigidos.

Figura 18 – Comparação entre os resultados obtidos a partir das simulações realizadas com os dados observados e as simulações com os dados da rodada histórica, brutos e corrigidos, dos GCMs, para a bacia hidrográfica das Almas.

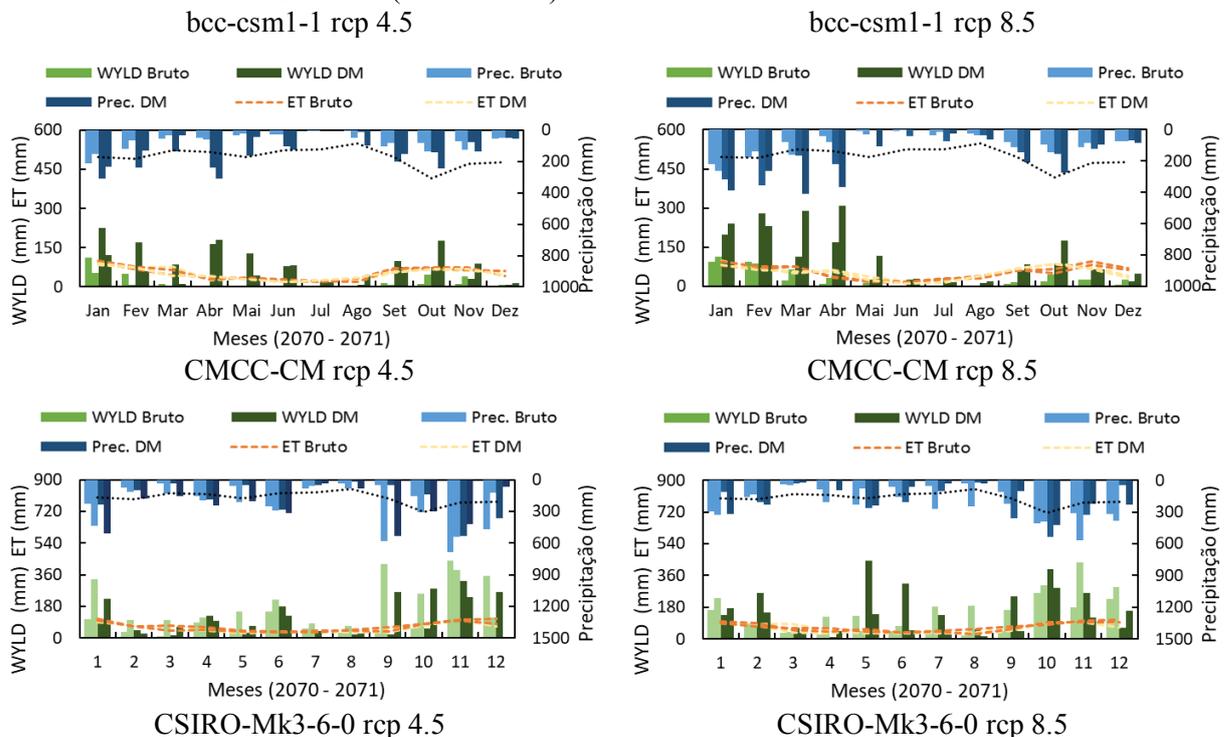


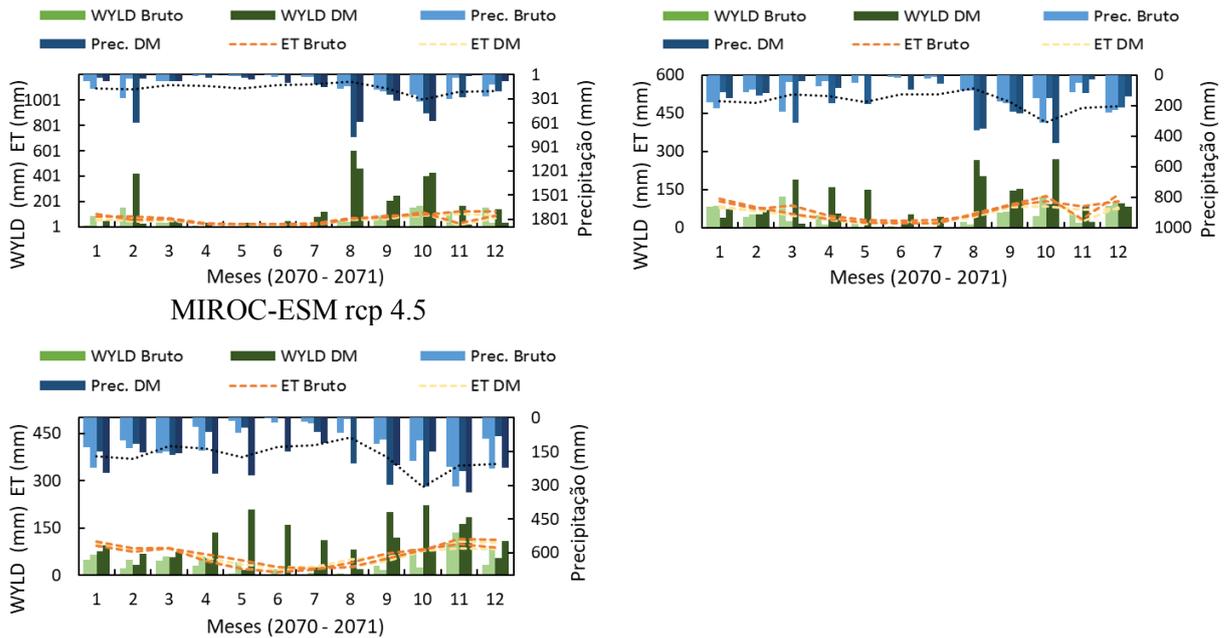
Mesmo que a série de dados analisadas seja reduzida, estes resultados nos ajudam a avaliar a hipótese levantada em literatura que afirma a necessidade da correção dos dados

provenientes de modelos de clima (Wang et al., 2019). Mesmo que não haja garantia de que os modelos que apresentam bom ajuste da rodada histórica irão dar boas simulações para as projeções futuras. O fato de os quatro modelos apresentarem melhores resultados para as séries corrigidas e que o padrão de simulação é passado para o cenário futuro, reforçam a hipótese de que algum tipo de correção ou ajuste dos dados de precipitação gerados pelos modelos ainda são necessários. Em relação aos dados de evapotranspiração, a temperatura mensal foi a melhor variável reproduzida pelos modelos durante a rodada histórica, o que vai de acordo com os resultados encontrados por Chen et al., (2017) e Woldesenbet et al., (2018), como consequência, a correção da variável mostrou-se menos significativa quando relacionado ao resultado final das simulações. Na comparação dos valores anuais de chuva.

Na análise da quantidade de chuva que chega anualmente nas bacias para o período 2070- 2071, quando comparado com a média anual dos valores observados, os sinais não se alteram em todos os casos, exceto para o modelo CSIRO-Mk3-6-0 durante a simulação do cenário rcp4.5. Ou seja, os modelos corrigidos ou não, apresentam a mesma relação de aumento ou diminuição do volume de chuva em relação à média anual (Figura 19).

Figura 19 - Resultado das variáveis precipitação, produção de água e evapotranspiração para as simulações dos cenários futuros rcp4.5 e rcp 8.4. A linha pontilhada no eixo da precipitação representa os valores históricos observados (2000 – 2004).





4.4 INTREGRAÇÃO MODELO SWAT E MODELOS DE CLIMA

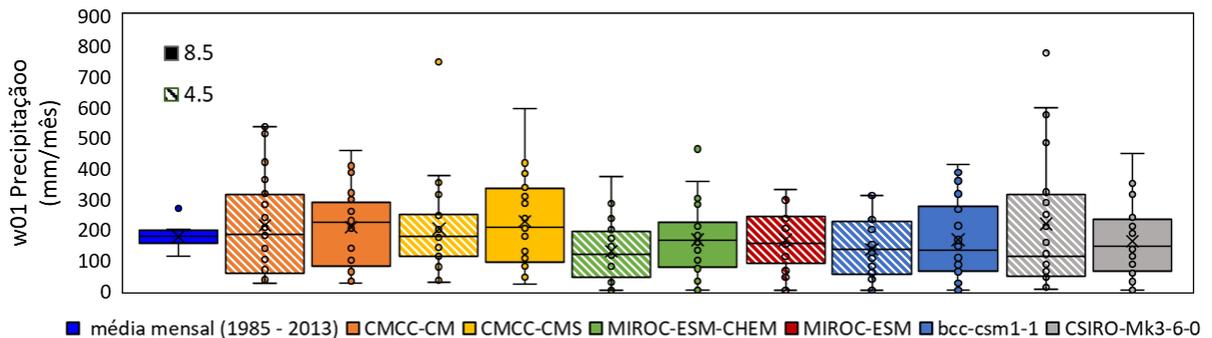
O uso combinado do modelo SWAT com os modelos de clima se deu através do uso dos dados de precipitação e temperatura corrigidos pelo método *Distribution Mapping* para os cenários rcp4.5 e rcp8.5. Os parâmetros utilizados no *setup* do modelo SWAT foram os ajustados após o processo de correção da evapotranspiração. Visto que para as projeções futuras foram utilizados os valores para a simulação de apenas dois anos 2070 – 2071, todas as conclusões tomadas neste tópico, devem interpretadas e usadas com cautela, pois o período de dados da amostra é pequeno, e pode haver a existência de vieses significativos.

Anterior da aplicação conjunta entre GCMs e o modelo SWAT, foi realizada a correção da evapotranspiração. Esse procedimento é uma tentativa de aproximar os valores calculados da ET com a realidade visto que muitas vezes apenas dados de temperatura estão disponíveis e se faz necessário calcular a evapotranspiração a partir do método de Hargreaves. Os parâmetros obtidos na calibração do modelo usando a equação de Hargreaves, são substituídos na simulação com a equação de Hargreaves junto com um ajuste nos valores de temperatura, fazendo com a diferença nos valores de evapotranspiração sejam reduzidas. As diferenças entre os valores de Hargreaves e Hargreaves variam de 20 a 4% com o volume evaporado por Hargreaves sendo sempre superior. Após a aplicação do método estas diferenças caem para em média 2%.

