



UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

INSTITUTO DE PESQUISAS HIDRÁULICAS

**PREVISÃO POR CONJUNTOS DE LONGO PRAZO DE
UMIDADE DO SOLO NA BACIA DO RIO IJUÍ**

BIBIANA RODRIGUES COLOSSI

Porto Alegre, outubro de 2015

BIBIANA RODRIGUES COLOSSI

**PREVISÃO POR CONJUNTOS DE LONGO PRAZO DE
UMIDADE DO SOLO NA BACIA DO RIO IJUÍ**

Dissertação de mestrado submetida ao Programa de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental da Universidade Federal do Rio Grande do Sul como requisito parcial para obtenção do título de Mestre em Engenharia.

Orientador: Dr. Carlos Eduardo Morelli Tucci

Porto Alegre, outubro de 2015

BIBIANA RODRIGUES COLOSSI

**PREVISÃO POR CONJUNTOS DE LONGO PRAZO DE
UMIDADE DO SOLO NA BACIA DO RIO IJUÍ**

Dissertação submetida ao Programa de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental da Universidade Federal do Rio Grande do Sul defendida e aprovada em 26/10/2015 pela Comissão avaliadora constituída por:

Banca Examinadora:

Prof.^a Dr.^a Eliana Veleda Klering - – CEPSRM/UFRGS

Prof. Dr. Joel Avruch Goldenfum – IPH/UFRGS

Prof. Dr. Juan Martin Bravo – IPH/UFRGS

DEDICATÓRIA

*À minha avó,
que tem a alma de engenheira.*

AGRADECIMENTOS

A realização da dissertação aqui apresentada recebeu a contribuição direta ou indireta de muitas pessoas. À elas, apresento meus sinceros agradecimentos:

Ao meu orientador prof. Carlos Tucci, que me orienta na pesquisa e, muitas vezes, na vida. Alguém com quem cada conversa é um incentivo a dar o meu melhor em qualquer situação. Sempre disposto a auxiliar, alguém a quem admiro como pessoa e como profissional.

À minha mãe, à minha irmã, à minha avó, às minhas dindas e às minhas tias, por compreenderem o motivo da minha ausência em vários momentos e por me apoiarem nos períodos mais difíceis. E que mesmo com todas as dificuldades propiciaram minha educação e permitiram que a ela eu me dedicasse.

Àqueles que, mais que colegas, ao longo do tempo tornaram-se amigos: Paulo Pontes, que durante a condução desta pesquisa inúmeras vezes me ajudou e orientou, sempre com calma e boa vontade. Fernando Fan, que com toda a disposição e empenho revisou a dissertação e fez sugestões durante a realização do trabalho, e cuja dedicação e competência são exemplos a serem seguidos. Vinícius Siqueira, com quem sempre é um prazer dividir um momento de estudo ou de descontração, e que sempre mostra-se disposto a partilhar o seu conhecimento. Aos três, é um orgulho ser colega de vocês, e uma satisfação notar, com o passar do tempo, o crescimento profissional de todos nós.

Aos grandes amigos Gabriela Nahra, Elder Gama, Anellena Andrade e Fernando Marques, que me acompanham a tanto tempo e sempre me incentivam e apoiam nesta jornada. À Gabriela, um agradecimento especial pela leitura e revisão da dissertação.

Às amigas e colegas de profissão Priscila Magnago e Juliana Freese, com quem compartilhei os anos de graduação e que, mesmo que geograficamente distantes, são parte importante da minha vida.

Ao Carlos Henrique Galdino, Daniela Adamatti e Juan Ticona, pessoas únicas que tive o prazer de conhecer no início do mestrado e com quem dividi tantos momentos.

Ao IRI Data Library, pela disponibilização dos dados de previsão de precipitação dos modelos CCM3v6, ECPC e GFDL.

Aos professores Walter Collischonn, Rodrigo Paiva e Juan Martin Bravo, que muitas vezes contribuíram para a execução deste estudo. Particularmente aos professores Rodrigo e Juan Martin, muito obrigada pelas considerações realizadas na defesa do plano da dissertação, que muito colaboraram para o prosseguimento da pesquisa.

Agradeço também aos professores membros da banca, Eliana Klering, Joel Goldenfum, e Juan Martin Bravo, pelas considerações e sugestões que em muito contribuíram para a melhoria da versão final da dissertação.

Por fim, agradeço à CAPES pela bolsa fornecida durante a realização do mestrado, e ao IPH e seu corpo docente, por proporcionar uma formação de alto nível.

RESUMO

A umidade do solo é a variável que representa a quantidade de água disponível para uma cultura. O conhecimento antecipado das condições de umidade do solo, especialmente em um horizonte de longo prazo, permite um melhor planejamento de ações no setor agrícola. Sobretudo em culturas não irrigadas, a previsão do nível de umidade no solo pode se tornar uma ferramenta de grande auxílio. Neste sentido, o estudo aqui conduzido avalia a previsibilidade da umidade do solo na bacia do rio Ijuí, onde há forte atividade do setor agrícola, através da simulação hidrológica. Sendo a precipitação a principal variável a determinar a umidade do solo, analisa-se aqui o desempenho diferentes conjuntos de previsão de precipitação para realização da previsão de umidade do solo, através do modelo de grandes bacias MGB-IPH (Modelo de Grandes Bacias – Instituto de Pesquisas Hidráulicas). Reconhecendo-se a grande dificuldade associada à previsão em longo prazo, realizam-se aqui previsões probabilísticas de umidade do solo, ou previsões por *ensemble*. O *ensemble*, ou conjunto, refere-se ao conjunto de membros de associados a cada modelo de previsão, e é uma alternativa para a consideração das incertezas na previsão. Foram empregadas as previsões de precipitação, considerando seus respectivos membros, de três modelos climatológicos (CCM3v6, ECPC e GFDL), gerando diferentes previsões de umidade do solo. Estas previsões de umidade do solo foram divididas em quatro grandes grupos: A) previsões realizadas com todos os membros do *ensemble* de um determinado modelo; B) previsões realizadas com a precipitação média dos membros de cada modelo; C) previsões empregando todos os membros de todos os modelos em uma mesma previsão de umidade do solo; e D) previsões baseadas em uma abordagem multimodelos, construindo um *ensemble* de modelos a partir da previsão realizada com a precipitação média prevista por cada modelo. Os resultados indicam que a previsão de umidade do solo a longo prazo baseada em previsões de precipitação pode ser útil para a identificação de períodos mais secos ou mais úmidos que o normal para a região. A determinação do nível exato de saturação do solo, contudo, ainda apresenta grandes limitações. Além disso, infere-se pelos resultados observados, produto da metodologia adotada, que a condução de previsões baseadas na média do *ensemble* (B) e na abordagem multimodelos (D) envolvem menos esforço e trazem resultados semelhantes ou melhores que as previsões baseadas em todos os membros dos modelos (A e C).

Palavras-Chave: Umidade do solo; Previsão hidrológica por conjuntos; modelo MGB-IPH.

ABSTRACT

Soil moisture represents the water quantity available to a crop. The previous knowledge of the soil moisture conditions, especially with long antecedence, allows a better planning of the actions in the agricultural sector. Especially in non-irrigated crops, a forecast of the soil moisture level can be an important tool. In this context, the study here presented assess the predictability of the soil moisture in the Ijuí river basin, using hydrologic simulation. As the rainfall is the main variable to determine soil moisture, this study analyzes the performance of different sets of forecasted precipitation to perform soil moisture forecasts, using the large basins model MGB-IPH (Large Basins Model - Institute of Hydraulic Research). Recognizing the great difficulty associated with long-term forecasting, this study performs probabilistic soil moisture forecasts, or ensemble forecasts. The ensemble refers to the set of members associated with each prediction model, and is an alternative to consider the uncertainties in the forecast. Precipitation forecasts from three different climatologic models (CCM3v6, ECPC and GFDL), including all of their members, originated different soil moisture forecasts. Those soil moisture predictions were divided into four groups: A) forecasts conducted with all ensemble members of a given model; B) forecasts made with the average predicted rainfall of the members of each model; C) forecasts employing all members of all models in the same soil moisture prediction; and D) forecasts based on a multimodel approach, building an ensemble of models from the forecast made with the average rainfall predicted by each model. Results indicate that long-term soil moisture forecasts based on precipitation forecasts can be useful for identifying drier or wetter periods than the average condition for the region. The determination of the exact level of soil saturation, however, still has serious limitations. Also, it appears from the observed results, a product of the selected methodology, that soil moisture predictions based on the average of the ensemble (B) and on the multimodel approach (D) involve less effort and bring similar or better results to the predictions based on all ensemble members of the models (A and C).

Keywords: Soil moisture; Ensemble hydrologic forecast; MGB-IPH model.

LISTA DE ILUSTRAÇÕES

Figura 2.1. Esquema representativo do balanço hídrico no solo.	5
Figura 2.2. Em a), solo saturado; b), na capacidade de campo; c) no ponto de murcha permanente.....	9
Figura 2.3. Representação esquemática de um tensiômetro.....	15
Figura 2.4. TDR (modelo Tektronix 1502 C) acoplado a computador.	15
Figura 2.5. Representação esquemática da sonda de nêutrons.	15
Figura 3.1. Representação esquemática de modelo climático empregado para previsão numérica do tempo.	24
Figura 3.2. Esquema da previsão por <i>ensemble</i>	25
Figura 4.1. Fluxograma representativo da metodologia geral da previsão de umidade do solo.	37
Figura 4.2. Termos do balanço de água no solo no modelo MGB-IPH para uma URH. 40	
Figura 4.3. Metodologia da correção de viés das precipitações. Exemplo de correção para o mês de outubro, modelo CCM3v6.....	46
Figura 4.4. Fluxograma representativo da metodologia na etapa de previsão e classificação dos resultados.....	51
Figura 4.5. Umidade do solo média da bacia do rio Ijuí para o período entre 1980-2004 e desvio-padrão, para a umidade do solo classificada em cinco classes.	52
Figura 4.6. Tabela de contingência para eventos dicótonos (binários).	54
Figura 5.1. Uso do solo e cobertura vegetal na Região Hidrográfica do Uruguai.....	57
Figura 5.2. Área em estudo em relação à bacia do rio Uruguai.	58
Figura 5.3. Bacia do rio Ijuí e hidrografia.	59
Figura 5.4. Limites municipais, estaduais, internacionais e principais municípios na região em estudo.....	59
Figura 5.5. Precipitação total anual média na bacia do rio Ijuí, com base no período entre 1980 e 2013.	60
Figura 5.6. Precipitação total média mensal para todas as 163 minibacias no rio Ijuí... 61	
Figura 5.7. Precipitação total média mensal dividida pela precipitação média total anual, para todas as 163 minibacias no rio Ijuí.	61
Figura 6.1. Rede de drenagem, minibacias e sub-bacias delimitadas na área de estudo. 63	
Figura 6.2. Reclassificação dos tipos de solos presentes na bacia do rio Ijuí.	65
Figura 6.3. Reclassificação dos usos do solo na bacia do rio Ijuí.	66

Figura 6.4. Unidades de resposta hidrológica na bacia do rio Ijuí.	67
Figura 6.5. Postos fluviométricos selecionados.....	69
Figura 6.6. Disponibilidade temporal de dados de vazão dos postos fluviométricos selecionados para o período de interesse.....	69
Figura 6.7. Postos pluviométricos selecionados.....	70
Figura 6.8. Disponibilidade temporal de dados de precipitação observada dos postos pluviométricos selecionados para o período de interesse.....	72
Figura 6.9. Estações climatológicas selecionadas.	74
Figura 6.10. Curva de permanência do posto fluviométrico 75320000, na sub-bacia 6, obtida na etapa de calibração do MGB-IPH.....	77
Figura 6.11. Detalhe do hidrograma do posto fluviométrico 75320000, na sub-bacia 6, obtido na etapa de calibração do MGB-IPH.....	77
Figura 6.12. Curva de permanência do posto fluviométrico 75295000, na sub-bacia 5, obtida na etapa de verificação da calibração do MGB-IPH.	78
Figura 6.13. Detalhe do hidrograma do posto fluviométrico 75295000, na sub-bacia 5, obtido na etapa de verificação da calibração do MGB-IPH.	78
Figura 7.1. Pontos com precipitação prevista para a região de interesse.	79
Figura 7.2. Exemplos de ajuste de função de erro das previsões. Modelo GFDL, mês de janeiro.	80
Figura 7.3. Correção de viés do modelo CCM3v6 para os meses de janeiro e julho.....	81
Figura 7.4. Correção de viés do modelo ECPC para os meses de janeiro e julho.....	82
Figura 7.5. Correção de viés do modelo GFDL para os meses de janeiro e julho.	83
Figura 7.6. Precipitação observada e precipitação prevista com 1 mês de antecedência, com e sem correção de viés, para o modelo CCM3v6. Valores relativos à precipitação média da bacia do rio Ijuí, média do <i>ensemble</i> de membros do modelo.....	86
Figura 7.7. Precipitação observada e precipitação prevista com 3 meses de antecedência, com e sem correção de viés, para o modelo CCM3v6. Valores relativos à precipitação média da bacia do rio Ijuí, média do <i>ensemble</i> de membros do modelo.....	86
Figura 7.8. Precipitação observada e precipitação prevista com 6 meses de antecedência, com e sem correção de viés, para o modelo CCM3v6. Valores relativos à precipitação média da bacia do rio Ijuí, média do <i>ensemble</i> de membros do modelo.....	86
Figura 7.9. Precipitação observada e precipitação prevista com 1 mês de antecedência, com e sem correção de viés, para o modelo ECPC. Valores relativos à precipitação média da bacia do rio Ijuí, média do <i>ensemble</i> de membros do modelo.....	87

Figura 7.10. Precipitação observada e precipitação prevista com 3 meses de antecedência, com e sem correção de viés, para o modelo ECPC. Valores relativos à precipitação média da bacia do rio Ijuí, média do <i>ensemble</i> de membros do modelo.....	87
Figura 7.11. Precipitação observada e precipitação prevista com 6 meses de antecedência, com e sem correção de viés, para o modelo ECPC. Valores relativos à precipitação média da bacia do rio Ijuí, média do <i>ensemble</i> de membros do modelo.....	87
Figura 7.12. Precipitação observada e precipitação prevista com 1 mês de antecedência, com e sem correção de viés, para o modelo GFDL. Valores relativos à precipitação média da bacia do rio Ijuí, média do <i>ensemble</i> de membros do modelo.....	88
Figura 7.13. Precipitação observada e precipitação prevista com 3 meses de antecedência, com e sem correção de viés, para o modelo GFDL. Valores relativos à precipitação média da bacia do rio Ijuí, média do <i>ensemble</i> de membros do modelo.....	88
Figura 7.14. Precipitação observada e precipitação prevista com 6 meses de antecedência, com e sem correção de viés, para o modelo GFDL. Valores relativos à precipitação média da bacia do rio Ijuí, média do <i>ensemble</i> de membros do modelo.....	88
Figura 7.15. Precipitação total anual média da bacia do rio Ijuí, observada e prevista pelo modelo CCM3v6, com e sem correção de viés. O valor apresentado para o ano de 2005 refere-se ao período entre junho e dezembro.....	89
Figura 7.16. Precipitação total anual média da bacia do rio Ijuí, observada e prevista pelo modelo ECPC, com e sem correção de viés. O valor apresentado para o ano de 2005 refere-se ao período entre junho e dezembro.....	89
Figura 7.17. Precipitação total anual média da bacia do rio Ijuí, observada e prevista pelo modelo GFDL, com e sem correção de viés. O valor apresentado para o ano de 2005 refere-se ao período entre junho e dezembro.....	90
Figura 7.18. Precipitação prevista pelo modelo CCM3v6 (média do <i>ensemble</i>) para horizonte de 1 mês, média mensal de longo período e observada na bacia, no período entre junho/2005 e dezembro/2013.	94
Figura 7.19. Precipitação prevista pelo modelo CCM3v6 (média do <i>ensemble</i>) para horizonte de 3 meses, média mensal de longo período e observada na bacia, no período entre junho/2005 e dezembro/2013.	94
Figura 7.20. Precipitação prevista pelo modelo CCM3v6 (média do <i>ensemble</i>) para horizonte de 6 meses, média mensal de longo período e observada na bacia, no período entre junho/2005 e dezembro/2013.	94

Figura 7.21. Precipitação prevista pelo modelo ECPC (média do <i>ensemble</i>) para horizonte de 1 mês, média mensal de longo período e observada na bacia, no período entre junho/2005 e dezembro/2013.	95
Figura 7.22. Precipitação prevista pelo modelo ECPC (média do <i>ensemble</i>) para horizonte de 3 meses, média mensal de longo período e observada na bacia, no período entre junho/2005 e dezembro/2013.	95
Figura 7.23. Precipitação prevista pelo modelo ECPC (média do <i>ensemble</i>) para horizonte de 6 meses, média mensal de longo período e observada na bacia, no período entre junho/2005 e dezembro/2013.	95
Figura 7.24. Precipitação prevista pelo modelo GFDL (média do <i>ensemble</i>) para horizonte de 1 mês, média mensal de longo período e observada na bacia, no período entre junho/2005 e dezembro/2013.	96
Figura 7.25. Precipitação prevista pelo modelo GFDL (média do <i>ensemble</i>) para horizonte de 3 meses, média mensal de longo período e observada na bacia, no período entre junho/2005 e dezembro/2013.	96
Figura 7.26. Precipitação prevista pelo modelo GFDL (média do <i>ensemble</i>) para horizonte de 6 meses, média mensal de longo período e observada na bacia, no período entre junho/2005 e dezembro/2013.	96
Figura 8.1. Saturação média mensal prevista com 1 mês de antecedência e pseudo-observada na bacia do rio Ijuí.	98
Figura 8.2. Saturação média mensal prevista com 3 meses de antecedência e pseudo-observada na bacia do rio Ijuí.	99
Figura 8.3. Saturação média mensal prevista com 6 meses de antecedência e pseudo-observada na bacia do rio Ijuí.	99
Figura 8.4. Classe pseudo-observada de saturação do solo e prevista pelo <i>ensemble</i> do modelo CCM3v6 (previsão código 1), para o horizonte de 1 mês.	102
Figura 8.5. Classe pseudo-observada de saturação do solo e prevista pelo <i>ensemble</i> do modelo ECPC (previsão código 2), para o horizonte de 1 mês.	102
Figura 8.6. Classe pseudo-observada de saturação do solo e prevista pelo <i>ensemble</i> do modelo GFDL (previsão código 3), para o horizonte de 1 mês.	102
Figura 8.7. Classe pseudo-observada de saturação do solo e prevista pelo <i>ensemble</i> do modelo CCM3v6 (previsão código 1), para o horizonte de 3 meses.	103
Figura 8.8. Classe pseudo-observada de saturação do solo e prevista pelo <i>ensemble</i> do modelo ECPC (previsão código 2), para o horizonte de 3 meses.	103

Figura 8.9. Classe pseudo-observada de saturação do solo e prevista pelo <i>ensemble</i> do modelo GFDL (previsão código 3), para o horizonte de 3 meses.	103
Figura 8.10. Classe pseudo-observada de saturação do solo e prevista pelo <i>ensemble</i> do modelo CCM3v6 (previsão código 1), para o horizonte de 6 meses.....	104
Figura 8.11. Classe pseudo-observada de saturação do solo e prevista pelo <i>ensemble</i> do modelo ECPC (previsão código 2), para o horizonte de 6 meses.....	104
Figura 8.12. Classe pseudo-observada de saturação do solo e prevista pelo <i>ensemble</i> do modelo GFDL (previsão código 3), para o horizonte de 6 meses.	104
Figura 8.13. Classe pseudo-observada de saturação do solo e prevista pela média do <i>ensemble</i> do modelo CCM3v6 (previsão código 4), para o horizonte de 1 mês.....	106
Figura 8.14. Classe pseudo-observada de saturação do solo e prevista pela média do <i>ensemble</i> do modelo ECPC (previsão código 5), para o horizonte de 1 mês.....	106
Figura 8.15. Classe pseudo-observada de saturação do solo e prevista pela média do <i>ensemble</i> do modelo GFDL (previsão código 6), para o horizonte de 1 mês.	106
Figura 8.16. Classe pseudo-observada de saturação do solo e prevista pela média do <i>ensemble</i> do modelo CCM3v6 (previsão código 4), para o horizonte de 3 meses.....	107
Figura 8.17. Classe pseudo-observada de saturação do solo e prevista pela média do <i>ensemble</i> do modelo ECPC (previsão código 5), para o horizonte de 3 meses.	107
Figura 8.18. Classe pseudo-observada de saturação do solo e prevista pela média do <i>ensemble</i> do modelo GFDL (previsão código 6), para o horizonte de 3 meses.....	107
Figura 8.19. Classe pseudo-observada de saturação do solo e prevista pela média do <i>ensemble</i> do modelo CCM3v6 (previsão código 4), para o horizonte de 6 meses.....	108
Figura 8.20. Classe pseudo-observada de saturação do solo e prevista pela média do <i>ensemble</i> do modelo ECPC (previsão código 5), para o horizonte de 6 meses.	108
Figura 8.21. Classe pseudo-observada de saturação do solo e prevista pela média do <i>ensemble</i> do modelo GFDL (previsão código 6), para o horizonte de 6 meses.....	108
Figura 8.22. Classe de saturação pseudo-observada e prevista pelo <i>superensemble</i> (previsão código 7) para o horizonte de 1 mês.....	110
Figura 8.23. Classe de saturação pseudo-observada e prevista pelo <i>superensemble</i> (previsão código 7) para o horizonte de 3 meses.....	110
Figura 8.24. Classe de saturação pseudo-observada e prevista pelo <i>superensemble</i> (previsão código 7) para o horizonte de 6 meses.....	110
Figura 8.25. Classe pseudo-observada de saturação do solo e prevista pelo <i>ensemble</i> das médias dos modelos (previsão código 8) para o horizonte de 1 mês.	112

Figura 8.26. Classe pseudo-observada de saturação do solo e prevista pelo ensemble das médias dos modelos (previsão código 8) para o horizonte de 3 meses.	112
Figura 8.27. Classe pseudo-observada de saturação do solo e prevista pelo ensemble das médias dos modelos (previsão código 8) para o horizonte de 6 meses.	112
Figura 8.28. Índice de acertos da previsão considerando-se faixas de tendência, conforme o horizonte de previsão.	114
Figura 8.29. Probabilidade de Detecção e Probabilidade de Falsa Detecção para as classes seca, normal e úmida, para as diferentes previsões.	119
Figura 8.30. Razão de Falso Alarme para as classes seca, normal e úmida, para as diferentes previsões.	120
Figura 8.31. BIAS para as classes seca, normal e úmida, para as diferentes previsões.	121
Figura 8.32. Tipo de erro conforme a probabilidade da previsão. Ensemble das médias. Horizonte de 1 mês.	129
Figura 8.33. Tipo de erro conforme a probabilidade da previsão. Ensemble das médias. Horizonte de 3 meses.	129
Figura 8.34. Tipo de erro conforme a probabilidade da previsão. Ensemble das médias. Horizonte de 6 meses.	130
Figura A.1. Missões atuais com medição de umidade do solo.	168
Figura A.2. Missões atuais com medição de umidade do solo.	169
Figura B.1. Minibacia do modelo MGB-IPH dividida em N classes de uso, tipo e cobertura do solo (URH).	175
Figura B.2. Esquema do balanço de água no solo do modelo MGB-IPH para uma Unidade de Resposta Hidrológica.	177
Figura B.3. Esquema dos processos de geração e propagação de escoamentos nas minibacias e propagação de vazão na rede de drenagem.	186
Figura C.1. Correção de viés do modelo CCM3v6 para os meses de janeiro a junho.	198
Figura C.2. Correção de viés do modelo CCM3v6 para os meses de julho a dezembro.	199
Figura C.3. Correção de viés do modelo ECPC para os meses de janeiro a junho.	200
Figura C.4. Correção de viés do modelo ECPC para os meses de julho a dezembro.	201
Figura C.5. Correção de viés do modelo GFDL para os meses de janeiro a junho.	202
Figura C.6. Correção de viés do modelo GFDL para os meses de julho a dezembro.	203

Figura E.1. Curva de permanência do posto fluviométrico 75155000, na sub-bacia 1, obtida na etapa de calibração do MGB-IPH.....	207
Figura E.2. Detalhe do hidrograma do posto fluviométrico 75155000, na sub-bacia 1, obtido na etapa de calibração do MGB-IPH.....	207
Figura E.3. Curva de permanência do posto fluviométrico 75185000, na sub-bacia 2, obtida na etapa de calibração do MGB-IPH.....	208
Figura E.4. Detalhe do hidrograma do posto fluviométrico 75185000, na sub-bacia 2, obtido na etapa de calibração do MGB-IPH.....	208
Figura E.5. Curva de permanência do posto fluviométrico 75200000, na sub-bacia 3, obtida na etapa de calibração do MGB-IPH.....	209
Figura E.6. Detalhe do hidrograma do posto fluviométrico 75200000, na sub-bacia 3, obtida na etapa de calibração do MGB-IPH.....	209
Figura E.7. Curva de permanência do posto fluviométrico 75205000, na sub-bacia 3, obtida na etapa de calibração do MGB-IPH.....	210
Figura E.8. Detalhe do hidrograma do posto fluviométrico 75205000, na sub-bacia 3, obtida na etapa de calibração do MGB-IPH.....	210
Figura E.9. Curva de permanência do posto fluviométrico 75230000, na sub-bacia 4, obtida na etapa de calibração do MGB-IPH.....	211
Figura E.10. Detalhe do hidrograma do posto fluviométrico 75230000, na sub-bacia 4, obtida na etapa de calibração do MGB-IPH.....	211
Figura E.11. Curva de permanência do posto fluviométrico 75295000, na sub-bacia 5, obtida na etapa de calibração do MGB-IPH.....	212
Figura E.12. Detalhe do hidrograma do posto fluviométrico 75295000, na sub-bacia 5, obtida na etapa de calibração do MGB-IPH.....	212
Figura E.13. Curva de permanência do posto fluviométrico 75320000, na sub-bacia 6, obtida na etapa de calibração do MGB-IPH.....	213
Figura E.14. Detalhe do hidrograma do posto fluviométrico 75320000, na sub-bacia 6, obtida na etapa de calibração do MGB-IPH.....	213
Figura E.15. Curva de permanência do posto fluviométrico 75155000, na sub-bacia 1, obtida na etapa de verificação da calibração do MGB-IPH.	214
Figura E.16. Detalhe do hidrograma do posto fluviométrico 75155000, na sub-bacia 1, obtido na etapa de verificação da calibração do MGB-IPH.	214
Figura E.17. Curva de permanência do posto fluviométrico 75186000, na sub-bacia 2, obtida na etapa de verificação da calibração do MGB-IPH.	215

Figura E.18. Detalhe do hidrograma do posto fluviométrico 75186000, na sub-bacia 2, obtido na etapa de verificação da calibração do MGB-IPH.	215
Figura E.19. Curva de permanência do posto fluviométrico 75200000, na sub-bacia 3, obtida na etapa de verificação da calibração do MGB-IPH.	216
Figura E.20. Detalhe do hidrograma do posto fluviométrico 75200000, na sub-bacia 3, obtido na etapa de verificação da calibração do MGB-IPH.	216
Figura E.21. Curva de permanência do posto fluviométrico 75205000, na sub-bacia 3, obtida na etapa de verificação da calibração do MGB-IPH.	217
Figura E.22. Detalhe do hidrograma do posto fluviométrico 75205000, na sub-bacia 3, obtido na etapa de verificação da calibração do MGB-IPH.	217
Figura E.23. Curva de permanência do posto fluviométrico 75230000, na sub-bacia 4, obtida na etapa de verificação da calibração do MGB-IPH.	218
Figura E.24. Detalhe do hidrograma do posto fluviométrico 75230000, na sub-bacia 4, obtido na etapa de verificação da calibração do MGB-IPH.	218
Figura E.25. Curva de permanência do posto fluviométrico 75295000, na sub-bacia 5, obtida na etapa de verificação da calibração do MGB-IPH.	219
Figura E.26. Detalhe do hidrograma do posto fluviométrico 75295000, na sub-bacia 5, obtido na etapa de verificação da calibração do MGB-IPH.	219

LISTA DE TABELAS

Tabela 3.1. Métricas padrão para verificação comumente usadas em sistemas de previsão hidrometeorológica.	27
Tabela 4.1. Resumo das principais informações sobre as bases de dados selecionadas.	44
Tabela 4.2. Limites do domínio dos dados históricos dos modelos CCM3v6, ECPC e GFDL. Valores referentes a totais mensais de precipitação.	47
Tabela 4.3. Previsões de umidade do solo para cada horizonte de previsão, com base na combinação de modelos e médias de ensembles da previsão de precipitação.	50
Tabela 4.4. Limites das cinco classes da anomalia da saturação do solo.	52
Tabela 6.1. Dados de entrada necessários para o programa PrePro-MGB.	62
Tabela 6.2. Sub-bacias definidas.	64
Tabela 6.3. Postos fluviométricos selecionados.	68
Tabela 6.4. Postos pluviométricos na bacia do rio Ijuí e entornos usados na simulação.	71
Tabela 6.5. Estações climatológicas na bacia do rio Ijuí e entornos usadas na simulação.	74
Tabela 6.6. Parâmetros fixos do MGB-IPH.	75
Tabela 6.7. Qualidade do ajuste na etapa de calibração do MGB-IPH.	76
Tabela 6.8. Qualidade do ajuste na etapa de verificação da calibração do MGB-IPH... ..	78
Tabela 7.1. Equações aplicadas para correção de viés nas previsões de precipitação do modelo CCM3v6, conforme o mês. Pprev é a precipitação prevista pelo modelo CCM3v6 para o membro x, para a minibacia y, para o mês z.	81
Tabela 7.2. Equações aplicadas para correção de viés nas previsões de precipitação do modelo ECPC, conforme o mês. Pprev é a precipitação prevista pelo modelo ECPC para o membro x, para a minibacia y, para o mês z.	82
Tabela 7.3. Equações aplicadas para correção de viés nas previsões de precipitação do modelo GFDL, conforme o mês. Pprev é a precipitação prevista pelo modelo GFDL para o membro x, para a minibacia y, para o mês z.	82
Tabela 7.4. Média dos erros absolutos mensais das precipitações previstas com e sem correção de viés.	85
Tabela 7.5. Exemplo do efeito do uso da faixa de extrapolação.	90

Tabela 7.6. Erro médio da precipitação prevista (com correção de viés) e da precipitação média de longo período em relação à precipitação total mensal média observada na bacia no período entre junho/2005 e dezembro/2013.	92
Tabela 7.7. Coeficiente de correlação de Pearson (r) e Coeficiente de Determinação (r ²) entre a série de precipitação observada total mensal média da bacia do rio Ijuí e as precipitações previstas (após correção de viés) ou média mensal de longo período.....	92
Tabela 8.1. Faixas de saturação.	113
Tabela 8.2. Índice de acertos da previsão considerando-se faixas de tendência.	114
Tabela 8.3. Índice de erros e acertos da previsão considerando-se três classes de saturação. Horizonte 1 mês.....	117
Tabela 8.4. Índice de erros e acertos da previsão considerando-se três classes de saturação. Horizonte 3 meses.	117
Tabela 8.5. Índice de erros e acertos da previsão considerando-se três classes de saturação. Horizonte 6 meses.	117
Tabela 8.6. Índice de erros e acertos da previsão fora dos meses de saturação pseudo-observada “normal”, considerando-se três classes de saturação. Horizonte 1 mês.....	125
Tabela 8.7. Índice de erros e acertos da previsão fora dos meses de saturação pseudo-observada “normal”, considerando-se três classes de saturação. Horizonte 3 meses...	125
Tabela 8.8. Índice de erros e acertos da previsão fora dos meses de saturação pseudo-observada “normal”, considerando-se três classes de saturação. Horizonte 6 meses...	125
Tabela 8.9. Índice de erros e acertos da previsão considerando-se cinco classes de saturação. Horizonte 1 mês.....	126
Tabela 8.10. Índice de erros e acertos da previsão considerando-se cinco classes de saturação. Horizonte 3 meses.	127
Tabela 8.11. Índice de erros e acertos da previsão considerando-se cinco classes de saturação. Horizonte 6 meses.	127
Tabela A.1. Bases de dados contribuintes para a International Soil Moisture Network.	162
Tabela A.2. Missões atuais e futuras com observação de umidade do solo.	170
Tabela C.1. Bases de dados de interesse de previsões disponíveis no IRI e suas características.....	193
Tabela D.1. Parâmetros fixos do MGB-IPH.....	204
Tabela D.2. Parâmetros calibráveis do MGB-IPH – Sub-bacia 1.	204
Tabela D.3. Parâmetros calibráveis do MGB-IPH – Sub-bacia 2.	205

Tabela D.4. Parâmetros calibráveis do MGB-IPH – Sub-bacia 3.	205
Tabela D.5. Parâmetros calibráveis do MGB-IPH – Sub-bacia 4.	205
Tabela D.6. Parâmetros calibráveis do MGB-IPH – Sub-bacia 5.	206
Tabela D.7. Parâmetros calibráveis do MGB-IPH – Sub-bacia 6.	206
Tabela D.8. Parâmetros calibráveis do MGB-IPH – Sub-bacia 7.	206
Tabela F.1. Classe de saturação pseudo-observada, prevista pelo ensemble de cada modelo (previsões tipo A), probabilidade da previsão e erro da previsão para o horizonte de 1 mês.	220
Tabela F.2. Classe de saturação pseudo-observada, prevista pelo <i>ensemble</i> de cada modelo (previsões tipo A), probabilidade da previsão e erro da previsão para o horizonte de 3 meses.	223
Tabela F.3. Classe de saturação pseudo-observada, prevista pelo <i>ensemble</i> de cada modelo (previsões tipo A), probabilidade da previsão e erro da previsão para o horizonte de 6 meses.	226
Tabela F.4. Classe de saturação pseudo-observada e probabilidade associada a cada classe de saturação conforme o <i>ensemble</i> do modelo CCM3v6 (tipo A) para o horizonte de 1 mês.	229
Tabela F.5. Classe de saturação pseudo-observada e probabilidade associada a cada classe de saturação conforme o <i>ensemble</i> do modelo ECPC (tipo A) para o horizonte de 1 mês.	232
Tabela F.6. Classe de saturação pseudo-observada e probabilidade associada a cada classe de saturação conforme o <i>ensemble</i> do modelo GFDL (tipo A) para o horizonte de 1 mês.	235
Tabela F.7. Classe de saturação pseudo-observada e probabilidade associada a cada classe de saturação conforme o <i>ensemble</i> do modelo CCM3v6 (tipo A) para o horizonte de 3 meses.	238
Tabela F.8. Classe de saturação pseudo-observada e probabilidade associada a cada classe de saturação conforme o <i>ensemble</i> do modelo ECPC (tipo A) para o horizonte de 3 meses.	241
Tabela F.9. Classe de saturação pseudo-observada e probabilidade associada a cada classe de saturação conforme o <i>ensemble</i> do modelo GFDL (tipo A) para o horizonte de 3 meses.	244

Tabela F.10. Classe de saturação pseudo-observada e probabilidade associada a cada classe de saturação conforme o <i>ensemble</i> do modelo CCM3v6 (tipo A) para o horizonte de 6 meses.....	247
Tabela F.11. Classe de saturação pseudo-observada e probabilidade associada a cada classe de saturação conforme o <i>ensemble</i> do modelo ECPC (tipo A) para o horizonte de 6 meses.	250
Tabela F.12. Classe de saturação pseudo-observada e probabilidade associada a cada classe de saturação conforme o <i>ensemble</i> do modelo GFDL (tipo A) para o horizonte de 6 meses.	253
Tabela F.13. Classe de saturação pseudo-observada, prevista pelo superensemble (tipo C) e erro da previsão para o horizonte de 1 mês.	256
Tabela F.14. Classe de saturação pseudo-observada, prevista pelo superensemble (tipo C) e erro da previsão para o horizonte de 3 meses.	259
Tabela F.15. Classe de saturação pseudo-observada, prevista pelo superensemble (tipo C) e erro da previsão para o horizonte de 6 meses.	262
Tabela F.16. Classe de saturação pseudo-observada e probabilidade associada a cada classe de saturação conforme o <i>superensemble</i> (tipo C) para o horizonte de 1 mês....	265
Tabela F.17. Classe de saturação pseudo-observada e probabilidade associada a cada classe de saturação conforme o <i>superensemble</i> (tipo C) para o horizonte de 3 meses.	268
Tabela F.18. Classe de saturação pseudo-observada e probabilidade associada a cada classe de saturação conforme o <i>superensemble</i> (tipo C) para o horizonte de 6 meses.	271
Tabela F.19. Classe de saturação pseudo-observada, prevista pela média do <i>ensemble</i> (de precipitação) de cada modelo (tipo B) e média do <i>ensemble</i> de modelos (tipo D) para o horizonte de 1 mês.....	274
Tabela F.20. Classe de saturação pseudo-observada, prevista pela média do <i>ensemble</i> (de precipitação) de cada modelo (tipo B) e média do <i>ensemble</i> de modelos (tipo D) para o horizonte de 3 meses.....	277
Tabela F.21. Classe de saturação pseudo-observada, prevista pela média do <i>ensemble</i> (de precipitação) de cada modelo (tipo B) e média do <i>ensemble</i> de modelos (tipo D) para o horizonte de 6 meses.....	280

LISTA DE ABREVIATURAS E SIGLAS

AGCM	Atmospheric General Circulation Model
ALOS-2	Advanced Land Observing Satellite-2 (DAICHI-2)
AMSR	Advanced Microwave Scanning Radiometer
AMRS-E	Advanced Microwave Scanning Radiometer – Earth Observation System
AMSU-A	Advanced Microwave Sounding Unit-A
ASCAT	Advanced Scatterometer
ASI	Agenzia Spaziale Italiana
BDMEP	Banco de Dados Meteorológicos para Ensino e Pesquisa, do INMET
BMA	Bayesian Model Averaging - ponderação bayesiana de modelos
C-Band SAR	C-Band Synthetic Aperture Radar
CAD	Capacidade de Água Disponível
CC	Capacidade de Campo
CCM	Community Climate Model
CDTI	Centro para el Desarrollo Tecnológico Industrial
CEOS	Committee on Earth Observation Satellites
CFS	Climate Forecast System
CML	Community Land Model
CNES	Centre National d'Etudes Spatiales
COLA	Center for Ocean-Land-Atmosphere Studies
CONAE	Comision Nacional de Actividades Espaciales
CPC	Climate Prediction Center
CSA	Canadian Space Agency

CSG	COSMO-SkyMed Seconda Generazione
CSG SAR	COSMO Seconda Generazione SAR
DLR	German Aerospace Center
DMSP	Defense Meteorological Satellite Program
EC	European Commission
ECHAM	European Community - HAMburg
ECMWF	European Centre for Medium Range Weather Forecasts
ECPC	Experimental Climate Prediction Center
ENOS	El Niño-Oscilação Sul
EPS	Ensemble Prediction System
ESA	European Space Agency
EUMETSAT	European Organization for the Exploitation of Metereological Satellites
FUNCEME	Fundação Cearense de Meteorologia e Recursos Hídricos
GCOM	Global Change Observation Mission
GEO	Group of Earth Observation
GEWEX	Global Energy and Water Exchanges Project
GFDL	Geophysical Fluid Dynamics Laboratory
GFZ	GFZ German Research Centre for Geosciences
GLDAS	Global Land Data Assimilation System
GRACE FO	Gravity Recovery and Climate Experiment - Follow-on
HiRAM	HIgh Resolution Atmospheric Model
INMET	Instituto Nacional de Meteorologia
INPE	Instituto Nacional de Pesquisas Espaciais

IRI	International Research Institute for Climate and Society
ISMN	International Soil Moisture Network
ISRO	Indian Space Research Organization
IV	Infravermelho
IVT	Infravermelho Termal
JAXA	Japan Aerospace Exploration Agency
JPSS	Joint Polar Satellite System
LDEO	Lamont-Doherty Earth Observatory
MDA	MacDonald Dettwiler and Associates
MDE	Modelo Digital de Elevação
Metop	Meteorological Operational Polar Satellite
MGB-IPH	Modelo de Grandes Bacias – Instituto de Pesquisas Hidráulicas
MIRAS	Microwave Imaging Radiometer using Aperture Synthesis
MMA	Ministério do Meio Ambiente
MODIS	Moderate Resolution Imaging Spectroradiometer
MVIRS	Moderate Resolution Visible and Infrared Imaging Spectroradiometer
MWRI	MicroWave Radiation Imager
NISAR	NASA ISRO - Synthetic Aperture Radar aka Dual Frequency SAR Mission
NOAA	National Oceanic and Atmospheric Administration
NRSCC	National Remote Sensing Centre of China
NSF	National Science Foundation
NSIPP	NASA's Seasonal to Interannual Prediction Project

NSMC-CMA	National Satellite Meteorological Center/Chinese Meteorological Administration
NWP	Numerical Weather Prediction
PALSAR-2	Phased Array type L-band Synthetic Aperture Radar-2
PDF	Probability Distribution Function
PMP	Ponto de Murcha Permanente
PNT	Previsão Numérica do Tempo
PSST	Persisted SST anomalies
QPF	Quantitative Precipitation Forecast
RISAT	Radar Imaging Satellite
S-band SAR	S-band Synthetic Aperture Radar (SAR)
SAOCOM	Satélite Argentino de Observación COm Microondas
SAR-L	L-Band Synthetic Aperture Radar
SIG	Sistema de Informações Geográfica
SMAP	Soil Moisture Active Passive
SMOS	Soil Moisture and Ocean Salinity (Earth Explorer Opportunity Mission)
SRTM	Shuttle Radar Topography Mission
SSM/I	Special Sensor Microwave Imager
SSM/IS	Special Sensor Microwave Imager Sounder
SSST	Scenario SST anomalies
SST	Sea Surface Temperature
Suomi NPP	Suomi National Polar-orbiting Partnership (NPP, S-NPP)
SWIM	Soil and Water Integrated Model
SWM	Surface Water Monitor

TDR	Time Domain Reflectometer
TMI	TRMM Microwave Imager
TRMM	Tropical Rainfall Measuring Mission
URH	Unidade de Resposta Hidrológica
USAF	United States Air Force
VIC	Variable Infiltration Capacity
VIIRS	Visible/Infrared Imager Radiometer Suite
VIS	Visível
WMO	World Meteorological Organization

LISTA DE SIMBOLOS

α	Parâmetro da lâmina de interceptação
γ	Constante psicrométrica, igual a 0,66 kPa °C ⁻¹
Δ	Gradiente da pressão de saturação do vapor em relação à temperatura
ΔV	Erro de volume entre hidrogramas calculados e observados
θ	Umidade da camada de solo à base de volume
λ	Calor latente de vaporização
λ_j	Índice de porosidade de solo
ρ_a	Massa específica do ar
ρ_w	Massa específica da água, igual a 1000 kg.m ⁻³
$A_{i,j}$	Área da URH j da minibacia i
b	Parâmetro do MGB-IPH que define o grau de heterogeneidade da capacidade de armazenamento de água no solo
CB	Parâmetro calibrável do MGB-IPH que controla o retardo do escoamento subterrâneo na minibacia
CO_2	Gás carbônico
c_p	Calor específico do ar úmido, igual a 1,013.10 ⁻³ MJ.kg ⁻¹ . °C ⁻¹
d	Drenagem
$Dbas_{i,j}$	Escoamento subterrâneo na minibacia i, na UHR j
$Dcap_{i,j}$	Fluxo ascendente do aquífero à camada superficial de solo na minibacia i, na UHR j
$Dint_{i,j}$	Escoamento subsuperficial na minibacia i, na UHR j
$DMcap_j$	Máximo fluxo ascendente no solo
$Dsup_{i,j}$	Escoamento superficial na minibacia i, na UHR j
e_d	Pressão do vapor

$EI_{i,j}$	Evaporação real da lâmina interceptada na minibacia i, na UHR j
$EPI_{i,j}$	Evaporações potencial da lâmina d'água interceptada na URH j da minibacia i
e_s	Pressão de saturação do vapor
$ET_{i,j}$	Evapotranspiração da água no solo na minibacia i, na UHR j
ET	Taxa de evaporação da água
fc	Fator de conversão de unidades, igual a $3,6 \times 10^{-6}$
G	Fluxo de energia para o solo
IAF	Índice de Área Foliar
Inf	Taxa de infiltração
$Kbas_j$	Parâmetro que define a máxima percolação quando o solo está saturado
$Kint_j$	Parâmetro de drenagem subsuperficial
L_i	Comprimento do maior afluente do rio principal da minibacia i
L_n	Radiação líquida de onda longa
m_l	Massa da fração líquida da amostra de solo
m_s	Massa da fração sólida de solo
m_T	Massa total da amostra de solo
n	Porosidade do solo
n	Coefficiente de Manning
N_{classe}	Número de membros com saturação em determinada classe
N_{modelo}	Número total de membros do modelo de previsão
NS	Coefficiente de Nash-Sutcliffe
NS_{log}	Coefficiente de Nash-Sutcliffe para os logaritmos das vazões
O_2	Oxigênio

Pa	Pascal
$P_{i,j}$	Precipitação que chega ao solo, na minibacia i, na UHR j
PC_i	Precipitação sono topo da cobertura vegetal na minibacia i
PC_{modelo}	Probabilidade de ocorrência de determinada classe de para o modelo em questão
$Q_{cal}(t)$:	Vazão calculada no tempo t
q_e	Fluxo de evapotranspiração
$Q_{obs}(t)$:	Vazão observada no tempo t
Q_{int_i}	Vazão de saída do reservatório subsuperficial, na minibacia i
Q_{mini_i}	Vazão que chega ao trecho de rio da minibacia i
Q_{sub_i}	Vazão de saída do reservatório subterrâneo, na minibacia i
Q_{sup_i}	Vazão de saída do reservatório superficial, na minibacia i
q_b	Escoamento subterrâneo equivalente
q_p	Escoamento superficial equivalente
q_z	Fluxo no limite inferior da camada de solo ($z=L$)
r_a	Resistência aerodinâmica
r_s	Resistência superficial da vegetação
S	Grau de saturação do solo
S_i	Declividade do maior afluente do rio principal da minibacia i
S_n	Radiação líquida de onda curta
$S_{i,j}$	Lâmina de água interceptada na URH j da minibacia i
S_{max}	Volume máximo do reservatório de interceptação
Tc_i	Tempo de concentração da minibacia i
TKI_i	Tempo de retardo do reservatório subuperficial, na minibacia i

TKB_i	Tempo de retardo do reservatório subterrâneo, na minibacia i
TKS_i	Tempo de retardo do reservatório superficial, na minibacia i
u_m	Umidade da camada de solo à base de massa
V_g	Volume da fase gasosa no solo; volume de ar
V_l	Volume da fase líquida no solo
V_n	Volume de poros no solo
V_s	Volume da fração sólida no solo
V_{bas_i}	Volume no reservatório subterrâneo na minibacia i
V_{int_i}	Volume no reservatório subsuperficial na minibacia i
V_{sup_i}	Volume no reservatório superficial na minibacia i
V_T	Volume total da amostra de solo
$W_{i,j}^{t-1}$	Volume de água armazenado na camada superficial do solo no início do período de tempo, na minibacia i , na UHR j
$W_{i,j}^t$	Volume de água armazenado na camada superficial do solo no final do período de tempo, na minibacia i , na UHR j
W_{c_j}	Limite mínimo de armazenamento de água no solo a partir do qual não há percolação
W_m	Capacidade máxima de armazenamento da camada de solo
W_{z_j}	Limite mínimo de armazenamento de água no solo a partir do qual haverá geração de escoamento superficial
X	Fração da área que está saturada
Z	Altura das árvores

SUMÁRIO

1. INTRODUÇÃO.....	1
1.1 Objetivos.....	4
1.1.1 Objetivo geral	4
1.1.2 Objetivos específicos	4
2. BALANÇO HÍDRICO E UMIDADE NO SOLO.....	5
2.1 Balanço hídrico no solo	5
2.2 Umidade no solo.....	7
2.2.1 Umidade no solo à base de massa	7
2.2.2 Umidade no solo à base de volume	8
2.2.3 Grau de saturação	8
2.2.4 Capacidade de campo e ponto de murcha permanente.....	9
2.3 Estimativa de umidade no solo.....	10
2.3.1 Modelos para balanço hídrico no solo na simulação hidrológica.....	10
2.3.2 Modelos para balanço hídrico no solo usados na agricultura.....	12
2.3.3 Medição em campo de umidade do solo	14
2.3.4 Estimativa de umidade do solo a partir de sensoriamento remoto	16
2.4 Bases de dados de umidade do solo.....	19
3. PREVISÃO.....	21
3.1 Previsão de precipitação	22
3.1.1 Características da previsão de precipitação	22
3.1.2 Previsão por ensemble	24
3.2 Simulação e previsão de umidade no solo.....	28
3.2.1 Alguns estudos já conduzidos	28
3.2.2 Considerações sobre os estudos já realizados.....	32
4. MODELO DE PREVISÃO DE LONGO PRAZO DE UMIDADE DO SOLO	35
4.1 Estrutura do trabalho	35

4.2	Modelo de balanço hídrico no solo.....	38
4.2.1	Modelo de Grandes Bacias: MGB-IPH.....	38
4.2.2	Períodos de calibração, verificação e previsão.....	41
4.2.3	Calibração e verificação do modelo.....	41
4.3	Previsão de precipitação.....	43
4.3.1	Dados disponíveis e selecionados.....	43
4.3.2	Correção de viés.....	45
4.3.3	Compatibilização temporal dos dados.....	48
4.4	Tipos de previsão de precipitação e previsão de umidade do solo associada.....	49
4.5	Classificação das previsões.....	52
4.6	Análise de desempenho das previsões.....	53
5.	BACIA HIDROGRÁFICA DO RIO IJUÍ.....	56
5.1	Localização.....	56
5.2	Caracterização.....	56
6.	SIMULAÇÃO HIDROLÓGICA.....	62
6.1	Geração de dados para o pré-processamento do MGB-IPH.....	62
6.1.1	Definição da rede de drenagem, minibacias e sub-bacias.....	63
6.1.2	Definição das Unidades de Resposta Hidrológica.....	64
6.2	Simulação no MGB-IPH.....	68
6.2.1	Seleção de dados de vazão observados.....	68
6.2.2	Seleção de dados de precipitação observados.....	70
6.2.3	Seleção de dados de clima observados.....	73
6.2.4	Calibração.....	75
6.2.5	Verificação da calibração.....	77
7.	PREVISÃO DE PRECIPITAÇÃO.....	79
7.1	Grade de previsão.....	79
7.2	Correção de viés das previsões de precipitação.....	80

7.3	Análise das precipitações previstas quanto a correção de viés.....	84
7.4	Análise das precipitações previstas em relação à média de longo período	91
8.	PREVISÃO DE UMIDADE NO SOLO	97
8.1	Resultados da previsão de umidade no solo – Nível de saturação	98
8.2	Resultados da previsão de umidade no solo – Classificação.....	100
8.2.1	Previsões tipo A – <i>Ensemble</i> – Códigos 1, 2 e 3	100
8.2.2	Previsões tipo B – Médias do <i>ensemble</i> – Códigos 4, 5 e 6	105
8.2.3	Previsões tipo C – <i>Superensemble</i> – Código 7	109
8.2.4	Previsões tipo D – <i>Ensemble</i> de modelos – Código 8	111
8.3	Análise de desempenho da previsão de umidade no solo.....	113
8.3.1	Análise de desempenho da previsão em Faixas.....	114
8.3.2	Análise de desempenho da previsão em Classes	116
8.3.3	Análise de desempenho da previsão quanto à Probabilidade – Previsão tipo D - <i>Ensemble</i> de modelos	128
8.3.4	Análise integrada do desempenho da previsão.....	131
9.	CONCLUSÕES E RECOMENDAÇÕES	134
9.1	Conclusões.....	134
9.2	Recomendações	139
10.	REFERÊNCIAS	140
A	ANEXO A	161
	Estimativas de umidade no solo	161
A.1	Bases de dados de umidade no solo.....	161
A.2	Estimativa de umidade no solo por Sensoriamento Remoto	167
B	ANEXO B	175
	Modelo Hidrológico de Grandes Bacias: MGB-IPH.....	175
B.1	Introdução	175
B.2	Processos Hidrológicos Verticais	177

B.2.1	Interceptação	177
B.2.2	Balanço hídrico no solo	179
B.2.3	Evapotranspiração.....	179
B.2.4	Escoamento superficial	180
B.2.5	Escoamento subsuperficial.....	182
B.2.6	Escoamento subterrâneo	182
B.2.7	Fluxo capilar ascendente.....	183
B.3	Processos Hidrológicos Horizontais	183
B.3.1	Propagação de vazões na rede de drenagem	185
B.3.2	Propagação de vazões na rede de drenagem com o modelo hidrodinâmico	188
C	ANEXO C	192
	Previsão de precipitação	192
C.1	Dados disponibilizados pelo <i>International Research Institute for Climate and Society</i> (IRI).....	192
C.2	Correção de viés da precipitação prevista.....	198
D	ANEXO D	204
	Parametrização adotada no modelo hidrológico.....	204
E	ANEXO E.....	207
	Qualidade do ajuste da simulação hidrológica para as vazões	207
E.1	Etapa de calibração do modelo	207
E.2	Etapa de verificação do modelo	214
F	ANEXO F.....	220
	Resultados da previsão de umidade do solo	220
F.1	Previsões tipo A: Ensemble - Classe mais provável de saturação do solo.....	220
F.2	Previsões tipo A: Ensemble - Previsão completa - Probabilidade de cada classe de umidade do solo.....	229
F.3	Previsões tipo C: Superensemble - Classe mais provável de saturação do solo	256

F.4 Previsões tipo C: Superensemble - Previsão completa – Probabilidade de cada classe de umidade do solo	265
F.5 Previsões tipos B e D: Média do ensemble (previsões tipo B) e ensemble das médias (multimodelos, previsões tipo D)	274

1. INTRODUÇÃO

A previsão de variáveis hidrológicas é a estimativa dos estados futuros dos fenômenos hidrológicos (WMO, 2009). Esta previsão pode ser de curto prazo, quando realizada com antecedência de horas até alguns dias no futuro; ou de longo prazo, prevendo o estado da variável para até nove meses à frente (GEORGAKAKOS & KRYSZTOFOWICZ, 2001). Contudo, a definição do limite entre *curto* prazo e *longo* prazo, ou ainda a inclusão do conceito de *médio* prazo, varia entre diferentes autores e conforme a variável de interesse. Usualmente, aceita-se que previsões de curto prazo são aquelas realizadas para um horizonte de até aproximadamente 10 dias.

A previsão hidrológica de longo prazo, que é o foco deste estudo, possui limitações. A modelagem hidrológica por si realiza diversas simplificações no processo de representação dos processos físicos. Além disso, há grandes incertezas relacionadas à previsão das variáveis empregadas na simulação hidrológica. A previsão de precipitação oriunda de modelos meteorológicos, usada como dado de entrada em modelos hidrológicos, naturalmente apresenta erros, e estes tendem a ser mais significativos quanto maior o horizonte da previsão.

A necessidade de avaliar e quantificar as incertezas associadas à previsão climática e hidrológica, para uma tomada de decisão no manejo dos recursos hídricos que leve em consideração um determinado nível de risco, impulsionou o uso de previsões por conjuntos, ou *ensemble*, nos últimos anos (DEMARGNE *et al.*, 2014). O *ensemble* é formado por diferentes membros de um modelo, onde cada membro representa uma diferente trajetória das condições atmosféricas ao longo do horizonte de previsão. Os membros são determinados, em geral, a partir de perturbações nas condições iniciais do modelo. O espalhamento entre os membros permite então a quantificação da incerteza das condições iniciais da previsão. Além da utilização da informação de probabilidade disponibilizada pelo uso do conjunto de membros de um modelo, uma abordagem multimodelos permite quantificar as incertezas devidas à formulação do modelo (KIRTMAN & PIRANI, 2009).

Ainda que a previsão hidrológica de longo prazo contenha grande incerteza, ela é útil nas áreas onde o planejamento é uma peça importante, como o setor energético e

agrícola (TUCCI, 2005). Uma vez que estes setores dependem diretamente da disponibilidade de recursos naturais, a previsão das variáveis representativas destes recursos é fundamental para orientar a tomada de decisão nestas áreas. Dentre as variáveis de interesse, destaca-se aqui a umidade do solo, com forte influência sobre a produção agrícola.

A umidade do solo possui um papel importante no ciclo hidrológico global e no balanço de energia. Ela é um parâmetro que afeta fluxos verticais de umidade e energia, assim como os fluxos horizontais. Ainda, eventos extremos de cheias e secas estão atrelados à condição de umidade do solo (WANG *et al.*, 2009 *apud* LIU e XIE, 2013; ROBOCK *et al.*, 1998). Desta forma, é necessária uma correta simulação da umidade no solo e suas alterações ao longo do tempo para modelar corretamente o ciclo hidrológico. Contudo, a umidade do solo é um parâmetro ainda mais importante para a agricultura, uma vez que é ela que indica a quantidade de água disponível para a cultura.

O conhecimento da umidade do solo prevista em longo prazo, ou seja, para um período de meses à frente, permite um melhor planejamento de ações no setor agrícola. Sobretudo para a cultura de sequeiros, culturas não irrigadas, esta previsão pode tornar-se uma ferramenta de grande auxílio. A região do rio Uruguai, parte da qual está aqui em estudo, possui apenas cerca de 7% de área irrigada em relação à área total cultivada, e este índice, assim como a área total irrigada, não apresentou alteração significativa na última década (ANA, 2013). À exceção do arroz irrigado, a utilização de irrigação no Rio Grande do Sul ainda é extremamente baixa, conforme a EMATER/RS (2009). O Estado possui cerca de 6.000.000 ha de lavouras de sequeiros: milho, soja, feijão, fumo, entre outras, das quais apenas aproximadamente 2% possuem sistema de irrigação. Desta forma, percebe-se que a cultura de sequeiros na região do rio Uruguai e no Rio Grande do Sul como um todo é bastante importante.

Além disso, também para a silvicultura a previsão de longo prazo pode ser empregada no planejamento das atividades, uma vez que a produtividade está diretamente relacionada com a disponibilidade hídrica. No Rio Grande do Sul, a área de florestas plantadas é coberta sobretudo por eucalipto e pinus, e em 2014 atingiu 597.000 ha, equivalente à 2% da área do estado e 8% da área com plantios florestais no Brasil. No mesmo ano, a cadeia produtiva de base florestal contribuiu com 4% do PIB do estado e 7% da geração de empregos (AGEFLOR, 2015).

Desta forma, percebe-se a grande aplicabilidade da previsão de longo prazo da umidade do solo no planejamento agrícola. Esta informação é de interesse na tomada de decisões como área a ser plantada, valoração de seguros agrícolas, entre outros. Contudo, a previsão em longo prazo da umidade do solo, levando em consideração às incertezas associadas à previsão, ainda não é realizada de forma sistemática. Neste sentido, e sabendo-se que a precipitação é a variável mais importante para a variação da umidade no solo (LIU & XIE, 2013), o estudo aqui conduzido apresenta uma metodologia para a previsão de longo prazo de umidade do solo através da simulação hidrológica, avaliando o desempenho da previsão resultante de diferentes conjuntos de previsão de precipitação. Esta metodologia pode ser replicada com relativa facilidade, uma vez que emprega apenas softwares livres e dados disponíveis para download.

1.1 Objetivos

1.1.1 Objetivo geral

Este estudo tem por objetivo avaliar a previsibilidade da umidade do solo em longo prazo através da simulação hidrológica, considerando-se as incertezas na previsão de precipitação.

Neste trabalho é avaliado o uso de diferentes conjuntos de previsão de precipitação com vistas a realizar uma previsão de umidade do solo, com antecedência de um, três e seis meses. A área em estudo é a bacia do rio Ijuí, sub-bacia do rio Uruguai, onde a cultura de sequeiros desempenha um papel importante. A simulação hidrológica é uma *hindcast* (previsão para um período passado), realizada com o modelo hidrológico de grandes bacias MGB-IPH (COLLISCHONN, 2001).

1.1.2 Objetivos específicos

Os objetivos específicos deste trabalho podem ser assim elencados:

- Analisar o desempenho da previsão de umidade do solo realizada com diferentes conjuntos de dados de precipitação prevista:
 - Todo o *ensemble* dos membros de um modelo de previsão;
 - Média do *ensemble* de um modelo;
 - Abordagem multimodelos, *ensemble* construído com a previsão média de cada modelo;
 - *Superensemble*, empregando todos os membros de todos os modelos em uma mesma previsão.

2. BALANÇO HÍDRICO E UMIDADE NO SOLO

2.1 Balanço hídrico no solo

A umidade do solo representa o volume de água armazenado na camada de solo. Esta camada deve incluir a totalidade ou, pelo menos, a maior parte da zona de absorção das raízes. Sendo assim, ela pode variar conforme a cultura de interesse. Entendendo-se o solo como um reservatório, tem-se que as entradas no mesmo são a precipitação, a irrigação, o fluxo subterrâneo que entra na camada de solo de interesse, a ascensão capilar e a parte do fluxo superficial que infiltra, e as saídas, a evapotranspiração, a percolação profunda e o fluxo subterrâneo de saída (Figura 2.1).

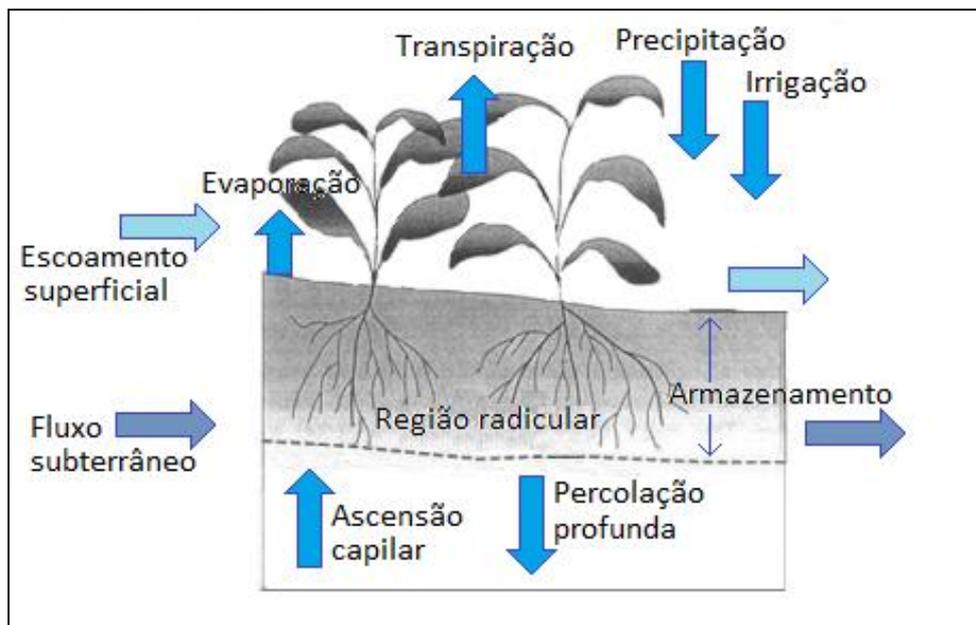


Figura 2.1. Esquema representativo do balanço hídrico no solo.
Adaptado de Conceição, 2010 e Gavande, 1972.

Considerando-se, então, uma camada de solo de espessura L . No intervalo de tempo entre t_i e t_{i+1} , tem-se, pela lei de conservação das massas, que:

$$\int_{t_i}^{t_{i+1}} (inf \pm q_p \pm q_b - q_e \pm q_z) dt = \int_{t_i}^{t_{i+1}} \int_0^L \left(\frac{\partial \theta}{\partial t} \right) dz dt \quad (1)$$

Onde:

inf [$mm \cdot dia^{-1}$]: Taxa de infiltração, função da precipitação, da irrigação e da interceptação;

q_p [mm.dia⁻¹]: Escoamento superficial equivalente;

q_b [mm.dia⁻¹]: Escoamento subterrâneo equivalente;

q_e [mm.dia⁻¹]: Fluxo de evapotranspiração;

q_z [mm.dia⁻¹]: Fluxo no limite inferior da camada de solo ($z=L$), positivo ou negativo conforme o gradiente de potencial em L ;

$\partial\theta/\partial t$ [mm³.mm⁻³.dia⁻¹]: Variação da quantidade de água armazenada.

2.2 Umidade no solo

O solo pode ser considerado como um sistema trifásico, onde se observa uma fase sólida, uma líquida, e uma gasosa. Conforme Reichardt (1985), a fase sólida do solo é constituída pelas partículas de solo propriamente ditas, ou seja, pela matéria mineral (proveniente da rocha que originou o solo) e orgânica com a qual o solo é formado. A parte gasosa possui uma composição média diferente da atmosfera livre, em geral com um teor CO₂ maior e um menor de O₂, devido à atividade biológica existente no solo. Já a parte líquida constitui-se de uma solução aquosa de sais minerais e componentes orgânicos.

A determinação quantitativa da fração líquida, desconsiderando-se os solutos presentes, ou seja, a quantificação da água presente na camada de interesse do solo pode estar baseada na massa ou no volume, e representa a umidade no solo. Os itens 2.2.1 e 2.2.2 descrevem estas duas definições, conforme Reichard e Timm (2004) e Hillel (1970).

2.2.1 Umidade no solo à base de massa

A umidade com base na massa é definida como:

$$u_m = \frac{m_l}{m_s} = \frac{m_T - m_s}{m_s} \quad (2)$$

Onde:

u_m [kg.kg⁻¹]: Umidade da camada de solo à base de massa;

m_l [kg]: Massa da fração líquida que, por ser uma solução diluída, é considerada como sendo a massa de água;

m_s [kg]: Massa da fração sólida;

m_T [kg]: Massa total da amostra de solo.

A umidade do solo em termos de massa, u_m , é um valor adimensional, e comumente expressa em porcentagem.

2.2.2 Umidade no solo à base de volume

A umidade com base no volume é definida como:

$$\theta = \frac{V_l}{V_T} = \frac{m_l}{V_s + V_n} = \frac{m_T - m_s}{V_s + V_l + V_g} \quad (3)$$

Onde:

θ [m³.m⁻³]: Umidade da camada de solo à base de volume;

V_l [m³]: Volume da fase líquida, considerado como o volume de água.
Admitindo-se a densidade da solução como sendo 1.000 kg.m⁻³, toma-se $V_l=m_l$;

V_T [m³]: Volume total da amostra de solo;

V_s [m³]: Volume da fração sólida;

V_g [m³]: Volume da fase gasosa; volume de ar;

V_n [m³]: Volume de poros. Igual à (V_l+V_g).

A umidade do solo em termos de volume, θ , também é adimensional, geralmente apresentada em porcentagem.

2.2.3 Grau de saturação

O grau de saturação (S) traz uma medida do volume de água existente na camada de solo em questão, relacionando-o com o volume de poros total do solo. O grau de saturação, de acordo com Hillel (1970), é dado por:

$$S = \frac{V_l}{V_n} = \frac{V_l}{V_l + V_g} \quad (4)$$

Onde:

S [m³.m⁻³]: Grau de saturação.

O grau de saturação varia entre 0% e 100%. S=0% indica um solo completamente seco; enquanto S=100% indica um solo saturado.

2.2.4 Capacidade de campo e ponto de murcha permanente

A Capacidade de Campo (CC) é definida, conforme Veihmeyer e Hendrickson (1949) *apud* Reichardt e Timm (2004), como “a quantidade de água retida pelo solo após drenagem de seu excesso, quando a velocidade do movimento descendente praticamente cessa, o que, usualmente, ocorre dois ou três dias após a chuva ou irrigação, em solo permeáveis de estrutura e textura uniformes”. Contudo, sendo o processo de redistribuição de água no solo contínuo, apesar da velocidade diminuir com o tempo, o processo continua indefinidamente, e uma tendência ao equilíbrio é usualmente atingida apenas após um longo período de tempo.

O Ponto de Murcha Permanente (PMP) é o teor de umidade do solo no qual uma planta atinge o ponto de murcha irrecuperável, ou seja, a planta não restabelece a turgidez, mesmo colocada em atmosfera úmida saturada por 12 horas (VEIHMEYER & HENDRICKSON, 1949 *apud* REICHARDT & TIMM, 2004).

Contudo, a definição exata da quantidade de água ou potencial mátrico associado à CC e ao PMP não é consenso, uma vez que observa-se que diferentes plantas respondem de maneira distinta a variações no teor de umidade do solo. A quantidade de água absorvida pelas plantas depende de fatores relacionados ao solo, como a condutividade hidráulica e relações entre umidade e potencial; fatores relativos à planta, como a fisiologia das raízes, profundidade e área foliar; e fatores associados à atmosfera, como o déficit de saturação, radiação solar e vento, entre outros (REICHARDT & TIMM, 2004).

Ainda que o Ponto de Murcha Permanente não possua uma definição exata, o termo pode ser entendido como sendo um limite. A diferença entre a Capacidade de Campo e o Ponto de Murcha Permanente representa a quantidade de água do solo disponível para uma planta (ver Figura 2.2).

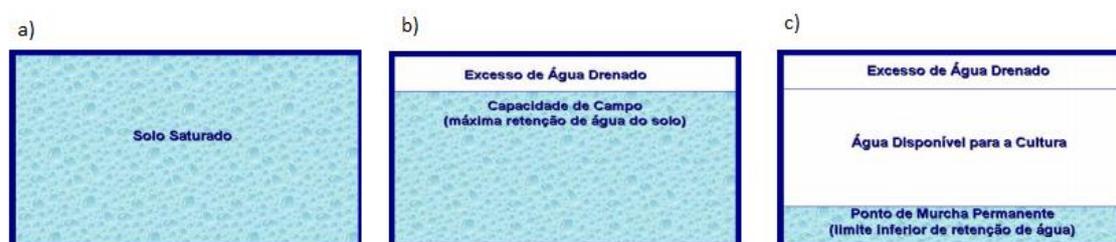


Figura 2.2. Em a), solo saturado; b), na capacidade de campo; c) no ponto de murcha permanente. Adaptado de Conceição, 2010.

2.3 Estimativa de umidade no solo

A estimativa da umidade do solo e das variáveis a ela associadas, como o grau de saturação, pode se dar através de diferentes abordagens, conforme a disponibilidade de dados e as características do estudo conduzido, sobretudo quanto à representatividade espacial e temporal. Apresentam-se aqui quatro diferentes metodologias para estimativa de umidade no solo, com diferentes aplicações e limitações associadas. Os itens 2.3.1 e 2.3.2 tratam da estimativa de umidade do solo através da realização do balanço hídrico no solo, por meio da modelagem hidrológica, e de métodos simplificados comumente usados no setor agrícola, respectivamente. Já a estimativa da umidade do solo através da identificação da quantidade de água na camada de solo é apresentada no item 2.3.3, para medições em campo, e no item 2.3.4, através de técnicas de sensoriamento remoto.

2.3.1 Modelos para balanço hídrico no solo na simulação hidrológica

Um modelo hidrológico busca representar o ciclo hidrológico, ou partes do mesmo, em uma região. Em modelos de transformação chuva-vazão, por exemplo, o objetivo principal da simulação é determinar a vazão em um rio. Contudo, esta saída principal é obtida através da simulação de outros processos e, conseqüentemente, da determinação de outras variáveis hidrológicas. Dentro da modelagem hidrológica, a representação do balanço hídrico no solo pode não ser o objetivo principal da simulação, mas é uma etapa importante da modelagem.

A representação do balanço hídrico no solo aplicada à modelagem hidrológica apresenta diferentes níveis de complexidade. Esta complexidade está principalmente relacionada ao objetivo do estudo e à disponibilidade de dados (ZHANG *et al.*, 2002). Uma abordagem relativamente simples, mas bastante empregada, é a aplicação do conceito de modelo balde (*bucket model*), onde o perfil de solo é tratado como um balde, a entrada é a precipitação, e o excesso de água gera escoamento superficial ou drenagem profunda, não estando mais disponível para evaporação. Este conceito pode ser melhor desenvolvido, passando a discretizar o perfil de solo em múltiplas camadas. O modelo de balanço hídrico no solo torna-se cada vez complexo ao considerar a vegetação, a resistência da cobertura vegetal e o seu papel na variação da evapotranspiração. Exemplos

de diferentes abordagens da aplicação da metodologia de *bucket model* para o balanço hídrico no solo podem ser encontrados nos trabalhos de White *et al.* (2000), Soldevilla-Martinez *et al.* (2013) e Romano *et al.* (2011). Ainda, uma abordagem mais complexa envolve a representação do solo através de múltiplas camadas, com a determinação da umidade do solo através da solução numérica da Equação de Richards para uma dimensão (PENG *et al.*, 2001).

Desta forma, diferentes modelos hidrológicos representam o balanço hídrico no solo através de distintas abordagens. O modelo MIKE SHE - *European Hydrological System Model* (ABBOTT *et al.*, 1986 (a); ABBOTT *et al.*, 1986 (b)) permite a representação da zona não saturada através de um modelo unidimensional de múltiplas camadas, baseado em uma solução numérica por diferenças finitas da Equação de Richards ou considerando fluxo gravitacional. Alternativamente, quando o nível de detalhamento necessário é menor, pode-se empregar um modelo de duas camadas na zona de raízes, calculando um balanço hídrico simples na zona não saturada (MIKE Powered by DHI, s.d.).

O modelo VIC - *Variable Infiltration Capacity (VIC) Macroscale Hydrologic Model* (LIANG, 1994; GAO *et al.*, 2010) representa o solo através de três camadas. O movimento entre as duas camadas superiores do solo é, e assim como no modelo MIKE SHE, representado pela Equação de Richards unidimensional.

O modelo TOPMODEL – *Topography-based hydrological model* (BEVEN & KIRKBY, 1979; BEVEN *et al.*, 1995) emprega o conceito de área de contribuição variável, considerando que a área na bacia capaz de gerar escoamento superficial varia ao longo do tempo (SILVA & KOBAYAMA, 2007). O modelo representa três camadas de solo, zona de raízes, zona não saturada e zona saturada, como três reservatórios interconectados (NOURANI *et al.*, 2011). O balanço hídrico para cada reservatório do solo é obtido através da equação de conservação de massa, enquanto o fluxo de água no solo é determinado através da lei de Darcy. A soma dos três reservatórios hipotéticos fornece o balanço hídrico na bacia (VESTENA *et al.*, 2013).

O modelo MGB-IPH (COLLISCHONN, 2001) divide a bacia em minibacias. Cada minibacia é coberta em diferentes proporções por diversas Unidades de Resposta Hidrológica (URHs), definidas pela cobertura e capacidade de armazenamento do solo.

O balanço de água no solo é realizado para cada URH, em cada minibacia. A metodologia considera a existência de apenas uma camada de solo, e a lâmina de água no solo no tempo t é igual ao balanço entre as entradas (lâmina de água no tempo $t-1$, precipitação efetiva e fluxo ascendente do aquífero) e saídas (evapotranspiração, escoamento superficial, escoamento subsuperficial e escoamento subterrâneo). A descrição detalhada do módulo de balanço de água no solo do modelo hidrológico MGB-IPH, empregado neste estudo, é apresentada no item 4.2.

Para fins agrícolas, contudo, abordagens mais simplificadas são em geral empregadas. O item a seguir mostra dois métodos comumente empregados no setor agrícola para realização do balanço hídrico no solo.

2.3.2 Modelos para balanço hídrico no solo usados na agricultura

Balanço hídrico de Thornthwaite e Mather

O balanço hídrico de Thornthwaite e Mather parte do objetivo de prover uma caracterização climática de uma região de interesse. O modelo proposto por Thornthwaite em 1948 e modificado por Mather em 1955 permite encontrar a evapotranspiração real, o déficit ou excedente hídrico e o total de água retida no solo a partir de três informações: CAD (Capacidade de Água Disponível), que representa o armazenamento máximo do solo de água disponível para as plantas; precipitação total e evapotranspiração potencial do período (PEREIRA, 2005).

O método de Thornthwaite e Mather, apesar de ter sido desenvolvido na década de 1950, é ainda bastante empregado. O Banco de Dados Climáticos do Brasil, elaborado pela Embrapa Monitoramento por Satélite, por exemplo, emprega este modelo para o cálculo do balanço hídrico climatológico. O balanço hídrico climático realizado pelo INMET - Instituto Nacional de Meteorologia (disponível em <http://www.inmet.gov.br/html/agro.html>) também emprega esta metodologia. Outros exemplos de aplicação podem ser encontrados nos trabalhos de Fietz *et al.* (2001) e D'Angiolella *et al.* (1999).

Particularmente quanto à estimativa da evapotranspiração potencial, a equação proposta por Thornthwaite (1948) foi determinada empiricamente, ajustada em estudo para a América do Norte. No Rio Grande do Sul, contudo, esta metodologia tende a subestimar a evapotranspiração (DORFMAN, 1977 *apud* BURIOL *et al.*, 2014), mas nem por isso deixa de ser amplamente empregada (BURIOL *et al.*, 2014). A estimativa da evapotranspiração pelo método de Thornthwaite tem como principal vantagem o fato de necessitar apenas de dados de temperatura do ar e as coordenadas geográficas do local.

Modelo FAO

O método proposto por Allen *et al* (1998), no boletim nº56 da FAO, também emprega o conceito de CAD para limitar o conteúdo de água disponível no solo dentro do balanço hídrico realizado. O armazenamento de água o solo é calculado através de um balanço envolvendo o armazenamento no período anterior, a precipitação total do dia, o escoamento superficial, a irrigação, o fluxo do reservatório subterrâneo para a camada superficial do solo, a evapotranspiração real do dia e a percolação profunda. A FAO recomenda que a evapotranspiração de referência, caso determinada através de dados meteorológicos, utilize o método de Penman-Monteith para estimativa da mesma. Esta evapotranspiração é então multiplicada por um coeficiente, conforme a cultura e o grau de estresse hídrico. O método de balanço hídrico da FAO foi empregado, por exemplo, no trabalho de Conceição (2010), em Circular Técnica de Embrapa Uva e Vinho para cálculo do balanço hídrico em fruteiras.

A principal diferença entre os modelos de balanço hídrico propostos por Thornthwaite e Mather e pela FAO reside no cálculo da evapotranspiração potencial. Enquanto a estimativa da evapotranspiração utilizando o método empírico de Thornthwaite necessita apenas de dados de temperatura do ar, o método de Penman-Monteith requer uma grande quantidade de dados meteorológicos. Contudo, ainda que os métodos empíricos tendam a apresentar bons resultados em escala mensal, para a estimativa da evapotranspiração potencial em escala diária torna-se necessário a realização do balanço de energia, como através do método de Penman-Monteith.

2.3.3 Medição em campo de umidade do solo

Medições em campo de umidade do solo são ferramentas no manejo agrícola e permitem, além da estimativa da condição atual de disponibilidade de água no solo, uma verificação dos resultados do balanço hídrico e de previsões realizadas. Contudo, apesar da medida em campo possuir resultados mais confiáveis, os resultados possuem baixa representatividade espacial. A seguir, realiza-se uma breve descrição de alguns métodos para realização de medições em campo da umidade do solo, de acordo com Mendes (2006).

Um método de bastante utilidade para o manejo da irrigação no setor agrícola é o uso do tensiômetro para inferir sobre o teor de umidade no solo. O tensiômetro mede o potencial mátrico (resultante das forças adsorptivas e de capilaridade que atuam no solo (HILLEL, 1970)) e, indiretamente, mede o teor de umidade no solo. Ele é composto por um tubo de metálico ou plástico com um manômetro na extremidade superior e um local para adição de água, e uma cápsula porosa na extremidade inferior. A Figura 2.3 a seguir traz a representação esquemática de um tensiômetro. Através da cápsula porosa, em contato com o solo, a água desloca-se. Se a água presente no solo estiver em um potencial mais baixo que a água contida nos poros da membrana no tensiômetro, haverá deslocamento de água no sentido tensiômetro-solo, criando uma sucção no aparelho que será registrada no manômetro. Um solo mais úmido provocará um deslocamento no sentido inverso, com alteração da pressão medida no manômetro. Para fins de monitoramento contínuo e automático, sensores eletrônicos transdutores de pressão podem substituir o manômetro.

Outro método para medição em campo da umidade do solo é o uso da reflectometria no domínio do tempo, através do instrumento TDR (*Time Domain Reflectometer*). O TDR mede o tempo de reflexão de um pulso eletromagnético emitido por uma sonda, composta por duas hastes paralelas cravadas no solo. Desta forma, o TDR mede a constante dielétrica do solo. Sendo a constante dielétrica da água, igual à 80,4 à 293 K, muito superior à constante dielétrica do ar (1,0 à 293 K) ou dos constituintes do solo (3,0 a 7,0 à 293 K) (MENDES, 2006), é possível determinar o teor de umidade no solo através da medida de suas propriedades dielétricas. O TDR pode ser utilizado em sistema automatizados de irrigação, por permitir a aquisição de dados em tempo real. A Figura 2.4 mostra um TDR.

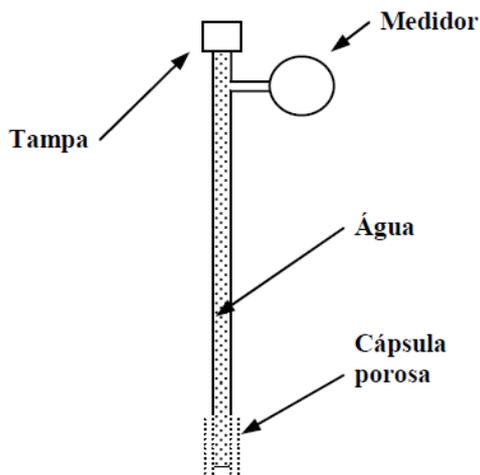


Figura 2.3. Representação esquemática de um tensiômetro.
 Fonte: Mendes, 2006.

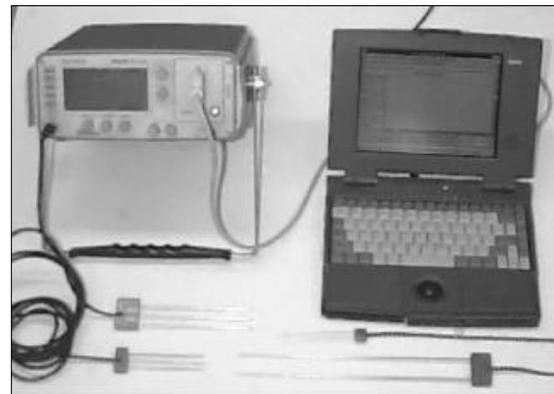


Figura 2.4. TDR (modelo Tektronix 1502 C) acoplado a computador.
 Fonte: Souza *et al.*, 2006.

A sonda de nêutrons baseia-se na inserção de uma fonte radioativa à profundidade desejada e de um detector. A fonte radioativa irá emitir nêutrons rápidos que, ao colidirem com os núcleos de hidrogênio na água presente no solo, perdem energia cinética, transformando-se em nêutrons moderados. Estes, por sua vez, são captados pelo detector, gerando pulsos elétricos. Este método apresenta erros relevantes sobretudo em solos ricos em outras fontes de hidrogênio que não a água, porém permite uma alta periodicidade de medição e a utilização em solos bastante secos, onde os tensiômetros não configuram uma opção, por estarem fora da faixa de operação do manômetro (ANDRADE *et al.*, 2001). Uma representação esquemática da sonda de nêutrons pode ser observada na Figura 2.5.

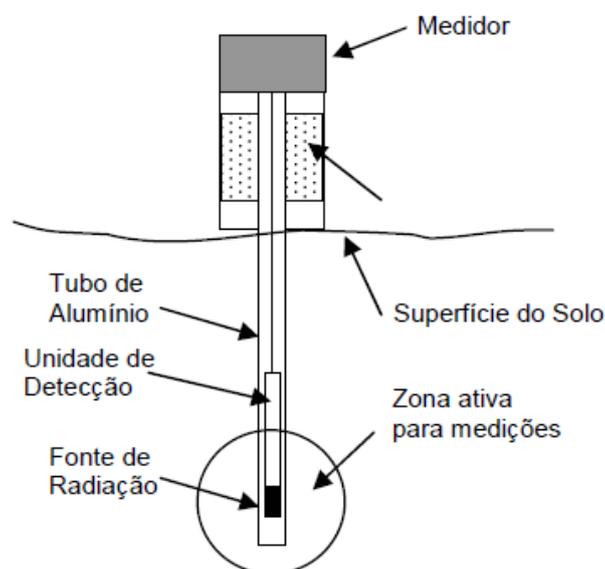


Figura 2.5. Representação esquemática da sonda de nêutrons.
 Fonte: Klar, 2004 *apud* Mendes, 2006.

2.3.4 Estimativa de umidade do solo a partir de sensoriamento remoto

Medidas em campo de umidade do solo fornecem resultados pontuais, não sendo representativas em escala espacial e, muitas vezes, temporal. Desta forma, técnicas para estimativa da umidade do solo através do sensoriamento remoto vêm sendo desenvolvidas. Sensoriamento remoto pode ser definido como a coleta de informações sobre um objeto sem contato direto com o mesmo. Nas ciências exatas e da terra, o termo está relacionado à obtenção de informações sobre a terra e a atmosfera através de instrumentos alocados em satélites (TUDelft, 2014). Tais técnicas permitem a realização de observações em grandes áreas e, uma vez que podem ser repetidas periodicamente na mesma área, possibilitam o acompanhamento da variação da umidade do solo ao longo do tempo.

Medidas realizadas entre as frequências do visível (VIS) (10^{15} Hz) e micro-ondas (10^9 Hz) são em geral as utilizadas para caracterizar e monitorar as variáveis de interesse em hidrologia (TUDelft, 2014), entre elas a umidade do solo. Contudo, dificuldades ainda existem na realização de medições acuradas deste parâmetro através do sensoriamento remoto.

Sensores ativos na faixa de micro-ondas baseados em instrumentos SAR (*Synthetic Aperture Radar* – Radar de Abertura Sintética) geram observações com resolução espacial melhor que sensores passivos como radiômetros, ou sistemas ativos não-SAR, como escaterômetros (por exemplo, QuikSCAT, ERS, Envisat e MetOp), atingindo resoluções da ordem de dezenas de metros, ao invés de dezenas de quilômetros. Contudo, sistemas SAR possuem uma dificuldade principal: como a umidade do solo, a rugosidade da superfície e a cobertura vegetal apresentam um efeito de retroespalhamento significativo e aproximadamente igual, as aplicações do sistema ficam limitadas a condições específicas de solo e cobertura vegetal ou exigem uma modelagem complexa para subtrair o efeito da vegetação. Ainda assim, dados provenientes de SAR são, atualmente, a principal fonte de informação sobre umidade do solo superficial (10-15 cm) (CEOS e ESA, 2014).

A primeira missão a satisfazer os principais requerimentos para realizar observações de umidade do solo para aplicações em modelagem hidrológica e

meteorológica foi a SMOS (*Soil Moisture and Ocean Salinity*), lançada em 2009 pela ESA (*European Space Agency*) e com duração prevista até 2017 (CEOS e ESA, 2014). A missão gera dados de livre acesso, com cobertura global. O tempo de revisita de uma mesma área varia entre um e três dias. O instrumento da missão, MIRAS (*Microwave Imaging Radiometer using Aperture Synthesis*) permite a detecção de um limite mínimo de 4% de umidade de solo em volume (ESA, 2014).

Recentemente lançada, a SMAP destaca-se por ser dedicada exclusivamente à medição de umidade do solo em escala global. A missão, conduzida pela NASA e pela CSA (*Canadian Space Agency*), foi lançada em janeiro de 2015 e deve se estender até junho de 2018. Os dados resultantes da missão, de acordo com a CEOS (2014), serão de livre acesso. O instrumento da missão inclui um radiômetro e um radar operando na banda L (sistema SAR), concebido de forma a realizar medições coincidentes da emissão da superfície e retroespalhamento, com a capacidade de medir as condições do solo através de uma cobertura moderada de vegetação. Os resultados do instrumento serão analisados para estimar as condições de umidade do solo e congelamento/degelo. A largura da faixa de varrimento das medições é de 1000 km, fornecendo uma cobertura global a cada três dias no Equador e dois dias em regiões de alta latitude no hemisfério norte (acima de 45°N) (NASA, 2014). Mais informações sobre a missão podem ser obtidas no endereço <http://smap.jpl.nasa.gov/>.

A Tabela A.2. disponível no ANEXO A traz dados sobre todas as missões, atuais e futuras, através das quais é possível obter informações sobre a umidade do solo. Esta tabela foi construída com dados disponibilizados pelo *Committee on Earth Observation Satellites*, através de sua base de dados. Mais informações sobre cada uma das missões podem ser obtidas em <http://www.eohandbook.com/>. No mesmo anexo, a Figura A.1. mostra ao longo do tempo o período de duração das missões atualmente em órbita. A Figura A.2 mostra as missões futuras.

Atualmente, existem 25 missões em órbita que possuem instrumentos capazes de realizar estimativas de umidade do solo superficial. Destas, apenas uma (Suomi NPP) não utiliza a faixa de micro-ondas, operando nas faixas do visível e infravermelho. Entre as missões futuras, há 12 missões aprovadas para o período entre 2015 e 2033; quatro planejadas e seis consideradas para o mesmo intervalo de tempo. Dentre as 47 missões, a sua maior parte é liderada e/ou tem a colaboração de agências norte-americanas (NASA,

USAF, NOAA) e europeias (ESA, EUMETSAT), porém agências de diversos outros países também possuem missões na área, como Japão, China, Índia, Alemanha, Itália, Espanha, Canada e Argentina.

Alguns estudos empregando dados de sensoriamento remoto para estimativa da umidade do solo são apresentados no item 3.2.1.

2.4 Bases de dados de umidade do solo

Dados observados de umidade do solo podem ser divididos em duas grandes categorias: medidos *in situ* ou obtidos através de técnicas de sensoriamento remoto. Uma base de dados de umidade do solo a partir de sensoriamento remoto é disponibilizada pela ESA, sendo de livre acesso para download através do endereço <http://www.esa-soilmoisture-cci.org/node/145>. A base cobre o período de 1978 a 2013 e foi construída empregando dados de sensores ativos e passivos na faixa de micro-ondas, resultando em três produtos:

- Conjunto de dados de sensores ativos; baseados em observações dos escaterômetros a bordo das missões ERS-1, ERS-2 e METOP-A. A base foi gerada pela Universidade de Viena (Technische Universität Wien - TUW);
- Conjunto de dados de sensores passivos; baseado nos dados dos sensores nas missões Nimbus 7 SMMR, DMSP SSM/I, TRMM TMI, Aqua AMSR-E, Coriolis WindSat e GCOM-W1 AMSR2. Elaborado pela Universidade de Amsterdam (Universiteit van Amsterdam - UvA) em colaboração com a NASA,
- Conjunto integrado de dados.

Dados de sensoriamento remoto, apesar de serem obtidos em ampla resolução espacial e temporal mais facilmente que dados de campo, requerem calibração e validação. Neste sentido, a *International Soil Moisture Network* (ISMN) (DORIGO *et al.*, 2011) é uma iniciativa internacional para criação e manutenção de uma base de dados de umidade do solo *in situ* global. O projeto é coordenado pelo *Global Energy and Water Exchanges Project* (GEWEX) em cooperação com o *Group of Earth Observation* (GEO) e o *Committee on Earth Observation Satellites* (CEOS). A base de dados previamente organizada através da *Global Soil Moisture Data Bank* (ROBOCK *et al.*, 2000) da Rutgers University opera agora em cooperação com a base da *International Soil Moisture Network*.

A rede completa contribuinte para a ISMN pode ser vista na Tabela A.1 no ANEXO A. São atualmente ao todo 2001 estações, distribuídas em 48 redes. Não há contribuição do Brasil para esta iniciativa. Da América do Sul, apenas o Chile participa da rede, porém, dispondo de apenas uma estação para medições em campo. A maior parte

das bases contribuintes, e com maior número de estações, encontra-se nos Estados Unidos (1206 estações), antiga União Soviética (337 estações), Europa (184 estações), China (117 estações) e Austrália (101 estações). Contribuem também Mongólia (44 estações), Índia (uma estação), Coreia (duas estações), havendo também algumas redes (ainda que com poucas estações) na África (8 estações ao todo). Os dados encontram-se disponíveis para visualização e download em <https://ismn.geo.tuwien.ac.at/data-access/>.

3. PREVISÃO

A previsão é a fase da simulação onde o modelo, após as fases de ajuste e verificação, é empregado para representar a saída do sistema a diferentes entradas (TUCCI, 2005). De acordo com o *Guide to Hydrological Practices* (WMO, 2009), as previsões podem ser classificadas, quanto ao prazo, como:

- *Previsões de curto prazo*: previsões realizadas para um horizonte de até dois dias;
- *Previsões de médio prazo*: para horizontes de previsão entre dois e dez dias;
- *Previsões de longo prazo*: previsões cujo horizonte é maior que dez dias.

Contudo, estes limites não são estáticos, e vêm evoluindo ao longo do tempo. A previsão de longo prazo pode ter um horizonte de alguns meses, ou mesmo englobar os três meses de uma estação, configurando assim uma previsão sazonal. Neste sentido, uma previsão de médio prazo pode abranger até algumas semanas.

O uso de modelos hidrológicos visando a realização de previsões requer que as entradas do mesmo sejam correspondentes ao horizonte de previsão. Considerando-se que características como uso e cobertura do solo mantêm-se constantes, tem-se que as principais variáveis de entrada sujeitas à alteração são a precipitação e a evaporação, que podem ser oriundas de previsões climáticas, realizadas para o horizonte de interesse. Contudo, a precipitação é a principal influência sobre a umidade do solo, e tem um impacto dominante sobre a sua variação (LIU & XIE, 2013), principalmente em bacias localizadas em climas tropicais e subtropicais, onde existe pouca ou nenhuma presença de neve. Desta forma, a principal variável a caracterizar uma previsão de umidade no solo passa a ser a precipitação, enquanto que, para os demais dados climáticos empregados no cálculo da evaporação, é admissível a representação dos mesmos através das suas médias históricas.

3.1 Previsão de precipitação

3.1.1 Características da previsão de precipitação

Quantitative Precipitation Forecast (QPF) são previsões quantitativas de precipitação, tipicamente derivadas de modelos meteorológicos (MELLER, 2012). Uma QPF é uma previsão de precipitação com espectro espacial e temporal que prevê a quantidade potencial de precipitação para uma região ou área específica (NOAA, 2014).

A QPF, quando não originária de modelos autorregressivos de análise das séries temporais de precipitação, redes neurais (ambos métodos estocásticos) ou *nowcasting* (esta última usada para previsões com um horizonte de até 6h), pode ser obtida através da previsão numérica do tempo (PNT), ou *numerical weather prediction* – NWP. A PNT é um método determinístico de obtenção da QPF, onde modelos matemáticos são construídos com o objetivo de representar o comportamento da atmosfera. O modelo numérico de predição calcula como o estado atual da atmosfera irá evoluir até o horizonte de previsão através da integração numérica no tempo das equações diferenciais que descrevem a mesma (MELLER, 2012).

Para uma antecedência de previsão superior a aproximadamente 10 dias a capacidade de previsão do modelo meteorológico diminui significativamente. Contudo, alterações nos valores médios mensais ou sazonais, ou seja, anomalias, ainda são passíveis de previsão. Isto é possível pois certas condições na superfície terrestre, com influência sobre o clima, são de lenta alteração, e podem ser empregadas como condição de contorno no modelo climático. A condição de superfície com efeito significativo sobre o clima mais importante é a temperatura da superfície do mar (*sea surface temperature* – SST) (IRI, s.d.). Para a realização da previsão climática podem-se considerar diferentes cenários de temperatura da superfície do mar: SST observada persistida ou SST prevista. Na corrente rotina de previsão do *International Research Institute for Climate and Society* – IRI, adota-se a seguinte classificação quanto à SST:

PSST - Persisted SST anomalies: As anomalias globais de SST são preditas como iguais à última observação. As anomalias de SST observadas são obtidas do mês prévio à previsão e adicionadas à média climatológica do mês, para obter assim os valores totais de SST usados como condições de contorno forçantes do modelo geral de circulação

atmosférica. Por exemplo, para uma previsão feita em agosto, as anomalias de SST observadas em julho são empregadas, e a estação prevista é set-out-nov. Previsões dinâmicas usando SST persistidas (PSST) como forçantes são usadas para rodadas com horizonte de apenas uma estação no futuro (três meses), pois os valores de SST podem sofrer alterações significativas em várias regiões para horizontes iguais ou superiores a quatro meses.

SSST - Scenario SST anomalies: Este termo se refere à existência de mais de um cenário para as anomalias de SST, obtidas através de previsões, neste caso. Três cenários de SST são definidos para a região tropical do oceano Pacífico, cada um previsto por uma fonte diferente: 1) modelo acoplado do NCEP (*National Centers for Environmental Prediction*); 2) modelo acoplado simplificado do *Lamont-Doherty Earth Observatory* (LDEO); e 3) modelo estatístico do NCEP/ *Climate Prediction Center's*. Para cada modelo atmosférico, um conjunto de rodadas (membros) é forçado com cada cenário de SST. A vantagem da existência de múltiplos cenários de SST é que a incerteza na sua previsão é incluída na simulação.

De conhecimento da condição de temperatura da superfície do mar, é possível então a realização a simulação climática empregando esta condição de SST como condição de contorno. A previsão é realizada através de um modelo geral de circulação atmosférica (*General Circulation Models - GCMs*), um modelo numérico capaz de representar os processos físicos que ocorrem na atmosfera, nos oceanos e na superfície terrestre. Um GCM utiliza uma grade tridimensional sobre o globo terrestre (vide Figura 3.1), com resolução horizontal comumente entre 250 km e 600 km, entre 10 e 20 camadas verticais na atmosfera e até cerca de 30 camadas nos oceanos (IPCC, 2013). Dentre as diversas saídas de um GCM, dentre elas pressão na superfície, vento, umidade, altura geopotencial, temperatura da superfície, encontra-se a precipitação.

Seja na previsão para curto ou longo prazo, as condições atuais da atmosfera são empregadas como condição inicial no modelo meteorológico/climático. O conhecimento do estado atual da atmosfera é, assim, de suma importância, e mesmo os menores erros nos dados observados, associados à própria limitação do modelo, fazem com que os resultados da previsão possam conter grandes erros (Met Office, 2014). Neste contexto, a previsão por conjuntos, ou *ensemble*, aparece como uma alternativa para avaliar as incertezas dos resultados das previsões.

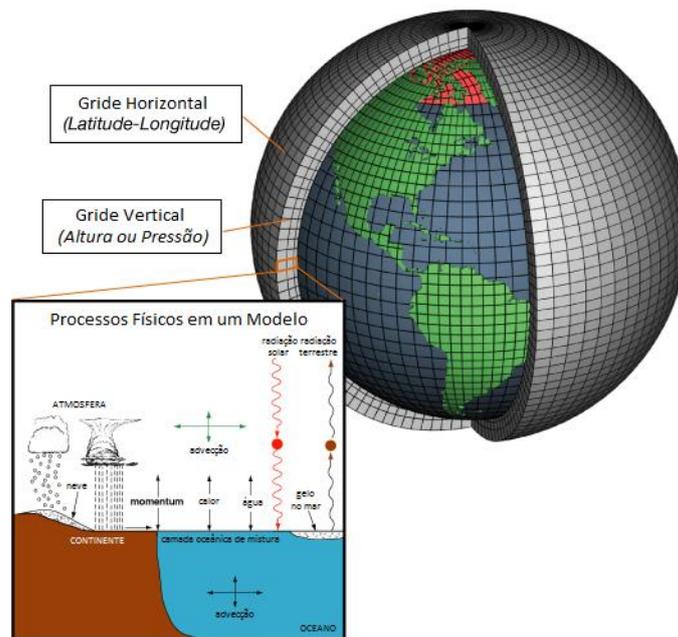


Figura 3.1. Representação esquemática de modelo climático empregado para previsão numérica do tempo.

Adaptado de NOAA (2012).