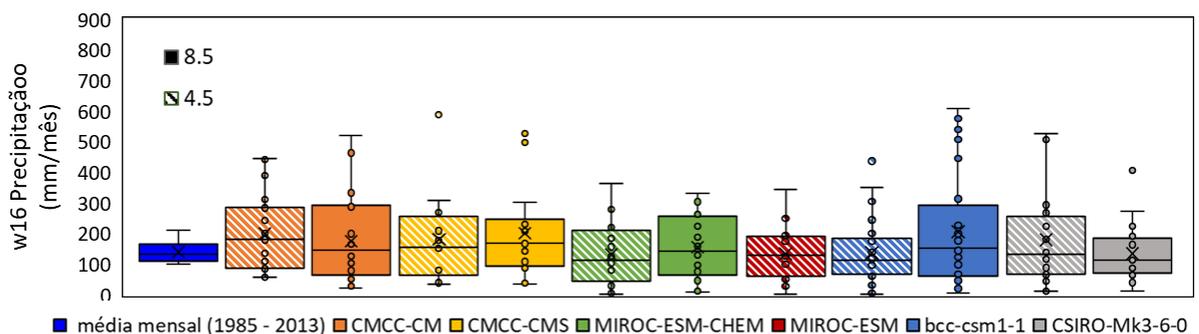
A Figura 20 apresenta dos dados de precipitação para os dois cenários futuros nas bacias hidrográficas das Almas (Figura 20(a)) e Itajaí-Açu (Figura 20(b)). O *boxplot* mais à esquerda do gráfico representa os valores médios mensais para o período de 1980 – 2013 e o restante são referentes aos seis GCMs combinando os períodos 2070 e 2071. Os seis modelos geram uma propagação semelhante em termos de mudança nos valores máximos e mínimos de chuva, e possuem uma mediana próxima aos valores da série histórica (1980-2013). Geralmente os modelos que apresentam menor variação na chuva mensal são o CSIRO-Mk3-6-0 para o rcp8.5, e o pacote MIROC para ambos os cenários. A família CMCC, principalmente o CMCC-CC para o cenário rcp4.5 apresentou a maior mediana, e o CSIRO-Mk3-6-0 para o rcp4.5 menor mediana, na maioria dos casos.

Figura 20 - Precipitação para os cenários rcp4.5 e rcp8.5 e para os modelos escolhidos nas bacias hidrográficas das Almas e Itajaí-Açu. O resultado para o restante das bacias estudadas pode ser encontrado no Apêndice D.

(a)

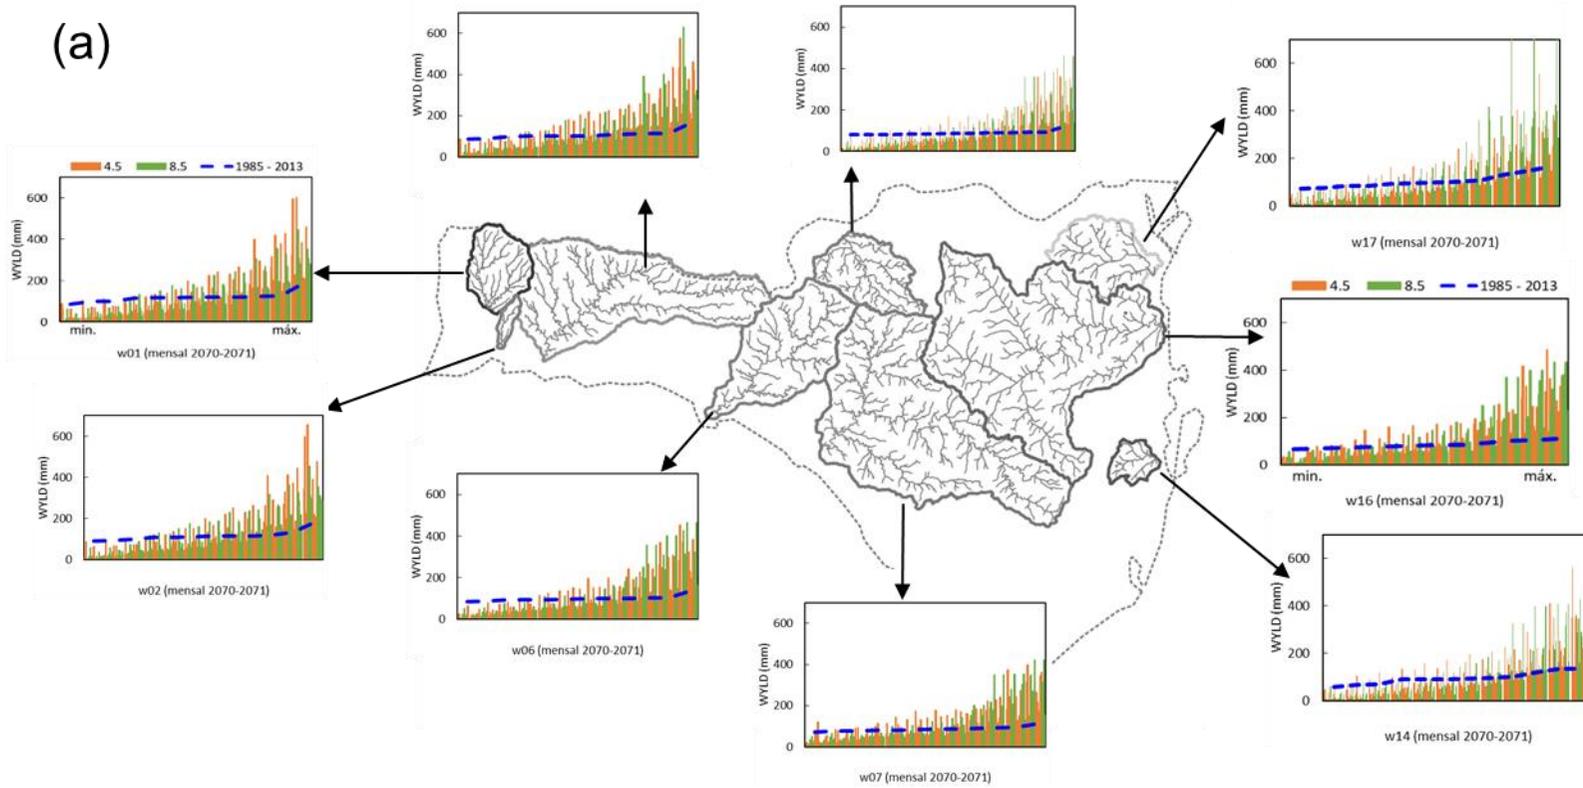


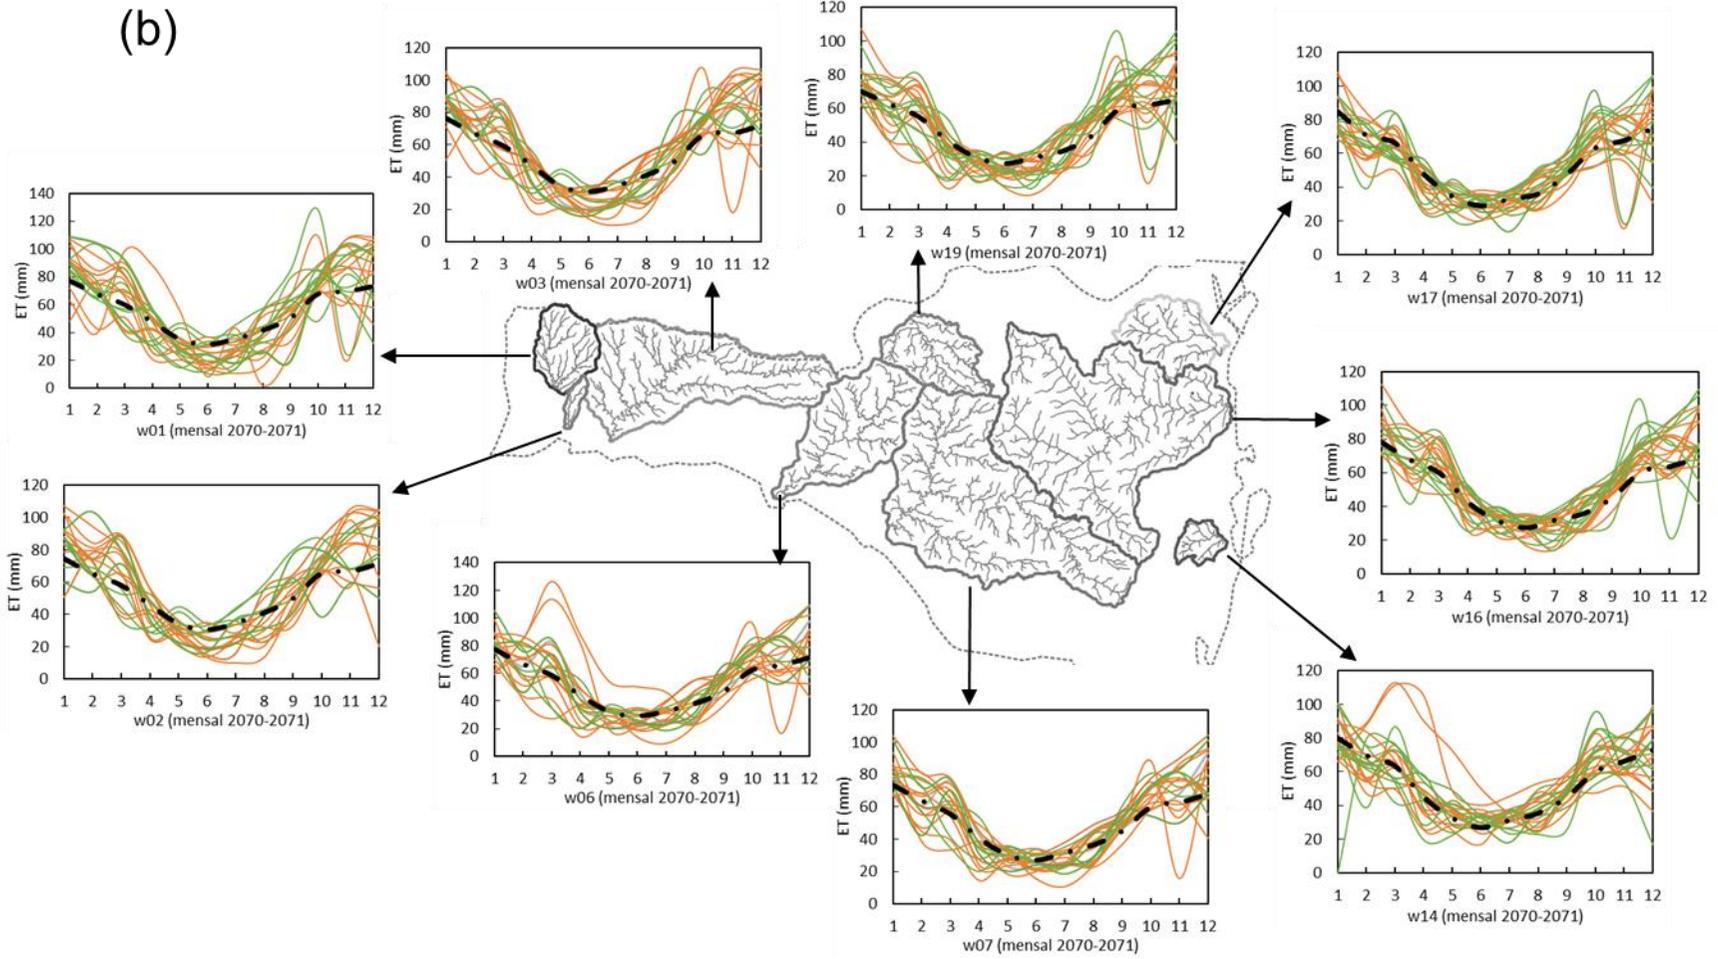
(b)