3.1.2 Previsão por ensemble

Sistemas de previsão por *ensemble* (EPS – *Ensemble Prediction Systems*) são sistemas de previsão numérica do tempo (PNT) onde, ao invés de se integrar o modelo uma única vez, o que produz uma previsão determinística, o modelo é rodado diversas vezes, cada uma com condições iniciais levemente diferentes. Também o modelo pode ser perturbado: o uso do mesmo modelo com diferentes conjuntos de parâmetros físicos é dito um *multi-physics EPS*, enquanto o uso de diversos modelos gera um *multi-model EPS* (sistema de previsão por conjunto de múltiplos modelos). Os diferentes tipos de perturbações (nas condições iniciais, nos parâmetros do modelo) ou o uso de mais de um modelo gera conjuntos capazes de avaliar diferentes tipos de incertezas: o *ensemble* gerado a partir de perturbações nas condições iniciais avalia a incertezas nestas condições; o *ensemble* produzido com alterações nos parâmetros quantifica a incerteza associada à parametrização adotada no modelo; já a abordagem multimodelos permite analisar a incerteza relativa a metodologia empregada na simulação.

Cada uma das soluções individuais da PNT participante do *ensemble*, ou seja, do conjunto de previsões, é dita um membro do conjunto (WMO, 2012). Um EPS normalmente contém um membro de controle da previsão, que é aquele onde não foram

inseridas perturbações, ou seja, aquele que se acredita representar a melhor estimativa das condições iniciais obtidas a partir das observações, e que corresponde então ao que seria a previsão determinística equivalente (MELLER, 2012).

Cada um dos membros irá gerar uma trajetória de condições da atmosfera diferente ao longo do período de previsão, com estados finais também diferentes (vide Figura 3.2). Havendo um adequado espalhamento dos membros, este possibilita a quantificação da incerteza da previsão, através da estimativa de uma função de distribuição de probabilidades (PDF - *probability distribution function*) da previsão (MELLER, 2012), o que viabiliza a produção de previsões probabilísticas (WMO, 2012).

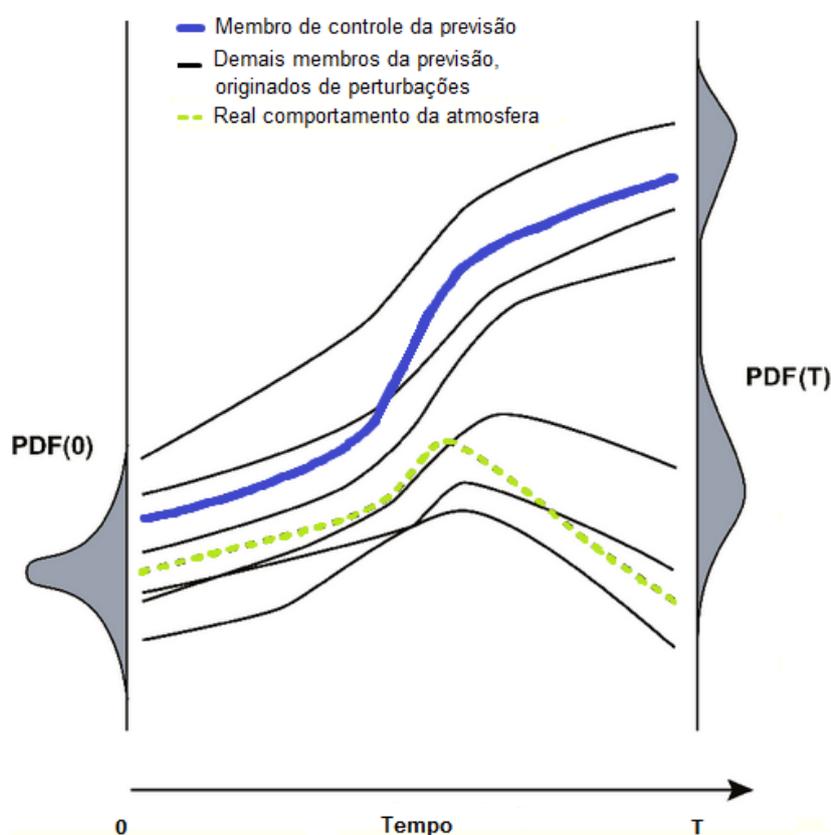


Figura 3.2. Esquema da previsão por *ensemble*.

PDF (0) representa a incerteza nas condições iniciais. A linha azul mais grossa representa a previsão determinística originada da melhor estimativa das condições iniciais, sendo assim o membro de controle da previsão. Um conjunto, ou *ensemble*, de membros originados de condições iniciais perturbadas para amostrar as incertezas iniciais pode ser usado para estimar a probabilidade dos diferentes estados futuros (PDF (T)), avaliando assim a incerteza da previsão. A linha verde tracejada indica o real comportamento da atmosfera.

Adaptado de Buizza, 2005.

No exemplo mostrado na Figura 3.2 observa-se que a previsão determinística (linha grossa azul) realizada com a que se acredita ser a melhor estimativa das condições iniciais não corresponde ao real comportamento futuro da atmosfera. O uso de perturbações nas condições iniciais gerou alguns membros cujo comportamento se aproxima do comportamento real, fazendo com que o sistema de previsão por ensemble tenha uma probabilidade diferente de zero de que o futuro estado da atmosfera atinja o valor futuro real (BUIZZA, 2005).

Contudo, ainda que o uso de todos os membros do conjunto abra mais opções de análise, configurando assim uma previsão totalmente probabilística, é também possível realizar uma previsão simples com informação complementar quanto à sua incerteza. Neste caso, a média dos membros pode ser usada como insumo nas diferentes aplicações que a previsão de precipitação ou outro fenômeno pode ter. A média simples dos membros da previsão, em geral, apresenta melhor desempenho que o membro de controle para os índices de avaliação (erro médio absoluto, raiz do erro quadrático médio, entre outros). Isto ocorre pois a média suaviza detalhes de difícil, ou até mesmo impossível previsão, e apresenta os elementos que podem ser previstos com mais confiança. Também por este motivo, a média dos membros raramente captura o risco de eventos extremos (WMO, 2012).

De uma forma geral, a utilização de uma previsão completamente probabilística fornece uma análise melhor e mais completa; porém o uso de uma previsão simples (a média dos membros, por exemplo) associada a um grau de incerteza facilita a tomada de decisão em relação à previsão totalmente probabilística, e pode trazer resultados mais confiáveis que uma previsão totalmente determinística, onde o modelo foi rodado apenas uma vez (WMO, 2012).

A análise de desempenho das previsões pode ser realizada através de uma série de medidas padrão de verificação comumente usadas em sistemas de previsão hidrológica. Tais medidas, de maneira geral, pode ser divididas em dois tipos: aquelas empregadas para avaliar os resultados de uma previsão determinística (ou uma previsão por ensemble transformada em uma previsão simples), e aquelas utilizadas para analisar previsões por conjuntos, totalmente probabilísticas. A Tabela 3.1 a seguir mostra as medidas mais comuns para verificação do desempenho de sistemas de previsão hidrometeorológica,

para previsões determinísticas e/ou probabilísticas. Mais informações sobre a verificação de previsões probabilísticas podem ser encontradas em Demargne *et al.* (2013).

Tabela 3.1. Métricas padrão para verificação comumente usadas em sistemas de previsão hidrometeorológica.

Atributo de qualidade	Métrica	Tipo de previsão	Eventos discretos?
Error Erro	Mean Absolute Error	Valor único	Não
	Mean Square Error	Valor único	Não
	Root Mean Square Error	Valor único	Não
	Mean Continuous Rank Probability Score (CRPS)	Probabilística	Não
	Brier Score	Probabilística	Sim
	Critical Success Index (or Threat Score)	Ambas	Sim
Bias Viés	Relative Mean Error (or Relative Bias)	Valor único	Não
	Frequency Bias	Ambas	Sim
Correlation Correlação	Pearson Correlation Coefficient	Valor único	Não
	Spearman Rank Correlation	Valor único	Não
Skill Destreza	Mean Absolute Error Skill Score	Valor único	Não
	Mean Square Error Skill Score	Valor único	Não
	Mean Continuous Rank Probability Skill Score	Probabilística	Não
	Brier Skill Score	Probabilística	Sim
	Equitable Threat Score (or Gilbert Skill Score)	Ambas	Sim
Reliability Confiança	Mean CRPS Reliability	Probabilística	Não
	Brier Score Reliability	Probabilística	Sim
	Reliability Diagram	Probabilística	Sim
	Rank Histogram	Probabilística	Sim
	Success Ratio	Ambas	Sim
Resolution Resolução	Mean CRPS Resolution	Probabilística	Não
	Brier Score Resolution	Probabilística	Sim
Discrimination Discriminação	Relative Operating Characteristic Score	Ambas	Sim
	Relative Operating Characteristic Diagram	Ambas	Sim
	Probability Of Detection (or Hit Rate)	Ambas	Sim
	Probability Of False Detection (or False Alarm Rate)	Ambas	Sim
Sharpness Agudeza	Forecast Frequency Histogram	Probabilística	Sim

Adaptado de Brown e Demargne (2013).

3.2 Simulação e previsão de umidade no solo

3.2.1 Alguns estudos já conduzidos

Cashion *et al.* (2005) ressaltam que valores acurados de umidade do solo são importantes para prever outras variáveis como vazão, infiltração e evapotranspiração. A umidade do solo pode ser usada em Modelos de Circulação Geral da Atmosfera (*Atmospheric General Circulation Model* – AGCM) na sua inicialização, como condição de contorno, ou mesmo como valor a ser verificado após a simulação (NIJSSEN *et al.*, 2001). Neste sentido, diferentes autores buscaram melhorar a estimativa de umidade do solo a ser usada como entrada em outros modelos ou avaliar sua influência sobre os mesmos como, por exemplo, Gevaerd e Freitas (2006) e Suarez *et al.* (2005), respectivamente. Para estas aplicações, tanto modelagens quanto observações de sensoriamento remoto podem ser usadas.

Diversos autores empregaram produtos de sensoriamento remoto para estimativa (observação) do teor de umidade do solo, analisaram ou compararam os resultados destes produtos, como Huza *et al.* (2014), Rossato (2010), De Jeu *et al.* (2014) e Liu *et al.* (2009). O trabalho conduzido por Liu *et al.* (2009) comparou os resultados de umidade do solo encontrados através do *Global Land Data Assimilation Model System* (GLDAS) para a bacia Murray Darling, na Austrália, com aqueles provenientes do sensor AMSR-E do satélite Aqua, da NASA. O GLDAS compreende, entre outros, o *Community Land Model* (CLM) e o esquema de superfície NOAH, que promovem uma caracterização temporal e espacial consistente do ciclo hidrológico e são usados neste estudo. O AMSR-E (*Advanced Microwave Scanning Radiometer – Earth Observation System*) é um sensor de baixa frequência dentro da faixa de micro-ondas, e por isso, bastante propício à estimativa de umidade do solo, pois consegue fornecer informações de conteúdo de água na primeira camada de solo, e não apenas na sua superfície. Os produtos derivados do GLDAS possuem resolução espacial de 0,25 graus, semelhante àquela dos produtos de sensoriamento remoto. Os resultados obtidos através do AMSR-E e do GLDAS mostraram padrões sazonais semelhantes, apresentando algumas diferenças em regiões ou épocas do ano específicas. Os resultados do trabalho indicam que ambas as metodologias, simulação e sensoriamento remoto, podem ser utilizadas para representar a umidade do solo (LIU *et al.*, 2009).

Contudo, a representação do estado futuro da umidade do solo requer a realização de simulações (enquanto o sensoriamento remoto constitui uma observação). Estudos direcionados à simulação e previsão de umidade do solo através do uso de modelos hidrológicos são bem mais escassos que aqueles destinados à previsão de vazões, por exemplo. Muitos dos trabalhos realizados com o objetivo de analisar a umidade do solo, especificamente, abordam tentativas de avaliar as diferentes metodologias para sua modelagem e melhorar a simulação desta variável, tais como os estudos conduzidos por Liu e Xie (2013), Sípek e Tesar (2013), Guo *et al* (2005), Saldanha (2009) e Nijssen *et al.* (2001).

Liu e Xie (2013), no estudo “*Improving simulation of soil moisture in China using a multiple meteorological forcing ensemble approach*”, empregaram o LSM (*Land Surface Model*) CLM3.5 (*Community Land Model* versão 3.5) sobre a China continental. Quatro diferentes conjuntos de forçantes meteorológicas foram utilizadas nas simulações. Os quatro conjuntos de umidade do solo simulados foram então agrupados, empregando-se para tanto uma média simples ou ponderação bayesiana de modelos (BMA – *Bayesian Model Averaging*), com vistas a diminuir as incertezas associadas às simulações. Os resultados, quando comparados aos dados observados em campo, mostraram que as quatro simulações, individualmente, representaram a variabilidade espacial e sazonal da umidade do solo, sem que nenhuma das quatro forçantes apresentasse resultados superiores em todas as regiões da área de estudo. A média simples das quatro simulações de umidades do solo, na maioria dos casos, apresentou resultados superiores quando comparadas ao uso dos membros individuais, porém não em todas as regiões. A ponderação bayesiana de modelos apresentou um resultado melhor que a média simples, mostrando-se superior a todos os membros individuais na maior parte das regiões. Os resultados encontrados por Liu e Xie (2013) indicam que o uso da média dos resultados da simulação por conjuntos pode ser melhor que o uso dos membros individualmente. A utilização da ponderação bayesiana de modelos pode trazer resultados ainda melhores, porém requer a existência de dados observados de umidade do solo. Ainda, os autores ressaltam que a incerteza na simulação de umidade do solo pelo LSM é, sobretudo, derivada da incerteza das forçantes meteorológicas usadas, além da incerteza nos parâmetros do modelo.

Sípek e Tesar (2013) compararam o uso de um modelo hidrológico (SWIM - *Soil and Water Integrated Model*) (KRYSANOVA *et al.*, 2005) ao uso de um modelo conceitual proposto por Laio *et al.* (2001), que considera a coluna de solo como um reservatório. A área de estudo é a bacia do rio Liz (República Checa), e possui pouco menos que 100 ha, coberta com floresta. A área possui medições em campo de umidade do solo realizadas com tensiômetro. O modelo SWIM foi calibrado para as vazões diárias usando um período de dois anos consecutivos, 2009 e 2010. O modelo de Laio foi calibrado para o mesmo período de tempo, porém usando os valores de umidade do solo, uma vez que o modelo não foi concebido para estimar fluxo superficial. Ambos os modelos foram capazes de simular a variação de umidade do solo de forma satisfatória, conforme os autores, com um desempenho levemente melhor por parte do modelo SWIM. O modelo Laio poderia ser melhorado através de uma estimativa mais aprimorada da evapotranspiração potencial, enquanto o SWIM tem incertezas associadas às taxas de percolação e evapotranspiração (SÍPEK & TESAR, 2013).

O trabalho de Guo *et al.* (2005) teve por objetivo explorar a melhoria na qualidade da umidade do solo simulada através do uso da média simples de 17 diferentes produtos de umidade do solo (W&M, CPC, GOLD, ERA, R1, R2, IIS, ISBA, SSiB, LaD, CLM, VISA, NSIPP, NOAH, SWAP, MOSES, MOSC), 14 deles de esquemas de superfície desacoplados e três de reanálise de modelos acoplados superfície-atmosfera. Isto se justifica pois, além das condições iniciais e dos modelos climáticos, também os esquemas de superfície possuem grandes incertezas associadas (grande número de variáveis, dados de observações esparsos, dificuldade na modelagem do sistema, entre outros). As simulações foram realizadas para o período entre 1986 e 1995, e os resultados foram comparados com observações em cinco diferentes regiões do mundo: Estados Unidos, China, Índia, Mongólia e na antiga União Soviética. Foram avaliadas as capacidades de avaliar a coluna de umidade do solo, a sua variação ao longo do ano e a variabilidade interanual. Em todas as regiões, o uso de múltiplos modelos foi superior à maioria dos produtos oriundos de modelos individuais. O estudo também indicou que, em geral, a inclusão de um produto com alta correlação aos dados observados ou com menor erro traz uma clara melhora na análise; contudo, a inclusão de um produto com desempenho relativamente ruim não traz aparentes prejuízos.

O estudo “*Global Retrospective Estimation of Soil Moisture Using the Variable Infiltration Capacity Land Surface Model, 1980-93*”, de Nijssen *et al.* (2001), apresentou o trabalho conduzido utilizando o modelo VIC (*Variable Infiltration Capacity*) para a simulação de umidade do solo, para o período entre 1979 e 1993. O primeiro ano de simulação foi usado como período de *spinup*, tendo seus resultados descartados, de forma a limitar os efeitos das condições iniciais usadas para implementar o modelo. A simulação empregou dados diários observados de precipitação e mínimos e máximos de temperatura, em uma grade de 2° x 2°, cobrindo a área continental terrestre, à exceção da Antártica e da Groenlândia. Dados meteorológicos do período em estudo, calculados como função da precipitação diária e da temperatura máxima e mínima diária, foram empregados como forçantes ao modelo. Os resultados de umidade do solo simulados foram bons, quando comparados a dados observados provenientes de duas bases de dados, uma em Illinois, Estados Unidos (dados para o período entre 1981 e 1996), e outra na Eurásia central (1978-1985), quanto ao ciclo anual e a representação de padrões espaciais. Contudo, a umidade simulada média mostrou-se menor que a observada. Além disso, a umidade do solo observada possui uma persistência interanual maior que a simulada, o que pode ser devido à interação entre camadas superficiais e mais profundas de solo não ter sido devidamente representada pelo modelo VIC (NIJSSEN *et al.*, 2001).

Todos os estudos supracitados são simulações com vistas a reproduzir dados observados de umidade no solo, não havendo o objetivo de produzir uma previsão ou *hindcast* da umidade no solo. Buscando realizar uma previsão de umidade, foram encontrados os estudos conduzidos por Saldanha (2012) e o sistema o *Surface Water Monitor*.

Saldanha (2012) (ver também Saldanha, 2009) desenvolveu um estudo de previsão de longo prazo de umidade do solo através do módulo de balanço de água no solo do MGB-IPH (COLLISCHONN, 2001). O objetivo do estudo foi avaliar se a previsão de longo prazo de umidade do solo pode ser empregada como subsídio no planejamento agrícola. Empregaram-se para tanto previsões de precipitação do modelo global CFS (*Climate Forecast System*), com resolução espacial de aproximadamente 250 km, realizadas com periodicidade mensal para o horizonte de até 6 meses. Empregou-se no estudo a média de 14 membros do *ensemble* de previsões gerado. Os resultados da previsão de umidade do solo saídas do MGB-IPH foram então, através de um modelo de

regressão linear, usados para realizar uma previsão da produtividade da soja na área em estudo. Os resultados da previsão de umidade do solo foram considerados satisfatórios, quando comparados aos encontrados na simulação de aferição, realizada com dados observados de precipitação, indicando que a previsão de longo prazo de umidade do solo pode ser empregada no planejamento agrícola.

Atualmente, existe um sistema operacional de previsão de umidade do solo para a área continental dos Estados Unidos, o *Surface Water Monitor* (SWM). A previsão é realizada através do modelo VIC, com horizontes de um, dois e três meses. As previsões usam dados meteorológicos históricos, do mesmo período do ano de interesse, ao invés de previsões dos mesmos, e o modelo hidrológico é inicializado com informações do estado atual quanto à, principalmente, umidade do solo e equivalente em água de neve. Mais informações sobre o *Surface Water Monitor*, projeto conduzido pela Universidade de Washington, podem ser obtidas em Wood (2008) e na página <http://www.hydro.washington.edu/forecast/monitor/outlook/index.shtml>. Um trabalho semelhante de previsão de umidade do solo através do modelo VIC é realizado pela Universidade de Princeton, Estados Unidos, para horizontes incluindo 72 horas, 15 dias, e 6 meses. Mais informações podem ser encontradas em <http://hydrology.princeton.edu/forecast/current.php>.

3.2.2 Considerações sobre os estudos já realizados

Analisando-se os estudos já realizados, percebe-se que diferentes enfoques podem ser empregados na tentativa de melhorar a simulação da umidade do solo, através diferentes modelos e abordagens dentro do processo de simulação. A existência de poucos estudos dedicados especificamente à previsão de longo prazo de umidade do solo reflete a dificuldade associada a este tipo de previsão. Além das grandes incertezas relacionadas as metodologias empregadas para a simulação desta variável, a escassez de dados observados de umidade que permitam a calibração dos modelos é, também, um desafio a ser superado. Apesar disso, Wood (2008) e Saldanha (2012) já realizaram estudos voltados precisamente para a previsão de umidade do solo, trazendo diferentes contribuições para a área. O trabalho aqui realizado visa contribuir neste cenário. As principais diferenças entre o estudo agora conduzido e os já realizados residem nos tipos

de dados empregados, no período simulado e/ou na metodologia de simulação hidrológica.

O *Surface Water Monitor* (SWM) (WOOD, 2008) emprega o modelo VIC (versão mais recente descrita por Gao *et al.*, 2010), onde o solo é representado através de três camadas, diferentemente do MGB-IPH, que trabalha com apenas uma camada de solo. O modelo emprega o conceito de curva de infiltração variável, conforme descrito por Zhao *et al.* (1980). As duas camadas mais superficiais de solo não admitem fluxo lateral, sendo o movimento da água descrito pela Equação de Richards unidimensional. A camada superficial possui capacidade de armazenamento bastante limitada, de forma que o escoamento superficial é calculado de forma unificada para as duas primeiras camadas de solo, conforme descrito por Liang *et al.* (1996). As previsões de umidade no solo realizadas pelo SWM empregam dados meteorológicos médios históricos, incluindo a precipitação. O estudo aqui realizado, visando identificar a existência de períodos mais secos ou mais úmidos que o normal para determinado mês, emprega previsões de precipitação oriundas de modelos gerais de circulação atmosférica.

A previsão de umidade do solo realizada por Saldanha (2012), assim como o estudo agora conduzido, empregou o MGB-IPH para realização da simulação hidrológica. À época do estudo, o MGB-IPH era discretizado em células quadradas, ao contrário da versão atual, que tem por unidade a minibacia. Contudo, a principal diferença entre o estudo anterior e o atual reside na previsão de precipitação empregada como entrada no modelo, e nas consequências que estas diferenças acarretam na análise dos resultados. A previsão conduzida por Saldanha (2012) empregou a média de 14 membros como previsão de precipitação, sendo realizada para três horizontes: 1, 3 e 6 meses. As séries de previsão de precipitação foram fornecidas pela Universidade de Princeton, com a devida correção de erros sistemáticos já realizada. O estudo agora realizado faz previsões para os mesmos três horizontes. Cada horizonte, contudo, agora envolve 69 previsões de precipitação: 24 previsões correspondentes aos 24 membros do modelo CCM3v6; 12 previsões relativas aos 12 membros do modelo ECPC; 30 previsões relativas aos 30 membros do modelo GFDL; e uma previsão associada à média do *ensemble* de previsões de precipitação de cada um dos três modelos empregados. Para cada horizonte, cada uma das 69 previsões de precipitação originou uma previsão individual de umidade do solo. A existência destes conjuntos de previsão permite que os resultados sejam apresentados não

como uma previsão simples, mas como uma previsão associada à uma probabilidade. Os resultados das previsões para cada conjunto de cada modelo são ainda comparados à previsão realizada com a média de cada modelo. Além disso, a utilização de diferentes modelos permite a formação de um *ensemble* de modelos, que também traz consigo uma informação de probabilidade.

As previsões de precipitação empregadas no estudo atual foram obtidas através da base de dados do IRI - *International Research Institute for Climate and Society*, de livre acesso para download. Além disso, a correção do viés existente nestas previsões faz parte da metodologia aqui proposta. Desta forma, a obtenção dos dados necessários para a aplicação da metodologia de previsão descrita no próximo capítulo não envolve a solicitação direta à alguma instituição ou pessoa. Sendo assim, esta metodologia é facilmente replicável, requerendo apenas acesso à internet para obtenção de todos os dados necessários e softwares utilizados.

Desta forma, as principais contribuições deste trabalho à área de previsão de umidade do solo residem na avaliação da previsão resultante de diferentes conjuntos de previsão de precipitação, no caráter probabilístico adicionado à previsão, e na estruturação de uma metodologia passível de ser replicada com facilidade.

4. MODELO DE PREVISÃO DE LONGO PRAZO DE UMIDADE DO SOLO

4.1 Estrutura do trabalho

A Figura 4.1 mostra uma representação esquemática da metodologia empregada no estudo aqui realizado. O estudo apresenta três etapas principais, a saber:

- Calibração do modelo hidrológico: Nesta etapa, são ajustados os parâmetros do modelo hidrológico, de forma a que este represente o ciclo hidrológico na bacia em estudo.
- Verificação da calibração: O modelo hidrológico é verificado quanto às vazões para um período diferente daquele em que foi realizada a calibração.
- Previsão: A etapa de previsão constitui-se naquela em que o modelo hidrológico calibrado e verificado é empregado para a estimativa da umidade do solo no futuro. Estas previsões são realizadas empregando-se diferentes conjuntos de previsão de precipitação por *ensemble*. São realizadas previsões de umidade do solo de longo prazo (horizonte de um, três e seis meses) através do módulo de balanço hídrico do modelo hidrológico MGB-IPH. Os resultados das previsões de umidade do solo são comparados à umidade do solo pseudo-verdadeira, estimada através do MGB-IPH com a precipitação observada no período de simulação.

Considera-se que o modelo hidrológico, calibrado e verificado com dados observados de vazão, representa apropriadamente o ciclo hidrológico na bacia em estudo, incluindo aí a umidade do solo. Os resultados da previsão de umidade do solo são analisados em relação à umidade do solo pseudo-observada. Neste sentido, as incertezas associadas à modelagem hidrológica em si e a parametrização do modelo não são analisadas, apenas aquelas relacionadas às incertezas da previsão meteorológica. A verificação do desempenho do modelo diretamente quanto à umidade do solo prevista exige a existência de uma série de dados observados de umidade do solo, medidos em campo. Na ausência destes, o modelo hidrológico é então calibrado e verificado com os dados observados de vazão, disponíveis. Procedimento semelhante foi realizado no estudo conduzido por Sípek e Tesar (2013), onde o modelo SWIM foi calibrado com

dados de vazão para a condução de uma simulação com o objetivo de analisar a umidade do solo.

A área de estudo compreende a bacia do rio Ijuí, sub-bacia do rio Uruguai, aproximadamente entre as latitudes 28°S e 29°30'S as longitudes 53°W e 55°30'W. As previsões de precipitação são disponibilizadas em escala mensal, ou seja, como a taxa média de precipitação por dia, para cada mês. É adotada uma distribuição da precipitação total mensal ao longo de cada mês, e o modelo hidrológico é implementado com passo diário. Em seguida, os resultados são agregados para valores mensais (umidade do solo média do mês), e nesta base avaliados.

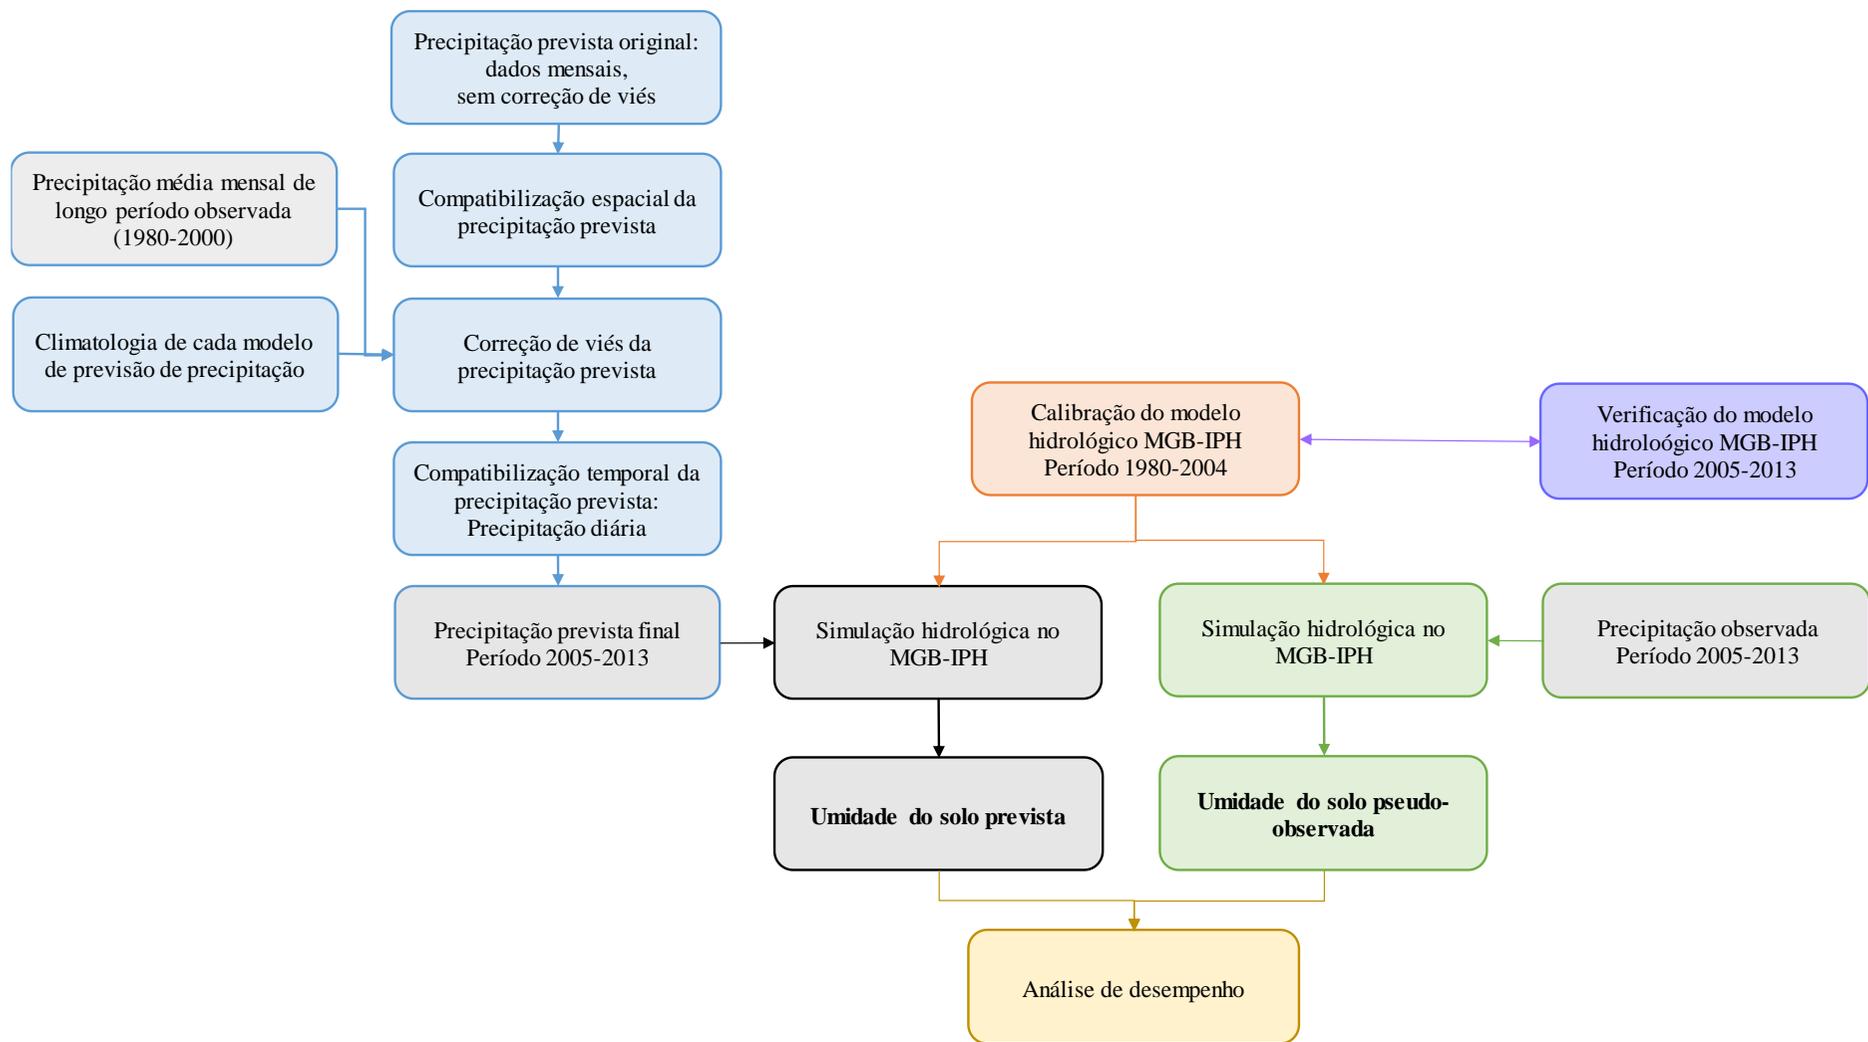


Figura 4.1. Fluxograma representativo da metodologia geral da previsão de umidade do solo.

4.2 Modelo de balanço hídrico no solo

O modelo de balanço hídrico no solo usado neste estudo é o módulo de balanço de água no solo do MGB-IPH (COLLISCHONN, 2001; COLLISCHONN *et al.*, 2007). O modelo vem sendo amplamente usado em bacias de grande escala e apresentou bons resultados para previsão de umidade do solo no trabalho realizado por Saldanha (2009). Neste estudo prévio, o MGB-IPH possuía uma discretização diferente da atual, com células quadradas. Hoje o modelo usa minibacias, delimitadas a partir dos trechos da rede de drenagem (PAIVA, 2009).

O MGB-IPH é considerado apropriado para realizar a previsão de umidade do solo pois, apesar de estimar a umidade do solo indiretamente (como resultado de um balanço hídrico) é um modelo hidrológico calibrado e verificado com dados observados (de vazão, precipitação e variáveis meteorológicas como vento e insolação). O modelo já foi aplicado em diversas bacias do Brasil, como pode ser observado nos trabalhos desenvolvidos por Collischonn (2006); Silva *et al.* (2007); Ribeiro Neto *et al.* (2008), Adam (2011); Collischonn *et al.* (2011), entre outros. Além disso, apesar de o MGB-IPH ter sido concebido como um modelo chuva-vazão, os demais componentes do ciclo hidrológico são também apropriadamente representados. Paz *et al.* (2014) avaliaram o efeito da representação dos processos hidrológicos verticais na simulação de inundações no Pantanal. Já Ruhoff *et al.* (2013) compararam, em dois locais no Rio Grande do Sul, a evapotranspiração estimada através de sensoriamento remoto usando dados do *Moderate Resolution Imaging Spectroradiometer* (MODIS) pelo algoritmo MOD16, estimada através medições em solo de fluxos de energia, e calculada através do MGB-IPH.

4.2.1 Modelo de Grandes Bacias: MGB-IPH

No MGB-IPH são simuladas as etapas de balanço de água no solo, evapotranspiração, interceptação, escoamento superficial, subsuperficial e subterrâneo e escoamento na rede de drenagem, para um intervalo de tempo diário ou menor. A bacia em estudo é discretizada em unidades menores, minibacias, cada uma com um trecho de rio. Áreas de comportamento hidrológico similar, no que concerne os tipos de solo e cobertura vegetal, são agrupadas em Unidades de Resposta Hidrológica (URH). Os processos hidrológicos verticais (interceptação, evapotranspiração, balanço de água no

solo, geração de escoamento superficial e subsuperficial e percolação no aquífero) são simulados para cada URH, em cada minibacia. A evapotranspiração é simulada através do método de Penman-Monteith, conforme apresentada em Shuttleworth (1993). Os volumes gerados nas URHs são somados e propagados em nível de minibacia, e posteriormente pela rede de drenagem, através do método de Muskingum-Cunge da forma descrita em Tucci (1998). Os parâmetros relacionados a características físicas da bacia são, de maneira geral, obtidos através do modelo digital de elevação (MDE) e mapas digitalizados (PAIVA, 2009). Os demais parâmetros são calibrados, manual e automaticamente, esta última através do algoritmo de otimização global multi-objetivo MOCOM-UA (YAPO *et al.*, 1998).

O módulo de balanço de água no solo do MGB-IPH é realizado com base na geração de escoamento superficial por excesso da capacidade de armazenamento, além de haver uma relação probabilística entre a umidade do solo e a fração de área do solo saturada (COLLISCHONN, 2001). A equação (5) e a Figura 4.2 a seguir mostram como é realizado cálculo do balanço hídrico no solo.

$$W_{i,j}^t = W_{i,j}^{t-1} + (P_{i,j} - ET_{i,j} - Dsup_{i,j} - Dint_{i,j} - Dbas_{i,j} + Dcap_{i,j}) \quad (5)$$

Onde:

$W_{i,j}^t$ [mm]: Volume de água armazenado na camada superficial do solo no final do período de tempo, na minibacia i, na UHR j;

$W_{i,j}^{t-1}$ [mm]: Volume de água armazenado na camada superficial do solo no início do período de tempo, na minibacia i, na UHR j;

$P_{i,j}$ [mm]: Precipitação que chega ao solo, ou seja, não interceptada, na minibacia i, na UHR j;

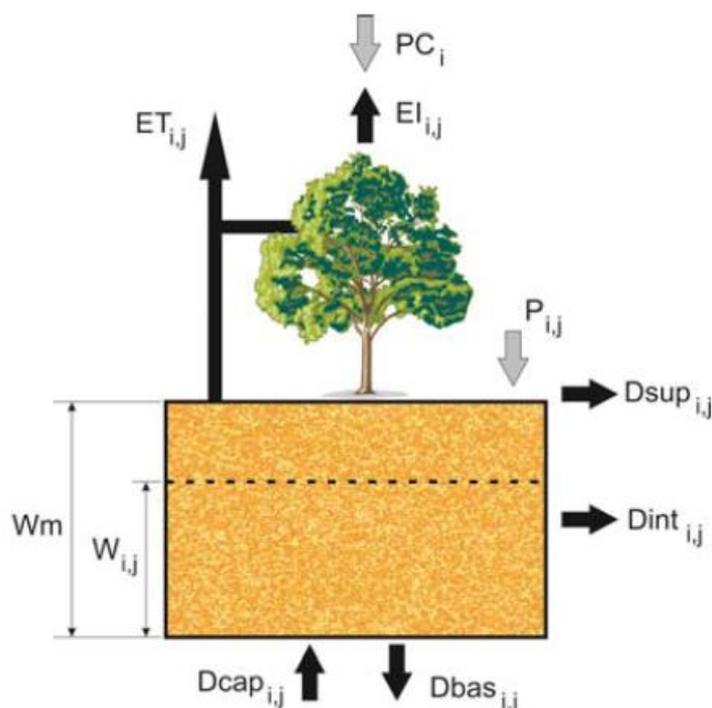
$ET_{i,j}$ [mm]: Evapotranspiração na minibacia i, na UHR j;

$Dsup_{i,j}$ [mm]: Escoamento superficial na minibacia i, na UHR j;

$Dint_{i,j}$ [mm]: Escoamento subsuperficial na minibacia i, na UHR j;

$Dbas_{i,j}$ [mm]: Escoamento subterrâneo, ou seja, o volume percolado ao aquífero na minibacia i, na UHR j;

$Dcap_{i,j}$ [mm]: Fluxo ascendente do aquífero, do reservatório subterrâneo, à camada superficial de solo na minibacia i, na UHR j.



**Figura 4.2. Termos do balanço de água no solo no modelo MGB-IPH para uma URH. W_m [mm] é o armazenamento máximo da camada de solo. PC [mm] é a precipitação sobre a cobertura vegetal. EI [mm] reaperesenta a evaporação real da lâmina interceptada. Os demais termos possuem mesmo significado que o utilizado na equação (5).
Fonte: Collischonn, 2007.**

A metodologia utilizada no módulo de balanço de água no solo é semelhante à do modelo LARSIM (BREMICKER, 1998), e é também empregada no modelo ARNO (TODINI, 1996). A geração de escoamento superficial (D_{sup}) é realizada considerando que existe uma relação entre o armazenamento no início do intervalo de tempo e a porcentagem de área saturada, conforme proposto por Todini (1996) e empregado no modelo ARNO. A geração de escoamento superficial ocorre somente em áreas saturadas, conforme um processo Dunniano. Estas áreas são variáveis em função do nível de saturação da bacia. É empregada uma relação probabilística entre a umidade do solo e a fração de área saturada, onde a infiltração é nula (COLLISCHONN, 2001). O escoamento subsuperficial é obtido através de uma relação não linear com o armazenamento de água no solo, enquanto o volume percolado ao aquífero é uma função linear do mesmo. Também o fluxo ascendente do aquífero é uma função do armazenamento atual.

Uma descrição mais completa do MGB-IPH pode ser encontrada no ANEXO B, em Collischonn (2001) e Paiva (2009). Informações sobre o modelo também podem ser encontradas na página do Grupo de Pesquisa de Hidrologia de Grande Escala do IPH-UFRGS, disponível em: <http://www.ufrgs.br/hge/mgb-iph/>.

Foi empregada, neste estudo, a versão tradicional do MGB-IPH, e não a rotina de previsão, uma vez que a assimilação das variáveis representa alterações apenas a curto prazo. Uma vez que o horizonte mais curto de previsão é de um mês, o efeito do uso desta rotina alternativa (rotina de previsão) não seria observado.

A aplicação do MGB-IPH requer um banco de dados SIG e séries históricas de dados de precipitação, vazão e dados climáticos. Quanto às séries históricas, em um primeiro momento, foram buscados todos os dados/estações existentes na área de estudo. Após análise da qualidade e extensão das séries de dados existentes, foram selecionados os postos a serem, de fato, utilizados no estudo. Quanto aos dados SIG, estes são empregados na etapa de pré-processamento do MGB-IPH, realizada com o programa PrePro-MGB. A saída do PrePro-MGB é um arquivo com informações da bacia, a ser empregado na simulação com o MGB-IPH propriamente dito. Mais informações sobre a integração do MGB-IPH com Sistema de Informação Geográfica podem ser obtidas em Fan e Collischonn (2014).

4.2.2 Períodos de calibração, verificação e previsão

Conforme disponibilidade de dados e períodos de interesse, são definidos os períodos de calibração do modelo, verificação e previsão. Desta forma, estabeleceu-se o período entre 01/01/1980 e 31/12/2004 como o período de calibração, e o período entre 01/06/2005 e 31/12/2013, como o período de verificação e previsão.

4.2.3 Calibração e verificação do modelo

A verificação do modelo, no caso o MGB-IPH, é realizada para um período diferente daquele utilizado para a calibração dos parâmetros do modelo. Tanto para a fase de calibração como a de verificação, são empregadas como medidas de desempenho, além da análise visual das curvas de permanência e dos hidrogramas gerados, o erro de volume dos hidrogramas (ΔV), o Coeficiente de Eficiência de Nash-Sutcliffe (NS) e o Coeficiente de Eficiência de Nash-Sutcliffe dos logaritmos das vazões (NS_{\log}). As equações (6) a (8) mostram estas medidas. Pelo objetivo do estudo ser uma previsão de umidade do solo, calculada através do módulo de balanço de água no solo do MGB-IPH, o erro do volume

nos hidrogramas é o índice de maior importância nas etapas de calibração e verificação, além de análise visual da curva de permanência de vazões.

- Coeficiente de Nash-Sutcliffe (NS): O coeficiente de Nash-Sutcliffe tem 1 como valor máximo, que representa um ajuste perfeito entre as vazões calculadas e observadas. Seu valor é fortemente influenciado pelos erros nas vazões máximas, e é calculado como segue:

$$NS = 1 - \frac{\sum(Q_{obs}(t) - Q_{cal}(t))^2}{\sum(Q_{obs}(t) - \overline{Q_{obs}})^2} \quad (6)$$

- Coeficiente de Nash-Sutcliffe para os logaritmos das vazões (NS_{log}): Assim como o coeficiente de Nash-Sutcliffe (NS), tem 1 como valor máximo, mas é mais influenciado por erros nas vazões mínimas que nas máximas.

$$NS_{log} = 1 - \frac{\sum(\log(Q_{obs}(t)) - \log(Q_{cal}(t)))^2}{\sum(\log(Q_{obs}(t)) - \overline{\log(Q_{obs}(t))})^2} \quad (7)$$

- Relação entre volume observado e calculado (ΔV): Representa a diferença relativa entre a soma das vazões observadas e calculadas, e é útil para observar se as perdas de água por evapotranspiração estão corretamente calculadas.

$$\Delta V = \frac{\sum(Q_{cal}(t)) - \sum(Q_{obs}(t))}{\sum(Q_{obs}(t))} \quad (8)$$

Onde:

$Q_{obs}(t)$: Vazão observada no tempo t;

$Q_{cal}(t)$: Vazão calculada no tempo t;

$\overline{Q_{obs}}$: Média das vazões observadas;

$\overline{\log(Q_{cal}(t))}$: Média do logaritmo das vazões observadas.

4.3 Previsão de precipitação

4.3.1 Dados disponíveis e selecionados

A principal fonte de dados de previsões de precipitação (entre outras variáveis) encontrada foi o IRI – *International Research Institute for Climate and Society*, parte do *Earth Institute*, na Universidade de Columbia, Estados Unidos. A previsão climática é realizada através de diferentes modelos de circulação geral atmosférica (AGCMs), sendo processada no instituto original (responsável pelo AGCM) e repassada ao IRI, ou no próprio IRI. Estes modelos são rodados diversas vezes, formando um ensemble (conjunto de previsões) para cada modelo, com um ou mais possíveis cenários para a temperatura da superfície do mar (*sea surface temperature* - SST) global.

O IRI possui disponíveis para download dados de 17 modelos ou versões de modelos. Dentre modelos disponíveis, foram selecionados os três que se adequam ao estudo aqui realizado, sobretudo com relação ao período de previsões disponibilizado e ao horizonte das previsões. Informações sobre todas as 17 bases de dados disponibilizadas pelo IRI são apresentadas no ANEXO C.

As três bases de dados aqui selecionadas possuem aproximadamente 10 anos de previsões, para o período comum de dezembro/2004 a julho/2014. Além disso, estas bases possuem um horizonte de previsão de 15 dias a 6,5 meses, o que se adequa às necessidades do estudo. Selecionou-se para as três bases a condição de temperatura da superfície do mar proveniente de três cenários (SSST), e não aquela persistida, tendo em vista que as previsões realizadas para um horizonte mais amplo utilizam este tipo de forçantes. Os dados dos modelos COLA 2.2, ECHAM 4.5 e NSIPP-1, que por suas características também seriam aplicáveis neste estudo, apresentavam acesso restrito no IRI na época de consulta, não estando, desta forma, disponíveis para download. A Tabela 4.1 mostra as principais informações sobre os modelos selecionados para o estudo.

Tabela 4.1. Resumo das principais informações sobre as bases de dados selecionadas.

Modelo	Informações	Resolução espacial	Membros
CCM3v6 – SSST	O CCM3.6 é uma versão do <i>Community Climate Model</i> (CCM) do NCAR pertencente à mesma família do CCM3.0, e não apresenta diferenças significativas em relação ao CCM3.2. As principais referências para o modelo CCM3v6 são os trabalhos de Hack <i>et al.</i> (1998), Hurrell <i>et al.</i> (1998) e Kiehl <i>et al.</i> (1998).	2,8125° x 2,789327° (T42)	24 membros
ECPC – SSST	Este é o modelo do <i>Experimental Climate Prediction Center</i> (ECPC), desenvolvido e rodado no <i>Scripps Institution of Oceanography</i> , Universidade da Califórnia, Estados Unidos (IRI, s.d.). O modelo possui resolução horizontal T62 (grade global de 192 X 94), e 28 níveis verticais (de HAAN et al., 2007).	1,875° x 1,904128°	12 membros
GFDL – SSST	O <i>Geophysical Fluid Dynamics Laboratory</i> (GFDL), da Universidade de Princeton, possui dois modelos atmosféricos globais, o AM3 e o HiRAM (<i>High Resolution Atmospheric Model</i>). No IRI, estão disponíveis as previsões do AM2, versão anterior ao AM3. As principais referências para os modelo GFDL são Delworth <i>et al.</i> (2006) e GFDL Global Atmospheric Model Development Team (2004).	2,5° x 2,0°	30 membros

4.3.2 Correção de viés

Modelos Gerais de Circulação, comumente a origem das variáveis climatológicas previstas que podem ser empregadas em estudos hidrológicos, ao terem seus resultados aplicados em escala regional, podem apresentar viés. Este viés, se não corrigido, pode conduzir a erros significativos (AHMED *et al.*, 2013). Desta forma, buscou-se corrigir o viés na previsão de precipitação de cada um dos três modelos empregados, CCM3v6, ECPC e GFDL, com base nos valores observados de precipitação.

Para tanto, o histórico de cada modelo foi analisado, quanto à frequência acumulada, em relação à precipitação observada média na bacia do rio Ijuí, para um período anterior ao de previsão. Escolheu-se o período entre janeiro/1980 e dezembro/2000, por ser este um período de existência de dados históricos comum entre os modelos. Para cada modelo, em cada mês do ano, foi ajustada a distribuição cumulativa de frequência de precipitação total mensal, empregando-se a série representativa da climatologia de cada modelo. As análises foram realizadas para a média da precipitação (histórico do modelo ou observada) total mensal na bacia do rio Ijuí.

Para a precipitação observada e para cada modelo, para cada mês do ano, os 21 dados de precipitação média da bacia (período entre 1980-2000) foram ordenados de forma crescente. Para cada posição da curva de frequência acumulada, determinou-se o erro da previsão, como $P_{prevista} - P_{observada}$. Esta série de erros, juntamente com os dados de precipitação prevista, permitiram o ajuste de uma função de erro, onde o erro é uma função da precipitação prevista:

$$Erro = Erro (P_{prevista}) \quad (9)$$

Onde:

$P_{prevista}$ [mm]: Média do *ensemble* de precipitação prevista pelo modelo X (CCM3v6, ECPC ou GFDL), para o mês Y (jan-dez), média da bacia do rio Ijuí.

Erro [mm]: Polinômio de 1º, 2º ou 3º grau, função de $P_{prevista}$.

Assim, para cada mês do ano, para cada modelo, a precipitação prevista foi corrigida da seguinte forma:

$$P_{\text{corrigida}} = P_{\text{prev}} - \text{Erro}(P_{\text{prev}}) \quad (10)$$

Onde:

P_{prev} [mm]: Precipitação média da bacia do rio Ijuí prevista por cada membro de cada modelo X (CCM3v6, ECPC ou GFDL), para o mês Y (jan-dez),

$\text{Erro}(P_{\text{prev}})$ [mm]: Erro definido conforme equação ajustada, calculado com a precipitação prevista para o membro, para a minibacia.

Adicionalmente, estabeleceram-se limites para a precipitação corrigida, de tal forma que:

- Se $P_{\text{corrigida}} < 0,0$ mm, então $P_{\text{corrigida}} = 0,0$ mm.

A Figura 4.3 mostra uma representação da metodologia empregada para a correção de viés das precipitações.

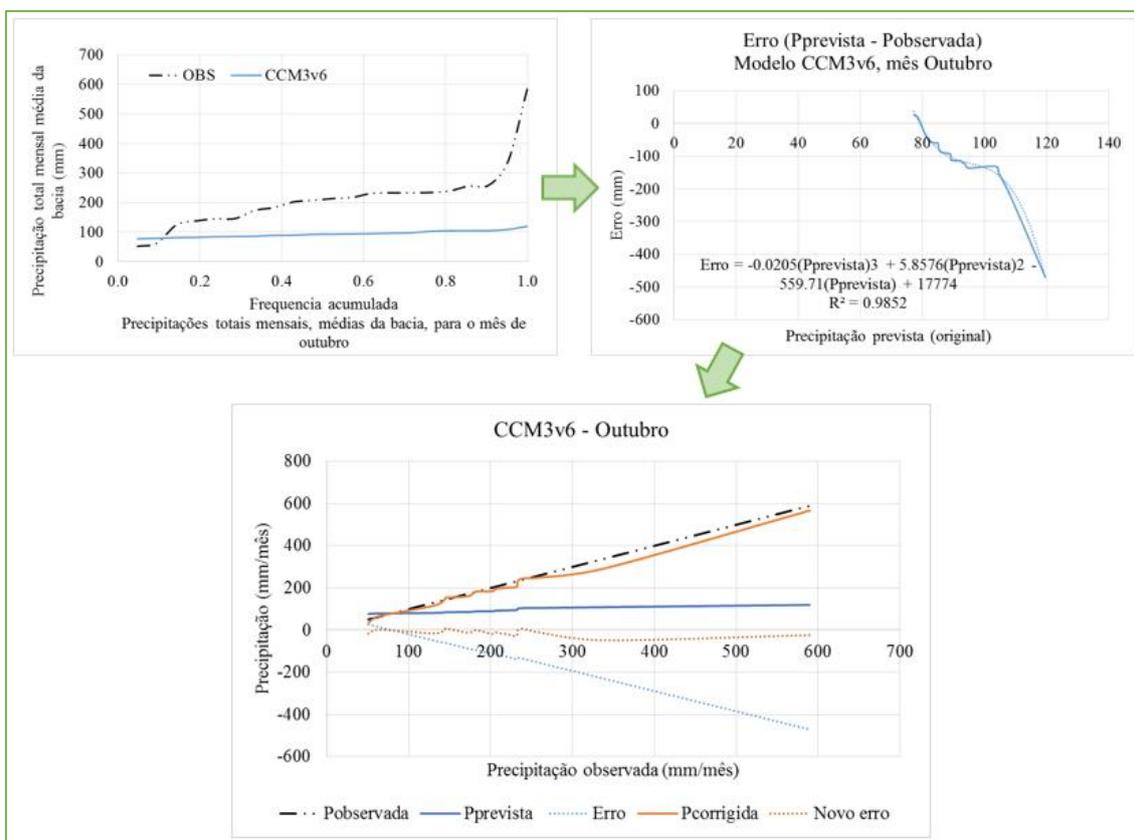


Figura 4.3. Metodologia da correção de viés das precipitações. Exemplo de correção para o mês de outubro, modelo CCM3v6.

A função de erro (polinômios de 1º, 2º ou 3º grau) pode assumir valores altos, implicando em correções errôneas, sobretudo se fora do domínio onde foi ajustada a função, ou seja, para valores maiores ou menores que aqueles observados na bacia para o período de 1980 a 2000. Com vistas a evitar estes erros por extrapolação, limitou-se a aplicação da correção de viés a uma faixa próxima ao domínio de ajuste das equações de erro. Uma vez que as curvas de erro e equações de correção foram determinadas para os dados históricos dos modelos CCM3v6, ECPC e GFDL para o período entre janeiro/1980 e dezembro/2000, a validade destas correções só é conhecida para valores de precipitação entre o mínimo e o máximo “observado” para cada mês no histórico de cada modelo, ou para uma região muito próxima a este domínio.

Desta forma, as correções foram aplicadas permitindo-se apenas uma pequena extrapolação dos valores mínimos e máximos presentes no domínio de definição das equações. A Tabela 4.2 a seguir mostra os valores mínimos e máximos de precipitação média da bacia presentes no histórico dos modelos. Precipitações previstas menores que 90% do limite inferior ou maiores que 120% do limite superior não foram corrigidas, mantendo-se o valor previsto original.

Tabela 4.2. Limites do domínio dos dados históricos dos modelos CCM3v6, ECPC e GFDL. Valores referentes a totais mensais de precipitação.

Mês	CCM3v6		ECPC		GFDL	
	Limite inferior (mm)	Limite superior (mm)	Limite inferior (mm)	Limite superior (mm)	Limite inferior (mm)	Limite superior (mm)
Janeiro	91,4	128,7	110,8	235,5	70,8	170,9
Fevereiro	77,9	150,7	75,6	157,4	60,1	146,2
Março	70,0	107,8	48,4	147,9	30,2	128,5
Abril	44,0	99,4	63,3	166,4	28,6	138,4
Mai	29,7	81,1	55,6	134,5	18,6	113,4
Junho	32,0	62,3	44,0	138,3	11,3	57,7
Julho	30,0	66,2	51,8	123,8	2,8	38,0
Agosto	53,9	88,1	72,0* ¹	178,6	4,2* ²	31,8
Setembro	67,7	115,1	130,7	219,6	19,7	52,1
Outubro	77,2	119,5	161,0	252,5	65,7	115,7
Novembro	81,9	121,6	111,8	181,0	69,5	149,8
Dezembro	93,4	131,6	92,6	218,0	75,8	187,5

*1: O mínimo observado o histórico do modelo ECPC é 71,4 mm, porém este valor gera precipitação corrigida negativa.

*2: O mínimo observado o histórico do modelo GFDL é 3,3 mm, porém este valor gera precipitação corrigida negativa.

4.3.3 Compatibilização temporal dos dados

Os dados de previsão de precipitação disponíveis encontram-se em escala mensal, ou seja, estes dados estão sob a forma de um valor total de precipitação prevista para cada mês, ou como uma taxa de chuva diária, constante para cada mês. Com vistas a encontrar valores diários para a precipitação prevista, adotou-se a seguinte metodologia:

- 1) Análise da precipitação observada “histórica” (para o período entre 1980 e 2004) na área de interesse.

Nesta etapa, os postos pluviométricos existentes na área em estudo foram analisados quanto à disponibilidade de dados e selecionados para o estudo. Os mesmos postos pluviométricos selecionados para a etapa de calibração do MGB-IPH são empregados nesta fase de compatibilização dos dados de precipitação prevista.

- 2) Para cada série de precipitação prevista (cada membro de cada modelo), para cada mês do período a ser simulado (2005-2013) empregou-se a distribuição de chuvas do mês com total precipitado observado mais próximo do total previsto (corrigido quanto ao viés). Ou seja, se a precipitação prevista para janeiro de 2010 é igual à 50 mm para o membro 3 do modelo XX, buscou-se na série histórica observada (no período entre 1980 e 2004) o mês de janeiro com total precipitado mais próximo à 50 mm (janeiro de YYYY). Aplicou-se então, na série do membro 3 do modelo XX no mês de janeiro de 2010 a mesma distribuição de chuvas ao longo do mês observada em janeiro de YYYY.

4.4 Tipos de previsão de precipitação e previsão de umidade do solo associada

São empregados neste estudo previsões de precipitação oriundas de três modelos climáticos, CCM3v6, ECPC e GFDL. Cada modelo possui um conjunto de membros (24 membros modelo CCM3v6, 12 do modelo ECPC e 30 do modelo GFDL). Para cada modelo, encontrou-se a precipitação média dos membros. O modelo hidrológico MGB-IPH foi rodado uma vez para cada previsão existente (cada membro de cada modelo (66 previsões) e cada média de precipitação prevista por cada modelo (três previsões)), para cada um dos três horizontes de previsão, totalizando 207 previsões (três horizontes X 69 previsões (66 membros + 3 médias de modelos)).

Para a análise dos resultados, considerou-se uma classificação dos valores de umidade do solo previstos mensais. O grau de saturação do solo previsto para cada mês foi comparado com a saturação média pseudo-observada (obtida através da simulação hidrológica com o MGB-IPH com a precipitação observada) em um período anterior. Desta forma, estabeleceu-se a *anomalia* de umidade no solo prevista para cada mês. A umidade do solo prevista para determinado mês foi então classificada, conforme o desvio em relação à média histórica, como mês *muito seco*, *seco*, *normal*, *úmido*, ou mês *muito úmido*. Para cada mês, os dados de previsão de precipitação deram origem à diferentes previsões de umidade do solo, a saber:

- A) Para o conjunto de membros (*ensemble*) de cada modelo: a classe de umidade do solo mais comum (a moda) entre os membros de um determinado modelo foi considerada como sendo a previsão do *ensemble* daquele modelo (totalizando três previsões, dado que há três modelos);
- B) Para a média da precipitação prevista por cada modelo: apenas uma previsão de umidade do solo está associada a esta série de precipitação, sendo esta considerada como a previsão da média do *ensemble* de cada modelo (totalizando três previsões, dado que há três modelos);
- C) Para o *superensemble*, originado do conjunto completo de membros, independentemente do modelo (66 membros para cada horizonte de previsão): a

classe de umidade do solo mais comum (a moda) entre os membros foi considerada como sendo a previsão do *superensemble* (totalizando uma previsão);

D) Para o *ensemble* de modelos, originado da média das previsões realizadas com a média de cada modelo: com a previsão de umidade realizada com a média da previsão de precipitação de cada modelo (as três previsões resultantes do item B) foi realizada uma média. Esta média é considerada como a previsão do *ensemble* de modelos (totalizando uma previsão).

Desta forma, para cada horizonte de previsão, para cada mês do período simulado, há 8 previsões de umidade do solo (Tabela 4.3):

Tabela 4.3. Previsões de umidade do solo para cada horizonte de previsão, com base na combinação de modelos e médias de ensembles da previsão de precipitação.

Código da previsão	Modelo climático	Critério da previsão	Característica da previsão de umidade do solo
1	CCMv6	A	Moda de 24 membros
2	ECPC	A	Moda de 12 membros
3	GFDL	A	Moda de 30 membros
4	CCMv6	B	Média de 24 membros
5	ECPC	B	Média de 12 membros
6	GFDL	B	Média de 30 membros
7	Três modelos	C	Moda dos 66 membros
8	Três modelos	D	Média da média dos três modelos

A Figura 4.4 mostra uma representação esquemática dos tipos de previsão e da previsão de umidade do solo associada a cada, seguida pela classificação dos resultados.

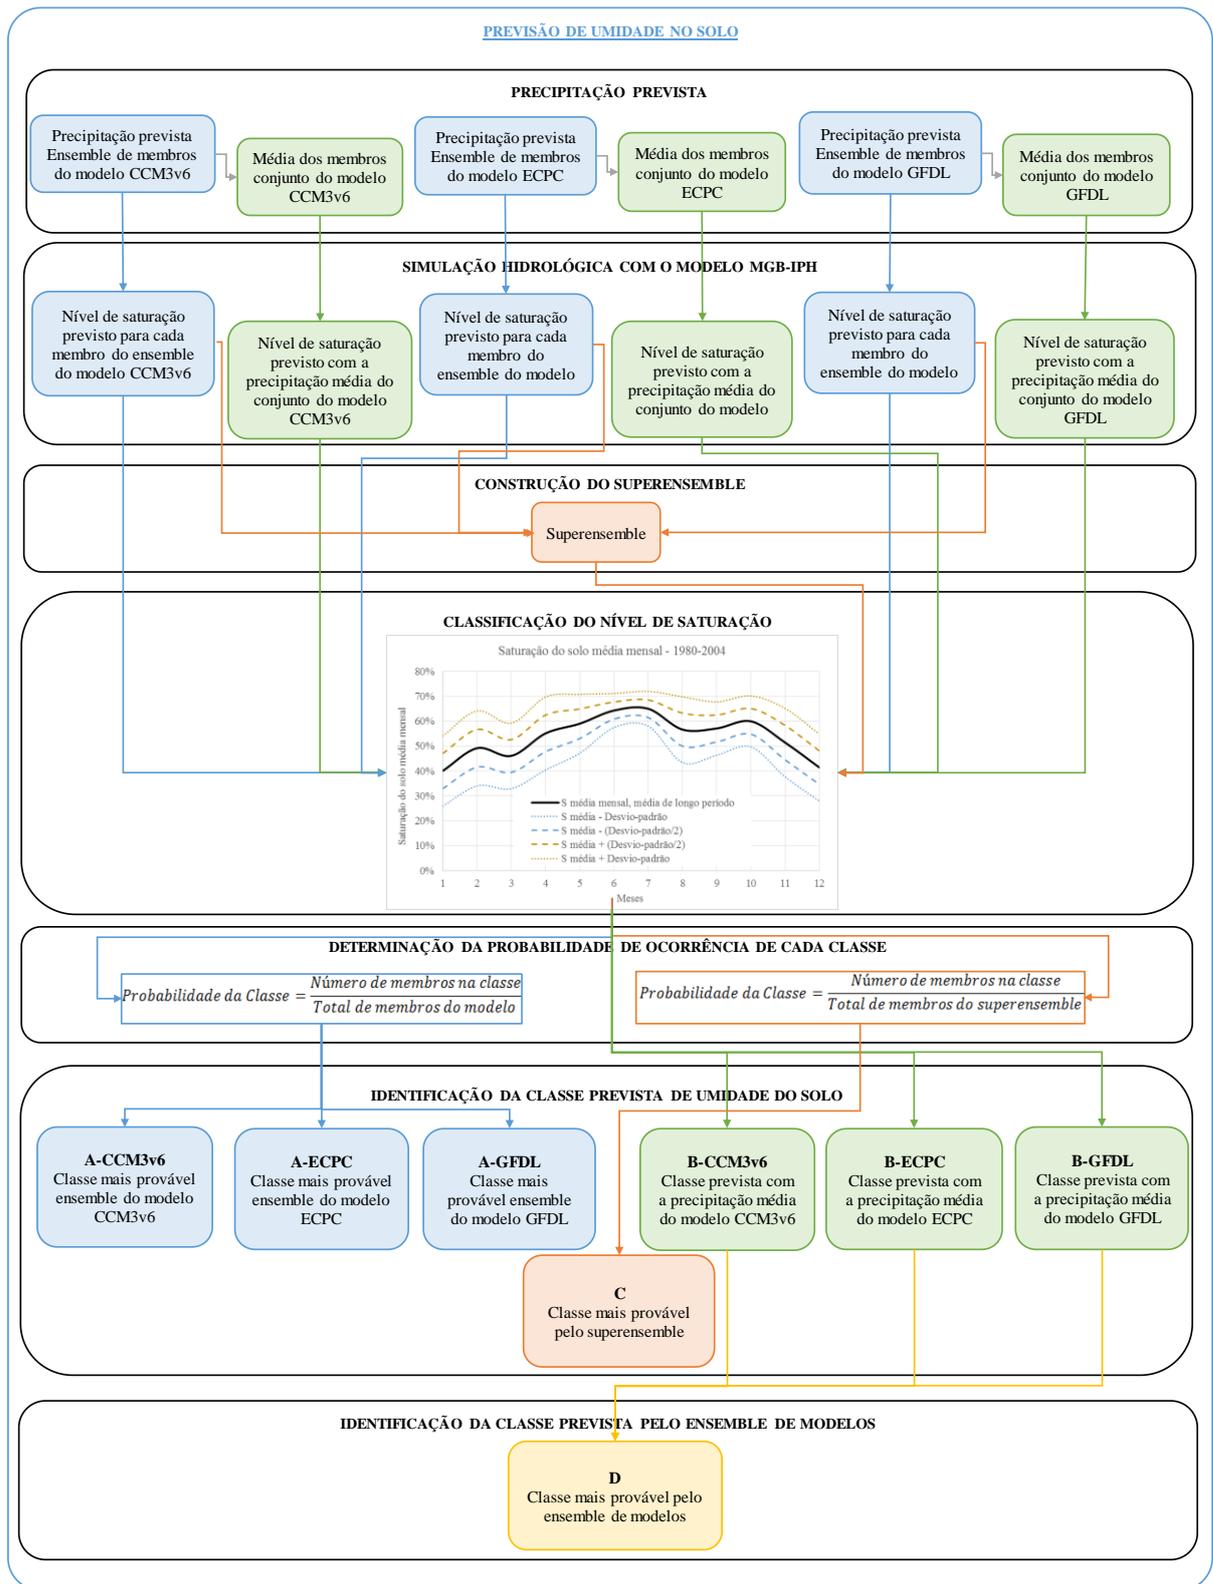


Figura 4.4. Fluxograma representativo da metodologia na etapa de previsão e classificação dos resultados.

4.5 Classificação das previsões

Os resultados das previsões de umidade do solo são analisados na forma de variação da saturação do solo média da bacia em relação à saturação média mensal de longo período, através de uma classificação. A saturação média de longo período foi calculada para o período entre janeiro/1980 e dezembro/2004, empregando-se para tanto a precipitação observada e os dados médios de clima no intervalo de tempo (1980-2004). Todos os dados são analisados em escala mensal. A anomalia em relação à saturação média de longo período foi estabelecida através de cinco classes, definidas conforme a Tabela 4.4. A Figura 4.5 mostra os valores dos limites das classes, para cada mês.

Tabela 4.4. Limites das cinco classes da anomalia da saturação do solo.

Classe	Código da classe	Limite inferior	Limite superior
Muito úmido	+2	S média + Desvio-padrão	-
Úmido	+1	S média + (Desvio-padrão/2)	S média + Desvio-padrão
Normal	0	S média - (Desvio-padrão/2)	S média + (Desvio-padrão/2)
Seco	-1	S média - Desvio-padrão	S média - (Desvio-padrão/2)
Muito seco	-2	-	S média - Desvio-padrão

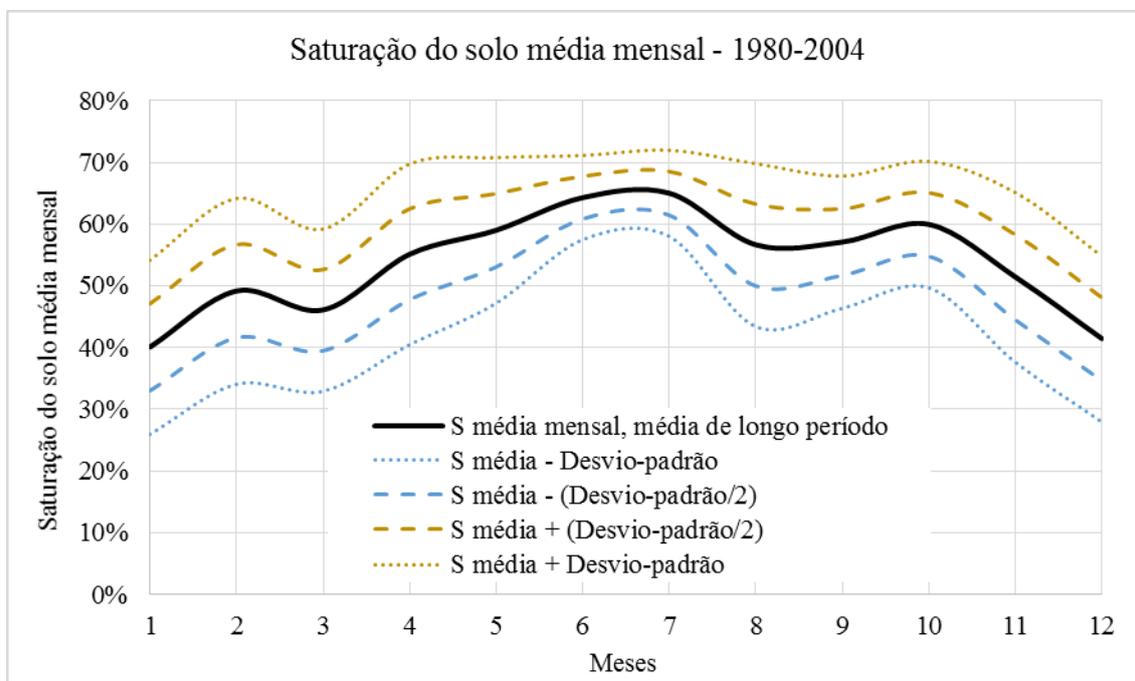


Figura 4.5. Umidade do solo média da bacia do rio Ijuí para o período entre 1980-2004 e desvio-padrão, para a umidade do solo classificada em cinco classes.

4.6 Análise de desempenho das previsões

O desempenho das previsões de umidade do solo são avaliados através da comparação com a umidade pseudo-verdadeira, ou seja, aquela calculada com os valores observados de precipitação. Todas as previsões, conforme descrito no item 4.4, foram convertidas para previsões simples com informação de probabilidade associada. Desta forma, as previsões são avaliadas através de medidas de desempenho previstas para previsões determinísticas.

Os itens a seguir apresentam as medidas de desempenho empregadas para a análise dos resultados das previsões de umidade no solo.

Índice de erros e acertos

Fazendo-se, para cada mês do período previsto:

$$\text{Erro} = (\text{Classe de saturação prevista}) - (\text{Classe pseudo} - \text{observada}) \quad (11)$$

Tem-se o índice de acertos da previsão como:

$$\text{Índice de acertos} = \frac{\text{Quantidade de meses de previsão onde o erro é igual a zero}}{\text{Quantidade de meses de previsão}} \quad (12)$$

Analisam-se também os diferentes erros possíveis na previsão, de forma que:

$$(\text{Índice de erro} = +1) = \frac{\text{Quantidade de meses de previsão onde o erro é igual a } +1}{\text{Quantidade de meses de previsão}} \quad (13)$$

$$(\text{Índice de erro} = -1) = \frac{\text{Quantidade de meses de previsão onde o erro é igual a } -1}{\text{Quantidade de meses de previsão}} \quad (14)$$

$$(\text{Índice de erro} = +2) = \frac{\text{Quantidade de meses de previsão onde o erro é igual a } +2}{\text{Quantidade de meses de previsão}} \quad (15)$$

$$(\text{Índice de erro} = -2) = \frac{\text{Quantidade de meses de previsão onde o erro é igual a } -2}{\text{Quantidade de meses de previsão}} \quad (16)$$

De forma semelhante ao mostrado nas equações (11) a (16), calculam-se os índices de erro=+3; erro=-3; erro=+4; erro=-4.

O índice de acertos, como o próprio nome diz, indica a quantidade de meses ao longo da previsão em que a classe de saturação prevista foi igual à classe pseudo-observada. A análise de diferentes erros (± 1 a ± 4) permite conhecer a amplitude deste erro e se há tendência nas previsões, através da análise dos totais de erros positivos e negativos.

Tabela de contingência

Dividindo-se, quanto aos dados pseudo-observados, a série simulada em três séries, uma relativa à classe seca, uma à classe normal, e outra à classe úmida, pode-se estabelecer uma tabela de contingência 2 X 2 para cada classe de saturação, conforme mostrada na Figura 4.6. A tabela de contingência é organizada quanto a quatro valores principais:

- a: acertos, eventos corretamente previstos;
- b: falsos alarmes, eventos previstos porém não ocorridos;
- c: eventos observados que não foram previstos;
- d: rejeição correta, eventos não observados e não previstos.

		Observado		
		Sim	Não	
Previsto	Sim	a	b	a+b
	Não	c	d	c+d
		a+c	b+d	n = a+b+c+d

Figura 4.6. Tabela de contingência para eventos dicótonos (binários).

Fonte: Wilks, 2006.

Com base na tabela de contingência de cada série, são analisados os resultados encontrados para Probabilidade de Detecção (POD) e Probabilidade de Falsa Detecção (POFD), Bias e Razão de Alarme Falso (RAF). Estas medidas são definidas conforme Wilks (2006), como:

$$POD = \frac{a}{a + c} \quad (17)$$

$$POFD = \frac{b}{b + d} \quad (18)$$

$$RAF = \frac{b}{a + b} \quad (19)$$

$$BIAS = \frac{a + b}{a + c} \quad (20)$$

POD analisa a quantidade de eventos corretamente previstos em relação ao total observado. POD varia entre 0 e 1, sendo o resultado melhor quanto mais próximo a 1. POFD avalia a proporção de eventos não observados porém previstos, dada a não ocorrência do evento. O valor varia entre 0 e 1, onde o ideal é um resultado mais próximo de zero. RAF apresenta a razão de eventos previstos e não observados, sobre o total de eventos previstos, e também varia entre 0 e 1, com melhores resultados quanto mais próximo de 0. Por fim, BIAS indica a relação entre o total de eventos previstos e os observados. Um valor de BIAS acima de 1 indica que a previsão prevê uma quantidade maior de eventos do que ocorre de fato. Resultados menores que 1 indicam que a previsão subestima a quantidade de eventos observados.

Os resultados da previsão de umidade do solo são analisados conforme a seguinte compatibilização temporal e espacial:

- Saturação média da bacia do rio Ijuí;
- Saturação média mensal.

Estes valores de saturação, médios mensais, médios da bacia são então classificados e analisados conforme descrito no item 4.4.

5. BACIA HIDROGRÁFICA DO RIO IJUÍ

5.1 Localização

A área de estudo é a bacia do rio Ijuí, na bacia do rio Uruguai. A área de estudo foi escolhida como tal por sua importância na produção agrícola no estado, sobretudo na cultura de sequeiros. Desta forma, um estudo de previsão de longo prazo de umidade do solo, como o aqui realizado, pode vir a ser de grande interesse nas ações de planejamento agrícola.

O rio Uruguai é um dos principais cursos d'água na bacia do rio da Prata e nasce do encontro dos rios Pelotas e Canoas. A sua bacia possui cerca de 385.000 km², dos quais aproximadamente 45%, 174.533 km², estão situados em território brasileiro, onde corresponde à Região Hidrográfica do Uruguai. Conforme observa-se na Figura 5.1, a bacia correspondente ao rio Ijuí encontra-se no trecho médio do rio Uruguai. Correspondendo à cerca de 2% do território nacional, a região do rio Uruguai destaca-se pelo potencial hidroelétrico e pelas atividades agroindustriais nela desenvolvidas (ANA, 2014). Ainda segundo a ANA, a região abriga uma população de cerca de 3.900.000 pessoas na parte brasileira, onde ocupa 384 municípios.

5.2 Caracterização

A bacia do rio Uruguai possui intensa ocupação do solo por atividade agrícola, como pode ser observado na figura a seguir, nas áreas em marrom e amarelo. De acordo com o Caderno da Região Hidrográfica do Uruguai (MMA, 2006), a bacia possui aproximadamente 24% de cobertura por mosaico agrícola e 16 % por agricultura intensiva. Como pode-se observar na Figura 5.1, a área da bacia do rio Ijuí possui forte atividade agrícola.

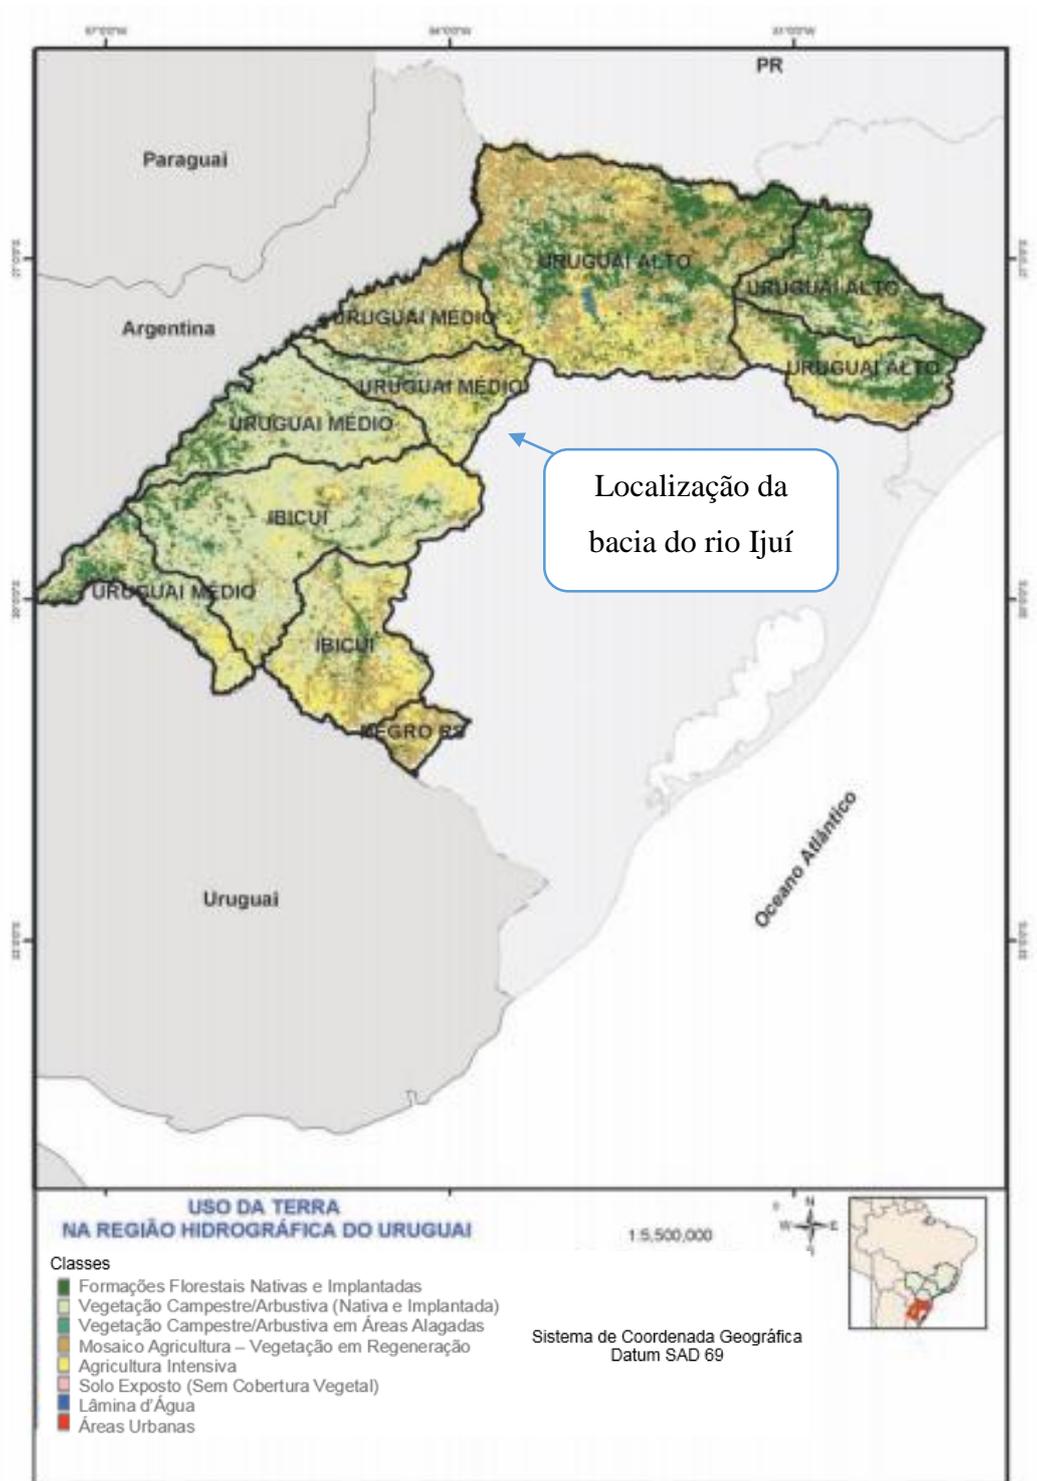


Figura 5.1. Uso do solo e cobertura vegetal na Região Hidrográfica do Uruguai.

Fonte: MMA, 2006.

A sub-bacia em estudo é aquela associada ao rio Ijuí. Conforme pode-se observar na Figura 5.2, a bacia analisada está localizada no trecho médio do rio Uruguai, dentro do Estado do Rio Grande do Sul. A área em estudo corresponde a 10.778,1 km², centrada nas coordenadas 54,076° W e 28,387° S. As figuras 5.2 a 5.4 a seguir mostram a região em estudo.

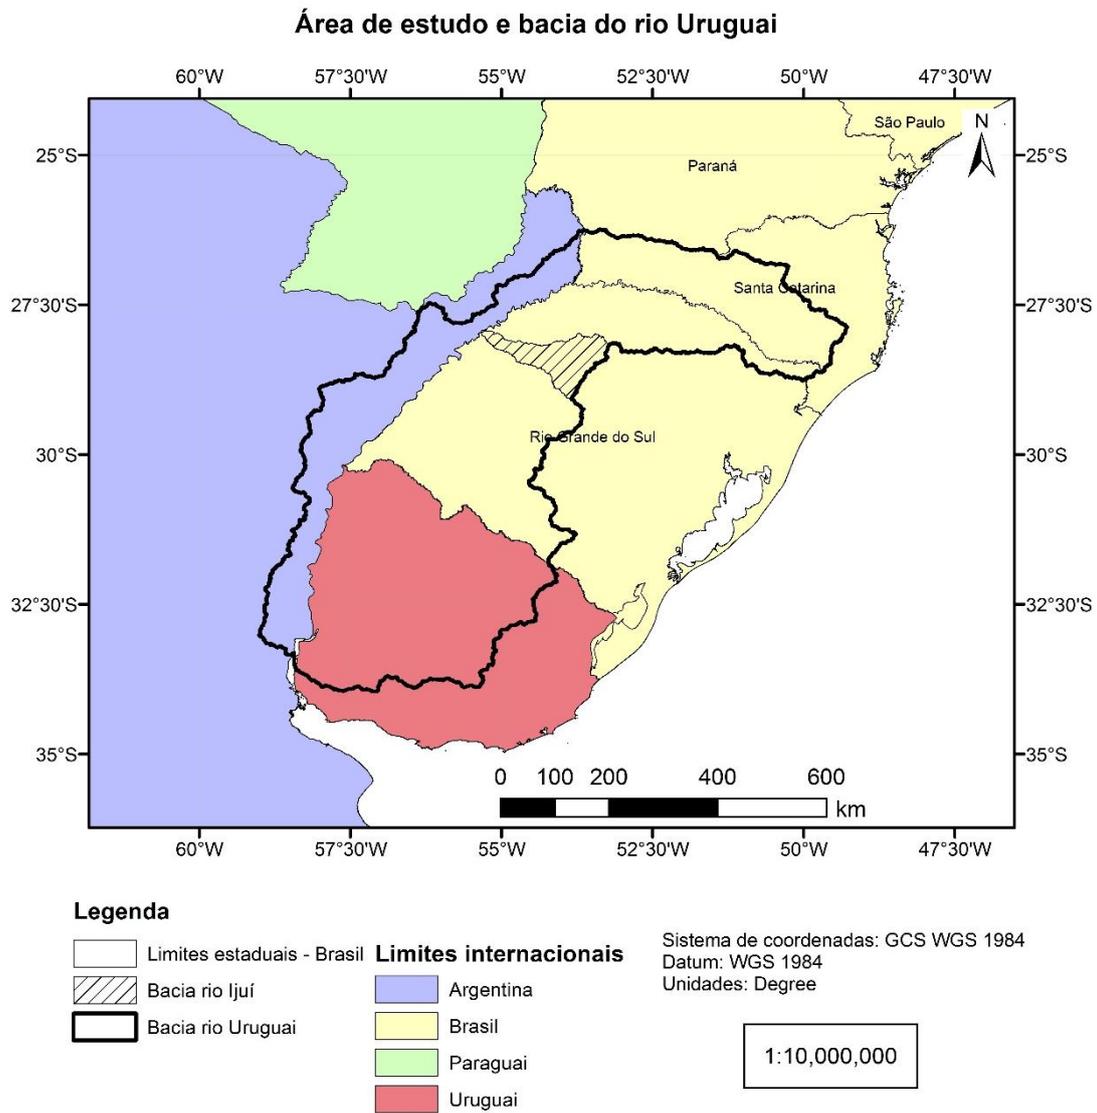


Figura 5.2. Área em estudo em relação à bacia do rio Uruguai.

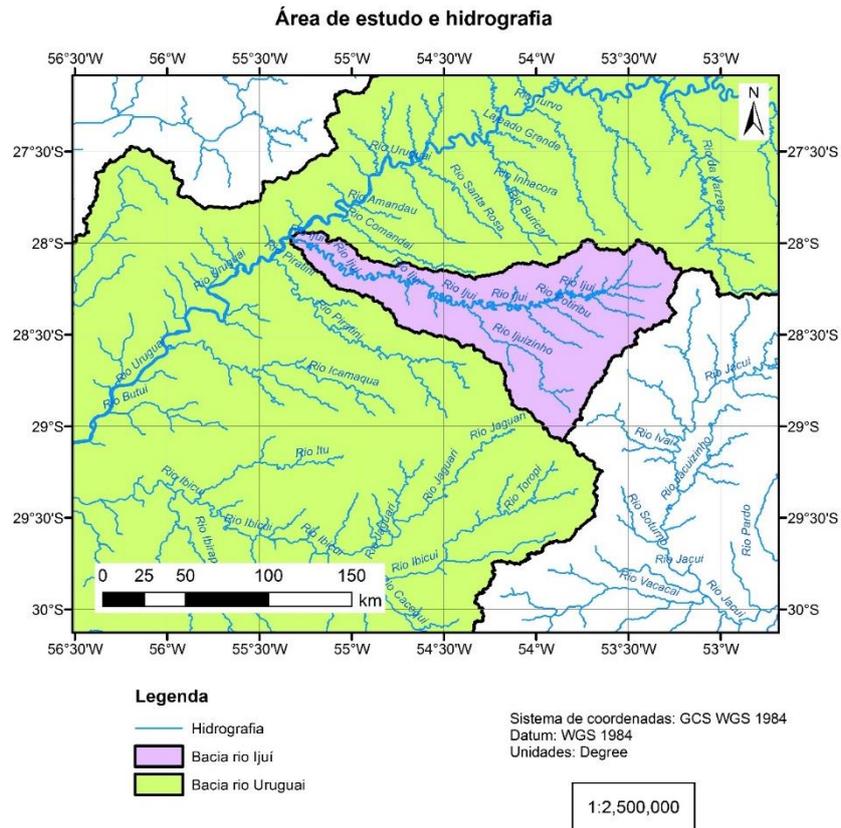


Figura 5.3. Bacia do rio Ijuí e hidrografia.

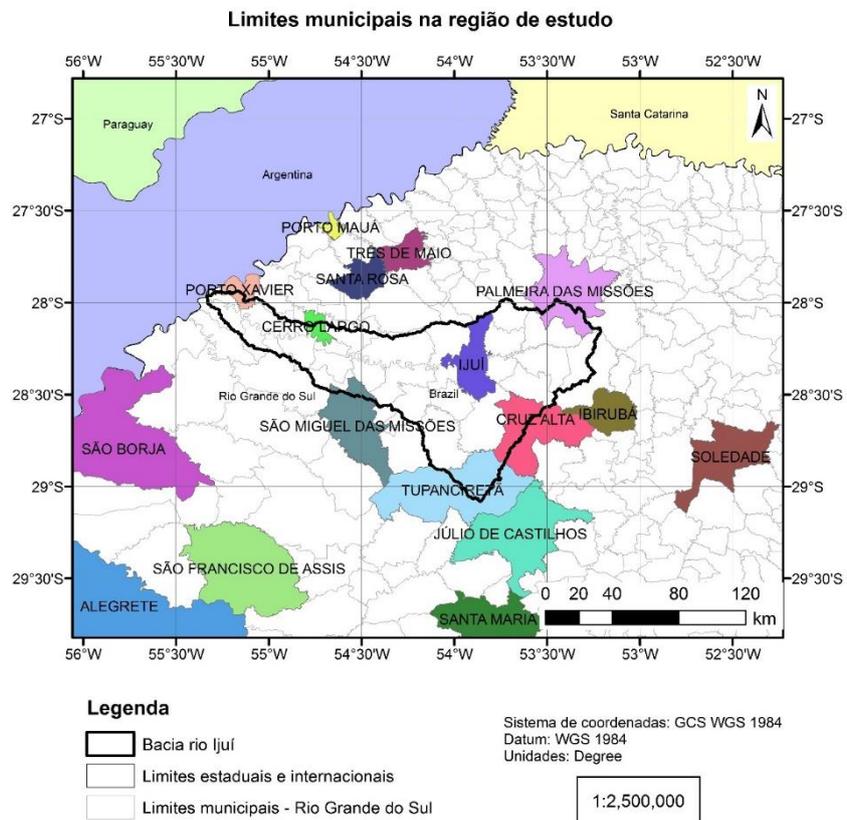


Figura 5.4. Limites municipais, estaduais, internacionais e principais municípios na região em estudo.

A região da bacia possui clima subtropical úmido (Cfa), conforme a classificação de Köppen, caracterizado por apresentar temperatura média superior a 22°C no verão e com mais de 30 mm de precipitação no mês mais seco. As figuras a seguir apresentam uma caracterização da bacia do rio Ijuí quanto ao regime de precipitações. Observa-se na Figura 5.5 que a precipitação total anual média na bacia varia entre 1790 mm e 1950 mm, sendo a média da bacia igual à 1870 mm por ano, conforme dados do período entre 1980 e 2013.

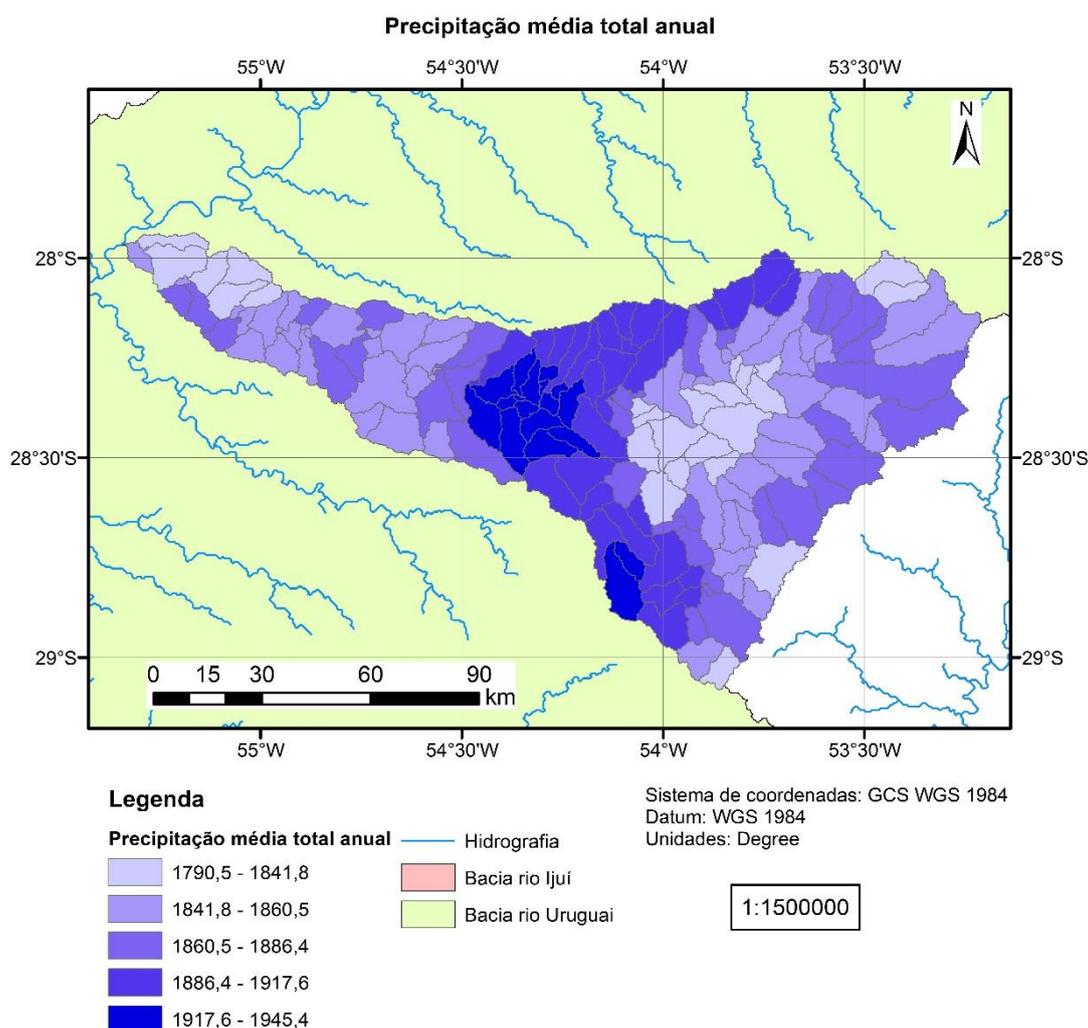


Figura 5.5. Precipitação total anual média na bacia do rio Ijuí, com base no período entre 1980 e 2013.

A Figura 5.6 apresenta a precipitação média total mensal ao longo do ano, para todas as 163 minibacias delimitadas. Já a Figura 5.7 apresenta os dados da Figura 5.6 divididos pela precipitação total anual média. Sabendo-se que o valor 0,0833 (igual à 1/12) significa que a precipitação média total do mês é proporcional à precipitação total

anual, observa-se que os valores não se afastam muito deste valor, o que indica que a bacia não possui forte sazonalidade quanto à precipitação.

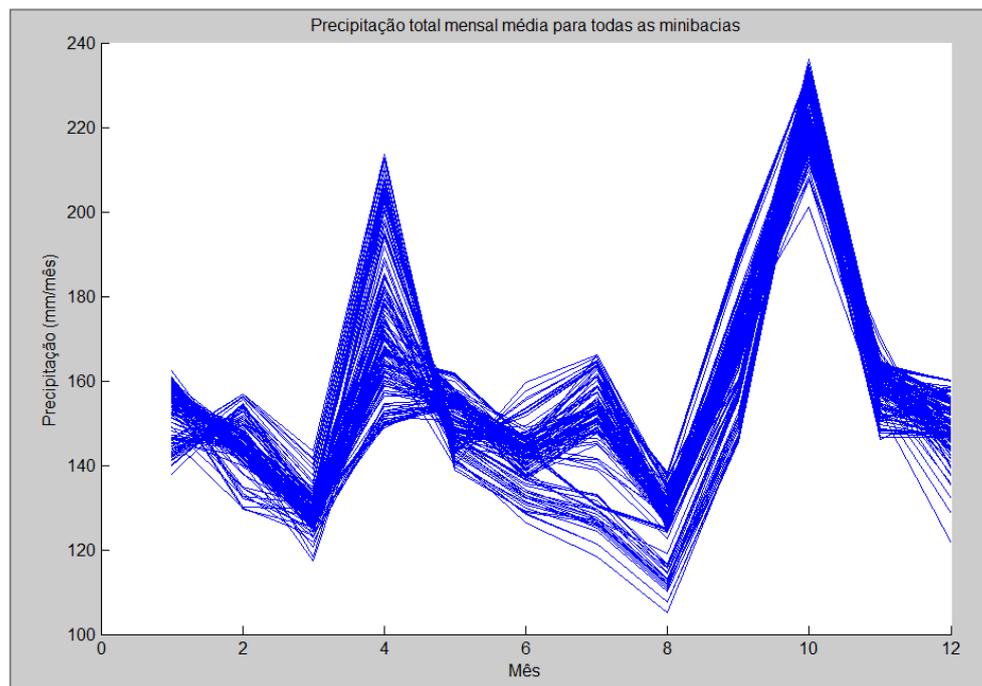


Figura 5.6. Precipitação total média mensal para todas as 163 minibacias no rio Ijuí.

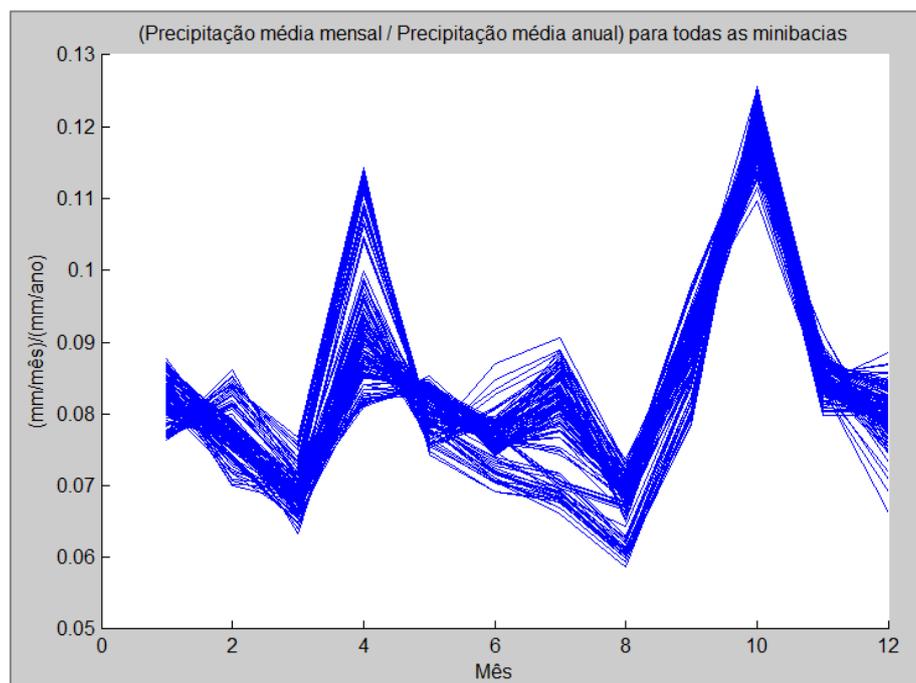


Figura 5.7. Precipitação total média mensal dividida pela precipitação média total anual, para todas as 163 minibacias no rio Ijuí.

6. SIMULAÇÃO HIDROLÓGICA

A simulação com o MGB-IPH envolve três etapas: uma etapa de preparação de dados necessários à utilização do PrePro-MGB, execução do PrePro-MGB com obtenção do arquivo de informações da bacia a ser simulada, e simulação com o MGB-IPH propriamente dita. A última etapa abrange as fases de calibração e verificação do modelo, e previsão de umidade do solo, neste caso. Os passos acima elencados são descritos neste capítulo.