A fim de obter uma ideia geral do regime hidrológico futuro, particularmente para WYLD a ET, os dados de GCM (precipitação e temperatura) foram aplicados para as bacias hidrográficas analisadas em simulações com o modelo SWAT corrigido para evapotranspiração. O uso das projeções causou impactos diretos nas quantidades estimadas de produção de água e evapotranspiração (Figura 21).

Figura 21 - Valores para a produção de água (a) e evapotranspiração (b) para as bacias hidrográficas estudadas. As linhas tracejadas representam os valores médios para os dados observados (1985-2013), as linhas e colunas em cor laranja são para o cenário rcp4.5 e as em cor verde ao cenário rcp 8.5.





Os resultados das simulações apontam que, para qualquer um dos dois cenários avaliados (rcp4.5 e rcp 8.5), o WYLD tem um aumento dos volumes máximos de água disponível para as bacias, quando comparados com a média mensal para os 29 anos de simulações (1985 – 2013). Esses resultados apontam que a produção de água aumentará significativamente durante a estação úmida e diminuirá ligeiramente durante a estação seca.

A evapotranspiração em média, mantém o mesmo padrão de sazonalidade observado durante a série histórica, com maiores taxas de evaporação durante o verão e primavera, e menores taxas durante o inverno e outono. Para as bacias das Almas, Iracema e Chapecó existe uma tendência na diminuição da quantidade de água evaporada para os meses mais frios (abril – agosto), em ambas as projeções. No geral, as alterações na evapotranspiração foram menos significativas em comparação com outros componentes analisados, o que consistente com outros trabalhos como Tan et al., (2017). Como as mudanças no uso da terra não foram consideradas neste estudo, acreditasse que as mudanças na evapotranspiração da bacia sejam amplificadas, por exemplo, se a expansão agropecuária e urbana continuar ocorrendo de forma não regulada.

5 CONCLUSÃO

Neste estudo, o cálculo das variáveis hidrológicas em nove bacias do estado de Santa Catarina foi realizado a partir do uso combinado entre modelo SWAT e modelos de clima, e a disponibilidade hídrica pode ser traduzida pela variável produção de água (WYLD). A abordagem foi baseada na identificação da resolução ideal para a chuva de entrada, calibração e validação do modelo SWAT, seleção dos GCMs utilizados nos cenários futuros, correção da evapotranspiração, e integração do SWAT (parâmetros calibrados) com os GCMs (dados de precipitação e temperatura).

A investigação da resolução espacial dos dados de chuva e sua influência na resposta hidrológica do modelo SWAT, foi realizada a partir da análise de quatro grades interpoladas (5 km, 10 km, 30 km, 90 km), junto com o arranjo original das estações de chuva. Os resultados apontam para duas conclusões principais. A primeira, é que para a análise total de um período de 29 anos em escala mensal, a resolução de 90 km, apresentou uma média satisfatória dos resultados ($KGE \geq 0,5$). O segundo ponto, analisa os resultados frente a três condições distintas, ano seco, úmido e médio. O detalhamento da rede de chuva se faz necessário quando períodos mais secos são analisados, com a grade 5 km apresentando os melhores resultados na maioria dos casos.

A calibração do modelo foi realizada para dois cenários, que contêm um total de sete condições iniciais. Quatro, referem-se as modificações que são feitas nos dados de chuva (arranjo original, 5 km, 10 km, 30 km, 90 km), e dois ao uso de métodos distintos no cálculo da evapotranspiração potencial (Hargreaves e Penman-Monteith). Para a chuva, o modelo apresentou três conjuntos diferentes de parâmetros, um que representa o arranjo original, outro que representa o modelo para as grades 5 km, 10 km e 30 km, e um último para a grade 90 km. Os resultados não apresentam diferença significativa entre arranjo original, 5 km, 10 km e 30 km, e a grade 90 km apresentou o pior desempenho. Para a modificação no cálculo da evapotranspiração, cada método apresenta um conjunto distinto de parâmetros, porém, em termos de eficiência (e.g. KGE), os resultados são similares. Na validação, as simulações que utilizam a equação de Penman-Monteith apresentam num conjunto total, melhores resultados. Como esperado, o modelo SWAT é menos sensível ao processo de evapotranspiração em escala mensal que a precipitação nas estimativas do balanço hídrico.

Para a representação das condições futuras de precipitação e temperatura no estado de Santa Catarina, foram selecionados oito GCMs de um total de 22 modelos analisados. O critério de seleção foi uma diferença menor que 50% entre as distribuições estatísticas dos dados observados e a rodada histórica de cada um dos GCMs. Quando avaliado a eficiência entre os dados dos modelos corrigidos pelo método do *Distribution Mapping* e dados brutos, os dados corrigidos mostram melhora significativa na representação das séries históricas. O uso dos dados brutos gera subestimação nos valores de precipitação, produção de água e evapotranspiração nas bacias estudadas. Embora existam diferenças entre os dados brutos e corrigidos, estes apresentam a mesma relação de aumento ou diminuição do volume de chuva em relação à média anual observada.

A correção da evapotranspiração foi passo anterior a aplicação conjunta do modelo SWAT com os GCMs, e mostrou-se ferramenta importante quando apenas dados de temperatura estão disponíveis para simulações futuras. O método é simples e baseado nas diferenças existentes entre as equações de Hargreaves e Penman-Monteith para as simulações das séries históricas de cada bacia hidrográfica analisada. Os resultados do experimento de simulações de cenário futuro apontam que a produção de água aumentará significativamente durante a estação úmida e diminuirá durante a estação seca. Para a confirmação desta tendência, as simulações devem ser extrapoladas para uma maior série de dados.

No geral, este estudo forneceu uma metodologia para obtenção de informações significativas sobre a disponibilidade de água, presente e futura, no nível regional, com um intervalo de tempo mensal. Essas informações são muito úteis para o desenvolvimento de uma visão geral do *status* real dos recursos hídricos na região. As incertezas têm papel importante neste tipo de estudo e devem ser abordadas mais detalhadamente quando o objetivo final for a utilização dos resultados em projetos envolvendo políticas públicas e análises impactos. Além disso, afim de validar algumas conclusões e dar continuidade ao estudo, algumas recomendações são sugeridas: (a) análise dos resultados em escala de tempo diária e sazonal; (b) ampliação da série analisada para as projeções futuras; (c) isolar as variáveis temperatura e precipitação nos cenários futuros, com o intuito de identificar suas respectivas influencias na resposta hidrológica da bacia; (d) modificação do uso da terra para os cenários futuros.

REFERÊNCIAS

- Abbaspour, K.C., Faramarzi, M., Ghasemi, S.S., Yang, H., 2009. Assessing the impact of climate change on water resources in Iran. *Water Resour. Res.* 45, 1–16. <https://doi.org/10.1029/2008WR007615>
- Abbaspour, K.C., Johnson, C. a., van Genuchten, M.T., 2004. Estimating Uncertain Flow and Transport Parameters Using a Sequential Uncertainty Fitting Procedure. *Vadose Zo. J.* 3, 1340. <https://doi.org/10.2136/vzj2004.1340>
- Abbaspour, K.C., Rouholahnejad, E., Vaghefi, S., Srinivasan, R., Yang, H., Kløve, B., 2015. A Continental-Scale Hydrology and Water Quality Model for Europe: Calibration and uncertainty of a high-resolution large-scale SWAT model. *J. Hydrol.* 524, 733–752. <https://doi.org/10.1016/j.jhydrol.2015.03.027>
- Abbaspour, K.C., Vejdani, M., Haghghat, S., Yang, J., 2007. SWAT-CUP Calibration and Uncertainty Programs for SWAT. fourth Int. SWAT Conf. 1596–1602. <https://doi.org/10.1007/s00402-009-1032-4>
- Ahrens, B., Beck, A., 2008. On upscaling of rain-gauge data for evaluating numerical weather forecasts. *Meteorol. Atmos. Phys.* 99, 155–167. <https://doi.org/10.1007/s00703-007-0261-8>
- Andréassian, V., 2005. Trois énigmes de modélisation hydrologique Three riddles in hydrological modeling.
- Arnold, J.G., Moriasi, D.N., Gassman, P.W., Abbaspour, K.C., White, M.J., Srinivasan, R., Santhi, C., Harmel, R.D., Griensven, a. Van, VanLiew, M.W., Kannan, N., Jha, M.K., 2012. Swat: Model Use, Calibration, and Validation. *Trans. ASABE* 55, 1491–1508.
- Asadzadeh, M., Leon, L., Yang, W., Bosch, D., 2016. One-day offset in daily hydrologic modeling: An exploration of the issue in automatic model calibration. *J. Hydrol.* 534, 164–177. <https://doi.org/10.1016/j.jhydrol.2015.12.056>
- Bailey, R.T., Wible, T.C., Arabi, M., Records, R.M., Ditty, J., 2016. Assessing regional-scale spatio-temporal patterns of groundwater – surface water interactions using a coupled SWAT-MODFLOW model. *Hydrol. Process.* 30, 4420–4433. <https://doi.org/10.1002/hyp.10933>
- Bartiko, D., Luiz, Chaffe, P.L.B., Bonumá, N.B., 2017. Nonstationarity in maximum annual daily streamflow series from Southern Brazil. *Rev. Bras. Recur. Hidricos* 22. <https://doi.org/http://dx.doi.org/10.1590/2318-0331.0217170054>

- Bartiko, D., Oliveira, D.Y., Bonumá, N.B., Chaffe, P.L.B., 2019. Spatial and seasonal patterns of flood change across Brazil. *Hydrol. Sci. J.* 64, 1071–1079. <https://doi.org/10.1080/02626667.2019.1619081>
- Bekele, E.G., Knapp, H.V., 2010. Watershed Modeling to Assessing Impacts of Potential Climate Change on Water Supply Availability. *Water Resour. Manag.* 24, 3299–3320. <https://doi.org/10.1007/s11269-010-9607-y>
- Beven, K., 2006. A manifesto for the equifinality thesis. *J. Hydrol.* 320, 18–36. <https://doi.org/10.1016/j.jhydrol.2005.07.007>
- Beven, K., Binley, A., 1992. The future of distributed models: Model Calibration and Uncertainty Prediction. *Hydrol. Process.* 6, 279–298.
- Beven, K.J., Alcock, R.E., 2012. Modelling everything everywhere: A new approach to decision-making for water management under uncertainty. *Freshw. Biol.* 57, 124–132. <https://doi.org/10.1111/j.1365-2427.2011.02592.x>
- Bieger, K., Arnold, J.G., Rathjens, H., White, M.J., Bosch, D.D., Allen, P.M., Volk, M., Srinivasan, R., 2017. INTRODUCTION TO SWAT + , A COMPLETELY RESTRUCTURED VERSION OF THE SOIL AND WATER ASSESSMENT TOOL 1. *J. Am. Water Resour. Assoc.* 53, 115–130. <https://doi.org/10.1111/1752-1688.12482>
- Bilondi, M.P., Abbaspour, K.C., Ghahraman, B., 2013. Application of three different calibration-uncertainty analysis methods in a semi-distributed rainfall-runoff model application. *Middle-East J. Sci. Res.* 15, 1255–1263. <https://doi.org/10.5829/idosi.mejsr.2013.15.9.11470>
- Bonumá, N.B., Reichert, J.M., Rodrigues, M.F., Monteiro, J.A.F., Arnold, J.G., Srinivasan, R., 2015. Modeling surface hydrology, soil erosion, nutrient transport, and future scenarios with the ecohydrological swat model in brazilian watersheds and river basins. *Tópicos em Ciência do Solo - Vol. IX* 9, 241–290.
- Borges, P. de A., Chaffe, P.L.B., 2019. Integrating climate models into hydrological modelling: What 's going on in Brazil? *Rev. Bras. Recur. Hidricos* 24, 1–17. <https://doi.org/https://doi.org/10.1590/2318-0331.241920180176>
- Boutt, D., Iroume, A., 2017. Preface for the South American Hydrology Virtual Special Issue 1–5. <https://doi.org/10.1002/hyp.11166>
- Boyle, D.P., Gupta, H. V., Sorooshian, S., 2000. Toward improved calibration of hydrologic models: Combining the strengths of manual and automatic methods. *Water Resour. Res.* 36, 3663–3674. <https://doi.org/10.1029/2000WR900207>

- Bressiani, D. de A., Gassman, P.W., Fernandes, J.G., Garbossa, L.H.P., Srinivasan, R., Bonumá, N.B., Mendiondo, E.M., 2015. A review of soil and water assessment tool (SWAT) applications in Brazil: Challenges and prospects. *Int. J. Agric. Biol. Eng.* 8, 1–27. <https://doi.org/10.3965/j.ijabe.20150803.1765>
- Brighenti, T.M., Bonumá, N.B., Chaffe, P.L.B., 2016. Hierarchical calibration of swat model for a watershed in Southern Brazil. *Rev. Bras. Recur. Hidricos* 21. <https://doi.org/10.21168/rbrh.v21n1.p53-64>
- Brighenti, T.M., Bonumá, N.B., Grison, F., Mota, A. de A., Kobiyama, M., Chaffe, P.L.B., 2019a. Two calibration methods for modeling stream flow and suspended sediment with the swat model. *Ecol. Eng.* 127, 103–113. <https://doi.org/10.1016/j.ecoleng.2018.11.007>
- Brighenti, T.M., Bonumá, N.B., Srinivasan, R., Chaffe, P.L.B., 2019b. Simulating sub-daily hydrological process with SWAT: a review. *Hydrol. Sci. J.* Published. <https://doi.org/10.1080/02626667.2019.1642477>
- Brigode, P., Bernardara, P., Paquet, E., Gailhard, J., Garavaglia, F., Merz, R., Mičovič, Z., Lawrence, D., Ribstein, P., 2014. Sensitivity analysis of SCHADEX extreme flood estimations to observed hydrometeorological variability. *Water Resour. Res.* 50, 353–370. <https://doi.org/10.1002/2013WR013687>
- Chagas, V.B.P., Chaffe, P.L.B., 2018. The Role of Land Cover in the Propagation of Rainfall Into Streamflow Trends. *Water Resour. Res.* 54, 5986–6004. <https://doi.org/10.1029/2018WR022947>
- Chen, J., Brissette, F.P., Lucas-Picher, P., Caya, D., 2017. Impacts of weighting climate models for hydro-meteorological climate change studies. *J. Hydrol.* 549, 534–546. <https://doi.org/10.1016/j.jhydrol.2017.04.025>
- Clark, M.P., Wilby, R.L., Gutmann, E.D., Vano, J.A., Gangopadhyay, S., Wood, A.W., Fowler, H.J., Prudhomme, C., Arnold, J.R., Brekke, L.D., 2016. Characterizing Uncertainty of the Hydrologic Impacts of Climate Change. *Curr. Clim. Chang. Reports* 2, 55–64. <https://doi.org/10.1007/s40641-016-0034-x>
- Daggupati, P., Deb, D., Srinivasan, R., Yeganantham, D., Mehta, V.M., Rosenberg, N.J., 2016. Large-Scale Fine-Resolution Hydrological Modeling Using Parameter Regionalization in the Missouri River Basin. *J. Am. Water Resour. Assoc.* 52, 648–666. <https://doi.org/10.1111/1752-1688.12413>
- Daggupati, P., Pai, N., Ale, S., Douglas-Mankin, K.R., Zeckoski, R.W., Jeong, J., Parajuli,

- P.B., Saraswat, D., Youssef, M.A., 2015. A Recommended Calibration and Validation Strategy for Hydrologic and Water Quality Models. *Trans. ASABE* 58, 1705–1719. <https://doi.org/10.13031/trans.58.10712>
- Dams, J., Nossent, J., Senbeta, T.B., Willems, P., Batelaan, O., 2015. Multi-model approach to assess the impact of climate change on runoff. *J. Hydrol.* 529, 1601–1616. <https://doi.org/10.1016/j.jhydrol.2015.08.023>
- Easton, Z.M., Fuka, D.R., Walter, M.T., Cowan, D.M., Schneiderman, E.M., Steenhuis, T.S., 2008. Re-conceptualizing the soil and water assessment tool (SWAT) model to predict runoff from variable source areas 279–291. <https://doi.org/10.1016/j.jhydrol.2007.10.008>
- Emmanuel, I., Andrieu, H., Leblois, E., Janey, N., Payrastre, O., 2015. Influence of rainfall spatial variability on rainfall-runoff modelling: Benefit of a simulation approach? *J. Hydrol.* 531, 337–348. <https://doi.org/10.1016/j.jhydrol.2015.04.058>
- Fenicia, F., Savenije, H.H.G., Matgen, P., Pfister, L., 2006. Is the groundwater reservoir linear? Learning from data in hydrological modelling. *Hydrol. Earth Syst. Sci. Discuss.* 10, 139–150. <https://doi.org/10.5194/hessd-2-1717-2005>
- Folton, N., Andréassian, V., Duperray, R., 2015. Hydrological impact of forest-fire from paired-catchment and rainfall–runoff modelling perspectives. *Hydrol. Sci. J.* 60, 1213–1224. <https://doi.org/10.1080/02626667.2015.1035274>
- Franco, A.C.L., Bonumá, N.B., 2017. Multi-variable SWAT model calibration with remotely sensed evapotranspiration and observed flow. *Rev. Bras. Recur. Hidricos* 22. <https://doi.org/http://dx.doi.org/10.1590/2318-0331.011716090>
- Garee, K., Chen, X., Bao, A., Wang, Y., Meng, F., 2017. Hydrological Modeling of the Upper Indus Basin: A Case Study from a High-Altitude Glacierized Catchment Hunza. *Water* 9, 17. <https://doi.org/10.3390/w9010017>
- Gassman, P.P.W., Reyes, M.M.R., Green, C.C.H., Arnold, J.J.G., 2007. The Soil and Water Assessment Tool: historical development, applications, and future research directions. *Trans. ASAE* 50, 1211–1250. <https://doi.org/10.1.1.88.6554>
- Gassman, P.W., Sadeghi, A.M., Srinivasan, R., 2014. Applications of the SWAT Model Special Section: Overview and Insights. *J. Environ. Qual.* 43, 1. <https://doi.org/10.2134/jeq2013.11.0466>
- Grusson, Y., Anctil, F., Sauvage, S., Pérez, J.M.S., 2017. Testing the SWAT Model with Gridded Weather Data of Different Spatial Resolutions. *Water* 9. <https://doi.org/10.3390/w9010054>