6.1 Geração de dados para o pré-processamento do MGB-IPH

O programa de pré-processamento (PrePro-MGB) gera o arquivo principal de entrada do modelo MGB-IPH a partir dos mapas em formato raster gerados com o auxílio do ArcGis, conforme descrito em Fan e Collischonn (2014). Os dados de entrada básicos necessários para rodar o PrePro-MGB são apresentados na Tabela 6.1.

Tabela 6.1. Dados de entrada necessários para o programa PrePro-MGB.

Dado/layer	Caráter	Tipo	Possível fonte
Modelo Digital de Elevação	Obrigatório	Raster	SRTM
Rede de drenagem	Obrigatório	Raster	Operação ArcHydro
Minibacias	Obrigatório	Raster	Operação ArcHydro/ Union/PolyToRaster
Direções de fluxo	Obrigatório	Raster	ArcHydro
Unidades de Resposta Hidrológica	Obrigatório	Raster	Definição de unidades de paisagem

Fonte: Collischonn *et al.*, 2010.

6.1.1 Definição da rede de drenagem, minibacias e sub-bacias

Os procedimentos de delimitação da rede de drenagem, das minibacias e das sub-bacias são realizados com o auxílio das ferramentas do Arc Hydro, do software ArcGIS 10. O modelo digital de elevação empregado é o *Shuttle Radar Topography Mission* (SRTM) com resolução espacial de 90 m, disponibilizado pelo *CGIAR - Consortium for Spatial Information* (CGIAR-CSI). O valor limite de área acumulada a partir do qual inicia-se a rede de drenagem foi especificado em 5000 células (cada célula tendo aproximadamente 89,04 m de lado), o que representa uma área de cerca de 39,6 km². A Figura 6.1 a seguir mostra a rede de drenagem e as 163 minibacias delimitadas.

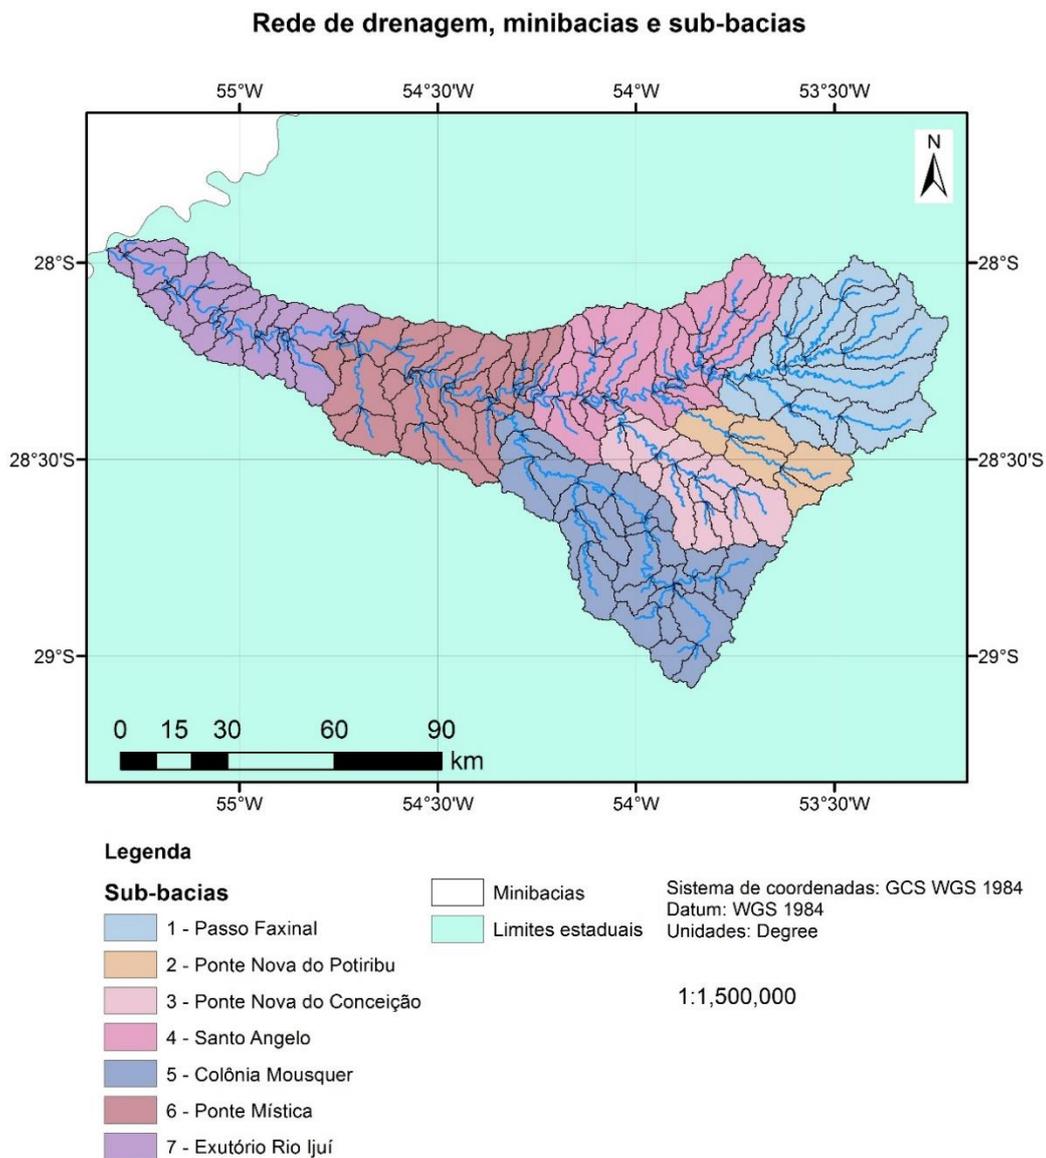


Figura 6.1. Rede de drenagem, minibacias e sub-bacias delimitadas na área de estudo.

A Tabela 6.2 a seguir traz informações sobre as sete sub-bacias delimitadas para a área de estudo. As seis primeiras sub-bacias foram escolhidas com base na existência de postos fluviométricos com série longa e com poucas falhas, nos principais rios da bacia. A última sub-bacia corresponde à área entre o exutório da bacia original (rio Ijuí), e as demais sub-bacias.

Tabela 6.2. Sub-bacias definidas.

Sub-bacia		Posto fluviométrico relacionado		Descrição da sub-bacia	Área (km ²)
Código	Nome	Código	Nome		
1	Passo Faxinal	75155000	Passo Faxinal	Bacia a montante do posto Passo Faxinal, no rio Ijuí	2011,18
2	Ponte Nova do Potiribu	75186000	Ponte Nova do Potiribu - Jusante	Bacia a montante dos postos Ponte Nova do Potiribu e Ponte Nova do Potiribu - Jusante (os postos possuem a mesma localização), no rio Potiribu	610,78
		75185000	Ponte Nova do Potiribu		
3	Ponte Nova do Conceição	75205000	Ponte Nova do Conceição	Bacia a montante do posto Ponte Nova do Conceição, no rio Conceição	970,67
4	Santo Ângelo	75230000	Santo Ângelo	Bacia incremental entre o posto Santo Ângelo e os postos Passo Faxinal, Ponte Nova do Potiribu e Ponte Nova do Conceição	1848,31
5	Colônia Mousquer	75295000	Colônia Mousquer	Bacia a montante do posto Colônia Mousquer, no rio Ijuizinho	2158,50
6	Ponte Mística	75320000	Ponte Mística	Bacia incremental entre o posto Ponte Mística e os postos Santo Angelo e Colônia Mousquer	1857,40
7	Exutório rio Ijuí			Bacia incremental entre o exutório do rio Ijuí e o posto Ponte Mística	1318,81

6.1.2 Definição das Unidades de Resposta Hidrológica

A definição das Unidades de Resposta Hidrológica (URH) baseou-se nos tipos de solos e nos usos da terra e tipo de cobertura vegetação na bacia em estudo. O layer com os tipos de solos foi obtido junto ao Ministério do Meio Ambiente, para todo o Brasil, com escala 1:5.000.000. Para as informações de uso da terra, utilizou-se o mapa disponibilizado pela European Space Agency (ESA), de 2009, com cobertura global e 300 m de resolução.

A área da bacia do rio Ijuí apresenta, em diferentes proporções, solos litólicos, latossolos e terra roxa. Solos litólicos são solos jovens e rasos, encontrando-se quase sempre associados a afloramentos rochosos. Conseqüentemente, solos litólicos são favoráveis a geração de escoamento em uma bacia hidrográfica. Já os latossolos são solos muito profundos, friáveis, porosos, de textura variável, com argila de atividade baixa, e são solos fortemente intemperizados, que geram escoamento superficial muito fraco, em geral. Por fim, terra roxa é um solo com textura argilosa, profundos à muito profundos, com boa porosidade e boa permeabilidade em todo o perfil (SILVA, 2000).

Os tipos de solo existentes na bacia foram reclassificados em dois tipos principais: solos rasos e solos profundos. Latossolos e terra roxa são solos com tendência a gerar menos escoamento superficial, sendo reclassificados como solos profundos. O solo litólico, por sua vez, é reclassificado como solo raso, gerando uma maior fração de escoamento superficial quando comparados aos solos profundos. O resultado da reclassificação pode ser observado na Figura 6.2.

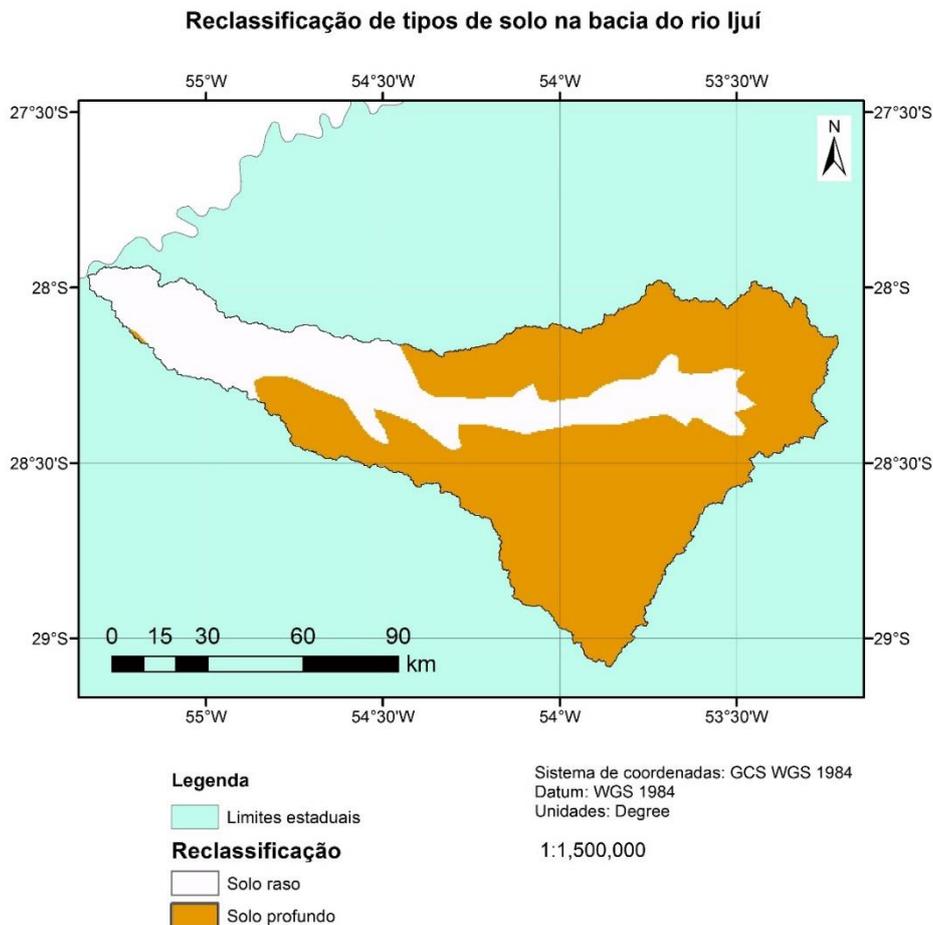


Figura 6.2. Reclassificação dos tipos de solos presentes na bacia do rio Ijuí.

O mapa de uso da terra, disponibilizado pela ESA, apresenta 22 categorias de uso do solo. Estas categorias, porém, podem e devem ser agrupadas, com vistas a facilitar a implementação do modelo. Consideram-se quatro categorias de uso do solo: Agricultura, Campo, Florestas e Água. A Figura 6.3 mostra a reclassificação dos usos do solo na bacia do rio Ijuí.

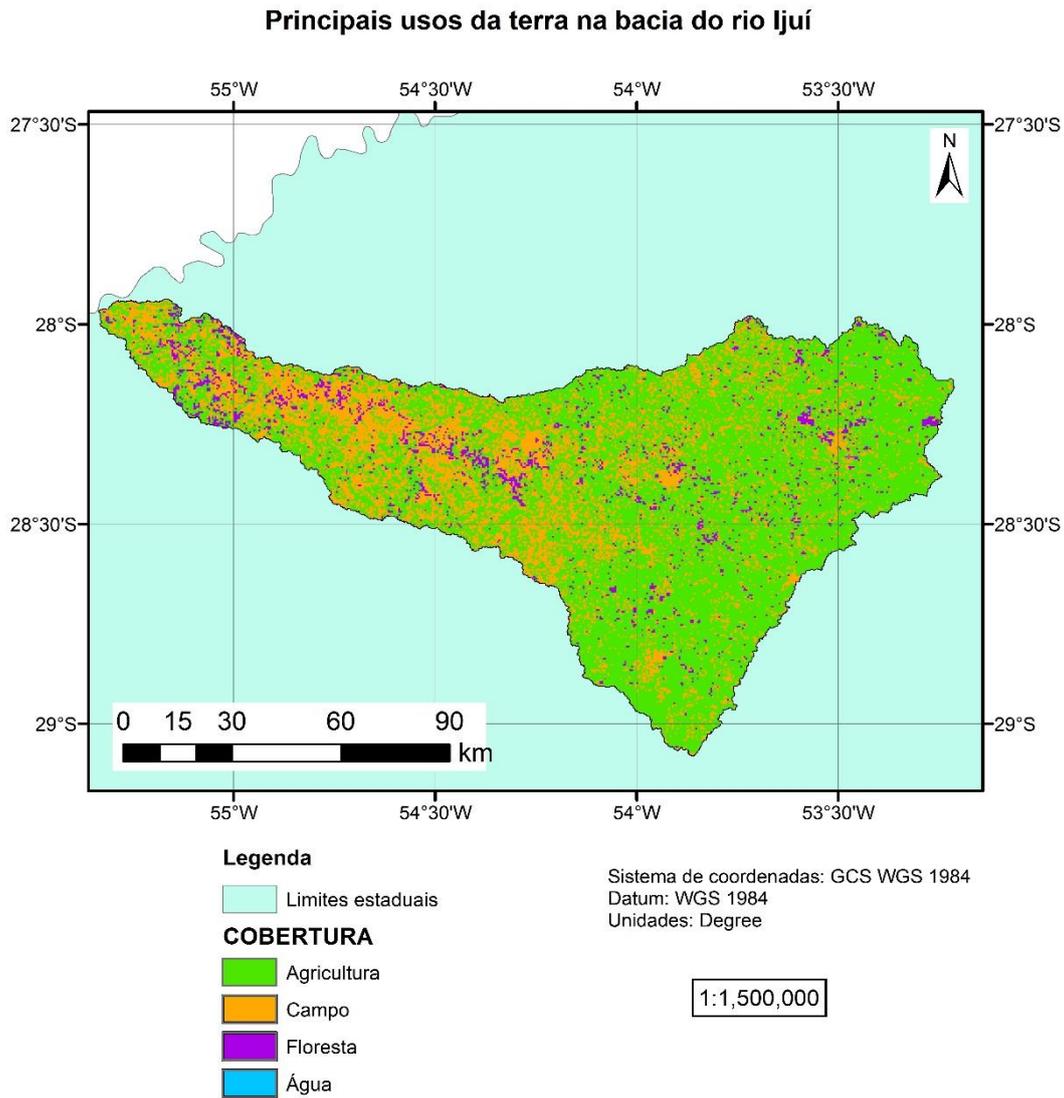


Figura 6.3. Reclassificação dos usos do solo na bacia do rio Ijuí.

As unidades de resposta hidrológica representam uma combinação das informações de tipo de solo e uso da terra. A Figura 6.4 a seguir mostra o mapa das URHs.

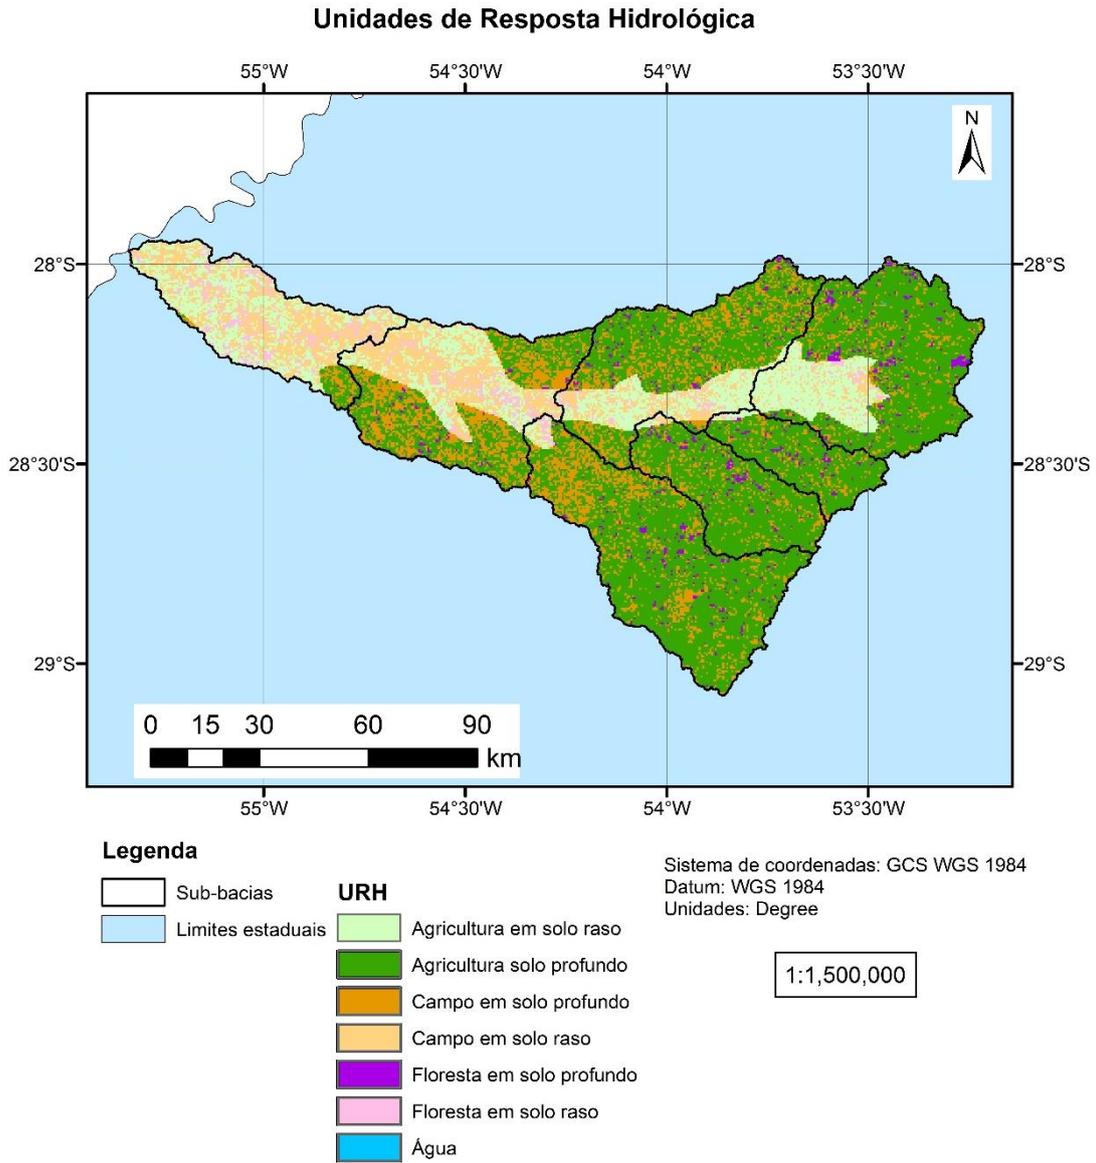


Figura 6.4. Unidades de resposta hidrológica na bacia do rio Ijuí.

6.2 Simulação no MGB-IPH

6.2.1 Seleção de dados de vazão observados

Os dados de vazão observados empregados durante os processos de calibração e verificação do modelo são provenientes da base de dados HidroWeb (<http://hidroweb.ana.gov.br/>) da ANA – Agência Nacional de Águas.

Existem na bacia do rio Ijuí 13 postos fluviométricos com dados de vazão. Conforme a existência, extensão e completude da série histórica de dados de cada posto, foram selecionadas as estações a serem utilizadas nas etapas de calibração e verificação da simulação. Foram identificados sete postos cobrindo total ou parcialmente o período entre 1980 e 2004, durante o qual é realizada a calibração do MGB-IPH; e seis postos para o período de verificação da calibração. Informações sobre as estações fluviométricas selecionadas são encontradas na Tabela 6.3. Os postos pertencem à sub-bacia 75 - Rios Uruguai, Ijuí e outros, no estado do Rio Grande do Sul. A área de drenagem dos postos varia entre 609 km² e 9450 km². A Figura 6.5 mostra a localização das estações, enquanto a Figura 6.6 mostra a disponibilidade de dados no período de interesse, ou seja, entre 01/01/1980 e 31/01/2013.

Tabela 6.3. Postos fluviométricos selecionados.

Código	Nome	Rio	Município	Respon sável	Opera dora	Latitude	Longitude	Altitude (m)	Área de drenagem (km ²)	Cali bração	Verifi cação
75155000	Passo Faxinal	Rio Ijuí	Ijuí	ANA	CPRM	-28:17:13	-53:46:51	200	1940	Sim	Sim
75200000	Conceição	Rio Conceição	Ijuí	ANA	CPRM	-28:27:18	-53:58:15	160	811	Sim	Sim
75205000	Ponte Nova do Conceição	Rio Conceição	Coronel Barros	ANA	CPRM	-28:23:5	-54:1:53	160	970	Sim	Sim
75230000*	Santo Ângelo	Rio Ijuí	Entre-Ijuis	ANA	CPRM	-28:21:19	-54:16:6	200	5440	Sim	Sim
75295000	Colônia Mousquer	Rio Ijuizinho	Santo Ângelo	ANA	CPRM	-28:23:23	-54:19:51	200	2160	Sim	Sim
75186000	Ponte Nova do Potiribu - Jusante	Rio Potiribu	Ijuí	ANA	CPRM	-28:22:15	-53:52:45	320	613	Não	Sim
75185000	Ponte Nova do Potiribu	Rio Potiribu	Ijuí	ANA	ANA	-28:22:38	-53:52:32	320	609	Sim	Não
75320000*	Ponte Mística	Rio Ijuí	São Luiz Gonzaga	ANA	ANA	-28:10:53	-54:44:18	160	9450	Sim	Não

* Código adicional: ANA.

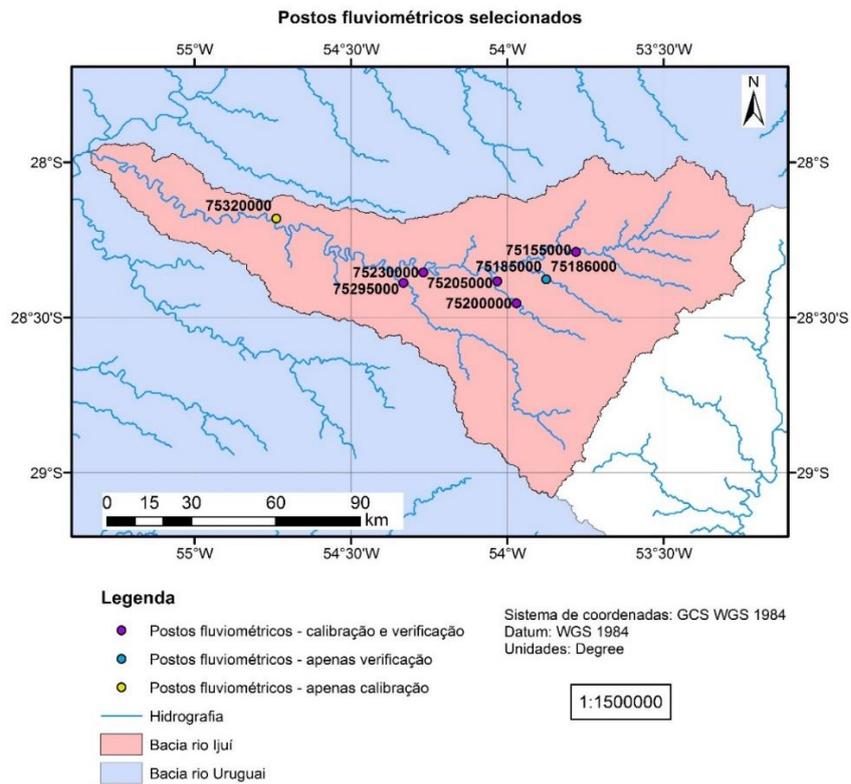


Figura 6.5. Postos fluviométricos selecionados.

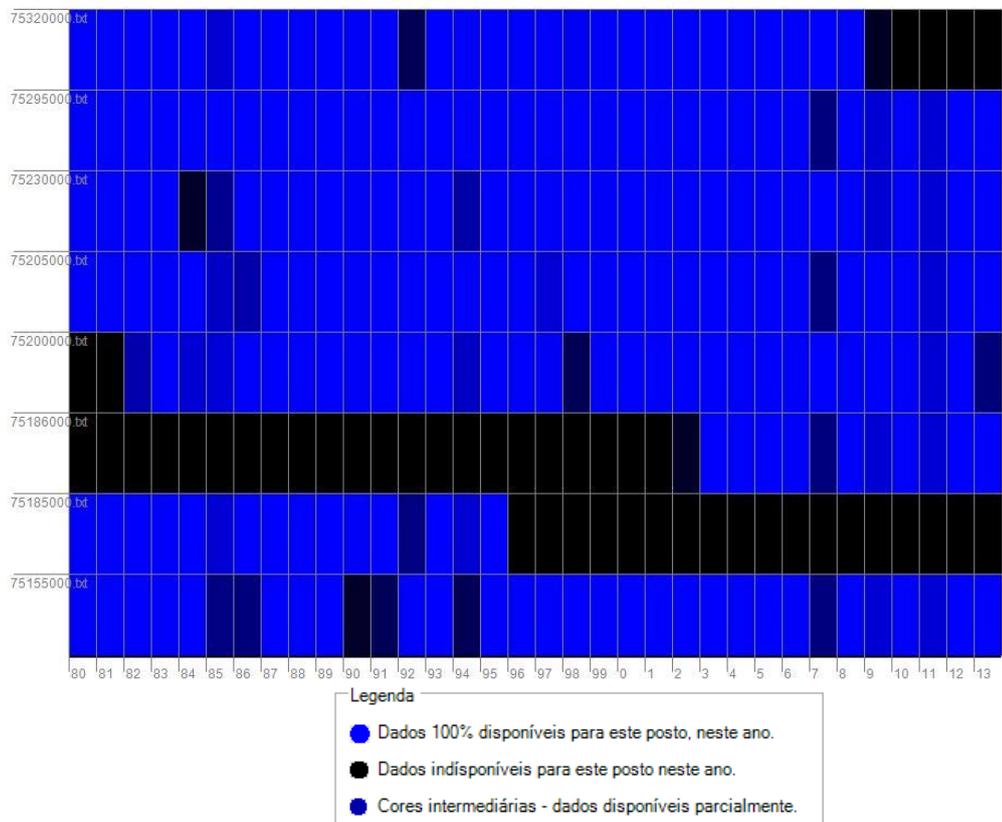


Figura 6.6. Disponibilidade temporal de dados de vazão dos postos fluviométricos selecionados para o período de interesse.

6.2.2 Seleção de dados de precipitação observados

A Tabela 6.4 mostra os postos pluviométricos selecionados para a simulação nas etapas de calibração do MGB-IPH e verificação da calibração e da previsão de umidade do solo. Os dados de precipitação empregados são provenientes do HidroWeb (<http://hidroweb.ana.gov.br/>) da ANA-Agência Nacional de Águas. Estes postos foram selecionados por sua disponibilidade de dados no período de interesse (1980-2004 para calibração e 2005-2013 para verificação) e localização na bacia do rio Ijuí ou nas suas proximidades. Todos os postos encontram-se no Rio Grande do Sul. Há 26 postos com dados disponíveis no período de calibração e 35 no de verificação, sendo 26 postos comuns a ambas as etapas. A Figura 6.7 mostra a localização dos postos selecionados. A Figura 6.8 mostra a disponibilidade de dados ao longo do período de interesse.

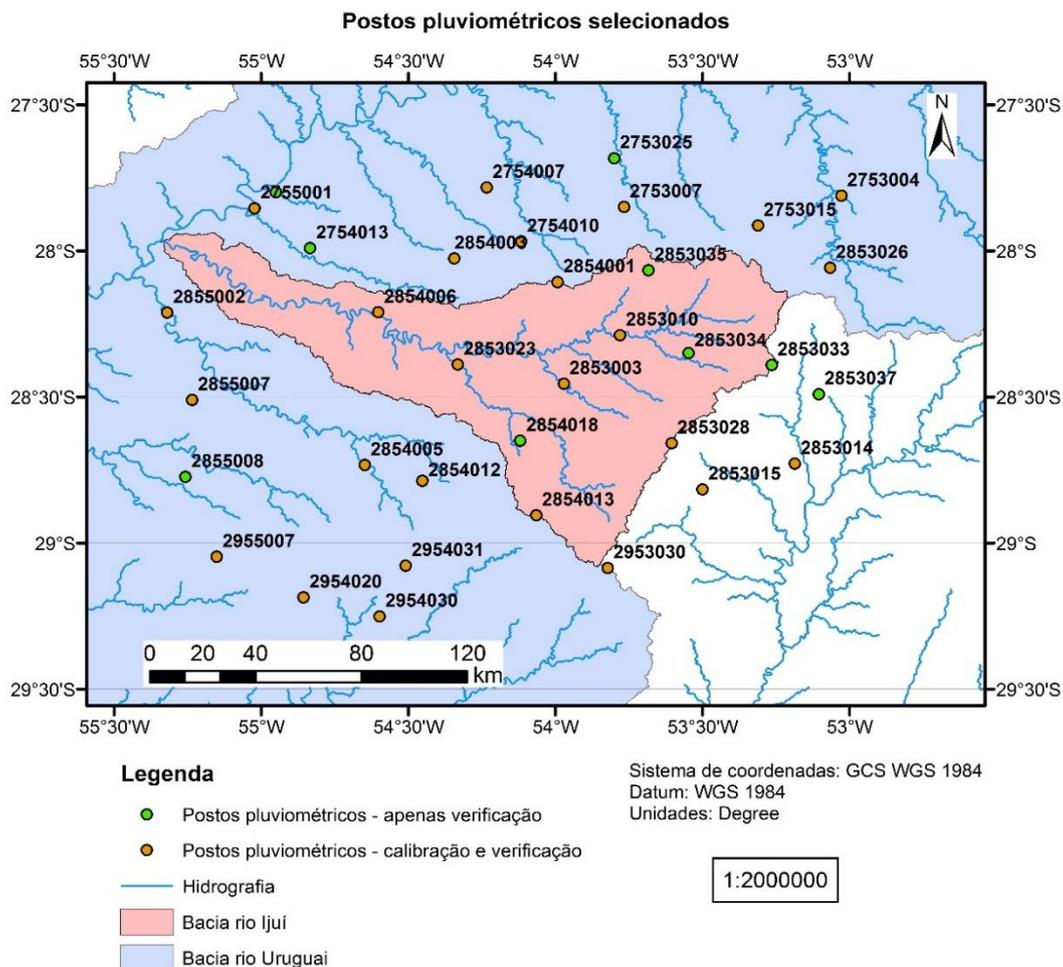


Figura 6.7. Postos pluviométricos selecionados.

Tabela 6.4. Postos pluviométricos na bacia do rio Ijuí e entornos usados na simulação.

Código	Nome	Código adicional	Município	Responsável	Operadora	Latitude (°)	Longitude (°)	Altitude (m)	Calibração	Verificação
2753004	Linha Cescon	-	Sarandi	ANA	CPRM	-27,812	-53,028	350	Sim	Sim
2753007	Santo Augusto	-	Santo Augusto	CEEE	CEEE	-27,850	-53,767	520	Sim	Sim
2753015	Palmeira das Missões	ANA	Palmeira das Missões	ANA	CPRM	-27,913	-53,311	610	Sim	Sim
2754007	Três de Maio	-	Três de Maio	CEEE	CEEE	-27,783	-54,233	403	Sim	Sim
2754010	Esquina Araujo	-	Independência	ANA	CPRM	-27,968	-54,116	400	Sim	Sim
2755001	Porto Lucena	ANA	Porto Lucena	ANA	CPRM	-27,854	-55,023	100	Sim	Sim
2853003	Conceição	-	Ijuí	ANA	CPRM	-28,455	-53,971	160	Sim	Sim
2853010	Passo Faxinal	-	Ijuí	ANA	CPRM	-28,289	-53,780	200	Sim	Sim
2853014	Santa Clara do Ingai	-	Cruz Alta	ANA	CPRM	-28,729	-53,186	390	Sim	Sim
2853015	Três Capões	-	Cruz Alta	CEEE	CEEE	-28,817	-53,500	350	Sim	Sim
2853023	Condor	ANA	Condor	ANA	CPRM	-28,389	-54,332	440	Sim	Sim
2853026	Chapada	-	Chapada	ANA	CPRM	-28,059	-53,066	450	Sim	Sim
2853028	Anderson Clayton	ANA	Cruz Alta	ANA	CPRM	-28,659	-53,605	440	Sim	Sim
2854001	Boa Vista	ANA	Catuipe	ANA	CPRM	-28,107	-53,993	447	Sim	Sim
2854003	Girua	-	Giruí	ANA	CPRM	-28,026	-54,344	400	Sim	Sim
2854005	Passo Major Zeferino	ANA	São Miguel das Missões	ANA	CPRM	-28,734	-54,648	160	Sim	Sim
2854006	Passo Viola	ANA	Guarani das Missões	ANA	CPRM	-28,211	-54,602	160	Sim	Sim
2854012	Coimbra	-	Santo Angelo	ANA	CPRM	-28,788	-54,452	300	Sim	Sim
2854013	São Bernardo	-	Tupancireta	ANA	CPRM	-28,905	-54,065	530	Sim	Sim
2855002	Passo do Sarmento	ANA	São Borja	ANA	CPRM	-28,212	-55,320	80	Sim	Sim
2855007	Santo Antônio das Missões	-	Santo Antônio das Missões	ANA	CPRM	-28,511	-55,235	200	Sim	Sim
2953030	Tupancireta	-	Tupancireta	ANA	CPRM	-29,086	-53,822	469	Sim	Sim
2954020	Santiago	ANA	Santiago	ANA	CPRM	-29,187	-54,856	420	Sim	Sim
2954030	Florida	-	Santiago	ANA	CPRM	-29,251	-54,598	370	Sim	Sim
2954031	Esquina dos Lima (Sta. Barbara)	-	Santiago	ANA	CPRM	-29,078	-54,509	420	Sim	Sim

Código	Nome	Código adicional	Município	Responsável	Operadora	Latitude (°)	Longitude (°)	Altitude (m)	Calibração	Verificação
2955007	Unistalda	-	Santiago	ANA	CPRM	-29,048	-55,151	380	Sim	Sim
2754013	Campina das Missões	-	Campina das Missões	ANA	CPRM	-27,991	-54,834	180	Não	Sim
2754014	São Martinho	-	São Martinho	ANA	CPRM	-27,800	-54,950	448	Não	Sim
2753025	Campo Novo	-	Planalto	ANA	CPRM	-27,683	-53,800	475	Não	Sim
2853033	Santa Barbara do Sul	-	Santa Bárbara do Sul	ANA	CPRM	-28,391	-53,264	500	Não	Sim
2853034	Panambi	-	Panambi	ANA	CPRM	-28,350	-53,547	480	Não	Sim
2853035	Nova Ramada	-	Nova Ramada	ANA	CPRM	-28,067	-53,683	533	Não	Sim
2853037	Campinas	-	Ibiruba	ANA	CPRM	-28,491	-53,105	400	Não	Sim
2854018	Jóia	-	Jóia	ANA	CPRM	-28,650	-54,119	314	Não	Sim
2855008	Itacumbi	-	Itacurubi	ANA	CPRM	-28,774	-55,257	180	Não	Sim

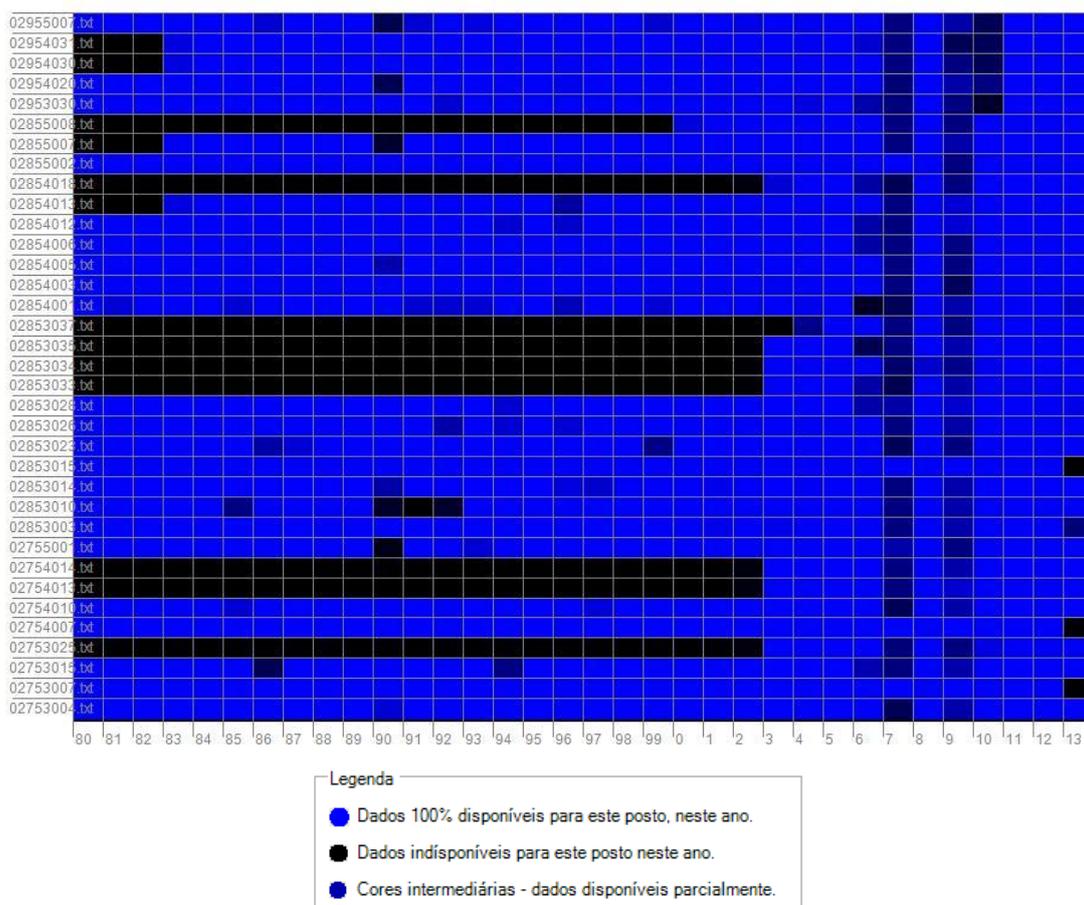


Figura 6.8. Disponibilidade temporal de dados de precipitação observada dos postos pluviométricos selecionados para o período de interesse.

6.2.3 Seleção de dados de clima observados

Para o cálculo da evapotranspiração no MGB-IPH, realizada através do método de Penman-Monteith, são necessários os seguintes dados climatológicos:

- Temperatura;
- Umidade relativa do ar;
- Velocidade do vento;
- Insolação;
- Pressão atmosférica.

A previsão de umidade do solo empregou dados climatológicos médios mensais de longo período, correspondentes ao período entre 1980-2004, anterior ao período de previsão.

Os dados climáticos observados foram obtidos através da base de dados interna do MGB-IPH, que dispõe de médias mensais. Foram selecionadas nove estações climatológicas localizadas na bacia do rio Ijuí ou nas suas proximidades. A Figura 6.9 mostra a localização destas estações, enquanto a Tabela 6.5 traz informações sobre as mesmas.

A ausência de dados de alguma variável meteorológica em uma estação exige a complementação da série, o que é realizado no próprio MGB-IPH com a adoção dos valores disponíveis mais próximos. Os valores de Insolação da estação 00083909 – Santo Ângelo não existem na base interna do MGB, tendo sido adotados para esta variável os valores observados na estação 00083907 – São Luiz Gonzaga. Da mesma forma, para os valores de horas de insolação por dia, indisponíveis para as estações 00083880 – Palmeira das Missões e 00083929 – Itaqui, foram adotados os valores correspondentes aos das estações 00083881 – Iraí, e 00083927 – Uruguaiana, respectivamente.

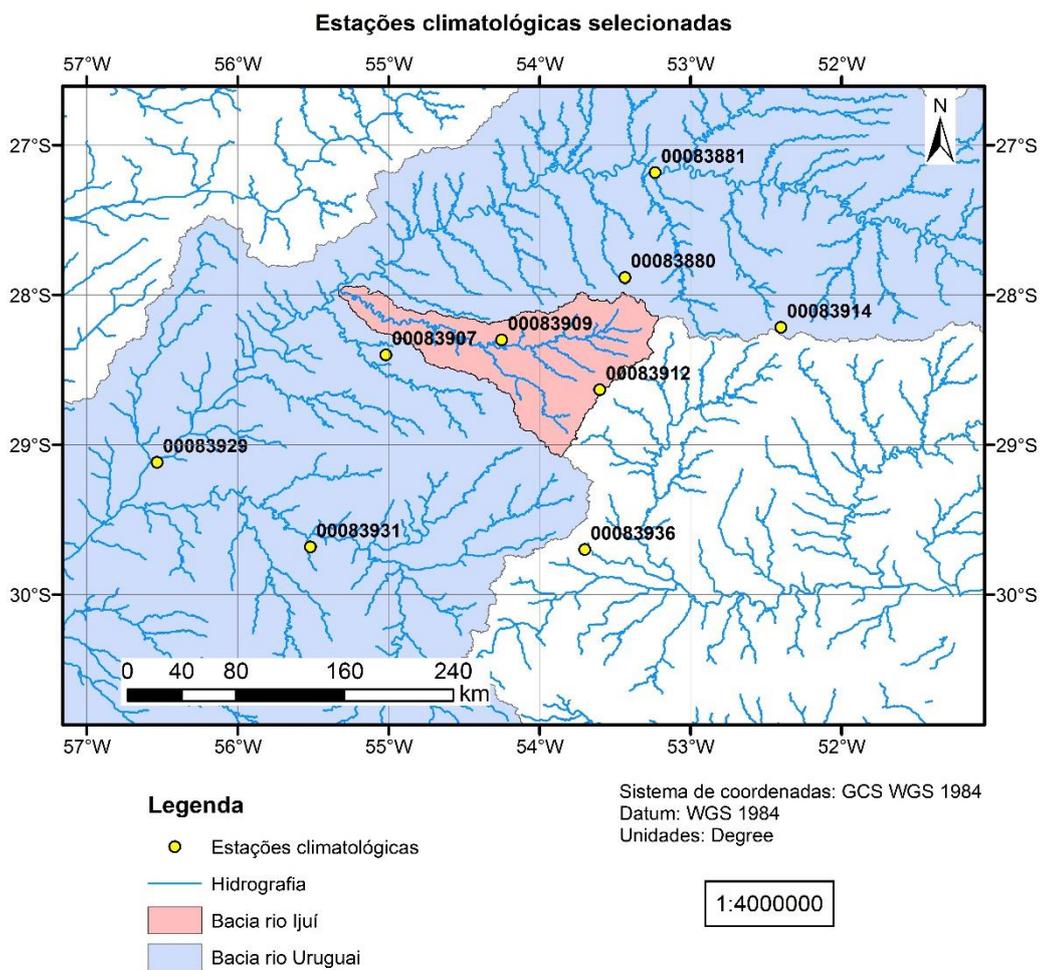


Figura 6.9. Estações climatológicas selecionadas.

Tabela 6.5. Estações climatológicas na bacia do rio Ijuí e entornos usadas na simulação.

Código	Estação	Latitude (°)	Longitude (°)
83907	São Luiz Gonzaga	-28,4	-55,017
83909	Santo Ângelo	-28,3	-54,25
83912	Cruz Alta	-28,633	-53,6
83880	Palmeira das Missões	-27,883	-53,433
83881	Iraí	-27,183	-53,233
83914	Passo Fundo	-28,217	-52,4
83929	Itaqui	-29,117	-56,533
83931	Alegrete	-29,683	-55,517
83936	Santa Maria	-29,7	-53,7

6.2.4 Calibração

A calibração do MGB-IPH é, neste estudo, realizada apenas manualmente, ou seja, a calibração automática dos parâmetros ditos “calibráveis” não é realizada. Isto é feito com o objetivo de garantir a coerência física dos parâmetros conforme a URH.

Parâmetros fixos

Os parâmetros fixos são associados a cada mês do ano, a cada URH. Os parâmetros fixos que devem ser definidos para aplicação do modelo são albedo, altura da vegetação, índice de área foliar, e resistência superficial em boas condições de umidade do solo. A Tabela 6.6 a seguir mostra os valores adotados para estes parâmetros. Os valores adotados foram empregados ignorando a separação entre solos rasos e profundos (por isso apenas quatro URHs são mostradas na Tabela 6.6, ao invés de sete). Além disso, os valores foram considerados constantes ao longo do ano.

Tabela 6.6. Parâmetros fixos do MGB-IPH.

URH	Albedo	IAF Índice de Área Foliar	Z Altura do Dossel (m)	rs Resistência Superficial (s/m)
Agricultura	0,22	2,00	0,70	70,0
Campo	0,23	2,00	0,50	70,0
Floresta	0,12	6,00	12,0	100,0
Água	0,08	1,00	0,50	0,00

Parâmetros calibráveis

A calibração dos parâmetros ditos calibráveis, realizada manualmente, buscou sobretudo minimizar erro entre os volumes calculado e observado (ΔV) e atingir um bom ajuste da curva de permanência, procurando, contudo, manter bons resultados para os coeficientes NS e NS_{log}. O conjunto de parâmetros calibráveis adotado para cada sub-bacia pode ser encontrado no ANEXO D.

Avaliação do ajuste

A Tabela 6.7 a seguir mostra os resultados das métricas que avaliam a qualidade do ajuste obtido com os conjuntos de parâmetros fixos e calibráveis empregados na simulação. Como pode-se observar, o ajuste apresentou coeficientes de Nash-Sutcliffe (NS) igual ou acima de 0,70, coeficientes de Nash-Sutcliffe para os logaritmos das vazões (NS log) acima de 0,80 e relação entre volume observado e calculado (ΔV) como $-1 \leq \Delta V \leq 1$, para seis dos sete postos fluviométricos empregados na calibração.

As figuras a seguir mostram as curvas de permanência e hidrogramas observados e calculados com o MGB-IPH para o posto fluviométrico mais à jusante na bacia do rio Ijuí. Como pode-se observar nas figuras 6.10 e 6.11, e na Tabela 6.7, o ajuste apresentado durante a etapa de calibração foi bom. Ainda que para as vazões de pico o ajuste não seja excelente, isto não interfere no objetivo do trabalho aqui realizado, onde o fundamental é a qualidade do ajuste nas vazões mais baixas. Além disso, as curvas de permanência calculadas mostraram-se muito próximas das observadas. Desta forma, considera-se a calibração adequada aos objetivos do estudo. As figuras das curvas de permanência e hidrogramas simulados e observados para todos os postos fluviométricos selecionados na bacia encontram-se no ANEXO E.

Tabela 6.7. Qualidade do ajuste na etapa de calibração do MGB-IPH.

Posto fluviométrico	Sub-bacia	NS	NS log	ΔV
75155000	1	0,7978	0,8050	0,2603
75185000	2	0,7839	0,8040	0,0170
75200000	3	0,7000	0,8589	0,6349
75205000	3	0,7716	0,8706	0,6288
75230000	4	0,8514	0,8635	-2,7987
75295000	5	0,7671	0,8351	-0,9641
75320000	6	0,8506	0,8889	0,2102

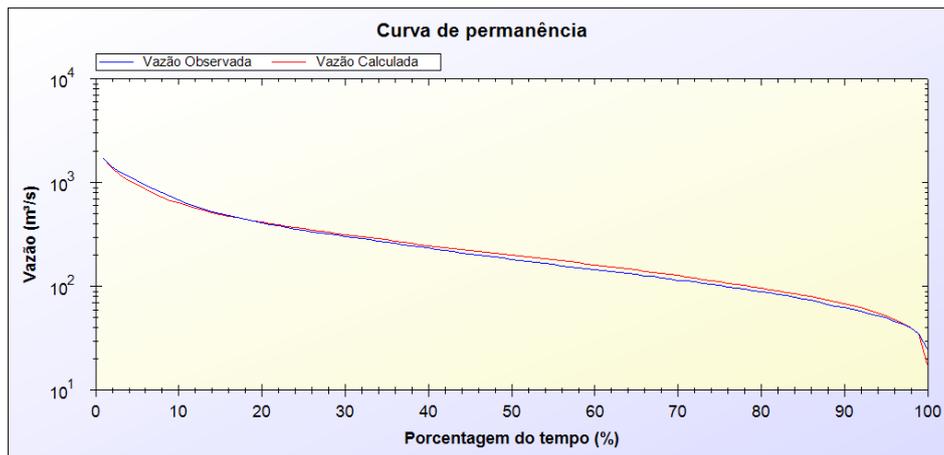


Figura 6.10. Curva de permanência do posto fluviométrico 75320000, na sub-bacia 6, obtida na etapa de calibração do MGB-IPH.

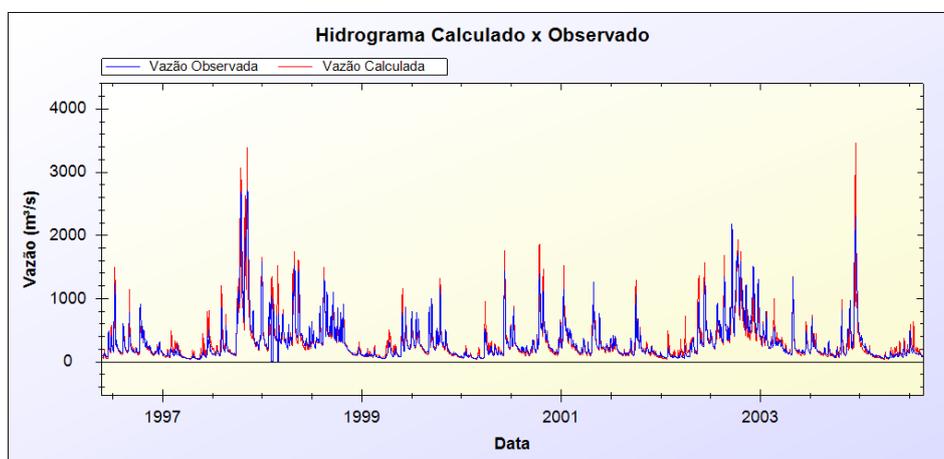


Figura 6.11. Detalhe do hidrograma do posto fluviométrico 75320000, na sub-bacia 6, obtido na etapa de calibração do MGB-IPH.

6.2.5 Verificação da calibração

A verificação da calibração tem por objetivo assegurar que o modelo calibrado continua representando apropriadamente os processos hidrológicos na bacia de interesse em um período diferente daquele da calibração. Esta verificação é realizada para o mesmo período da etapa de previsão (2005-2013) para verificar a qualidade da simulação hidrológica neste intervalo de tempo; ou seja, esta verificação visa assegurar que o MGB-IPH é capaz de apropriadamente simular a bacia do rio Ijuí no período de interesse.

A Tabela 6.8 mostra os resultados das medidas de desempenho para todos os postos fluviométricos selecionados para a etapa de verificação da calibração. As figuras 6.12 e 6.13 a seguir mostram a curva de permanência e hidrogramas observado e calculado com o MGB-IPH para a estação fluviométrica mais a jusante na bacia do rio

Ijuí. As figuras relativas a todos os postos fluviométricos da bacia encontram-se no ANEXO E. Observando-se a qualidade do ajuste, considera-se que o MGB-IPH está devidamente calibrado e é capaz de representar os processos hidrológicos na bacia do rio Ijuí no período de interesse (2005-2013).

Tabela 6.8. Qualidade do ajuste na etapa de verificação da calibração do MGB-IPH.

Posto fluviométrico	Sub-bacia	NS	NS log	ΔV
75155000	1	0,6463	0,7978	15,5709
75186000	2	0,6677	0,8165	-7,2160
75200000	3	0,6182	0,8372	10,3998
75205000	3	0,6333	0,8759	5,0602
75230000	4	0,7590	0,8523	5,2927
75295000	5	0,7150	0,8032	7,1697

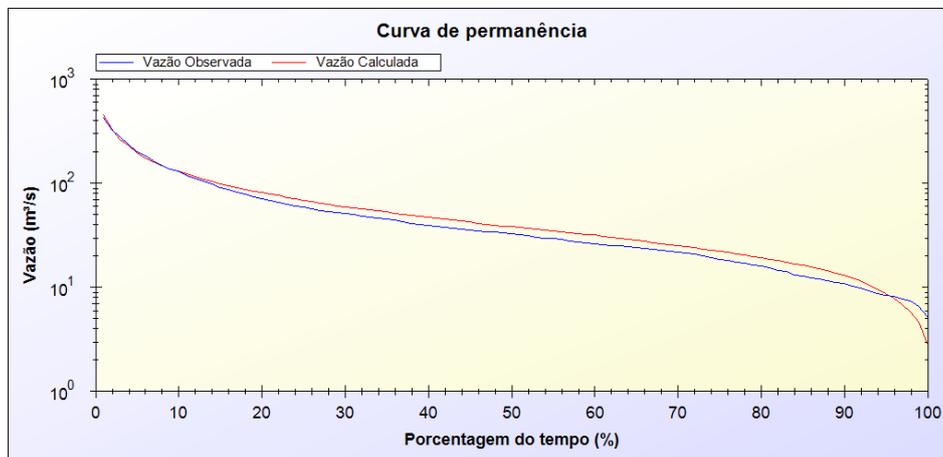


Figura 6.12. Curva de permanência do posto fluviométrico 75295000, na sub-bacia 5, obtida na etapa de verificação da calibração do MGB-IPH.

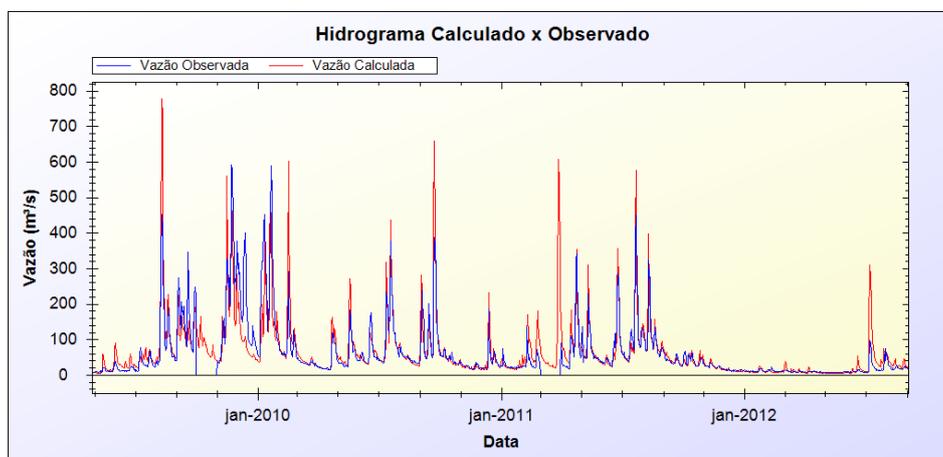


Figura 6.13. Detalhe do hidrograma do posto fluviométrico 75295000, na sub-bacia 5, obtido na etapa de verificação da calibração do MGB-IPH.

7. PREVISÃO DE PRECIPITAÇÃO

7.1 Grade de previsão

A Figura 7.1 a seguir mostra os pontos com dados de previsão de precipitação para a região de interesse, para os modelos de previsão selecionados. O espaçamento da grade de cada modelo pode ser conferido na Tabela 4.1. Para cada membro de cada modelo, foram selecionados os 9 pontos (3 X 3 pontos) mais próximos da bacia do rio Ijuí, de forma a cobrir a bacia e todo o seu entorno. Os dados referentes a estes pontos foram organizados e alimentados no MGB-IPH, de forma a determinar a precipitação associada a cada minibacia, em cada intervalo de tempo. Os dados foram então ajustados no tempo, conforme o horizonte da previsão, e corrigidos quanto ao viés.

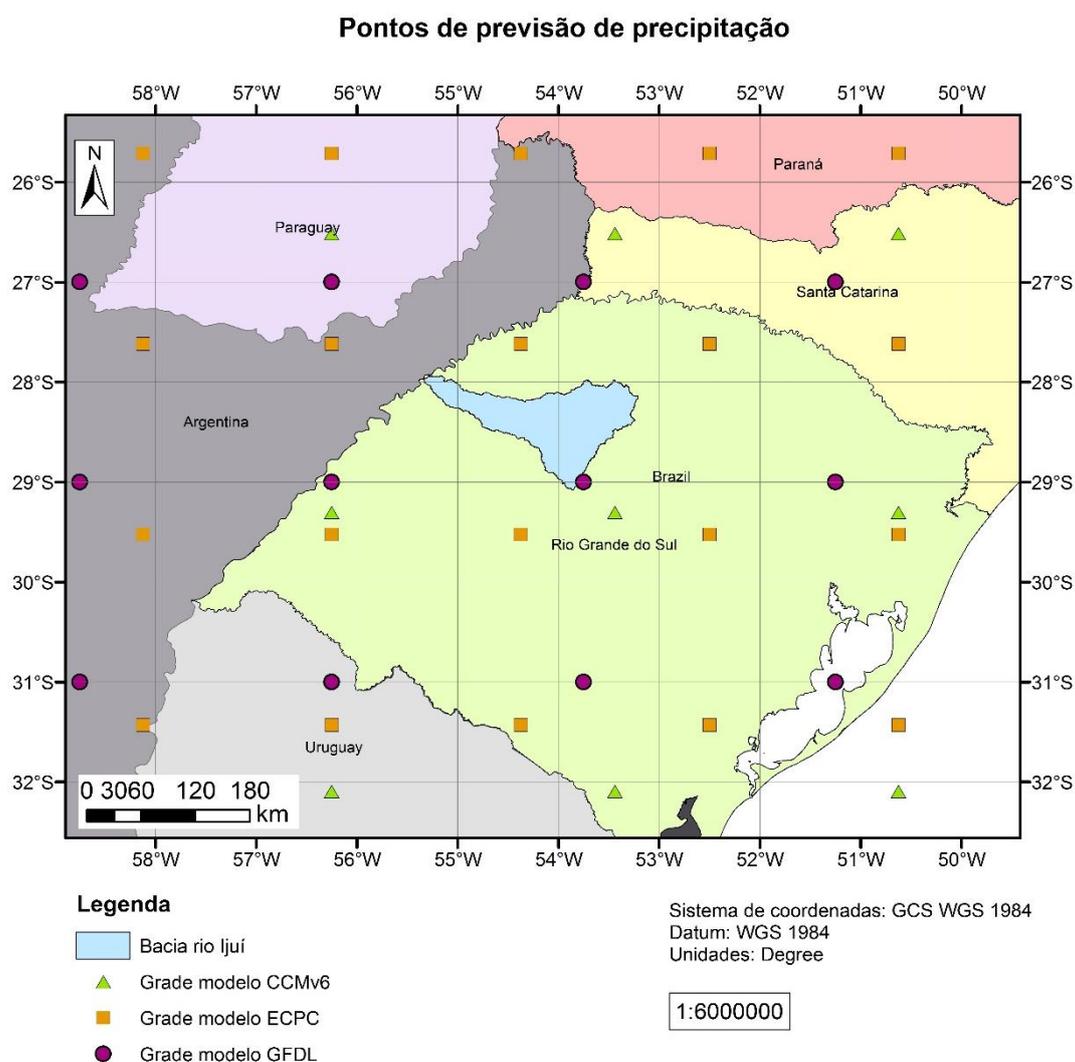


Figura 7.1. Pontos com precipitação prevista para a região de interesse.

7.2 Correção de viés das previsões de precipitação

Para a correção do viés, foi aplicada a metodologia descrita no item 4.3.2 na página 45. As tabelas 7.1, 7.2 e 7.3 mostram as equações aplicadas sobre cada previsão (precipitação média da bacia, para cada mês) para encontrar a precipitação total mensal prevista corrigida média da bacia. Para a determinação das equações de erro e, conseqüentemente, de correção das precipitações previstas (conforme item 4.3.2, $(P_{\text{corrigida}} = P_{\text{prevista}} - \text{Erro})$, onde Erro é uma função da P_{prevista}), a escolha entre o ajuste com polinômio de 1º, 2º ou 3º grau buscou a opção de função onde a correção fosse menor para precipitações mais baixas. Ou seja, entre diferentes equações de ajuste com qualidade semelhante (aderência semelhante aos dados), optou-se por aquela com menor crescimento nos extremos, sobretudo para precipitações mais baixas. A Figura 7.2 mostra como exemplo o ajuste da função de erro para o modelo GFDL, para o mês de janeiro. Como pode-se observar, o ajuste com polinômio de 1º grau tende a fornecer valores mais altos de erro para precipitação mais baixas. Desta forma, optou-se pela correção da precipitação prevista com um erro ajustado como um polinômio de 2º grau.

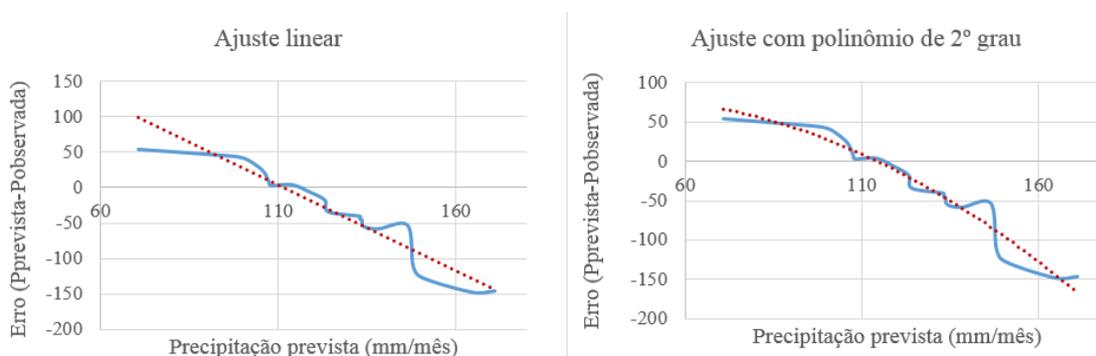


Figura 7.2. Exemplos de ajuste de função de erro das previsões. Modelo GFDL, mês de janeiro.

As figuras 7.3 a 7.5 mostram, para os meses de janeiro e julho, as precipitações totais mensais médias da bacia do rio Ijuí, observada, média do *ensemble* sem e com correção, e o erro antes e após a correção de viés. As figuras referentes aos resultados da correção de viés para todos os meses do ano podem ser analisados no ANEXO C, no item C.2.

As figuras a seguir mostram os resultados da correção realizada com base nos dados do período de 1980-2000, escolhido como o período de análise e anterior à previsão de umidade do solo.

Observa-se pelas figuras a seguir que as precipitações previstas pelos modelos CCM3v6, ECPC e GFDL, antes apresentando diferenças significativas em relação às precipitações observadas, após a correção de viés mostram-se mais coerentes com a realidade da bacia. Os erros, calculados como Precipitação Prevista com frequência acumulada x menos Precipitação Observada com frequência acumulada x, após o processo de correção, ficam em torno de zero. As imagens referentes à correção de viés para os demais meses do ano (ver item C.2 no ANEXO C) mantém o padrão apresentado pelo apresentado nas figuras aqui apresentadas.

Tabela 7.1. Equações aplicadas para correção de viés nas previsões de precipitação do modelo CCM3v6, conforme o mês. Pprev é a precipitação prevista pelo modelo CCM3v6 para o membro x, para a minibacia y, para o mês z.

CCM3v6	Pcorrigida = Pprev - Erroc
Janeiro	$P_{corrigida} = P_{prev} - (-0,0363.P_{prev}^2 + 1,4316.P_{prev} + 232,54)$
Fevereiro	$P_{corrigida} = P_{prev} - (-3,755.P_{prev} + 347,52)$
Março	$P_{corrigida} = P_{prev} - (-0,05.P_{prev}^2 + 5,1616.P_{prev} - 94,11)$
Abril	$P_{corrigida} = P_{prev} - (0,0532.P_{prev}^2 - 12,418.P_{prev} + 448,97)$
Maio	$P_{corrigida} = P_{prev} - (-0,0429.P_{prev}^2 - 1,2664.P_{prev} + 91,843)$
Junho	$P_{corrigida} = P_{prev} - (-5,0725.P_{prev} + 131,77)$
Julho	$P_{corrigida} = P_{prev} - (-0,278.P_{prev}^2 + 18,32.P_{prev} - 327,35)$
Agosto	$P_{corrigida} = P_{prev} - (-0,1966.P_{prev}^2 + 19,834.P_{prev} - 457,26)$
Setembro	$P_{corrigida} = P_{prev} - (-4,6606.P_{prev} + 325,19)$
Outubro	$P_{corrigida} = P_{prev} - (-0,0205.P_{prev}^3 + 5,8576.P_{prev}^2 - 559,71.P_{prev} + 17774)$
Novembro	$P_{corrigida} = P_{prev} - (-0,2505.P_{prev}^2 + 41,506.P_{prev} - 1643,8)$
Dezembro	$P_{corrigida} = P_{prev} - (-4,6135.P_{prev} + 481,37)$

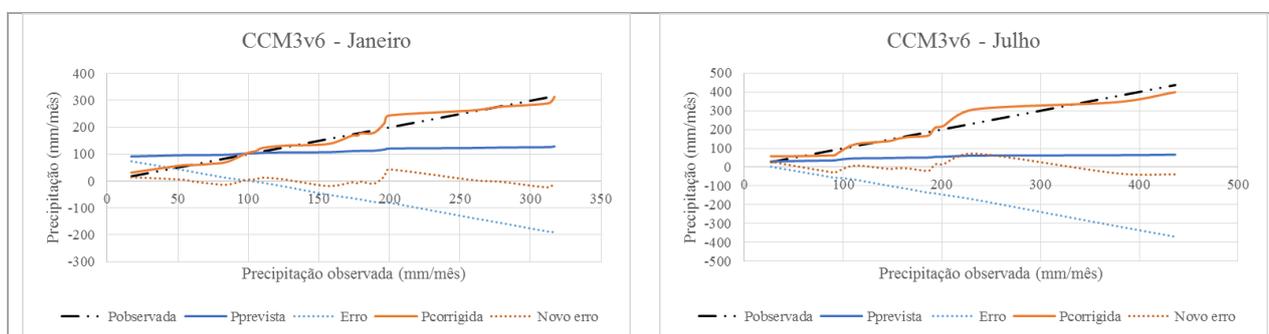


Figura 7.3. Correção de viés do modelo CCM3v6 para os meses de janeiro e julho.

Tabela 7.2. Equações aplicadas para correção de viés nas previsões de precipitação do modelo ECPC, conforme o mês. Pprev é a precipitação prevista pelo modelo ECPC para o membro x, para a minibacia y, para o mês z.

ECPC	Pcorrigida = Pprev - Erroc
Janeiro	$P_{corrigida} = P_{prev} - (-0,0018.P_{prev}^2 - 0,5493.P_{prev} + 144,28)$
Fevereiro	$P_{corrigida} = P_{prev} - (-0,0777.P_{prev}^2 + 15,963.P_{prev} - 737,17)$
Março	$P_{corrigida} = P_{prev} - (-0,0138.P_{prev}^2 + 1,7474.P_{prev} - 53,774)$
Abril	$P_{corrigida} = P_{prev} - (0,0401.P_{prev}^2 - 11,471.P_{prev} + 612,75)$
Mai	$P_{corrigida} = P_{prev} - (-0,0572.P_{prev}^2 + 7,4284.P_{prev} - 211,05)$
Junho	$P_{corrigida} = P_{prev} - (-1,427.P_{prev} + 56,697)$
Julho	$P_{corrigida} = P_{prev} - (-0,0772.P_{prev}^2 + 9,9096.P_{prev} - 313,82)$
Agosto	$P_{corrigida} = P_{prev} - (-0,0053.P_{prev}^2 - 0,5701.P_{prev} + 139,93)$
Setembro	$P_{corrigida} = P_{prev} - (-0,0025.P_{prev}^2 - 1,6779.P_{prev} + 335,16)$
Outubro	$P_{corrigida} = P_{prev} - (-0,0382.P_{prev}^2 + 12,134.P_{prev} - 891,99)$
Novembro	$P_{corrigida} = P_{prev} - (-0,0743.P_{prev}^2 + 18,042.P_{prev} - 1024,2)$
Dezembro	$P_{corrigida} = P_{prev} - (-0,9888.P_{prev} + 132,21)$

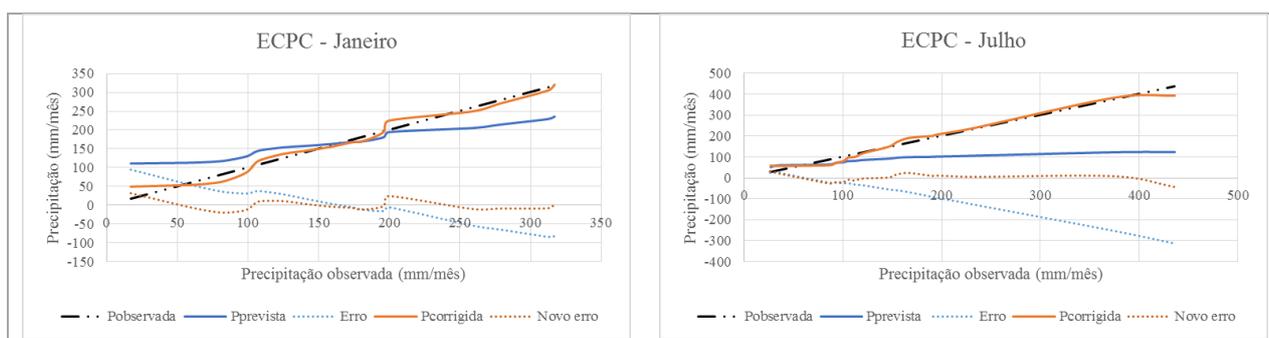


Figura 7.4. Correção de viés do modelo ECPC para os meses de janeiro e julho.

Tabela 7.3. Equações aplicadas para correção de viés nas previsões de precipitação do modelo GFDL, conforme o mês. Pprev é a precipitação prevista pelo modelo GFDL para o membro x, para a minibacia y, para o mês z.

GFDL	Pcorrigida = Pprev - Erroc
Janeiro	$P_{corrigida} = P_{prev} - (-0,0143.P_{prev}^2 + 1,1182.P_{prev} + 58,503)$
Fevereiro	$P_{corrigida} = P_{prev} - (-0,0482.P_{prev}^2 + 7,1986.P_{prev} - 246,4)$
Março	$P_{corrigida} = P_{prev} - (-0,0002.P_{prev}^2 - 1,2982.P_{prev} + 54,416)$
Abril	$P_{corrigida} = P_{prev} - (-2,3013.P_{prev} + 57,743)$
Mai	$P_{corrigida} = P_{prev} - (-4,0189.P_{prev} + 79,672)$
Junho	$P_{corrigida} = P_{prev} - (0,0046.P_{prev}^2 - 3,7136.P_{prev} - 31,759)$
Julho	$P_{corrigida} = P_{prev} - (-0,2728.P_{prev}^2 + 0,2251.P_{prev} - 29,317)$
Agosto	$P_{corrigida} = P_{prev} - (-0,089.P_{prev}^2 - 6,413.P_{prev} + 31,878)$
Setembro	$P_{corrigida} = P_{prev} - (-6,7371.P_{prev} + 89,88)$
Outubro	$P_{corrigida} = P_{prev} - (-0,0138.P_{prev}^3 + 3,5848.P_{prev}^2 - 311,57.P_{prev} + 8934,5)$
Novembro	$P_{corrigida} = P_{prev} - (-0,0384.P_{prev}^2 + 4,5003.P_{prev} - 82,582)$
Dezembro	$P_{corrigida} = P_{prev} - (-1,2586.P_{prev} + 128,64)$

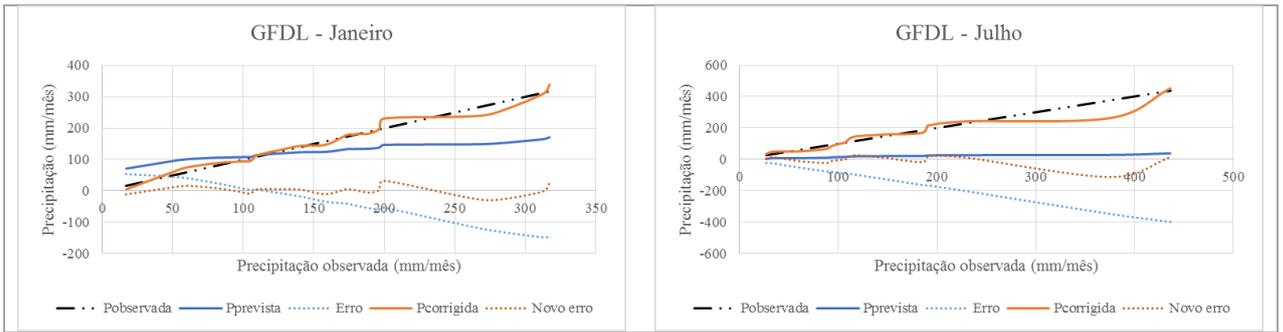


Figura 7.5. Correção de viés do modelo GFDL para os meses de janeiro e julho.

7.3 Análise das precipitações previstas quanto a correção de viés

Uma vez que as previsões originais se encontravam em escala mensal, a correção de viés também foi realizada para as precipitações totais mensais. Como pode-se observar nas figuras 7.6 a 7.14, a correção de viés aplicada gerou uma melhora perceptível na qualidade das precipitações previstas para os diferentes horizontes. As previsões originais, claramente subestimadas, agora mostram-se mais coerentes com a precipitação observada, e apresentam uma amplitude de variação mais próxima à realidade da bacia.

A Tabela 7.4 mostra a média dos erros das precipitações mensais para o período de previsão. O erro, neste caso, é definido como a diferença entre a precipitação mensal média da bacia prevista pelo modelo, e a precipitação observada (Eq. (21)). Observa-se que a correção de viés diminuiu o erro médio absoluto em até 99%. O melhor desempenho da correção de viés foi observado para o modelo CCM3v6. Resultados com qualidade semelhante foram encontrados para o modelo GFDL. Este modelo, contudo, ainda apresenta uma tendência a subestimar a precipitação na bacia, ainda que este viés seja muito menor quando comparado ao existente antes correção de viés. Já o modelo ECPC, que antes da correção de viés possuía um viés negativo (Precipitação do modelo < Precipitação observada), após a correção apresenta um viés positivo, porém menor em valor absoluto em relação ao viés apresentado antes da correção. Para o modelo ECPC, as previsões com 1 mês de antecedência apresentam desempenho levemente melhor em relação as previsões com 3 e 6 meses. Contudo, para os demais modelos, a menor média de erro foi encontrada para o horizonte de 3 meses.

$$\text{Erro médio absoluto} = \frac{\sum(P_y - P_{obs})}{n} \quad (21)$$

Onde:

P_y [mm]: Precipitação mensal a ser analisada, prevista sem ou com correção de viés;

P_{obs} [mm]: Precipitação observada para o mês;

n : Número de intervalos de tempo (neste caso, o número de meses entre junho/2005 e dezembro/2013).

Tabela 7.4. Média dos erros absolutos mensais das precipitações previstas com e sem correção de viés.

	CCM3v6	ECPC	GFDL
Horizonte 1 mês - Erro médio SEM correção	-72,6 mm	-27,1 mm	-85,4 mm
Horizonte 1 mês - Erro médio COM correção	-3,2 mm	13,8 mm	-16,6 mm
Horizonte 1 mês - Diferença no erro	-96%	-49%	-81%
Horizonte 3 meses - Erro médio SEM correção	-71,0 mm	-21,5 mm	-82,3 mm
Horizonte 3 meses - Erro médio COM correção	1,0 mm	16,6 mm	-6,4 mm
Horizonte 3 meses - Diferença no erro	-99%	-23%	-92%
Horizonte 6 meses - Erro médio SEM correção	-69,8 mm	-19,1 mm	-82,4 mm
Horizonte 6 meses - Erro médio COM correção	6,7 mm	18,0 mm	-12,7 mm
Horizonte 6 meses - Diferença no erro	-90%	-6%	-85%

As figuras 7.6 a 7.14 a seguir mostram os resultados das precipitações observada e previstas médias da bacia do rio Ijuí, para o período de simulação (junho/2005 a dezembro/2013).

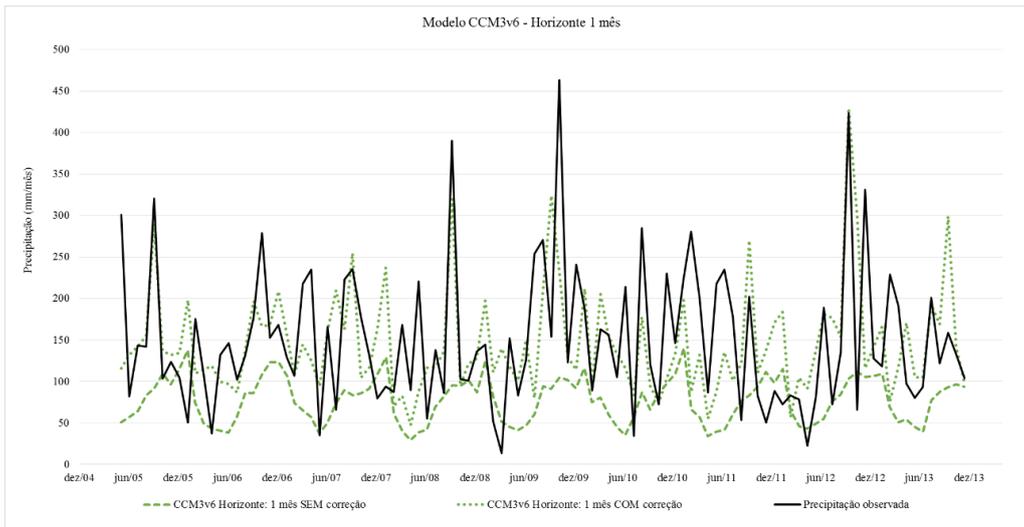


Figura 7.6. Precipitação observada e precipitação prevista com 1 mês de antecedência, com e sem correção de viés, para o modelo CCM3v6. Valores relativos à precipitação média da bacia do rio Ijuí, média do *ensemble* de membros do modelo.

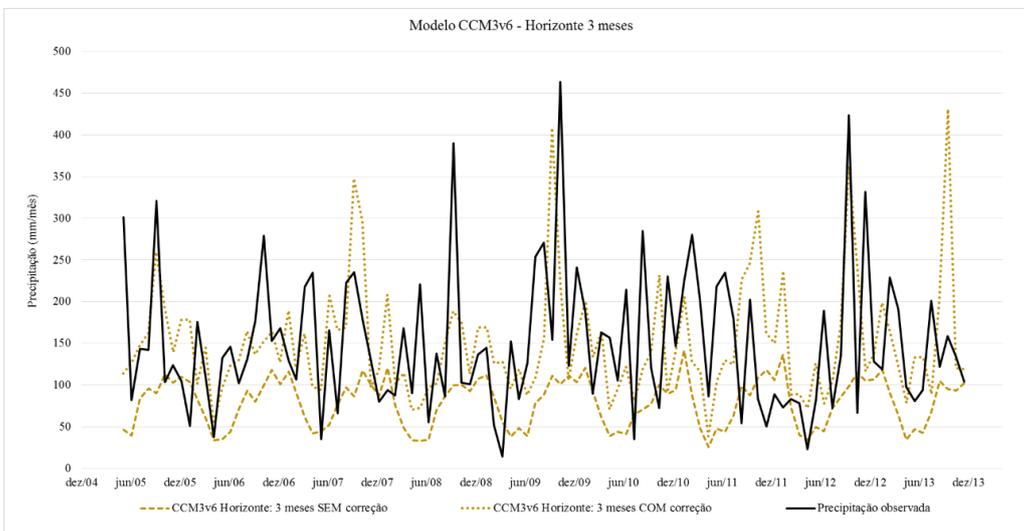


Figura 7.7. Precipitação observada e precipitação prevista com 3 meses de antecedência, com e sem correção de viés, para o modelo CCM3v6. Valores relativos à precipitação média da bacia do rio Ijuí, média do *ensemble* de membros do modelo.

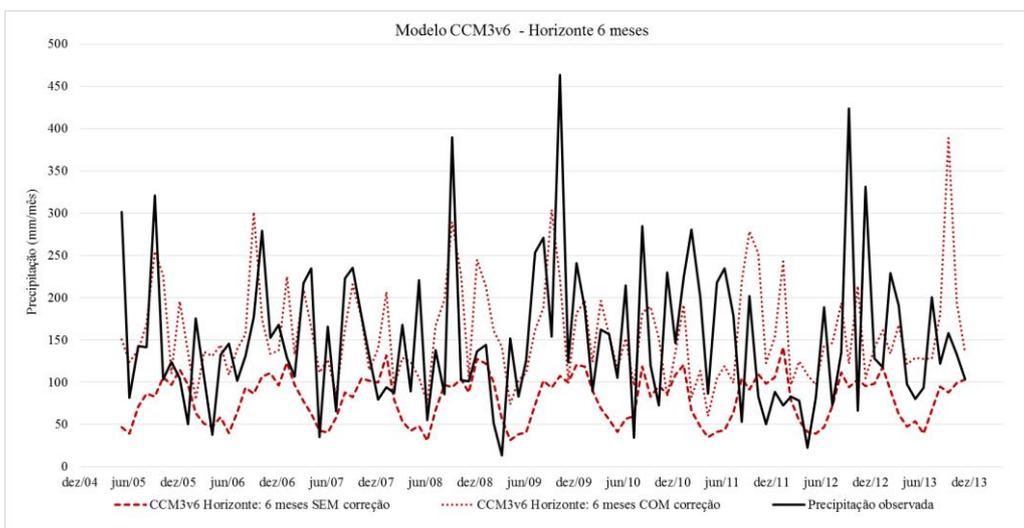


Figura 7.8. Precipitação observada e precipitação prevista com 6 meses de antecedência, com e sem correção de viés, para o modelo CCM3v6. Valores relativos à precipitação média da bacia do rio Ijuí, média do *ensemble* de membros do modelo.

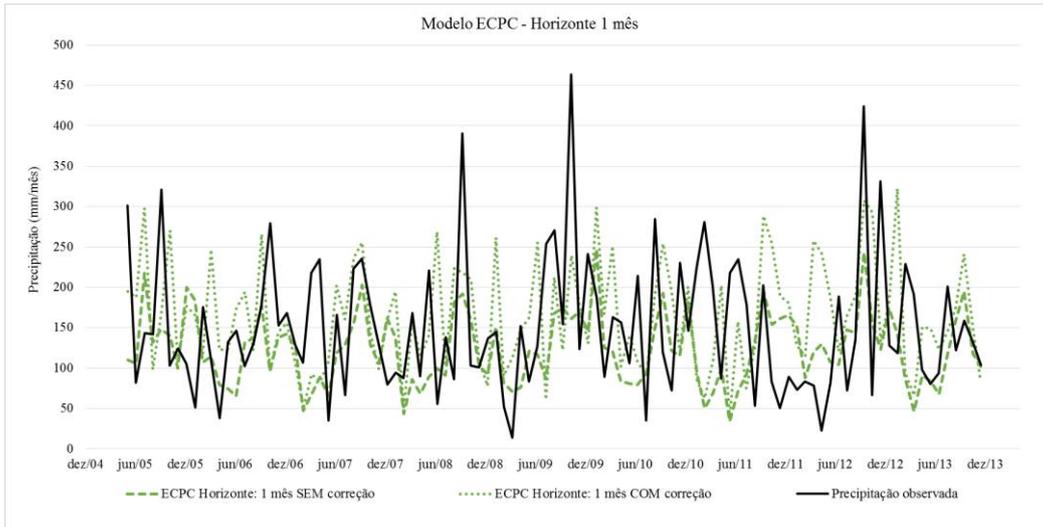


Figura 7.9. Precipitação observada e precipitação prevista com 1 mês de antecedência, com e sem correção de viés, para o modelo ECPC. Valores relativos à precipitação média da bacia do rio Ijuí, média do *ensemble* de membros do modelo.

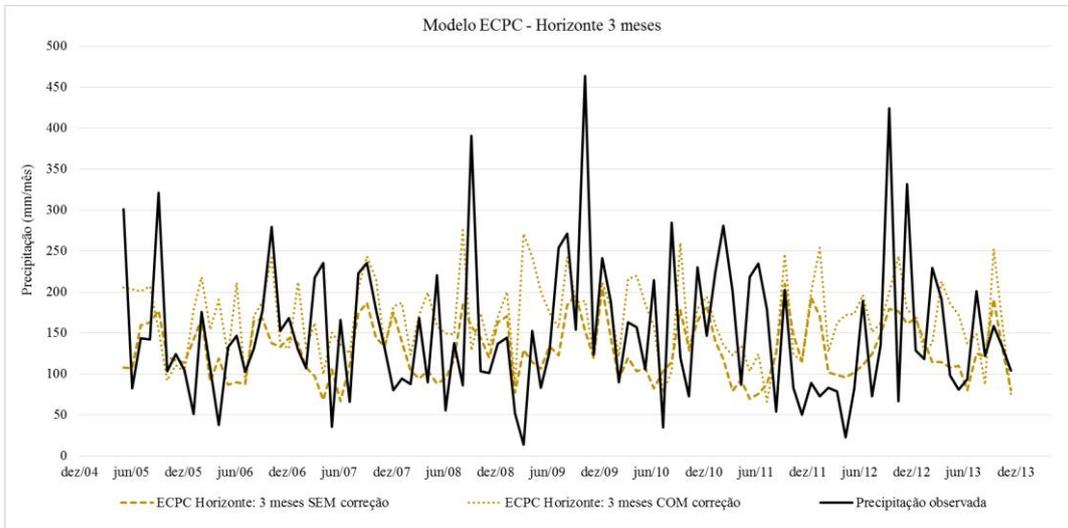


Figura 7.10. Precipitação observada e precipitação prevista com 3 meses de antecedência, com e sem correção de viés, para o modelo ECPC. Valores relativos à precipitação média da bacia do rio Ijuí, média do *ensemble* de membros do modelo.

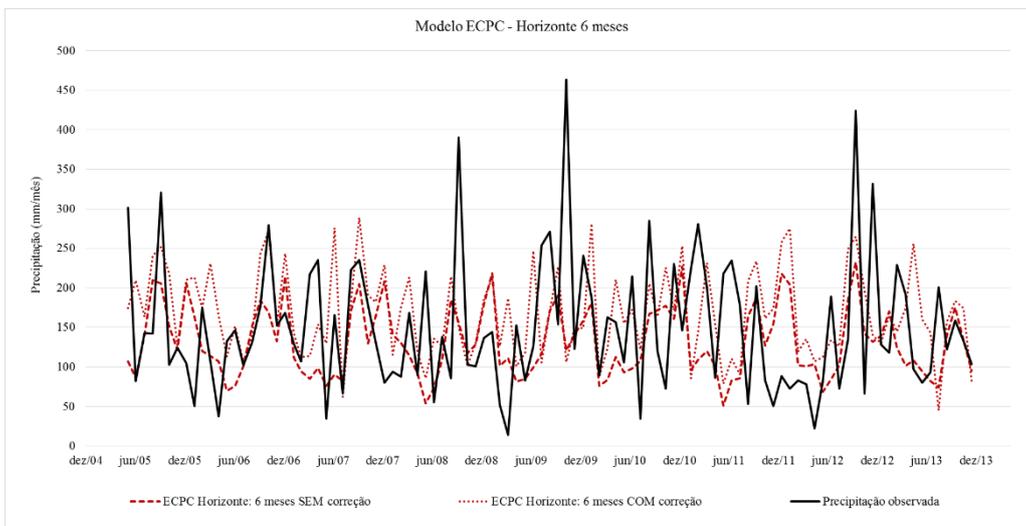


Figura 7.11. Precipitação observada e precipitação prevista com 6 meses de antecedência, com e sem correção de viés, para o modelo ECPC. Valores relativos à precipitação média da bacia do rio Ijuí, média do *ensemble* de membros do modelo.

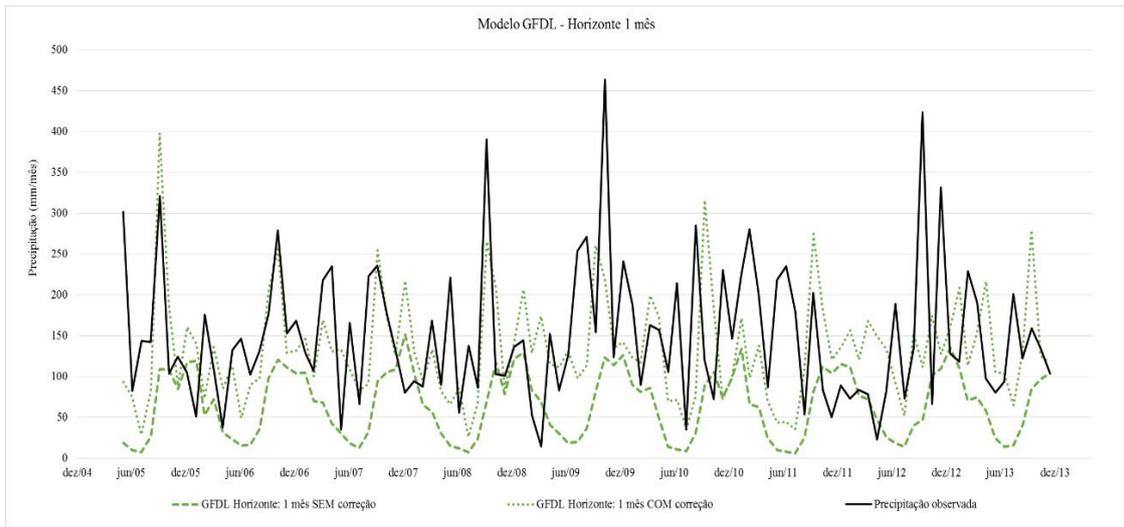


Figura 7.12. Precipitação observada e precipitação prevista com 1 mês de antecedência, com e sem correção de viés, para o modelo GFDL. Valores relativos à precipitação média da bacia do rio Ijuí, média do *ensemble* de membros do modelo.

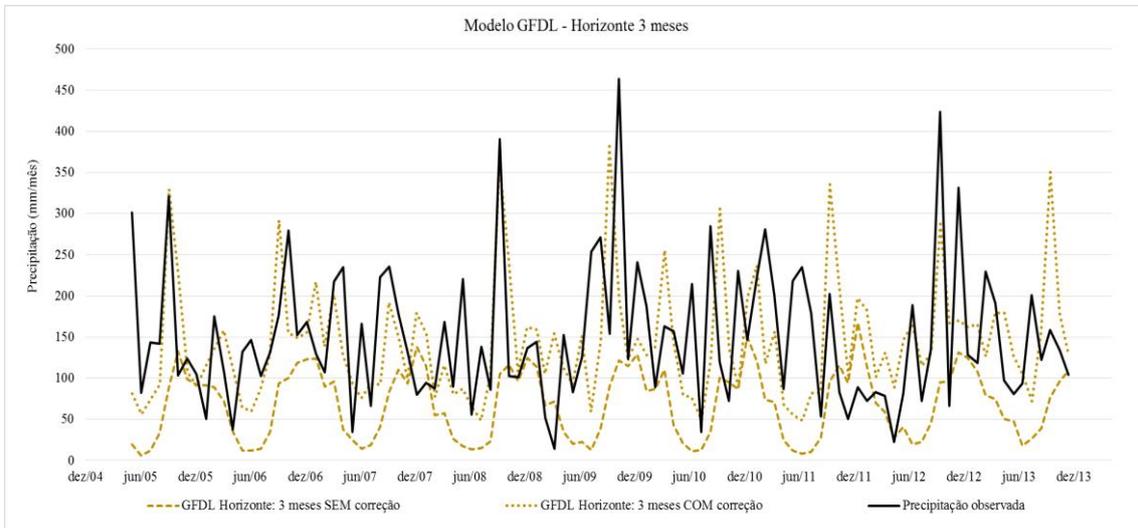


Figura 7.13. Precipitação observada e precipitação prevista com 3 meses de antecedência, com e sem correção de viés, para o modelo GFDL. Valores relativos à precipitação média da bacia do rio Ijuí, média do *ensemble* de membros do modelo.

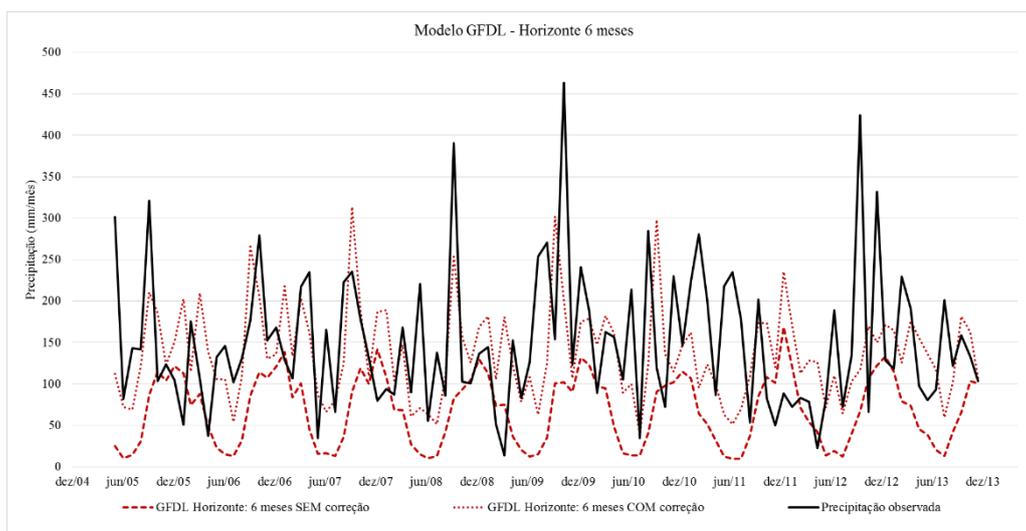


Figura 7.14. Precipitação observada e precipitação prevista com 6 meses de antecedência, com e sem correção de viés, para o modelo GFDL. Valores relativos à precipitação média da bacia do rio Ijuí, média do *ensemble* de membros do modelo.

As figuras 7.15 a 7.17. mostram os valores de precipitação total anual média na bacia, média do *ensemble*, para os modelos CCM3v6, ECPC e GFDL. Pode-se observar que os totais anuais, após a correção de viés, mostram-se próximos aos valores observados. Os totais anuais das previsões sem a correção de viés, ao contrário, são extremamente subestimados, apresentando até 1000 mm de diferença entre o observado e o previsto, para os modelos CCM3v6 e GFDL.

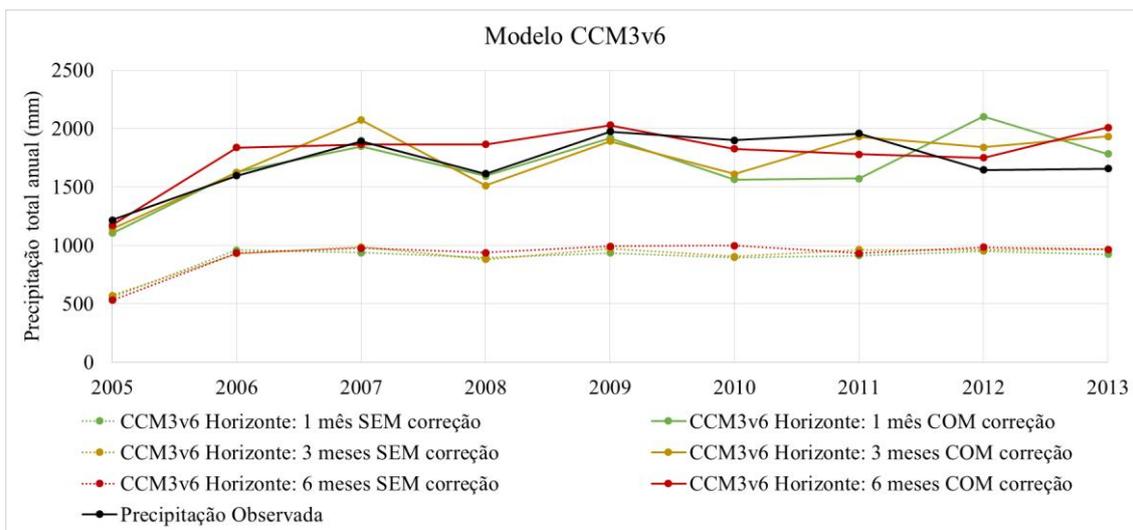


Figura 7.15. Precipitação total anual média da bacia do rio Ijuí, observada e prevista pelo modelo CCM3v6, com e sem correção de viés. O valor apresentado para o ano de 2005 refere-se ao período entre junho e dezembro.

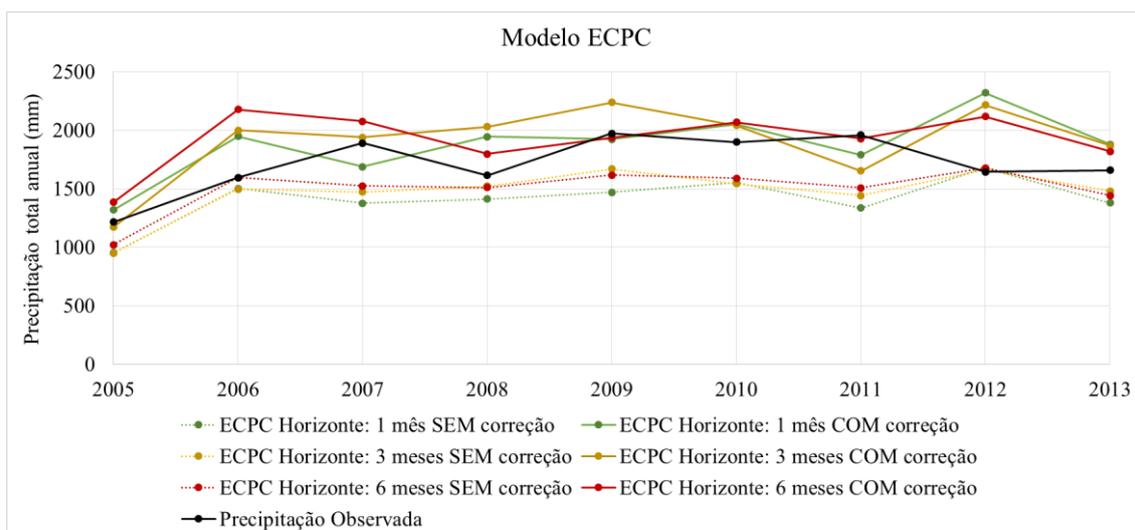


Figura 7.16. Precipitação total anual média da bacia do rio Ijuí, observada e prevista pelo modelo ECPC, com e sem correção de viés. O valor apresentado para o ano de 2005 refere-se ao período entre junho e dezembro.