- Grusson, Y., Sun, X., Gascoïn, S., Sauvage, S., Raghavan, S., Anctil, F., Sáchez-Pérez, J.M., 2015. Assessing the capability of the SWAT model to simulate snow, snow melt and streamflow dynamics over an alpine watershed. *J. Hydrol.* 531, 574–588. <https://doi.org/10.1016/j.jhydrol.2015.10.070>
- Gupta, H.V., Sorooshian, S., Yapo, P.O., 1999. STATUS OF AUTOMATIC CALIBRATION FOR HYDROLOGIC MODELS: COMPARISON WITH MULTILEVEL EXPERT CALIBRATION. *J. Hydrol. Eng.* 135–143. <https://doi.org/10.1002/fut.20174>
- Gupta, H.V., Sorooshian, S., Yapo, P.O., 1998. Toward improved calibration of hydrologic models: Multiple and noncommensurable measures of information. *Water Resour. Res.* 34, 751–763. <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. *J. Hydrol.* 377, 80–91. <https://doi.org/10.1016/j.jhydrol.2009.08.003>
- Guse, B., Pfannerstill, M., Gafurov, A., Kiesel, J., Lehr, C., Fohrer, N., 2017. Identifying the connective strength between model parameters and performance criteria. *Hydrol. Earth Syst. Sci. Discuss.* 1–30. <https://doi.org/10.5194/hess-2017-28>
- Habte, K., Mamo, M., Jain, M.K., 2013. Runoff and Sediment Modeling Using SWAT in Gumera Catchment, Ethiopia. *Open J. Mod. Hydrol.* 2013, 196–205. <https://doi.org/10.4236/ojmh.2013.34024>
- Hall, B.J.W., Grey, D., Garrick, D., Fung, F., Brown, C., Dadson, S.J., 2014. Coping with the curse of freshwater variability. *Science (80-.)*. 346, 429–430.
- Harmel, R.D., Cooper, R.J., Slade, R.M., Haney, R.L., Arnold, J.G., 2006. Cumulative Uncertainty in Measured Streamflow and Water Quality Data for Small Watersheds. *Asabe* 49, 689–701.
- Harmel, R.D., Smith, P.K., 2007. Consideration of measurement uncertainty in the evaluation of goodness-of-fit in hydrologic and water quality modeling. *J. Hydrol.* 337, 326–336. <https://doi.org/10.1016/j.jhydrol.2007.01.043>
- Hewitson, B., Janetos, A.C., Carter, T.R., Giorgi, F., Jones, R.G., Kwon, W.-T., Mearns, L.O., Schipper, E.L.F., van Aalst, M., 2014. Regional Context. *Clim. Chang.* 2014 Impacts, Adapt. Vulnerability. Part A Glob. Sect. Asp. Contrib. Work. Gr. II to Fifth Assess. Rep. Intergov. Panel Clim. Chang. 1133–1197. <https://doi.org/10.1017/CBO9781107415386.001>

- Idhayachandhiran, I., Meter, K. Van, Nandita, B., 2019. A Race against Time : Modelling Time Lags in Watershed Response. *Water Resour. Res.* <https://doi.org/10.1029/2018WR023815>
- IPCC, 2014. *Climate Change 2014 Synthesis Report*.
- Jeong, J., Kannan, N., Arnold, J., Glick, R., Gosselink, L., Srinivasan, R., 2010. Development and Integration of Sub-hourly Rainfall-Runoff Modeling Capability Within a Watershed Model. *Water Resour. Manag.* 24, 4505–4527. <https://doi.org/10.1007/s11269-010-9670-4>
- Jha, M.K., Gassman, P.W., Panagopoulos, Y., 2013. Regional changes in nitrate loadings in the Upper Mississippi River Basin under predicted mid-century climate. *Reg. Environ. Chang.* 15, 449–460. <https://doi.org/10.1007/s10113-013-0539-y>
- Kampf, S.K., Burges, S.J., 2010. Quantifying the water balance in a planar hillslope plot: Effects of measurement errors on flow prediction. *J. Hydrol.* 380, 191–202. <https://doi.org/10.1016/j.jhydrol.2009.10.036>
- Kayastha, N., Ye, J., Fenicia, F., Kuzmin, V., Solomatine, D.P., 2013. Fuzzy committees of specialized rainfall-runoff models: Further enhancements and tests. *Hydrol. Earth Syst. Sci.* 17, 4441–4451. <https://doi.org/10.5194/hess-17-4441-2013>
- Kim, C., Kim, D.-H., 2018. Effect of rainfall spatial distribution and duration on minimum spatial resolution of rainfall data for accurate surface runoff prediction. *J. Hydro-environment Res.* 10, 1–8. <https://doi.org/https://doi.org/10.1016/j.jher.2018.04.001>
- Kirchner, J.W., 2006. Getting the right answers for the right reasons: Linking measurements, analyses, and models to advance the science of hydrology. *Water Resour. Res.* 42, 1–5. <https://doi.org/10.1029/2005WR004362>
- Klemeš, V., 1986. Operational testing of hydrological simulation models. *Hydrol. Sci. J.* 31, 13–24. <https://doi.org/10.1080/02626668609491024>
- Knutti, R., Masson, D., Gettelman, A., 2013. Climate model genealogy: Generation CMIP5 and how we got there. *Geophys. Res. Lett.* 40, 1194–1199. <https://doi.org/10.1002/grl.50256>
- Kollat, J.B., Reed, P.M., Wagener, T., 2012. When are multiobjective calibration trade-offs in hydrologic models meaningful? *Water Resour. Res.* 48, 1–19. <https://doi.org/10.1029/2011WR011534>
- Krysanova, V., Arnold, J.G., 2008. Advances in ecohydrological modelling with SWAT—a review. *Hydrol. Sci. J.* 53, 939–947. <https://doi.org/10.1623/hysj.53.5.939>

- Krysanova, V., Mu, D., Becker, A., 1998. Development and test of a spatially distributed hydrological / water quality model for mesoscale watersheds 106, 261–289.
- Krysanova, V., Srinivasan, R., 2015. Assessment of climate and land use change impacts with SWAT. *Reg. Environ. Chang.* 15, 431–434. <https://doi.org/10.1007/s10113-014-0742-5>
- Krysanova, V., White, M., 2015. Advances in water resources assessment with SWAT—an overview *Advances in water resources assessment with SWAT—an overview* (in press). *Hydrol. Sci. J.* 60, 771–783.
- Kundu, S., Khare, D., Mondal, A., 2017. Individual and combined impacts of future climate and land use changes on the water balance. *Ecol. Eng.* 105, 42–57. <https://doi.org/10.1016/j.ecoleng.2017.04.061>
- Liew, M.W. Van, Veith, T.L., Bosch, D.D., Arnold, J.G., 2007. Suitability of SWAT for the Conservation Effects Assessment Project : Comparison on USDA Agricultural Research Service Watersheds. *J. Hydrol. Eng.* 12, 173–189.
- Lobligeois, F., Andréassian, V., Perrin, C., Tabary, P., Loumagne, C., 2014. When does higher spatial resolution rainfall information improve streamflow simulation? An evaluation using 3620 flood events. *Hydrol. Earth Syst. Sci.* 18, 575–594. <https://doi.org/10.5194/hess-18-575-2014>
- Ly, S., Charles, C., Degré, A., 2013. Different methods for spatial interpolation of rainfall data for operational hydrology and hydrological modeling at watershed scale: a review. *Biotechnol. Agron. Société Environ.* 17, 392–406.
- Magand, C., Ducharne, A., Le Moine, N., Brigode, P., 2015. Parameter transferability under changing climate: case study with a land surface model in the Durance watershed, France. *Hydrol. Sci. J.* 6667, 141217125340005. <https://doi.org/10.1080/02626667.2014.993643>
- Maraun, D., Widmann, M., Gutiérrez, J.M., Kotlarski, S., Chandler, R.E., Hertig, E., Wibig, J., Huth, R., Wilcke, R.A.I., 2015. VALUE: A framework to validate downscaling approaches for climate change studies. *Earth's Futur.* 3, 1–14. <https://doi.org/10.1002/2014EF000259>
- Marengo, J.A., 2008. Water and Climate Change. *Estud. avançados* 22, 83–96.
- McIntyre, N.R., Wheater, H.S., 2004. Calibration of an in-river phosphorus model: Prior evaluation of data needs and model uncertainty. *J. Hydrol.* 290, 100–116. <https://doi.org/10.1016/j.jhydrol.2003.12.003>

- Meaurio, M., Zabaleta, A., Boithias, L., Epelde, A.M., Sauvage, S., Sánchez-Pérez, J.-M., Srinivasan, R., Antiguada, I., 2017. Assessing the hydrological response from an ensemble of CMIP5 climate projections in the transition zone of the Atlantic region (Bay of Biscay). *J. Hydrol.* 548, 46–62. <https://doi.org/10.1016/j.jhydrol.2017.02.029>
- Mehta, V.M., Mendoza, K., Daggupati, P., Srinivasan, R., Rosenberg, N.J., Deb, D., 2016. High-Resolution Simulations of Decadal Climate Variability Impacts on Water Yield in the Missouri River Basin with the Soil and Water Assessment Tool (SWAT). *J. Hydrometeorol.* 17, 2455–2476. <https://doi.org/10.1175/JHM-D-15-0039.1>
- Monteiro, J.A.F., Strauch, M., Srinivasan, R., Abbaspour, K., Gücker, B., 2016. Accuracy of grid precipitation data for Brazil: Application in river discharge modelling of the Tocantins catchment. *Hydrol. Process.* 30, 1419–1430. <https://doi.org/10.1002/hyp.10708>
- Moriasi, D.N., Arnold, J.G., Van Liew, M.W., Binger, R.L., Harmel, R.D., Veith, T.L., 2007. Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Trans. ASABE* 50, 885–900. <https://doi.org/10.13031/2013.23153>
- Nash, J.E., Sutcliffe, J. V., 1970. River flow forecasting through conceptual models part I - A discussion of principles. *J. Hydrol.* 10, 282–290. [https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6)
- Nicolle, P., Pushpalatha, R., Perrin, C., François, D., Thiéry, D., Mathevet, T., Le Lay, M., Besson, F., Soubeyroux, J.M., Viel, C., Regimbeau, F., Andréassian, V., Maugis, P., Augeard, B., Morice, E., 2014. Benchmarking hydrological models for low-flow simulation and forecasting on French catchments. *Hydrol. Earth Syst. Sci.* 18, 2829–2857. <https://doi.org/10.5194/hess-18-2829-2014>
- Nicótina, L., Alessi Celegon, E., Rinaldo, A., Marani, M., 2008. On the impact of rainfall patterns on the hydrologic response. *Water Resour. Res.* 44, 1–14. <https://doi.org/10.1029/2007WR006654>
- Osei, M.A., Amekudzi, L.K., Wemegah, D.D., Preko, K., Gyawu, E.S., Obiri-danso, K., 2018. Hydro-Climatic Modelling of an Ungauged Basin in Kumasi , Ghana. *Hydrol. Earth Syst. Sci. Discuss.* 1–21.
- Osuch, M., Romanowicz, R.J., Booij, M.J., 2015. The influence of parametric uncertainty on the relationships between HBV model parameters and climatic characteristics. *Hydrol. Sci. J.* 60, 1299–1316. <https://doi.org/10.1080/02626667.2014.967694>
- Oudin, L., Hervieu, F., Michel, C., Perrin, C., Andreassian, V., Anctil, F., Loumagne, C.,