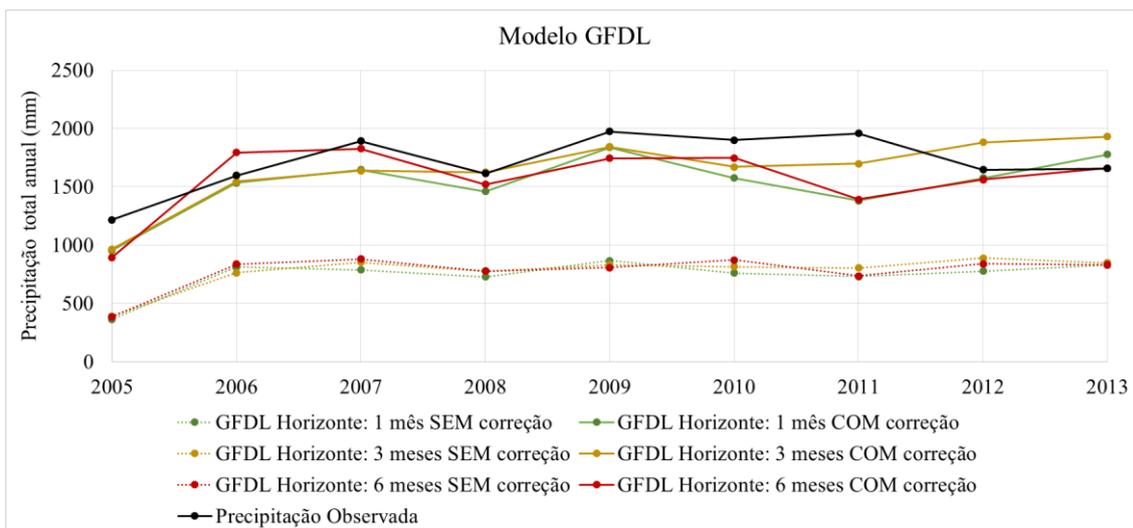


Figura 7.17. Precipitação total anual média da bacia do rio Ijuí, observada e prevista pelo modelo GFDL, com e sem correção de viés. O valor apresentado para o ano de 2005 refere-se ao período entre junho e dezembro.

As precipitações extremas observadas na bacia nem sempre foram devidamente representadas pelas previsões. Isso pode ser devido simplesmente a erros de previsão dos modelos, ou devido à limitação do domínio de ajuste das equações de correção do viés. O uso da pequena faixa de extrapolação possível ($0,9 * \text{mínimo do histórico do modelo}$ e $1,2 * \text{máximo do histórico do modelo}$) busca diminuir este segundo tipo de erro. Por exemplo, em dezembro de 2012 a precipitação observada foi de 331,5 mm. Corrigindo-se apenas valores no domínio do histórico dos modelos, ainda que algum dos modelos identificasse esta ocorrência de precipitação extrema, nenhuma precipitação corrigida seria capaz de atingir o valor observado. Admitindo-se uma extrapolação de 20% além do limite superior de cada modelo, os três modelos seriam capazes de adequadamente representar a precipitação observada. A Tabela 7.5 mostra os valores de precipitação corrigida associados a cada valor de precipitação prevista do modelo.

Tabela 7.5. Exemplo do efeito do uso da faixa de extrapolação.

	CCM3v6	ECPC	GFDL
Pmax	131,6	218,0	187,5
Pcorrigida = função de (Pmax)	257,4	301,4	294,9
Pmax * 1.2	157,9	261,7	225,0
Pcorrigida = função de (Pmax * 1.2)	405,2	388,2	379,6

*Pmax é a precipitação máxima do domínio do histórico do modelo.

7.4 Análise das precipitações previstas em relação à média de longo período

Na ausência de dados de precipitação prevista, há a alternativa de empregar-se os dados de precipitação média de longo período de cada mês do ano para realizar a estimativa de umidade do solo. A Tabela 7.6 mostra os erros médios absolutos e raízes do erro médio quadrático, para a precipitação total mensal, média da bacia, calculados conforme equações (21) (apresentada no item 7.3) e (22). Os valores são comparados ao erro associado à utilização da precipitação média mensal. A Tabela 7.7 mostra o Coeficiente de Correlação de Pearson (r) e o Coeficiente de Determinação (r^2) entre a série de precipitação observada e as séries de precipitação prevista, ou a média mensal de longo período. O coeficiente de correlação r analisa o nível de correlação linear entre as duas variáveis, variando entre -1 (alta correlação negativa) e +1 (alta correlação positiva). Valores próximos a zero indicam baixa correlação linear. O coeficiente de determinação r^2 varia entre 0 e 1, onde 1 indica ajustes melhores. Todas as análises são realizadas para os valores de precipitação total mensal média da bacia, para o período entre junho/2005 e dezembro/2013.

$$\text{Raiz do erro médio quadrático} = \sqrt{\frac{\sum (Py - Pobs)^2}{n}} \quad (22)$$

Onde:

Py [mm]: Precipitação a ser analisada, mensal prevista ou média mensal de longo período;

$Pobs$ [mm]: Precipitação observada para o mês;

n : Número de intervalos de tempo (neste caso, o número de meses entre junho/2005 e dezembro/2013).

Tabela 7.6. Erro médio da precipitação prevista (com correção de viés) e da precipitação média de longo período em relação à precipitação total mensal média observada na bacia no período entre junho/2005 e dezembro/2013.

Erro em relação à precipitação observada		Horizonte 1 mês	Horizonte 3 meses	Horizonte 6 meses
Erro médio absoluto (mm)	CCM3v6	-3,2	1,0	6,7
	ECPC	13,8	16,6	18,0
	GFDL	-16,6	-6,4	-12,7
	Precipitação média mensal	8,26		
Raiz do erro médio quadrático (mm)	CCM3v6	82,67	96,10	91,53
	ECPC	106,89	93,79	99,02
	GFDL	97,68	92,83	93,09
	Precipitação média mensal	81,17		

Tabela 7.7. Coeficiente de correlação de Pearson (r) e Coeficiente de Determinação (r²) entre a série de precipitação observada total mensal média da bacia do rio Ijuí e as precipitações previstas (após correção de viés) ou média mensal de longo período.

Precipitação prevista (ou média mensal)		r	r ²
Precipitação média mensal		0,286	0,082
CCM3v6	Horizonte 1 mês	0,402	0,161
CCM3v6	Horizonte 3 meses	0,229	0,052
CCM3v6	Horizonte 6 meses	0,208	0,043
ECPC	Horizonte 1 mês	0,026	0,001
ECPC	Horizonte 3 meses	0,101	0,010
ECPC	Horizonte 6 meses	0,075	0,006
GFDL	Horizonte 1 mês	0,182	0,033
GFDL	Horizonte 3 meses	0,303	0,092
GFDL	Horizonte 6 meses	0,180	0,033

O erro médio da precipitação sazonal, em relação à precipitação total mensal observada na bacia no período entre junho/2005 e dezembro/2013 é de 8,26 mm. O modelo CCM3v6, para todos os horizontes de previsão, apresenta desempenho superior à precipitação média mensal, assim como o modelo GFDL para o horizonte de 3 meses. Quanto à raiz do erro médio quadrático, nenhum dos modelos, para nenhum dos horizontes, obteve um erro menor que a precipitação média mensal. Quanto ao coeficiente de correlação r e o coeficiente de determinação r², apenas o modelo CCM3v6, para o horizonte de previsão de 1 mês, e o GFDL, para horizonte de 3 meses, obtiveram desempenhos melhores que o uso das médias mensais. Isto indica que a previsão de longo

prazo de precipitação precisa ainda de uma significativa melhora de desempenho de forma a representar apropriadamente a precipitação observada. Contudo, a utilização da precipitação média mensal não permite a representação de situações extremas (precipitações maiores ou menores que a média do mês). Desta forma, é válido o emprego das previsões de precipitação para a previsão da anomalia de umidade no solo. As figuras 7.18 a 7.26 a seguir mostram as séries de precipitação previstas (média do *ensemble*) versus a precipitação média mensal de longo período. Pode-se observar que as previsões, ainda que não perfeitamente, muitas vezes são capazes de representar a ocorrência de valores bastante altos ou baixos de precipitação, ao contrário da precipitação média mensal. Pela análise visual das figuras, percebe-se que o baixo desempenho das previsões pode estar associado a erros de fase do hietograma. Por exemplo, para o modelo ECPC, horizonte de 1 mês (Figura 7.21) a precipitação prevista foi de 97 mm, enquanto a precipitação observada na bacia em novembro de 2006 foi de 279 mm. Contudo, para outubro de 2006, a previsão do modelo previu 266 mm (enquanto o valor observado foi de 177 mm). Ao calcular-se os erros (absoluto, raiz do erro quadrático) ou coeficiente de correlação, o modelo apresenta um desempenho bastante ruim, pior até que a média mensal de longo período (218 mm para outubro e 157 para novembro).

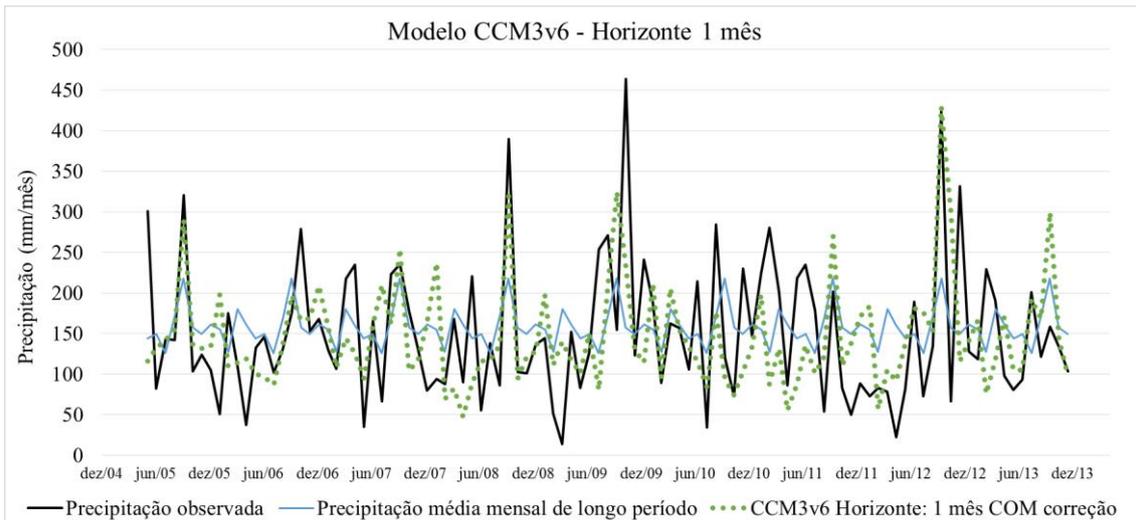


Figura 7.18. Precipitação prevista pelo modelo CCM3v6 (média do *ensemble*) para horizonte de 1 mês, média mensal de longo período e observada na bacia, no período entre junho/2005 e dezembro/2013.

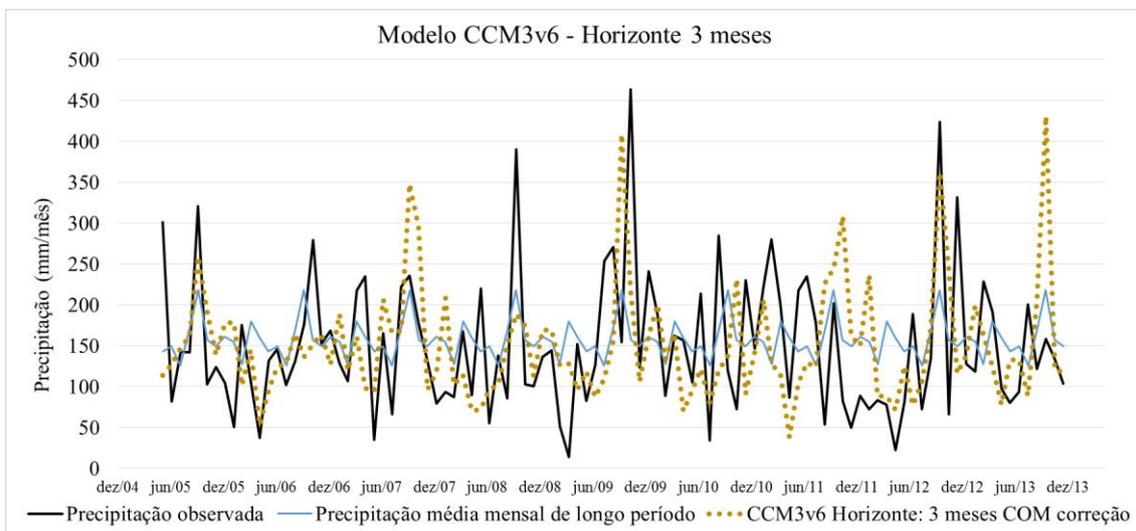


Figura 7.19. Precipitação prevista pelo modelo CCM3v6 (média do *ensemble*) para horizonte de 3 meses, média mensal de longo período e observada na bacia, no período entre junho/2005 e dezembro/2013.

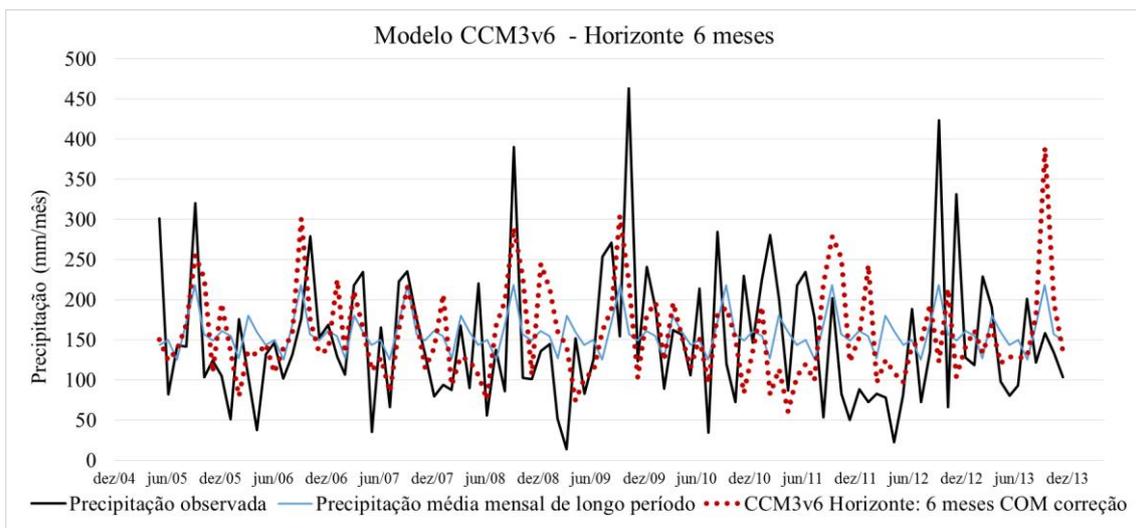


Figura 7.20. Precipitação prevista pelo modelo CCM3v6 (média do *ensemble*) para horizonte de 6 meses, média mensal de longo período e observada na bacia, no período entre junho/2005 e dezembro/2013.

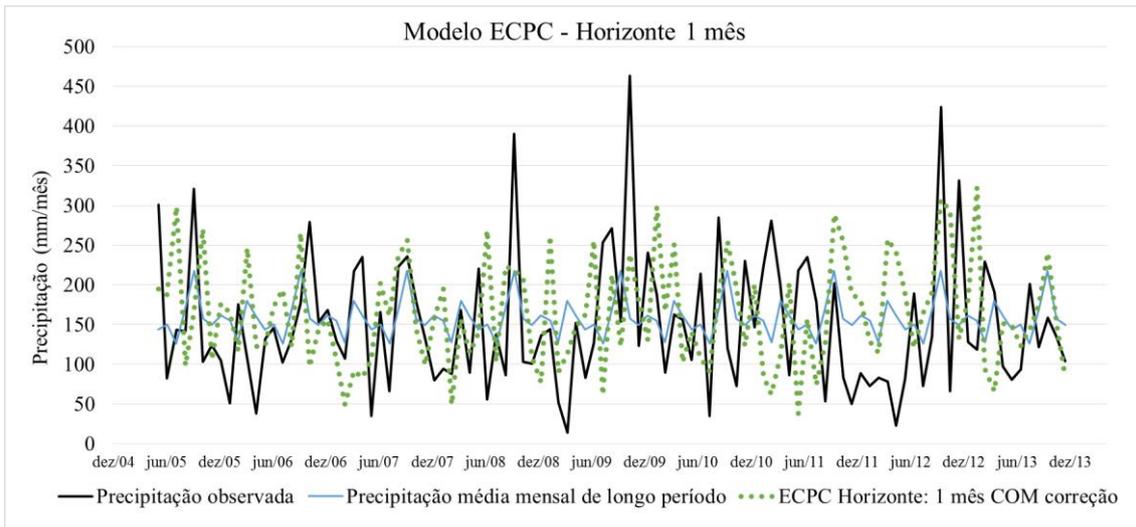


Figura 7.21. Precipitação prevista pelo modelo ECPC (média do *ensemble*) para horizonte de 1 mês, média mensal de longo período e observada na bacia, no período entre junho/2005 e dezembro/2013.

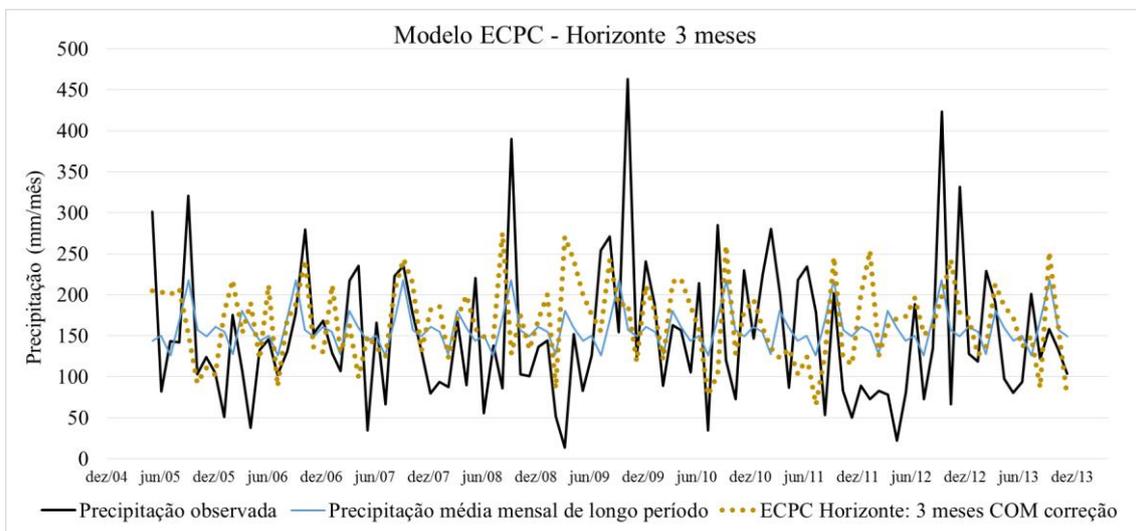


Figura 7.22. Precipitação prevista pelo modelo ECPC (média do *ensemble*) para horizonte de 3 meses, média mensal de longo período e observada na bacia, no período entre junho/2005 e dezembro/2013.

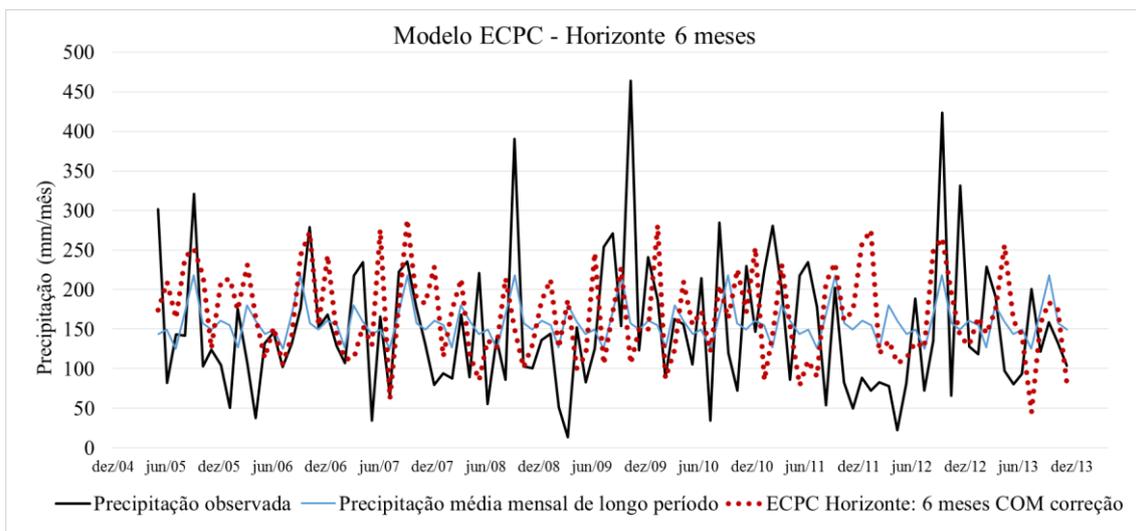


Figura 7.23. Precipitação prevista pelo modelo ECPC (média do *ensemble*) para horizonte de 6 meses, média mensal de longo período e observada na bacia, no período entre junho/2005 e dezembro/2013.

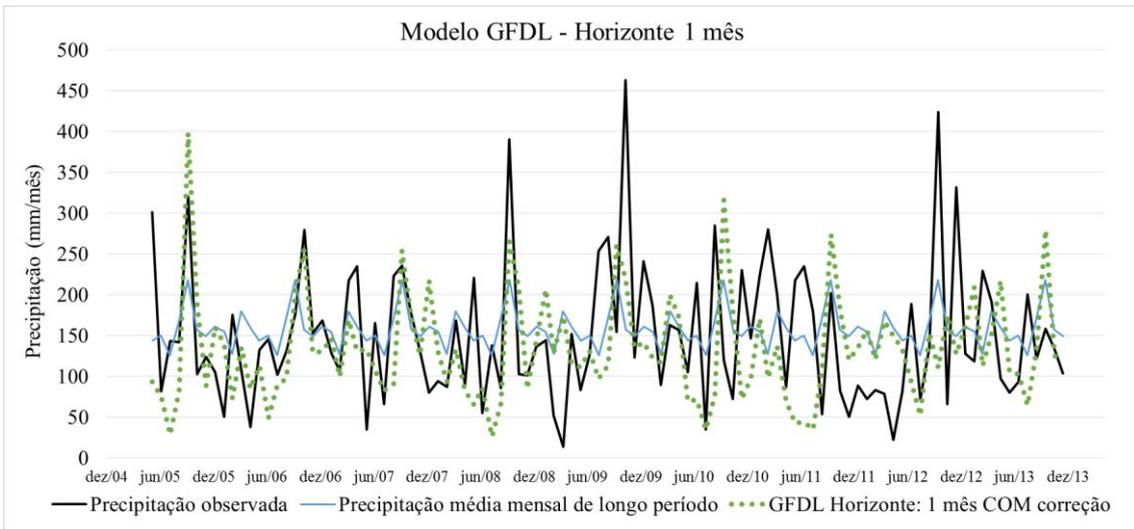


Figura 7.24. Precipitação prevista pelo modelo GFDL (média do ensemble) para horizonte de 1 mês, média mensal de longo período e observada na bacia, no período entre junho/2005 e dezembro/2013.

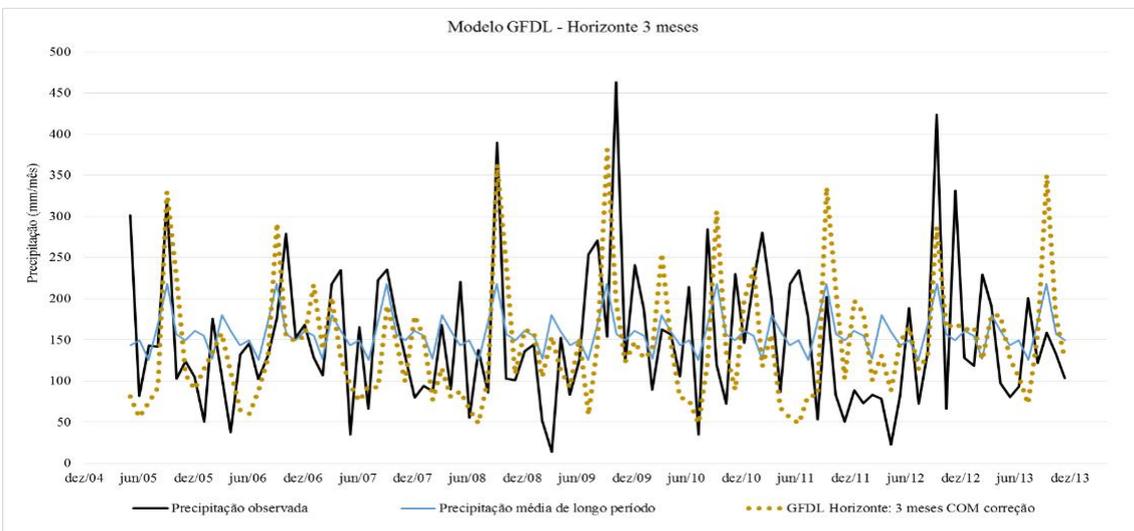


Figura 7.25. Precipitação prevista pelo modelo GFDL (média do ensemble) para horizonte de 3 meses, média mensal de longo período e observada na bacia, no período entre junho/2005 e dezembro/2013.

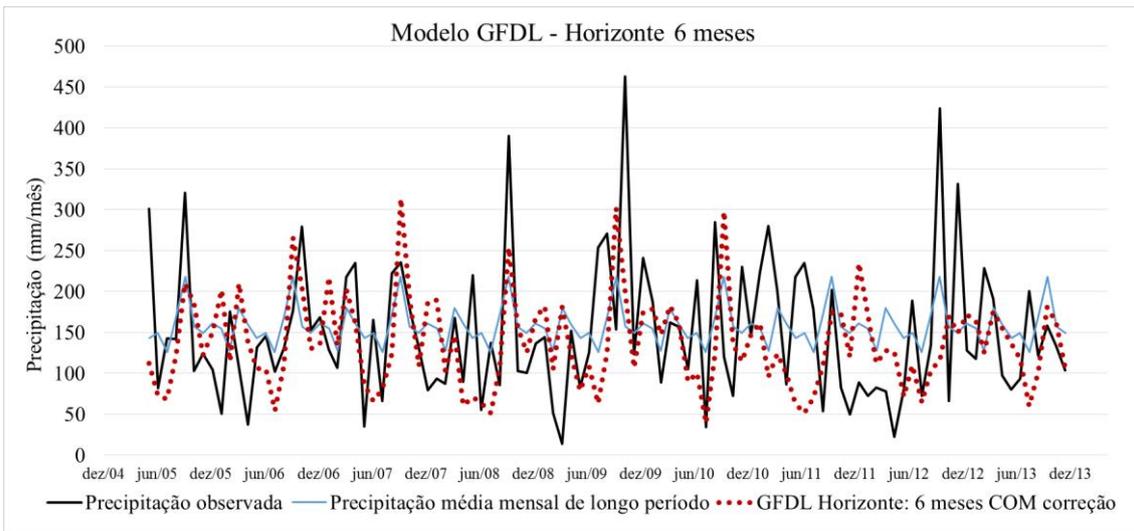


Figura 7.26. Precipitação prevista pelo modelo GFDL (média do ensemble) para horizonte de 6 meses, média mensal de longo período e observada na bacia, no período entre junho/2005 e dezembro/2013.

8. PREVISÃO DE UMIDADE NO SOLO

Este capítulo traz os resultados das previsões de umidade do solo realizadas através do MGB-IPH empregando previsões de precipitação, assim como a análise destes resultados. A descrição das previsões de precipitação utilizadas encontra-se no item 4.3 da metodologia e no capítulo 7. Cada arquivo de previsão de precipitação gerou uma previsão diferente de umidade no solo. Assim, foram realizadas ao todo 207 simulações com o MGB-IPH:

- 3 horizontes de previsão:
 - 3 médias:
 - Média da precipitação prevista pelos membros do modelo CCM3v6;
 - Média da precipitação prevista pelos membros do modelo ECPC;
 - Média da precipitação prevista pelos membros do modelo GFDL.
 - 66 membros:
 - 24 membros do modelo CCM3v6;
 - 12 membros do modelo ECPC;
 - 30 membros do modelo GFDL.

As previsões foram analisadas conforme as combinações apresentadas na Tabela 4.3, item 4.4. Desta forma, para cada mês do período simulado, existem 8 previsões de umidade do solo.

A previsão de umidade no solo é aqui apresentada na forma de grau de saturação do solo (S), ou seja, como uma variação de 0% (solo completamente seco) a 100% (solo saturado). Esta saturação é calculada como a lâmina média em uma minibacia (para cada intervalo de tempo) dividida pela lâmina máxima média da minibacia. A capacidade máxima do solo é um parâmetro calibrável no MGB-IPH (W_m), determinado para cada sub-bacia, em cada URH. Os valores adotados podem ser analisados no ANEXO D.

A variação entre as minibacias pode ser grande, porém uma minibacia é uma área excessivamente pequena para a análise apropriada dos resultados. Analisou-se a variabilidade entre as sub-bacias e, sendo os resultados bastante similares entre uma e outra sub-bacia, optou-se por avaliar os resultados para toda a bacia do rio Ijuí. A grade de baixa resolução dos modelos de previsão (ver Figura 7.1) indica que a análise de resultados em uma escala espacial mais detalhada não apresenta ganhos.

8.1 Resultados da previsão de umidade no solo – Nível de saturação

Previsões tipo B - Médias do ensemble

As figuras 8.1 a 8.3 mostram a saturação calculada com a precipitação média do *ensemble* de cada modelo, para cada horizonte. Os resultados apresentados neste item 8.1 referem-se às previsões do tipo B, códigos 4, 5 e 6, conforme descrito na Tabela 4.3. Os resultados de saturação simples são neste item apresentados de forma ilustrativa, uma vez que a análise de resultados é realizada sobre os valores de saturação classificados, conforme descrito no item 8.2. Desta forma, são apresentados neste item apenas os resultados referentes às previsões tipo B (média do ensemble de cada modelo).

Observa-se nas figuras a seguir que a concordância entre as previsões e os valores de saturação pseudo-observada é relativamente pequena. Contudo, geralmente, a tendência (período mais seco ou mais úmido) é representada, por um ou mais modelos. Apesar disso, observa-se que alguns valores extremos (por exemplo, os mínimos em abril/2009 e entre dezembro/2011 e maio/2012) não foram identificados por nenhum dos modelos, em nenhum dos horizontes.

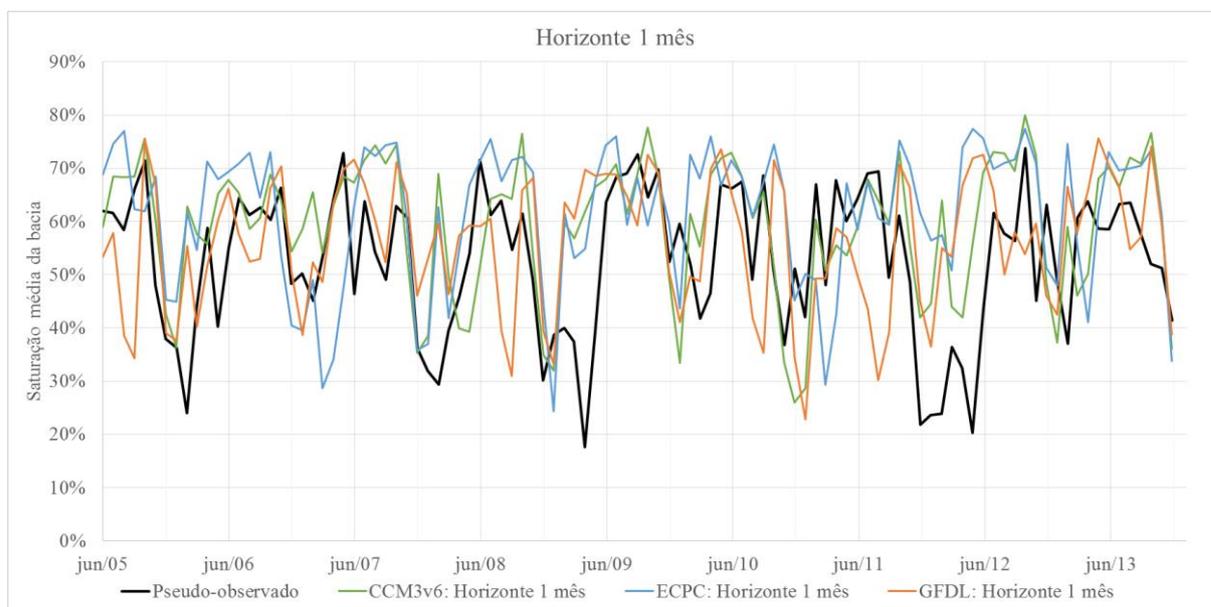


Figura 8.1. Saturação média mensal prevista com 1 mês de antecedência e pseudo-observada na bacia do rio Ijuí.

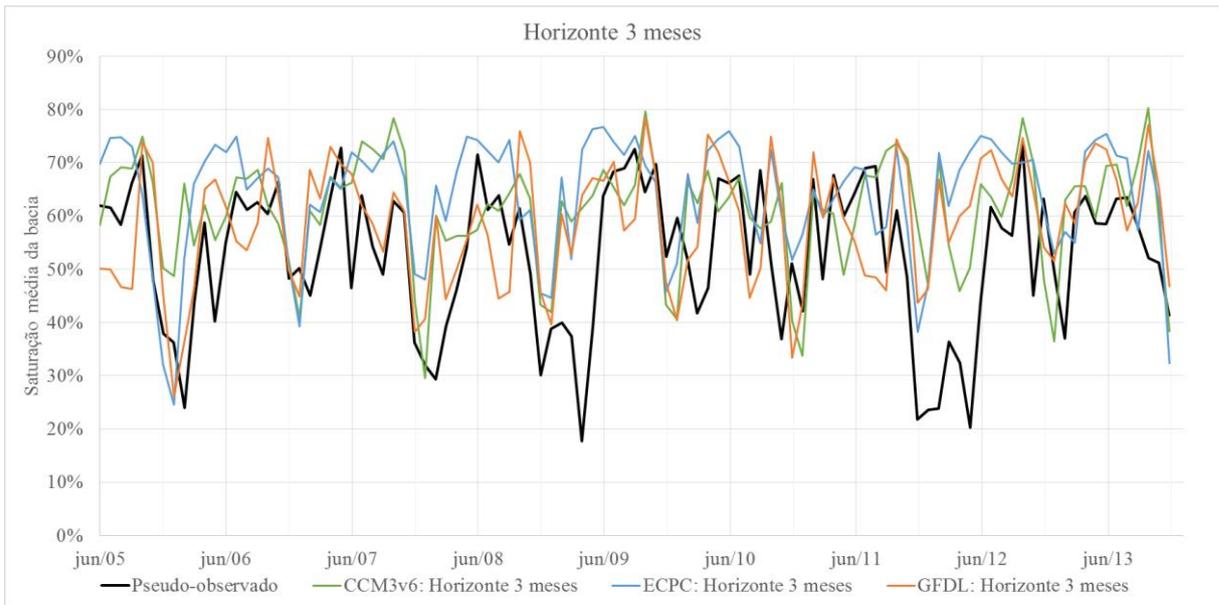


Figura 8.2. Saturação média mensal prevista com 3 meses de antecedência e pseudo-observada na bacia do rio Ijuí.

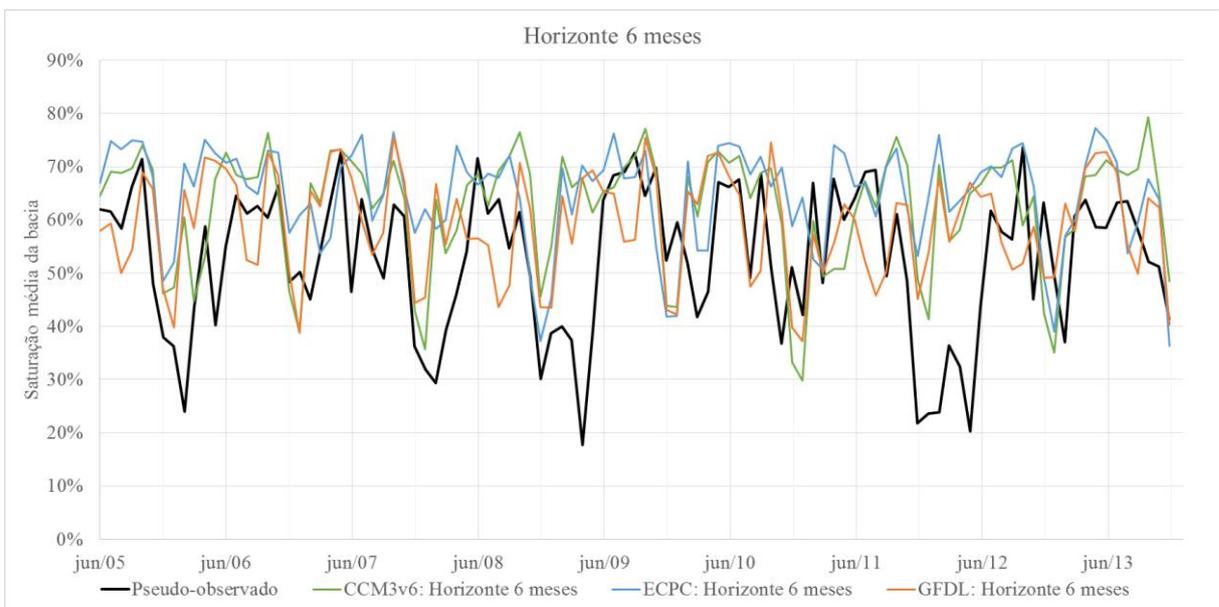


Figura 8.3. Saturação média mensal prevista com 6 meses de antecedência e pseudo-observada na bacia do rio Ijuí.

8.2 Resultados da previsão de umidade no solo – Classificação

Os resultados a seguir são analisados com base na variação do grau de saturação em relação à saturação média mensal de longo período, conforme a classificação apresentada no item 4.5.

Os itens a seguir apresentam os resultados das previsões de saturação do solo e os erros associados a cada mês de previsão, quando da comparação das previsões com os valores pseudo-observados. O erro das previsões é definido como (classe prevista menos classe pseudo-observada), podendo variar entre 0 (classe prevista = pseudo-observada, ou seja, acerto da previsão) e ± 4 , conforme descrito no item 4.6.

8.2.1 Previsões tipo A – *Ensemble* – Códigos 1, 2 e 3

A previsão de umidade no solo, determinação do grau de saturação, compatibilização para escala mensal e classificação conforme a Tabela 4.4 foi realizada para cada membro, de cada modelo. Então, para cada mês do período de simulação, para cada modelo, realizou-se uma contagem do número de membros em cada classe de saturação (-2 a +2). A probabilidade de ocorrência de determinada classe foi determinada como:

$$PC_{modelo} = \frac{N_{classe}}{N_{modelo}} \quad (23)$$

Onde:

PC_{modelo} : Probabilidade de ocorrência de determinada classe de saturação (-2, -1, 0, +1 ou +2) para o modelo em questão (CCM3v6, ECPC ou GFDL);

N_{classe} : Número de membros com saturação em determinada classe;

N_{modelo} : Número total de membros do modelo em questão (24 para CCM3v6, 12 para ECPC e 30 para GFDL).

Em cada mês, para cada modelo, considerou-se a classe prevista como a classe com maior probabilidade, determinada a partir da equação (23). Considerou-se para esta escolha de apresentação e análise dos resultados a facilitação da interpretação e eventual

tomada de decisão por parte do usuário das previsões. Conforme WMO (2012), este tipo de apresentação de resultados – previsão simples associada à uma probabilidade – é de mais fácil análise por parte do usuário que uma previsão totalmente probabilística, mas ainda tem vantagens sobre uma previsão completamente determinística, sem a informação de incerteza. As figuras 8.4 a 8.12 apresentam os resultados da previsão por *ensemble* (tipo A) quanto a classe mais provável de saturação, para os diferentes horizontes de previsão. As tabelas F.1 a F.3, no ANEXO F mostram os resultados referentes à classe mais provável de saturação do solo para os três horizontes de previsão, e o erro referente a cada previsão. As tabelas F.4 a F.12 mostram o resultado completo da previsão probabilística de umidade do solo. Cada tabela traz a informação de classe de saturação pseudo-verdadeira e probabilidade de ocorrência de cada classe de saturação conforme o *ensemble* de cada modelo. A probabilidade referente a cada classe é calculada pela Equação (23).

As figuras a seguir mostram que a previsão realizada com a classe mais provável do *ensemble* de cada modelo possui, em geral, uma tendência a subestimar a classe de saturação do solo. Esta tendência é bastante destacada para o caso do modelo GFDL, horizontes de 1 e 3 meses. Destaca-se ainda que poucas vezes ao longo da série simulada a classe exata de saturação pseudo-verdadeira foi identificada pela previsão. Contudo, muitas vezes, a classe prevista foi uma classe imediatamente acima ou abaixo da classe pseudo-observada. Isso indica que a previsão, apesar de não ser capaz de identificar, na maior parte das vezes, a classe exata de saturação do solo, apresenta um desempenho melhor em reconhecer a tendência, ou seja, o nível aproximado de umidade no solo.

Previsões tipo A - Horizonte de 1 mês

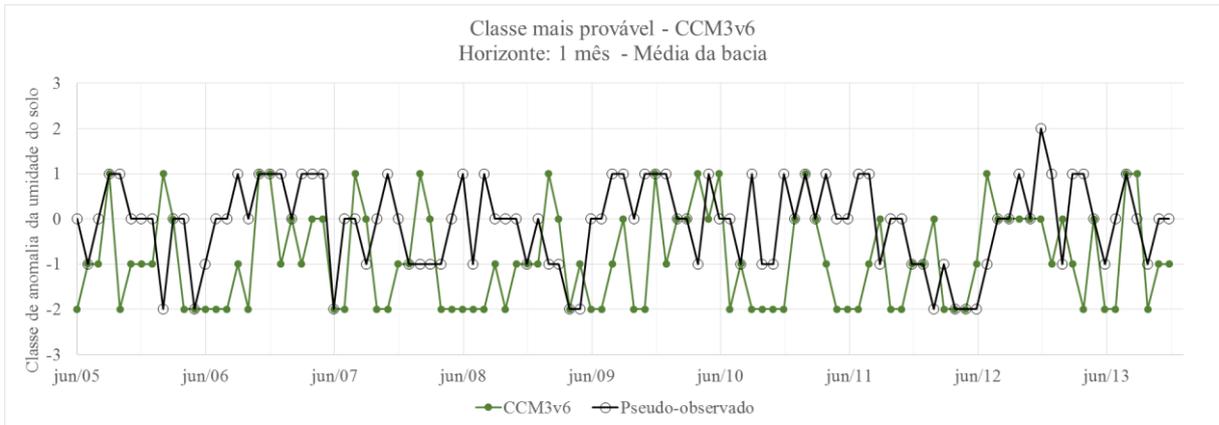


Figura 8.4. Classe pseudo-observada de saturação do solo e prevista pelo *ensemble* do modelo CCM3v6 (previsão código 1), para o horizonte de 1 mês.

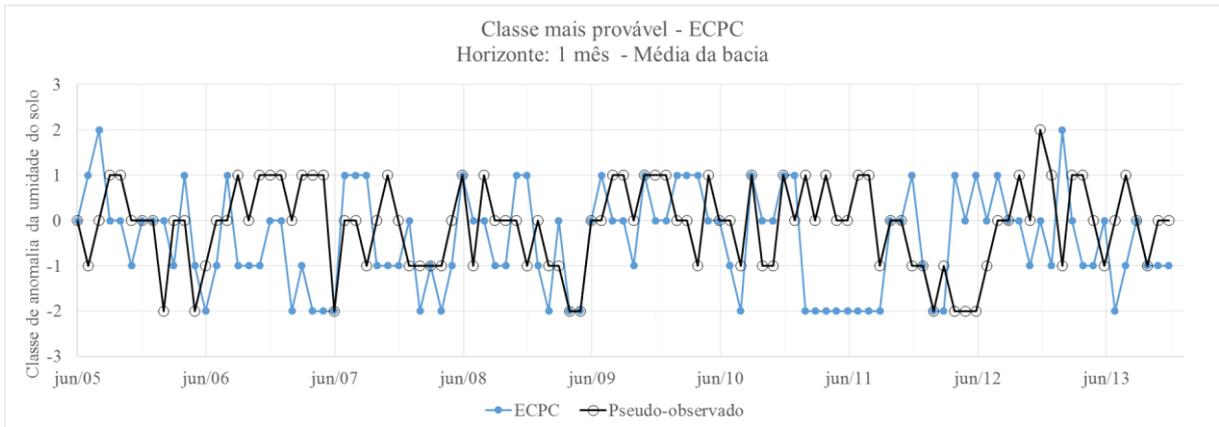


Figura 8.5. Classe pseudo-observada de saturação do solo e prevista pelo *ensemble* do modelo ECPC (previsão código 2), para o horizonte de 1 mês.

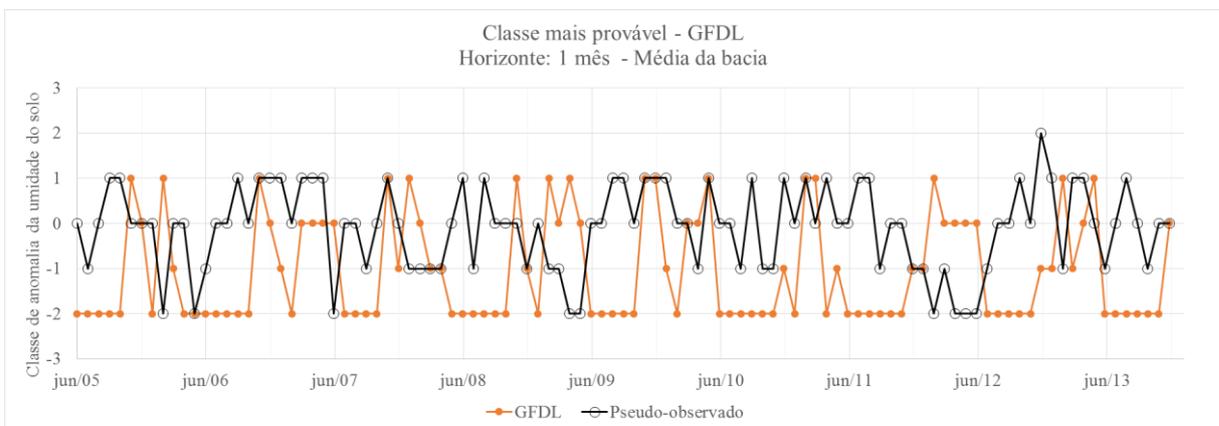


Figura 8.6. Classe pseudo-observada de saturação do solo e prevista pelo *ensemble* do modelo GFDL (previsão código 3), para o horizonte de 1 mês.

Previsões tipo A - Horizonte de 3 meses

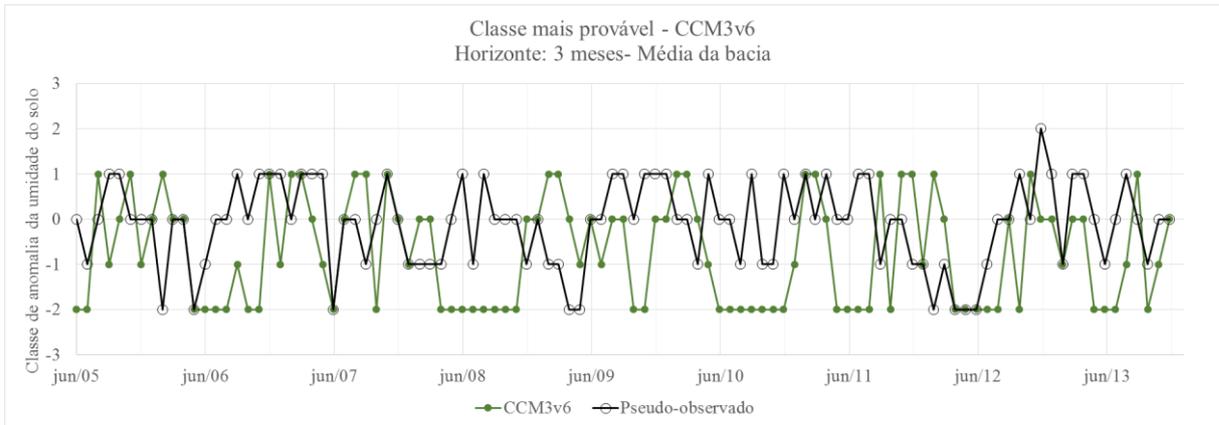


Figura 8.7. Classe pseudo-observada de saturação do solo e prevista pelo *ensemble* do modelo CCM3v6 (previsão código 1), para o horizonte de 3 meses.

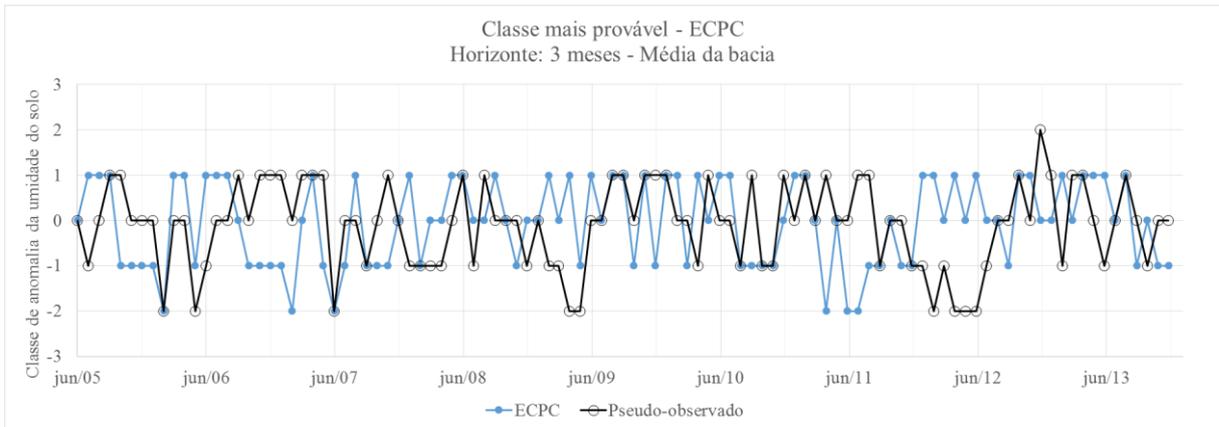


Figura 8.8. Classe pseudo-observada de saturação do solo e prevista pelo *ensemble* do modelo ECPC (previsão código 2), para o horizonte de 3 meses.