2005. Which potential evapotranspiration input for a lumped rainfall – runoff model ? Part 2 — Towards a simple and efficient potential evapotranspiration model for rainfall – runoff modelling. *J. Hydrol.* 303, 290–306. <https://doi.org/10.1016/j.jhydrol.2004.08.026>
- Pilgrim, D.H., Chapman, T.G., Doran, D.G., 1988. Problems of rainfall-runoff modelling in arid and semiarid regions. *Hydrol. Sci. J.* 33, 379–400. <https://doi.org/10.1080/02626668809491261>
- Price, K., Purucker, S.T., Kraemer, S.R., Babendreier, J.E., 2012. Tradeoffs among watershed model calibration targets for parameter estimation. *Water Resour. Res.* 48, 1–16. <https://doi.org/10.1029/2012WR012005>
- Rahbeh, M., Chanasyk, D., Miller, J., 2011. Two-Way Calibration-Validation of SWAT Model for a Small Prairie Watershed with Short Observed Record. *Can. Water Resour. J.* 36, 247–270. <https://doi.org/10.4296/cwrj3603884>
- Raneesh, K.Y., Thampi Santosh, G., 2011. A study on the impact of climate change on streamflow at the watershed scale in the humid tropics. *Hydrol. Sci. J.* 56, 946–965. <https://doi.org/10.1080/02626667.2011.595371>
- Rathjens, H., Bieger, K., Srinivasan, R., Arnold, J.G., 2016. CMhyd User Manual Documentation for preparing simulated climate change data for hydrologic impact studies.
- Rathjens, H., Oppelt, N., 2012a. SWAT model calibration of a grid-based setup. *Adv. Geosci.* 32, 55–61. <https://doi.org/10.5194/adgeo-32-55-2012>
- Rathjens, H., Oppelt, N., 2012b. SWATgrid : An interface for setting up SWAT in a grid-based discretization scheme. *Comput. Geosci.* 45, 161–167. <https://doi.org/10.1016/j.cageo.2011.11.004>
- Rathjens, H., Oppelt, N., Bosch, D.D., Arnold, J.G., Volk, M., 2014. Development of a grid-based version of the SWAT landscape model. *Hydrol. Process.* <https://doi.org/10.1002/hyp.10197>
- Ritter, A., Muñoz-Carpena, R., 2013. Performance evaluation of hydrological models: Statistical significance for reducing subjectivity in goodness-of-fit assessments. *J. Hydrol.* 480, 33–45. <https://doi.org/10.1016/j.jhydrol.2012.12.004>
- Rouholahnejad, E., Abbaspour, K.C., Srinivasan, R., Bacu, V., Lehmann, A., 2014. Water resources of the Black Sea Basin at high spatial and temporal resolution. *Water Resour. Res.* 50, (7):5866-5885. <https://doi.org/10.1002/2013WR014132>.Received

- Rouholahnejad, E., Abbaspour, K.C., Vejdani, M., Srinivasan, R., Schulin, R., Lehmann, A., 2012. A parallelization framework for calibration of hydrological models. *Environ. Model. Softw.* 31, 28–36. <https://doi.org/10.1016/j.envsoft.2011.12.001>
- Saurral, R.I., Barros, V.R., Lettenmaier, D.P., 2008. Land use impact on the Uruguay River discharge. *Geophys. Res. Lett.* 35, 1–6. <https://doi.org/10.1029/2008GL033707>
- Schaefli, B., Gupta, H. V., 2007. Do Nash values have value? *Bettina. Hydrol. Process.* 21, 2075–2080. <https://doi.org/10.1002/hyp>
- Shepard, D., 1968. A two-dimensional interpolation function for irregularly-spaced data, in: *Proceedings of the 1968 23rd ACM National Conference.*
- Shrestha, B., Cochrane, T.A., Caruso, B.S., Arias, M.E., Piman, T., 2016. Uncertainty in flow and sediment projections due to future climate scenarios for the 3S Rivers in the Mekong Basin. *J. Hydrol.* 540, 1088–1104. <https://doi.org/10.1016/j.jhydrol.2016.07.019>
- Sikorska, A.E., Seibert, J., 2018. Value of different precipitation data for flood prediction in an alpine catchment: A Bayesian approach. *J. Hydrol.* 556, 961–971. <https://doi.org/10.1016/j.jhydrol.2016.06.031>
- Stisen, S., Tumbo, M., 2015. Interpolation of daily raingauge data for hydrological modelling in data sparse regions using pattern information from satellite data. *Hydrol. Sci. J.* 60, 1911–1926. <https://doi.org/10.1080/02626667.2014.992789>
- Stryker, J., Wemple, B., Bomblies, A., 2017. Modeling sediment mobilization using a distributed hydrological model coupled with a bank stability model. *Water Resour. Res.* 53, 2051–2073. <https://doi.org/10.1002/2016WR019143>
- Tan, M.L., Ibrahim, A.L., Yusop, Z., Chua, V.P., Chan, N.W., 2017. Climate change impacts under CMIP5 RCP scenarios on water resources of the Kelantan River Basin, Malaysia. *Atmos. Res.* 189, 1–10. <https://doi.org/10.1016/j.atmosres.2017.01.008>
- Teutschbein, C., Seibert, J., 2013. Is bias correction of regional climate model (RCM) simulations possible for non-stationary conditions. *Hydrol. Earth Syst. Sci.* 17, 5061–5077. <https://doi.org/10.5194/hess-17-5061-2013>
- Teutschbein, C., Seibert, J., 2012. Bias correction of regional climate model simulations for hydrological climate-change impact studies: Review and evaluation of different methods. *J. Hydrol.* 456–457, 12–29. <https://doi.org/10.1016/j.jhydrol.2012.05.052>
- Tuo, Y., Duan, Z., Disse, M., Chiogna, G., 2016. Evaluation of precipitation input for SWAT modeling in Alpine catchment: A case study in the Adige river basin (Italy). *Sci. Total Environ.* 573, 66–82. <https://doi.org/10.1016/j.scitotenv.2016.08.034>

- Tuppad, P., Mankin, K.R.D., Lee, T., Srinivasan, R., Arnold, J.G., 2011. SOIL AND WATER ASSESSMENT TOOL (SWAT) HYDROLOGIC/WATER QUALITY MODEL: EXTENDED CAPABILITY AND WIDER ADOPTION. *Trans. ASABE* 54, 1677–1684.
- Vaghefi, A.S., Mousavi, S.J., Abbaspour, K.C., Srinivasan, R., Arnold, J.R., 2015. Integration of hydrologic and water allocation models in basin-scale water resources management considering crop pattern and climate change: Karkheh River Basin in Iran. *Reg. Environ. Chang.* 15, 475–484. <https://doi.org/10.1007/s10113-013-0573-9>
- Van Griensven, a., Meixner, T., Srinivasan, R., Grunwald, S., 2008. Fit-for-purpose analysis of uncertainty using split-sampling evaluations. *Hydrol. Sci. J.* 53, 1090–1103. <https://doi.org/10.1623/hysj.53.5.1090>
- Van Griensven, A., Bauwens, W., 2005. Application and evaluation of ESWAT on the Dender basin and the Wister Lake basin. *Hydrol. Process.* 838, 827–838. <https://doi.org/10.1002/hyp.5614>
- Van Griensven, A., Bauwens, W., 2001. Integral water quality modelling of catchments. *Water Sci. Technol.* 43, 321–328.
- van Griensven, A., Meixner, T., Grunwald, S., Bishop, T., Diluzio, M., Srinivasan, R., 2006. A global sensitivity analysis tool for the parameters of multi-variable catchment models. *J. Hydrol.* 324, 10–23. <https://doi.org/10.1016/j.jhydrol.2005.09.008>
- Van Griensven, A., Ndomba, P., Yalew, S., Kilonzo, F., 2012. Critical review of SWAT applications in the upper Nile basin countries. *Hydrol. Earth Syst. Sci.* 16, 3371–3381. <https://doi.org/10.5194/hess-16-3371-2012>
- Vrugt, J., Beven, K., 2016. Embracing Equifinality with Efficiency: Limits of Acceptability Sampling Using the DREAM_ABC. *J. Hydrol.* **, **.
- Wagner, P.D., Fiener, P., Wilken, F., Kumar, S., Schneider, K., 2012. Comparison and evaluation of spatial interpolation schemes for daily rainfall in data scarce regions. *J. Hydrol.* 464–465, 388–400. <https://doi.org/10.1016/j.jhydrol.2012.07.026>
- Wagner, P.D., Reichenau, T.G., Kumar, S., Schneider, K., 2015. Development of a new downscaling method for hydrologic assessment of climate change impacts in data scarce regions and its application in the Western Ghats, India. *Reg. Environ. Chang.* 15, 435–447. <https://doi.org/10.1007/s10113-013-0481-z>
- Wang, H., Chen, J., Xu, C., Chen, H., Guo, S., Xie, P., Li, X., 2019. Does the weighting of

- climate simulations result in a better quantification of hydrological impacts? *Hydrol. Earth Syst. Sci.* 23, 4033–4050.
- Wang, Q., Xu, Youpeng, Xu, Yu, Wu, L., Wang, Y., Han, L., 2018. Catena Spatial hydrological responses to land use and land cover changes in a typical catchment of the Yangtze River Delta region. *Catena* 170, 305–315. <https://doi.org/10.1016/j.catena.2018.06.022>
- Wang, W., Wang, D., Singh, V.P., Wang, Y., Wu, J., Wang, L., Zou, X., Liu, J., Zou, Y., He, R., 2018. Optimization of rainfall networks using information entropy and temporal variability analysis. *J. Hydrol.* 559, 136–155. <https://doi.org/10.1016/j.jhydrol.2018.02.010>
- Woldesenbet, T.A., Elagib, N.A., Ribbe, L., Heinrich, J., 2018. Catchment response to climate and land use changes in the Upper Blue Nile sub-basins, Ethiopia. *Sci. Total Environ.* 644, 193–206. <https://doi.org/10.1016/j.scitotenv.2018.06.198>
- Wood, E.F., Roundy, J.K., Troy, T.J., Beek, L.P.H. van, Bierkens, M.F.P., Blyth, E., Roo, A. de, Döll, P., Ek, M., Famiglietti, J., Gochis, D., Giesen, N. van de, Houser, P., Jaffé, P.R., Kollet, S., Lehner, B., Lettenmaier, D.P., Peters-Lidard, C., Sivapalan, M., Sheffield, J., Wade, A., Paul Whitehead, 2011. Hyperresolution global land surface modeling: Meeting a grand challenge for monitoring Earth’s terrestrial water. *Water Resour. Res.* 47, 1–10. <https://doi.org/10.1029/2010WR010090>
- Xavier, A.C., King, C.W., Scanlon, B.R., 2016. Daily gridded meteorological variables in Brazil (1980–2013). *Int. J. Climatol.* 36, 2644–2659. <https://doi.org/10.1002/joc.4518>
- Xu, C., 1999. Operational testing of a water balance model for predicting climate change impacts. *Agric. For. Meteorol.* 98–99, 295–304. [https://doi.org/10.1016/S0168-1923\(99\)00106-9](https://doi.org/10.1016/S0168-1923(99)00106-9)
- Yang, J., Reichert, P., Abbaspour, K.C., 2007. Bayesian uncertainty analysis in distributed hydrologic modeling: A case study in the Thur River basin (Switzerland). *Water Resour. Res.* 43, 1–13. <https://doi.org/10.1029/2006WR005497>
- Yang, X., Warren, R., He, Y., Ye, J., Li, Q., Wang, G., 2018. Impacts of climate change on TN load and its control in a River Basin with complex pollution sources. *Sci. Total Environ.* 615, 1155–1163. <https://doi.org/10.1016/j.scitotenv.2017.09.288>
- Yapo, P.O., Gupta, H.V., Sorooshian, S., 1996. Automatic calibration of conceptual rainfall-runoff models: sensitivity to calibration data. *J. Hydrol.* 181, 23–48. [https://doi.org/10.1016/0022-1694\(95\)02918-4](https://doi.org/10.1016/0022-1694(95)02918-4)

- Yen, H., Hoque, Y., Harmel, R.D., Jeong, J., 2015. The impact of considering uncertainty in measured calibration/validation data during auto-calibration of hydrologic and water quality models. *Stoch. Environ. Res. Risk Assess.* 29, 1891–1901. <https://doi.org/10.1007/s00477-015-1047-z>
- Yen, H., Hoque, Y.M., Wang, X., Harmel, R.D., 2016. Applications of Explicitly Incorporated/Post-Processing Measurement Uncertainty in Watershed Modeling. *J. Am. Water Resour. Assoc.* 52, 523–540. <https://doi.org/10.1111/1752-1688.12401>
- Yen, H., Wang, X., Fontane, D.G., Harmel, R.D., Arabi, M., 2014. A framework for propagation of uncertainty contributed by parameterization, input data, model structure, and calibration/validation data in watershed modeling. *Environ. Model. Softw.* 54, 211–221. <https://doi.org/10.1016/j.envsoft.2014.01.004>
- Zhang, J., Han, D., Song, Y., Dai, Q., 2018. Study on the effect of rainfall spatial variability on runoff modelling. *J. Hydroinformatics* 20, 577–587. <https://doi.org/10.2166/hydro.2018.129>
- Zhang, X., Srinivasan, R., 2009. Gis-Based Spatial Precipitation Estimation : A comparison of geostatistical approaches. *J. Am. Water Resour. Assoc.* 45, 894–906.
- Zhang, X., Xu, Y.P., Fu, G., 2014. Uncertainties in SWAT extreme flow simulation under climate change. *J. Hydrol.* 515, 205–222. <https://doi.org/10.1016/j.jhydrol.2014.04.064>
- Zhao, L., A, J.X., XU, C., Zhonggen, W., 2013. Evapotranspiration estimation methods in hydrological models. *J. Geogr. Sci* 23, 359–369. <https://doi.org/10.1007/s11442-013-1015-9>
- Zoccatelli, D., Borga, M., Viglione, A., Chirico, G.B., Blöschl, G., 2011. Spatial moments of catchment rainfall: Rainfall spatial organisation, basin morphology, and flood response. *Hydrol. Earth Syst. Sci.* 15, 3767–3783. <https://doi.org/10.5194/hess-15-3767-2011>

APÊNDICE A

Tabela 14 - Porcentagens das simulações apresentas na Figura 12 para as respectivas curvas de Probabilidade Cumulativa. Segundo a classificação de Ritter e Muñoz-Carpena, (2013).

w01_30	default	5	10	30	90
Very good	0.00%	28.50%	27.80%	28.70%	26.50%
Good	1.20%	51.60%	52.20%	49.40%	44.80%
Acceptable	28.50%	16.30%	16.50%	17.30%	20.90%
Unsatisfactory	70.30%	3.60%	3.50%	4.60%	7.80%

w01_49	default	5	10	30	90
Very good	0.00%	2.40%	2.30%	3.00%	4.00%
Good	0.80%	24.60%	19.70%	25.70%	27.40%
Acceptable	3.90%	67.10%	69.80%	66.50%	64.50%
Unsatisfactory	95.30%	5.90%	8.20%	4.80%	4.10%

w02_5	default	5	10	30	90
Very good	0.40%	10.00%	11.50%	10.90%	19.50%
Good	5.80%	63.40%	63.80%	63.50%	44.50%
Acceptable	14.00%	23.10%	21.40%	21.70%	24.80%
Unsatisfactory	79.80%	3.50%	3.30%	3.90%	11.20%

w03_14	default	5	10	30	90
Very good	0.30%	10.50%	11.40%	11.10%	20.10%
Good	5.80%	66.00%	61.80%	64.10%	47.30%
Acceptable	14.10%	20.40%	22.80%	20.70%	22.80%
Unsatisfactory	79.80%	3.10%	4.00%	4.10%	9.80%

w06_120	default	5	10	30	90
Very good	0.10%	3.10%	3.30%	2.90%	1.20%
Good	3.70%	34.30%	33.30%	26.90%	11.60%
Acceptable	9.40%	55.30%	55.90%	59.90%	26.30%
Unsatisfactory	86.80%	7.30%	7.50%	10.30%	60.90%

w06_28	default	5	10	30	90
Very good	0.70%	1.10%	0.80%	0.70%	0.80%
Good	75.60%	44.60%	42.60%	37.20%	35.20%
Acceptable	13.70%	40.60%	43.80%	48.60%	49.50%
Unsatisfactory	10.00%	13.70%	12.80%	13.50%	14.50%

w14_33	default	5	10	30	90
Very good	0.00%	0.00%	0.00%	0.00%	0.00%
Good	0.00%	1.00%	0.00%	0.00%	0.00%
Acceptable	0.00%	10.70%	0.00%	0.00%	0.00%
Unsatisfactory	100.00%	88.30%	100.00%	100.00%	100.00%

w17_83	default	5	10	30	90
Very good	1.20%	0.00%	0.00%	0.00%	0.00%
Good	16.20%	2.40%	2.00%	1.30%	0.20%
Acceptable	31.80%	3.70%	3.80%	3.00%	1.00%
Unsatisfactory	50.80%	93.90%	94.20%	95.70%	98.80%

w19_95	default	5	10	30	90
Very good	18.90%	0.00%	0.00%	0.00%	7.80%
Good	13.70%	28.50%	25.20%	16.90%	29.80%
Acceptable	43.30%	57.70%	58.60%	63.60%	46.20%
Unsatisfactory	24.10%	13.80%	16.20%	19.50%	16.20%

w19_139	default	5	10	30	90
Very good	3.90%	0.10%	0.20%	0.60%	1.40%
Good	2.00%	12.10%	11.10%	18.10%	15.90%
Acceptable	51.60%	49.00%	49.30%	49.90%	45.30%
Unsatisfactory	42.50%	38.80%	39.40%	31.40%	37.40%

APÊNDICE B

Figura 22 – Distribuição espacial da média anual de chuvas para o período de 1985 - 2013.

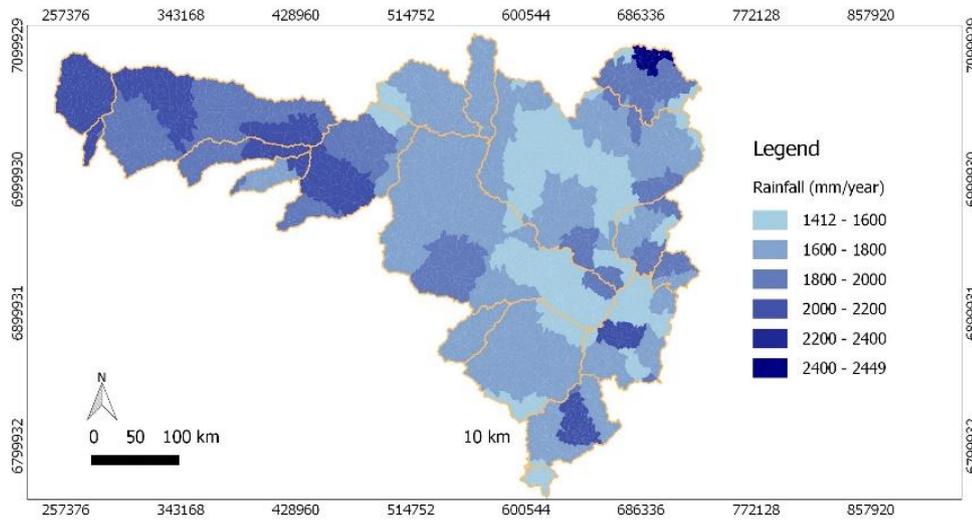
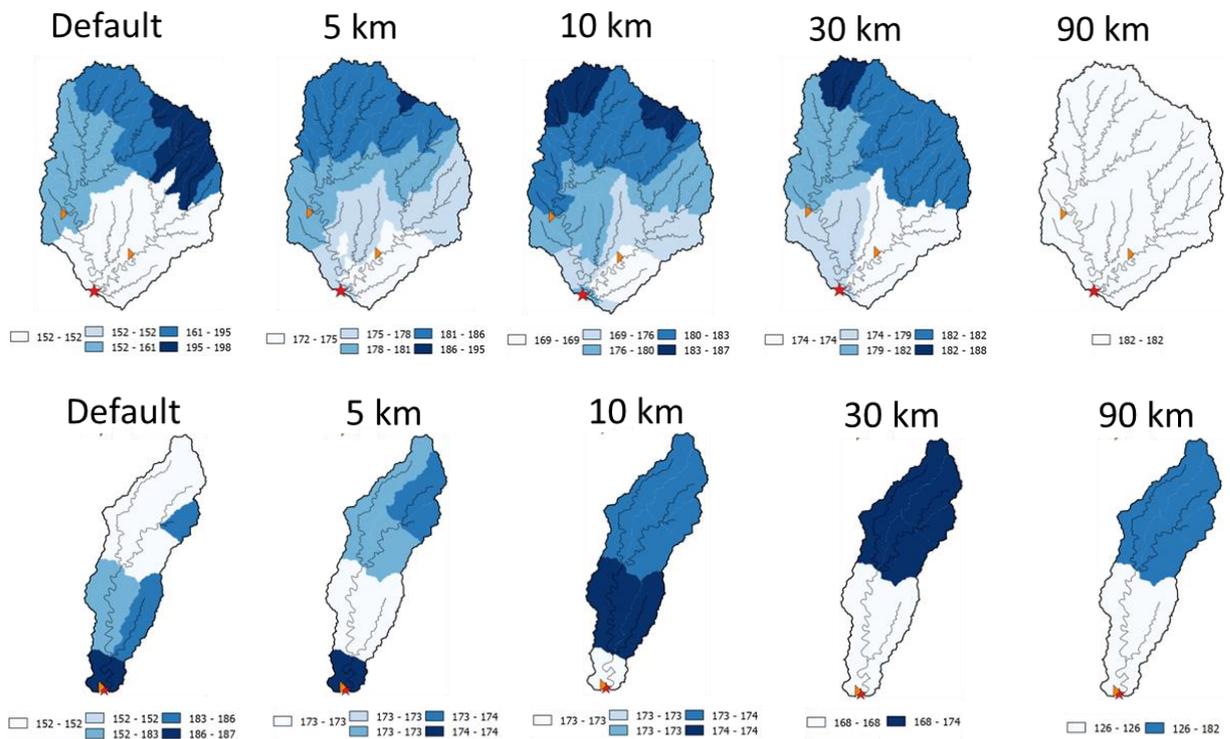
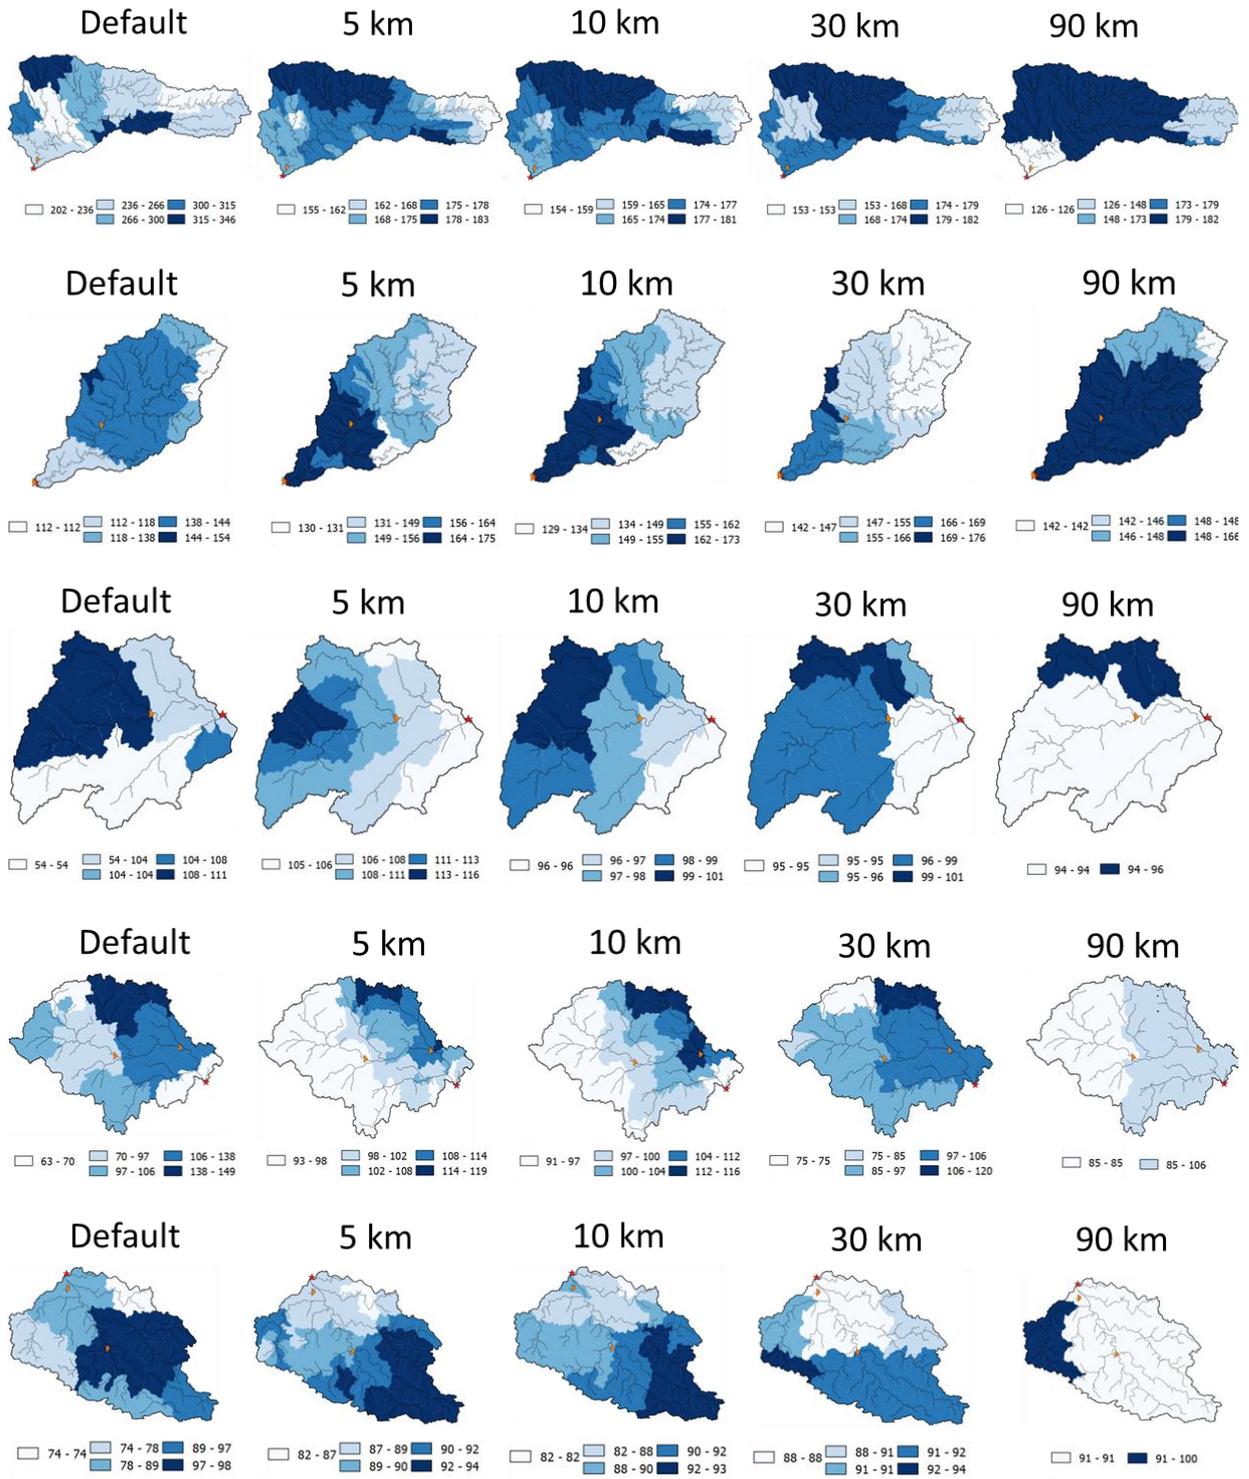


Figura 23 - Distribuição espacial da chuva mensal para o arranjo original das estações e diferentes tamanhos de grade (5 km, 10 km, 30 km, 90 km), para o ano mais seco avaliado.





APÊNDICE C

Tabela 15 – Diferença em % entre as distribuições dos parâmetros *shape* e *scale* para os dados observados e da rodada histórica dos modelos de circulação global.

	Atlântico		Prata	
	<i>scale</i>	<i>shape</i>	<i>scale</i>	<i>shape</i>
ACCESS1.3	38,31	74,66	38,97	83,41
ACCESS1-0	31,49	60,79	42,69	84,67
bcc-csm1-1	47,79	33,07	57,91	35,06
bcc-csm1-1-m	38,89	46,73	47,65	38,17
BNU-ESM	69,11	171,67	78,04	240,74
CCSM4	60,73	168,84	65,57	177,06
CMCC-CESM	72,20	123,69	78,96	270,50
CMCC-CM	18,30	38,06	22,76	36,564
CMCC-CMS	31,49	42,65	44,20	64,75
CNRM-CM5	39,55	115,79	60,89	125,60
CSIRO-Mk3-6-0	47,92	37,88	65,54	101,42
FGOALS_g2	61,97	98,46	70,69	113,87
GFDL-ESM2G	69,2	156,65	74,44	218,26
GFDL-ESM2M	67,58	112,43	73,28	183,84
GISS-E2-H	51,26	43,54	54,74	25,964
inmcm4	81,52	273,07	86,37	380,11
MIROC4h	30,44	54,95	23,88	36,88
MIROC-ESM	45,51	45,12	55,67	63,50
MIROC-ESM-CHEM	44,29	36,14	52,74	50,31
MRI-CGCM3	42,46	75,34	54,19	91,41
MRI-ESM1	39,22	71,38	51,73	96,79
NorESM1-M	76,90	211,00	82,16	252,80

APÊNDICE D

Figura 24 - Precipitação para os cenários rcp4.5 e rcp8.5 e para os modelos escolhidos para cada bacias hidrográficas.