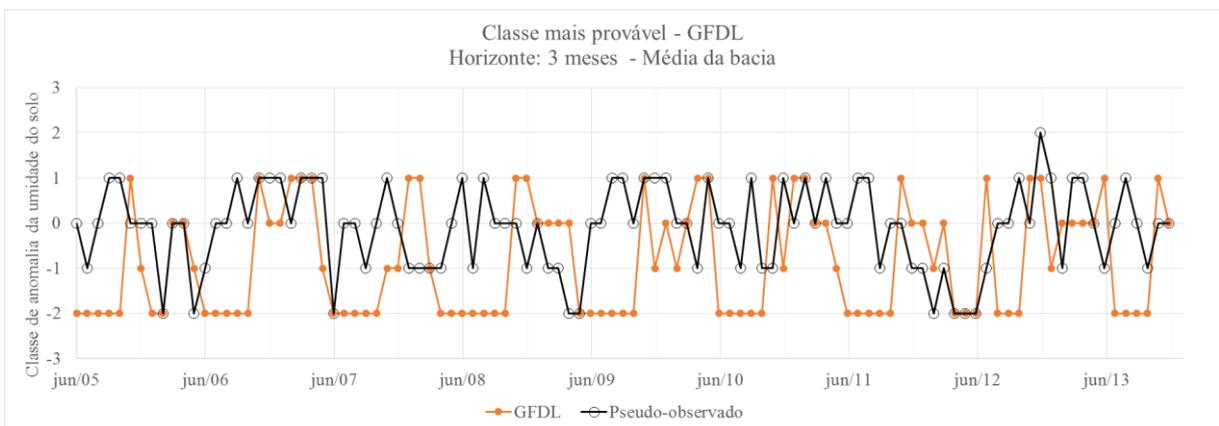


Figura 8.9. Classe pseudo-observada de saturação do solo e prevista pelo *ensemble* do modelo GFDL (previsão código 3), para o horizonte de 3 meses.

Previsões tipo A - Horizonte de 6 meses

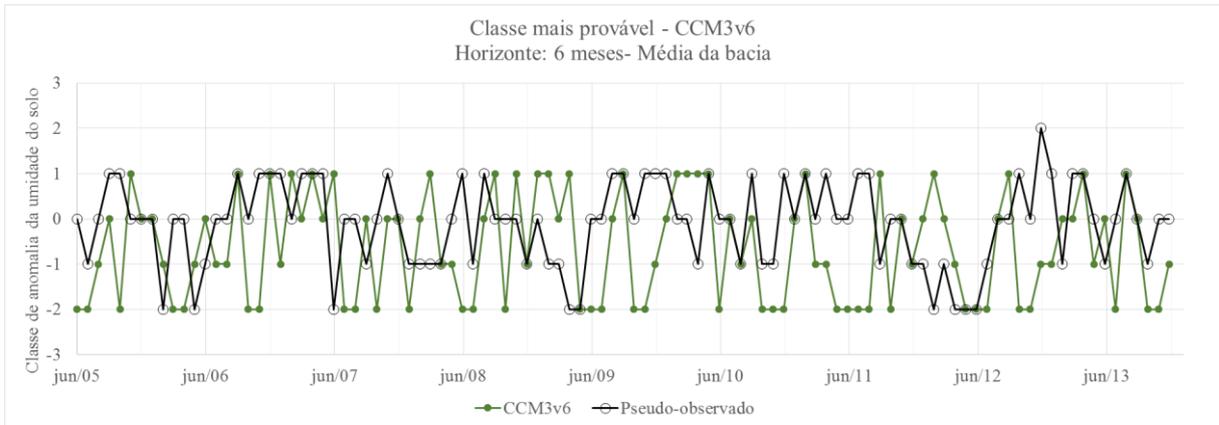


Figura 8.10. Classe pseudo-observada de saturação do solo e prevista pelo *ensemble* do modelo CCM3v6 (previsão código 1), para o horizonte de 6 meses.

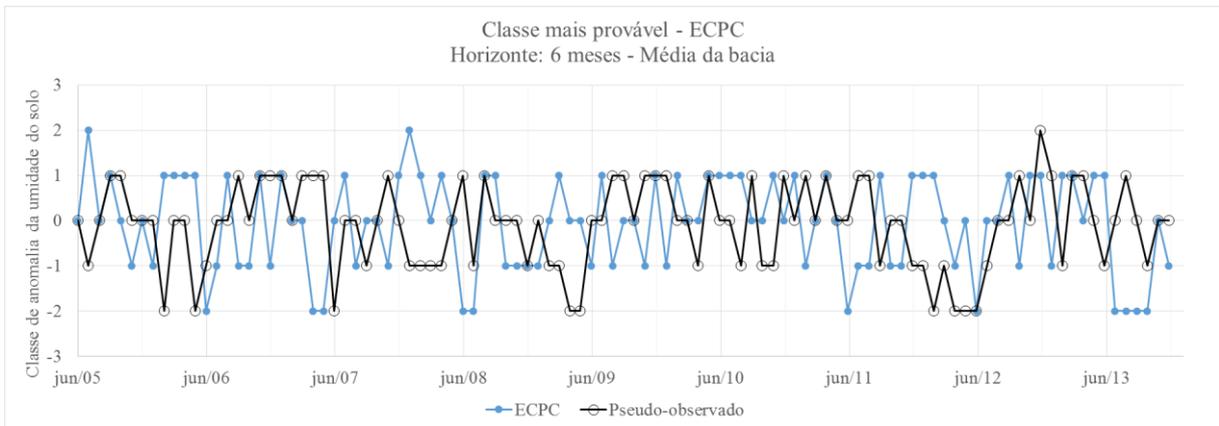


Figura 8.11. Classe pseudo-observada de saturação do solo e prevista pelo *ensemble* do modelo ECPC (previsão código 2), para o horizonte de 6 meses.

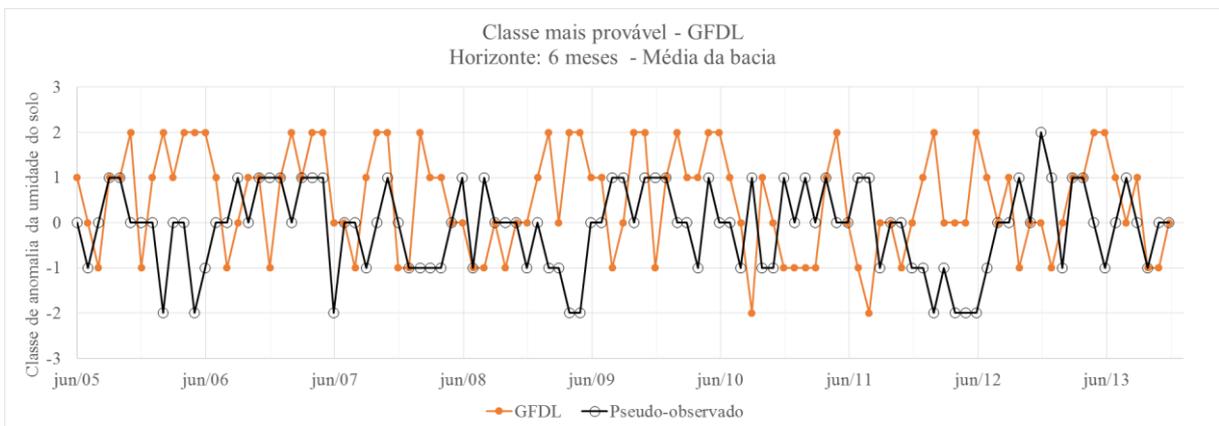


Figura 8.12. Classe pseudo-observada de saturação do solo e prevista pelo *ensemble* do modelo GFDL (previsão código 3), para o horizonte de 6 meses.

8.2.2 Previsões tipo B – Médias do *ensemble* – Códigos 4, 5 e 6

As figuras 8.13 a 8.21 mostram os resultados da previsão de umidade do solo realizada com a média do *ensemble* da previsão de precipitação de cada modelo (previsões tipo B). As tabelas F.19 a F.21, no ANEXO F, mostram os resultados na forma de tabela.

A análise das figuras mostra que o desempenho das médias (previsões tipo B) em identificar a classe exata de saturação do solo é melhor que o desempenho do *ensemble* (previsões tipo A), mostrado no item anterior. Avaliando-se quanto à capacidade de reconhecer a faixa de umidade, ou seja, analisando-se se a previsão indica uma classe de saturação imediatamente acima ou abaixo da pseudo-observada, o desempenho da previsão com as médias mostra-se ainda melhor que o desempenho do *ensemble*.

O modelo ECPC (previsão código 5), para o horizonte de 1 mês, apresentou uma tendência a superestimar a previsão. Isso foi intensificado para os horizontes de 3 e 6 meses de previsão. Quanto as previsões realizadas com o modelo GFDL (código 6), a previsão com 3 meses de antecipação mostrou uma forte tendência a superestimar a previsão. Esta tendência é ainda mais intensa para o horizonte de 6 meses. O modelo CCM3v6 (código 4) foi aquele capaz de melhor identificar a classe de saturação pseudo-observada. Este resultado está coerente com a análise do desempenho das previsões de precipitação, realizada no item 8.3.

Previsões tipo B - Média do *ensemble* - Horizonte de 1 mês

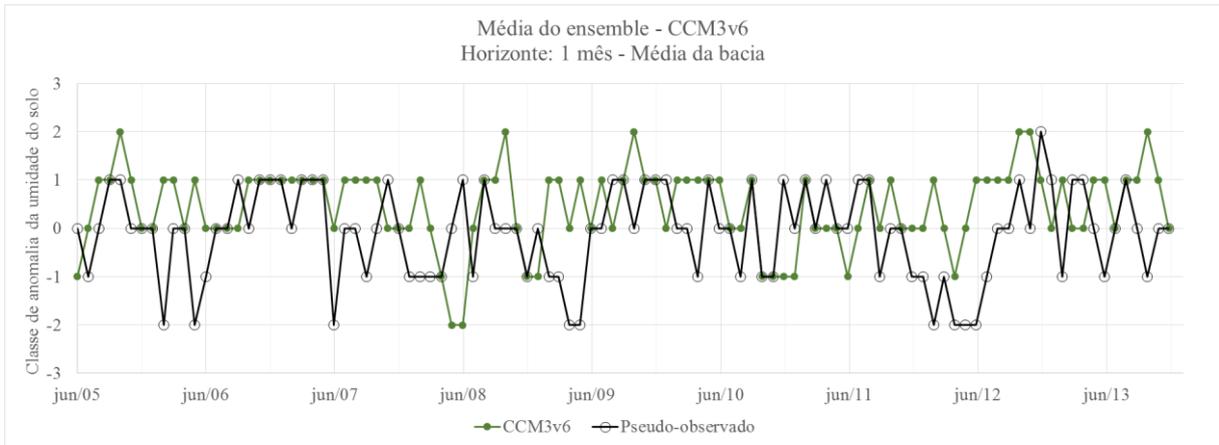


Figura 8.13. Classe pseudo-observada de saturação do solo e prevista pela média do ensemble do modelo CCM3v6 (previsão código 4), para o horizonte de 1 mês.

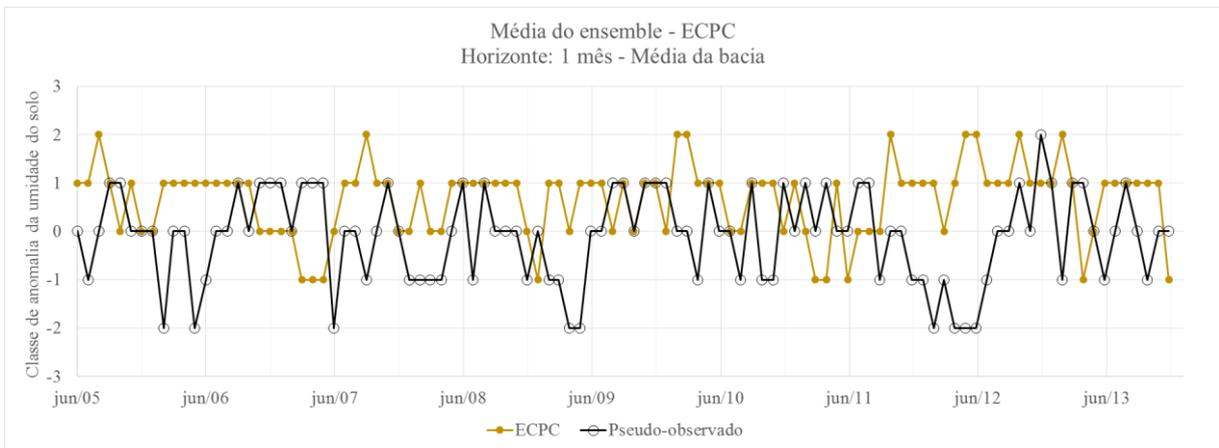


Figura 8.14. Classe pseudo-observada de saturação do solo e prevista pela média do ensemble do modelo ECPC (previsão código 5), para o horizonte de 1 mês.

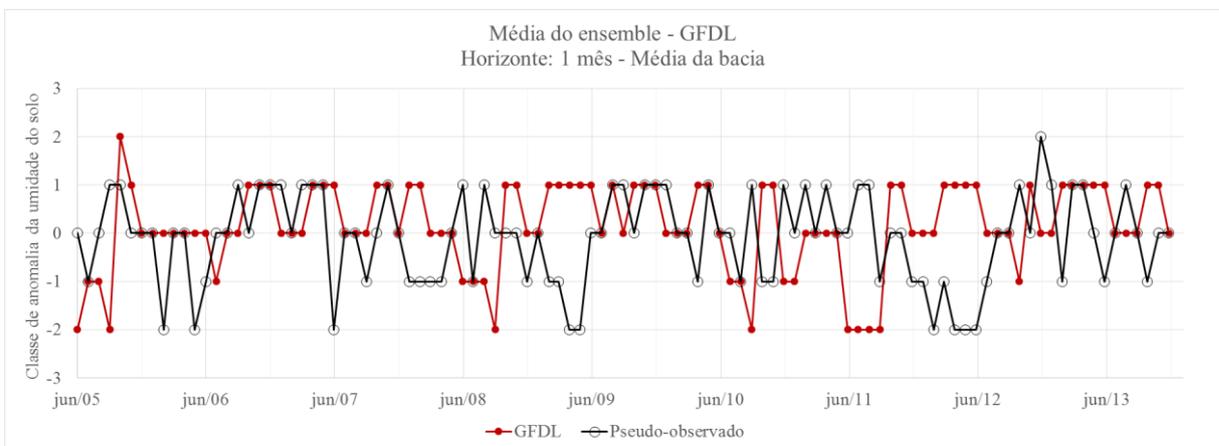


Figura 8.15. Classe pseudo-observada de saturação do solo e prevista pela média do ensemble do modelo GFDL (previsão código 6), para o horizonte de 1 mês.

Previsões tipo B - Média do *ensemble* - Horizonte de 3 meses

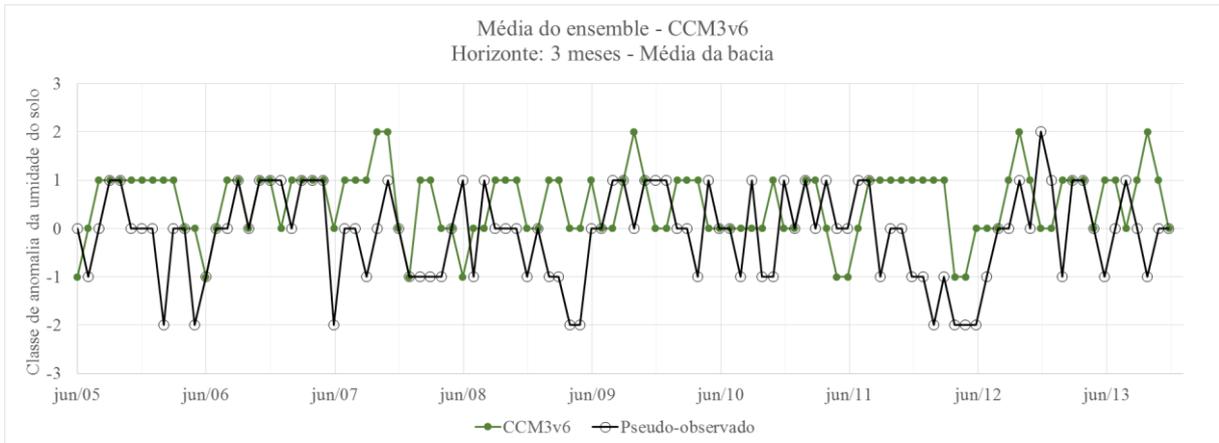


Figura 8.16. Classe pseudo-observada de saturação do solo e prevista pela média do ensemble do modelo CCM3v6 (previsão código 4), para o horizonte de 3 meses.

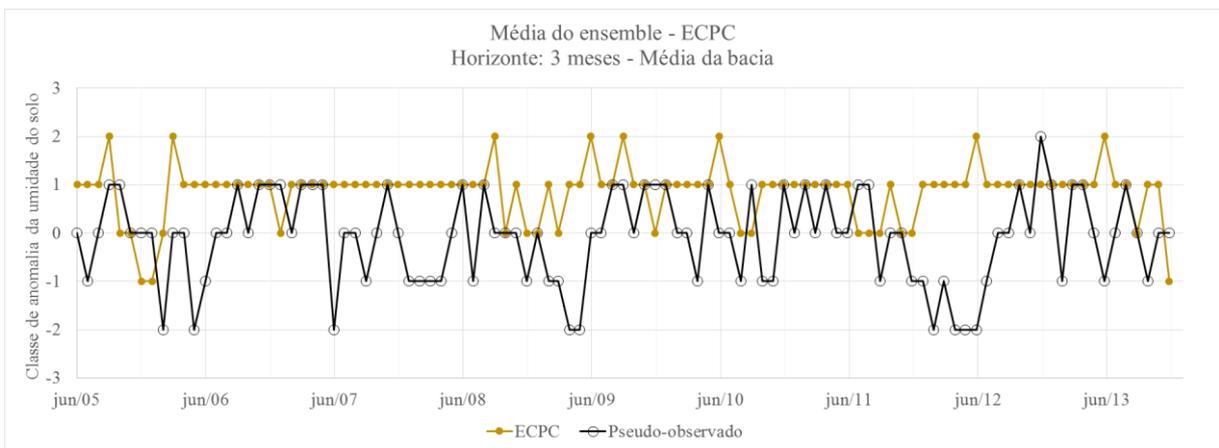


Figura 8.17. Classe pseudo-observada de saturação do solo e prevista pela média do ensemble do modelo ECPC (previsão código 5), para o horizonte de 3 meses.

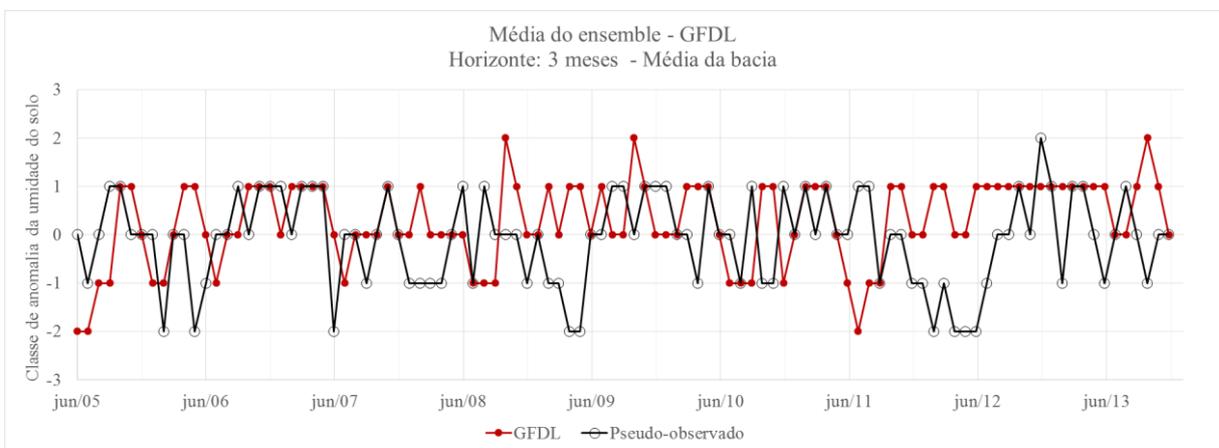


Figura 8.18. Classe pseudo-observada de saturação do solo e prevista pela média do ensemble do modelo GFDL (previsão código 6), para o horizonte de 3 meses.

Previsões tipo B - Média do *ensemble* - Horizonte de 6 meses

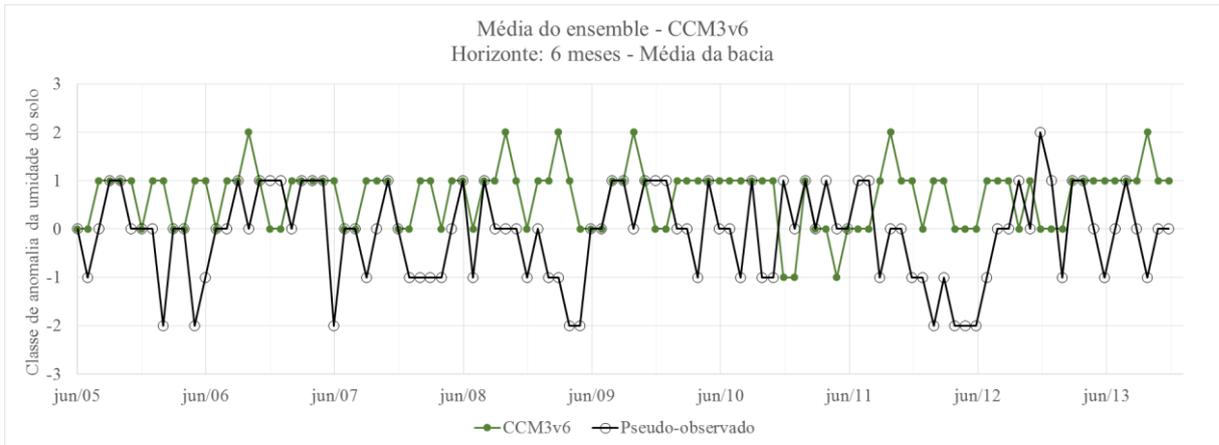


Figura 8.19. Classe pseudo-observada de saturação do solo e prevista pela média do ensemble do modelo CCM3v6 (previsão código 4), para o horizonte de 6 meses.

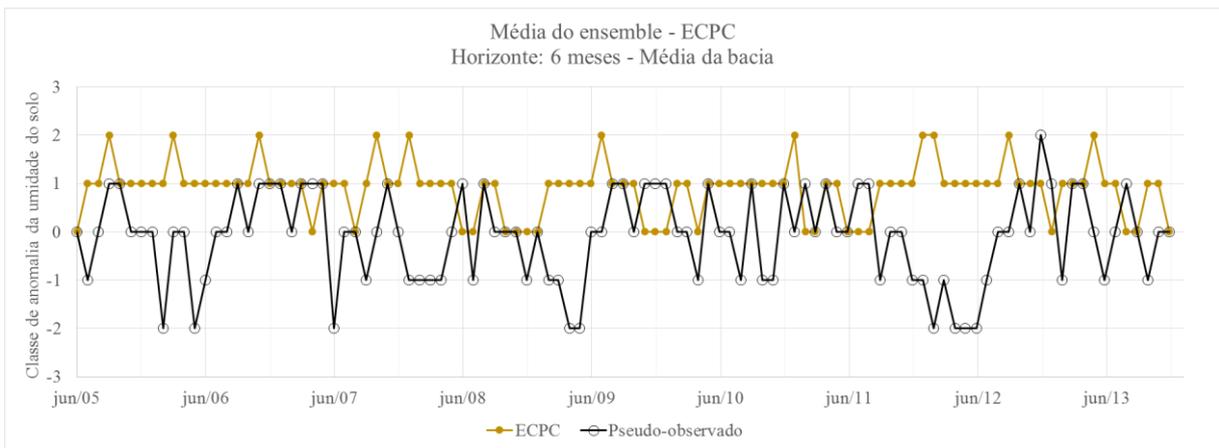


Figura 8.20. Classe pseudo-observada de saturação do solo e prevista pela média do ensemble do modelo ECPC (previsão código 5), para o horizonte de 6 meses.

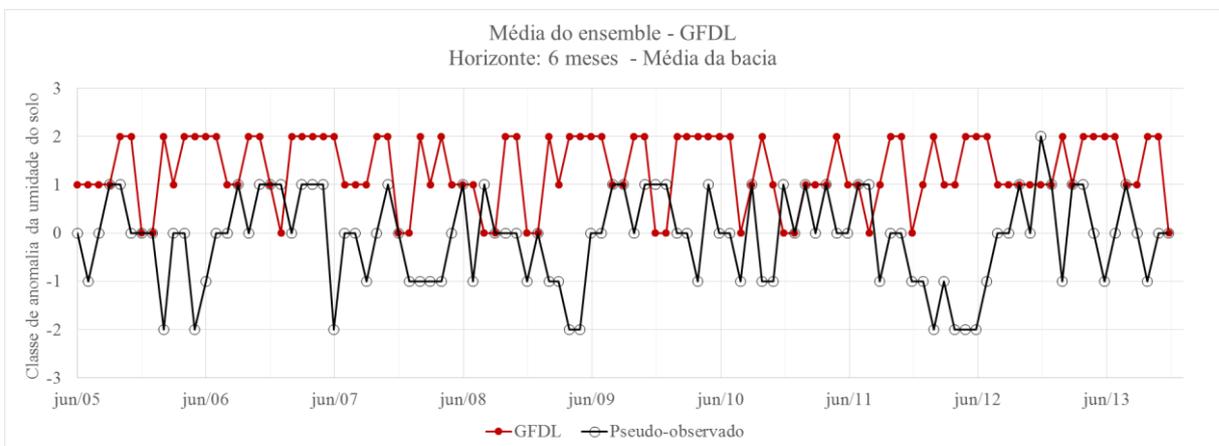


Figura 8.21. Classe pseudo-observada de saturação do solo e prevista pela média do ensemble do modelo GFDL (previsão código 6), para o horizonte de 6 meses.

8.2.3 Previsões tipo C – *Superensemble* – Código 7

A partir da definição de classes de saturação prevista para cada membro, o *superensemble* foi determinado desconsiderando-se a separação entre modelos, ou seja, como um total de 66 membros (24 CCM3v6, 12 ECPC e 30 GFDL) para cada horizonte. As figuras 8.22 a 8.24 apresentam os resultados encontrados. As tabelas F.13 a F.18, no ANEXO F, trazem os resultados completos da previsão, com informação da probabilidade associada a cada classe de saturação.

O *superensemble* apresenta uma forte tendência a subestimar a saturação do solo. O principal motivo pelo qual isto ocorre está ligado a distribuição dos membros e à correção de viés. A correção de viés da precipitação foi determinada com a média dos membros. Porém, o espalhamento dos membros não é homogêneo (muitos membros muito baixos, alguns muito altos). Utilizando-se cada membro do *ensemble* para realizar uma previsão individual de umidade no solo há muitos membros com classe baixa de saturação. Ao se fazer a contagem de membros em cada classe, determinando-se a probabilidade associada a cada nível de saturação, as classes mais secas (mais baixas) tendem a ser aquelas com maior probabilidade, fazendo com que haja uma tendência a subestimar a previsão. Esse efeito já é sentido ao se trabalhar com cada modelo separadamente, nas previsões do tipo A. Com o *superensemble*, o efeito é intensificado, e a previsão resultante fica prejudicada.

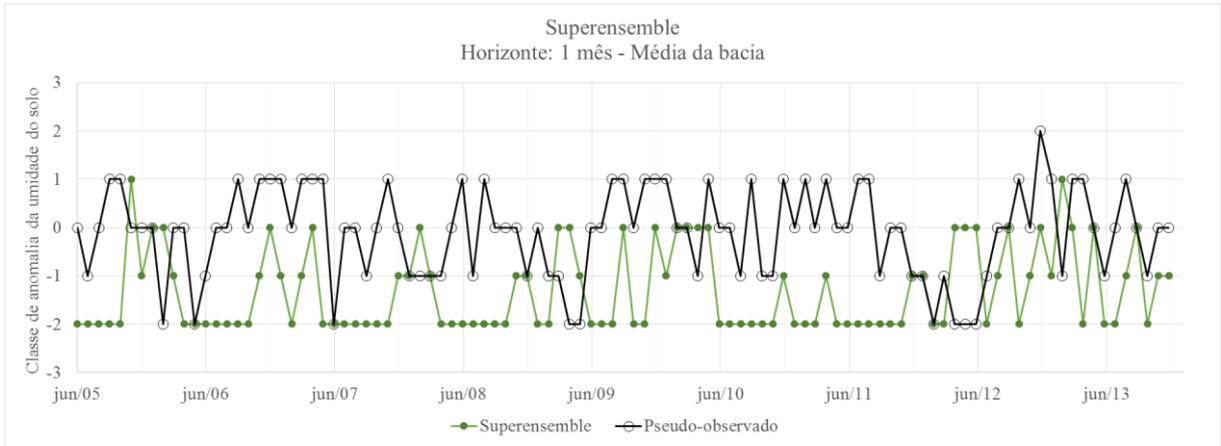


Figura 8.22. Classe de saturação pseudo-observada e prevista pelo *superensemble* (previsão código 7) para o horizonte de 1 mês.

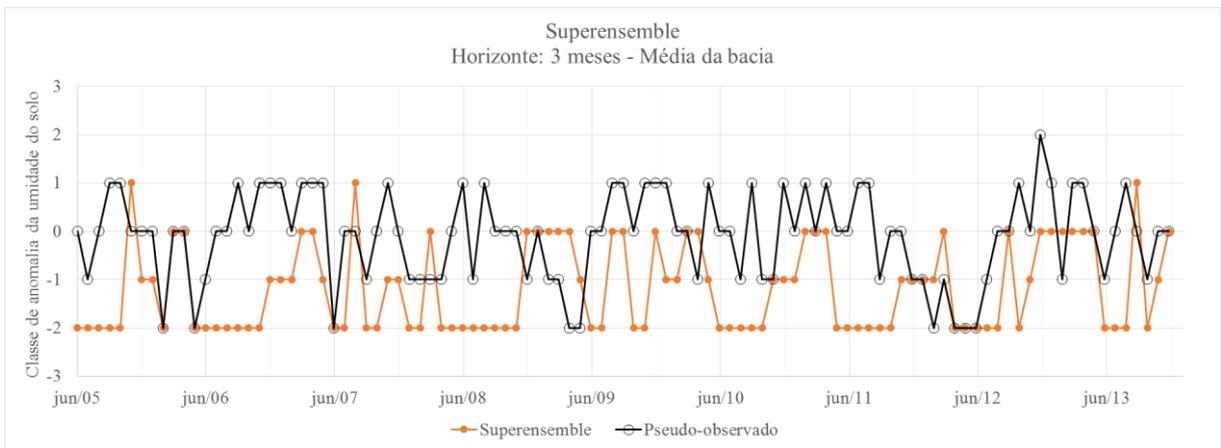


Figura 8.23. Classe de saturação pseudo-observada e prevista pelo *superensemble* (previsão código 7) para o horizonte de 3 meses.

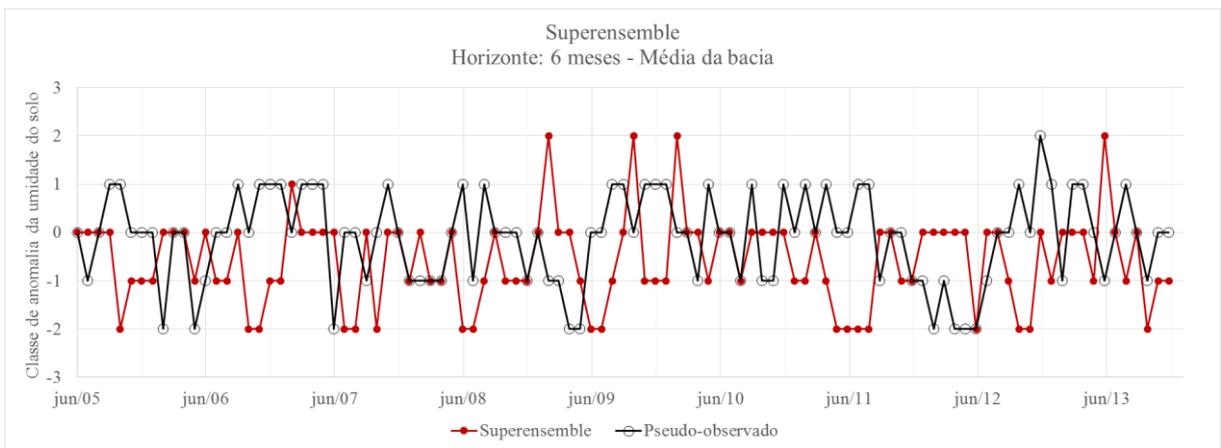


Figura 8.24. Classe de saturação pseudo-observada e prevista pelo *superensemble* (previsão código 7) para o horizonte de 6 meses.

8.2.4 Previsões tipo D – *Ensemble* de modelos – Código 8

As figuras 8.25 a 8.27 mostram a série prevista com o *ensemble* construído com as médias dos três modelos – um *ensemble* de modelos. O resultado do *ensemble* das médias (de saturação) foi calculado como a média (arredondada para o número inteiro mais próximo) das classes encontradas pela previsão realizada com a média (de precipitação) de cada modelo. Ou seja, a previsão do tipo D é originada a partir de uma média, arredondada para um número inteiro, das previsões tipo B. As tabelas F.19 a F.21, no ANEXO F, mostram os resultados do *ensemble* das médias em forma de tabela.

Observa-se nas figuras a seguir que o *ensemble* das médias, apesar de possuir resultados mais coerentes com a umidade do solo pseudo-observada do que o *superensemble* (tipo C), é no geral incapaz de identificar a ocorrência de eventos extremos, ou seja, meses em que a classe de saturação seja classificada como -2 ou +2.

Analisando-se a Tabela 7.4, percebe-se que a média do erro médio da precipitação entre dos modelos tende a ficar mais positivo quanto mais distante o horizonte de previsão. Isto explica porque o *ensemble* de modelos passa a prever a ocorrência de alguns valores extremos (e positivos, ou seja, mais úmido) para os horizontes 3 e 6 meses.

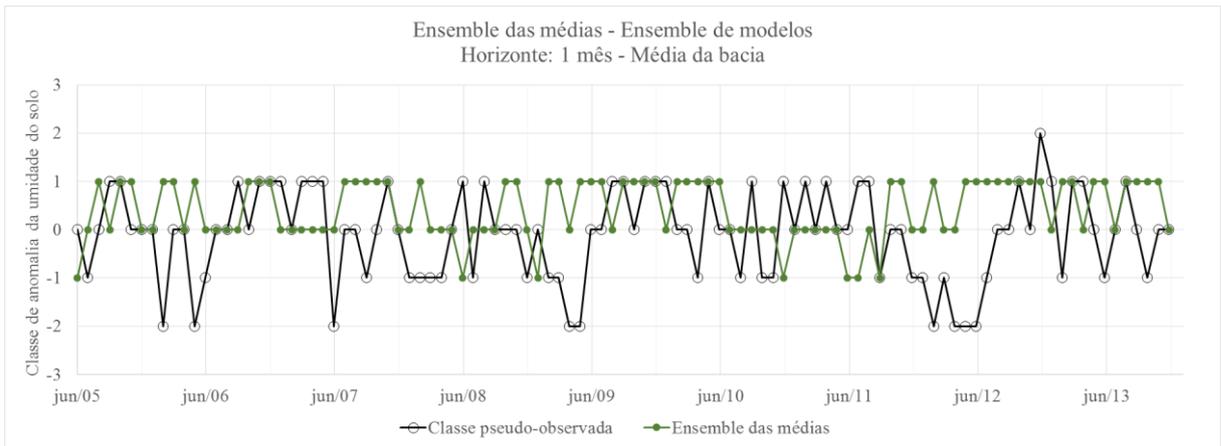


Figura 8.25. Classe pseudo-observada de saturação do solo e prevista pelo ensemble das médias dos modelos (previsão código 8) para o horizonte de 1 mês.

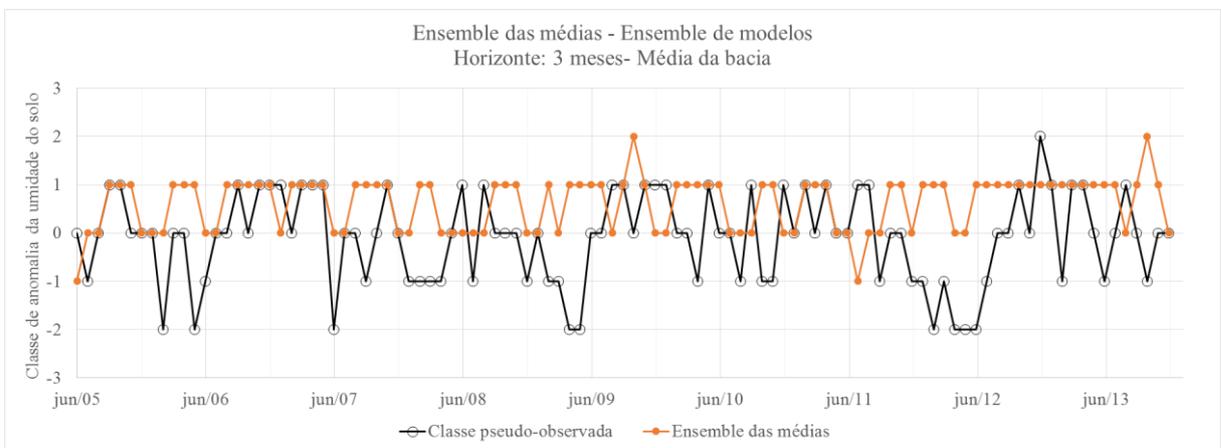


Figura 8.26. Classe pseudo-observada de saturação do solo e prevista pelo ensemble das médias dos modelos (previsão código 8) para o horizonte de 3 meses.

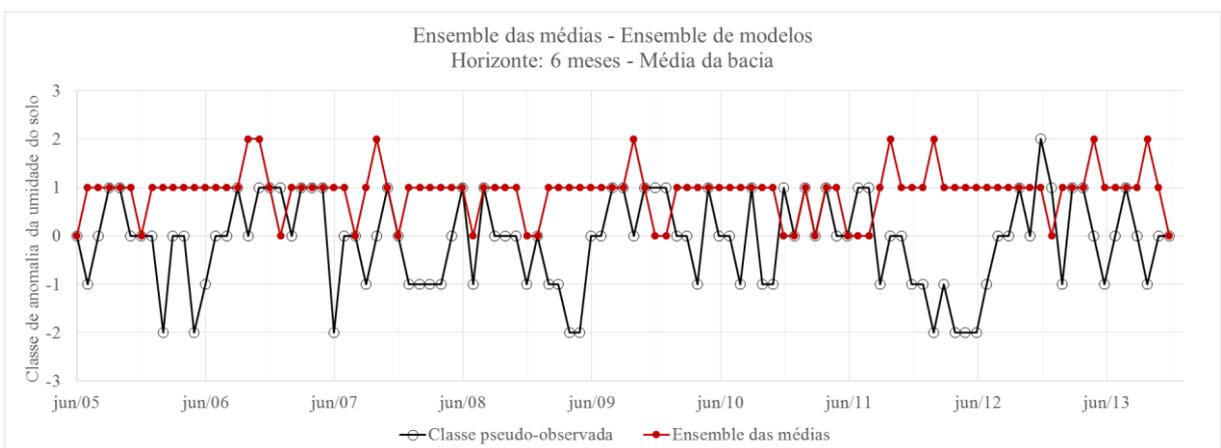


Figura 8.27. Classe pseudo-observada de saturação do solo e prevista pelo ensemble das médias dos modelos (previsão código 8) para o horizonte de 6 meses.

8.3 Análise de desempenho da previsão de umidade no solo

Conforme descrito no Capítulo 4, os resultados da previsão de umidade no solo são comparados a simulação do MGB-IPH empregando a precipitação observada para o período de interesse, encontrando-se assim a saturação do solo pseudo-observada.

Adotando-se a classificação por códigos (-2 a 2), conforme a Tabela 4.4, os resultados podem ser reclassificados em faixas. As faixas são definidas conforme a Tabela 8.1. Para uma saturação pseudo-observada na classe +2, o uso das faixas permite que previsões de saturação na classe +2 ou classe +1 sejam consideradas como acertos da previsão. Desta forma, ao invés de avaliar se a saturação prevista acerta ou erra a classe de saturação pseudo-observada, o uso das faixas permite avaliar a tendência de umidade no solo, um período úmido, normal ou seco.

Tabela 8.1. Faixas de saturação.

Faixas	Limite inferior	Valor central (pseudo-observado)	Limite superior
Úmido	+1	+2	+2
Normal a úmido	0	+1	+2
Normal	-1	0	+1
Normal a seco	-2	-1	0
Seco	-2	-2	-1

O item 8.3.1 a seguir avalia o desempenho da previsão de umidade do solo utilizando-se as faixas de saturação. O item 8.3.2 analisa os resultados quanto às classes de saturação: primeiramente avalia-se o desempenho adotando-se apenas três classes de saturação, seco (classes -2 e -1), normal (classe 0) e úmido (classes +1 e +2). Em seguida, analisam-se os resultados sob o ponto de vista das cinco classes previstas. Por fim, o item 6.5.3 avalia a relação entre o desempenho dos resultados e a probabilidade associada a previsão, para o *ensemble* de modelos (previsão tipo D, código 8).

8.3.1 Análise de desempenho da previsão em Faixas

O uso das faixas equivale a considerar que erros iguais a +1 ou -1 são aceitáveis. Desta forma, há um intervalo de uma classe de sobreposição entre as faixas, conforme mostrado na Tabela 8.1. A Tabela 8.2 e a Figura 8.28 mostram o índice de acertos para cada tipo de previsão, para os três horizontes.

Tabela 8.2. Índice de acertos da previsão considerando-se faixas de tendência.

Código da previsão	1	2	3	7	4	5	6	8
Horizonte de previsão	Ensemble			Super ensemble	Média			Ensemble das médias
	CCM3v6	ECPC	GFDL		CCM3v6	ECPC	GFDL	
1 mês	58%	71%	41%	46%	78%	67%	69%	80%
3 meses	59%	74%	53%	59%	76%	70%	74%	77%
6 meses	63%	64%	60%	63%	70%	66%	52%	66%

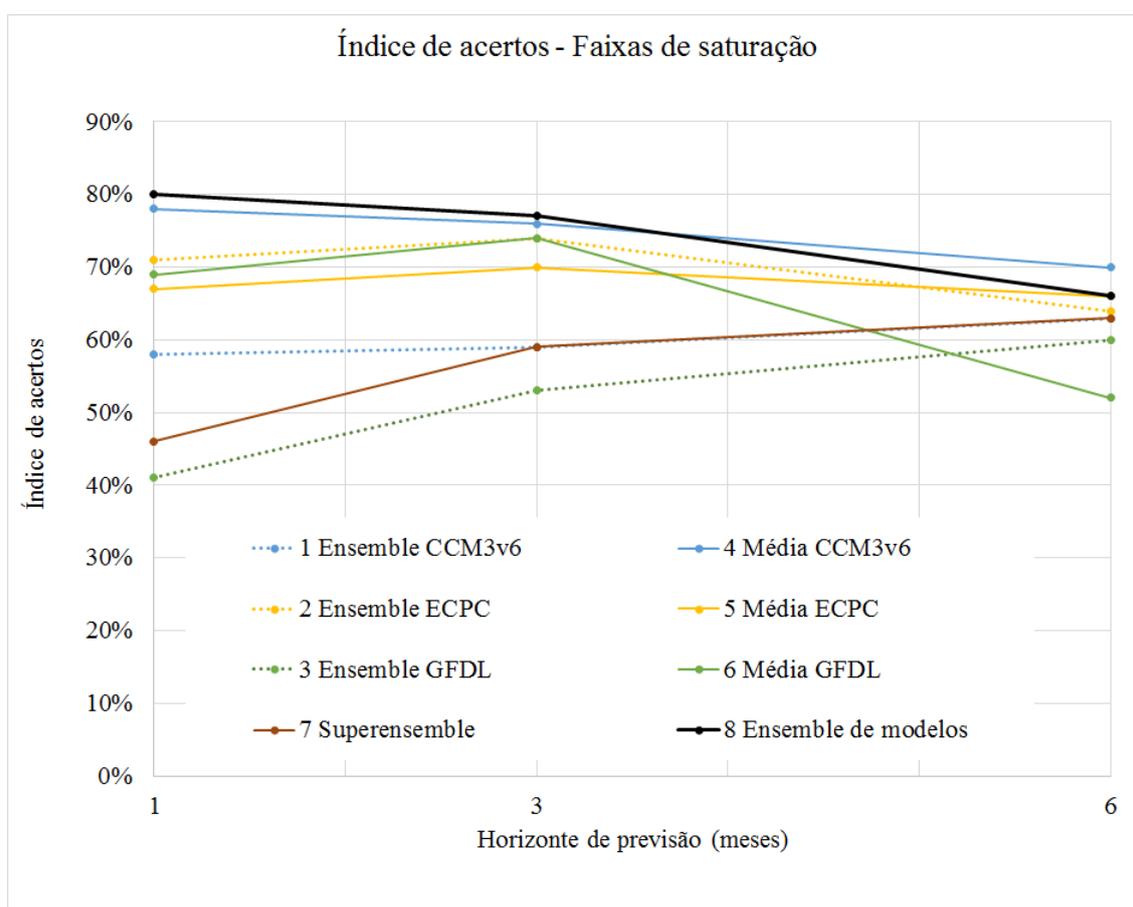


Figura 8.28. Índice de acertos da previsão considerando-se faixas de tendência, conforme o horizonte de previsão.

Exceto para o modelo ECPC, nos horizontes de 1 e 3 meses, a previsão realizada com as médias do *ensemble* (tipo B) apresentou desempenho superior à previsão feita com cada membro do conjunto (tipo A, códigos 1, 2 e 3). Este resultado está associado ao espalhamento dos membros e ao fato da correção de viés ter sido determinada pela média do *ensemble*. Este problema do espalhamento inadequado dos membros tem seu efeito intensificado ao avaliar-se o desempenho da previsão com o *superensemble* (código 7), onde os membros dos três modelos são tratados como um único conjunto.

O emprego do *ensemble* das médias (código 8) como previsão obteve bons resultados, superior a qualquer das demais previsões (*ensemble*, média de cada modelo isolado ou *superensemble*) para os horizontes 1 e 3 meses. Para o horizonte de 6 meses, o resultado foi inferior apenas à média do modelo CCM3v6 (previsão código 4).

Quanto aos horizontes de previsão, para a média do modelo CCM3v6 (previsão código 4) e para o *ensemble* das médias (código 8), há uma tendência à melhor desempenho quanto mais curto o horizonte. A diferença no índice de acertos entre os horizontes 1 e 3 meses é, contudo, pequena. O *superensemble* (código 7) possui um desempenho melhor quanto mais distante o horizonte de previsão, o que está ligado à melhora na performance do *ensemble* do modelo GFDL (código 3).

8.3.2 Análise de desempenho da previsão em Classes

Saturação em três classes

A análise quanto a três classes de saturação requer uma reclassificação dos resultados das cinco classes previstas. Desta forma, a divisão entre as classes muito seco (-2) e seco (-1) deixa de existir, assim como a separação entre as classes úmido (+1) e muito úmido (+2). As tabelas 8.3 a 8.5 mostram o desempenho das previsões no período de simulação considerando-se as três classes. O erro é definido como a classe de saturação prevista *menos* a classe pseudo-verdadeira. Desta forma, erro=0 equivale a um acerto na previsão. Erros positivos (+1, +2) indicam uma superestimativa da previsão em relação aos valores pseudo-observados, enquanto erros negativos (-1, -2) indicam subestimativas.

Os resultados mostram que a taxa de erro=0 é relativamente baixa, nunca superior à 37% para qualquer das 8 diferentes previsões. Contudo, uma quantidade importante dos erros é igual a ± 1 , o que indica que, na maior parte do tempo, a previsão de saturação do solo erra entre as categorias seco e normal ou normal e úmido. A taxa de erros ± 2 é de no máximo 30%. Ou seja, na pior das previsões (mais incorreta), a indicação de período seco quando o observado foi úmido, ou úmido quando o observado foi seco, ocorre em 30% do tempo.

**Tabela 8.3. Índice de erros e acertos da previsão considerando-se três classes de saturação.
Horizonte 1 mês.**

Código da previsão	1	2	3	7	4	5	6	8
Tipo de erro	Ensemble			Super-ensemble	Média			Ensemble das médias
	CCM3v6	ECPC	GFDL		CCM3v6	ECPC	GFDL	
Erro= 0	36%	27%	25%	28%	37%	21%	37%	27%
Erro= +1	9%	19%	13%	9%	34%	38%	22%	38%
Erro= -1	33%	33%	38%	40%	14%	14%	17%	19%
Erro = +2	5%	8%	6%	1%	14%	22%	17%	15%
Erro = -2	17%	13%	18%	22%	2%	5%	8%	1%
Acertos: Erro= 0	36%	27%	25%	28%	37%	21%	37%	27%
Total erros positivos	14%	27%	18%	10%	48%	60%	39%	52%
Total erros negativos	50%	46%	56%	62%	16%	18%	24%	20%

**Tabela 8.4. Índice de erros e acertos da previsão considerando-se três classes de saturação.
Horizonte 3 meses.**

Código da previsão	1	2	3	7	4	5	6	8
Tipo de erro	Ensemble			Super-ensemble	Média			Ensemble das médias
	CCM3v6	ECPC	GFDL		CCM3v6	ECPC	GFDL	
Erro= 0	31%	31%	31%	31%	32%	28%	35%	33%
Erro= +1	16%	23%	14%	11%	36%	38%	29%	38%
Erro= -1	32%	23%	32%	40%	16%	9%	16%	12%
Erro = +2	7%	12%	7%	0%	16%	25%	15%	17%
Erro = -2	15%	11%	17%	18%	1%	0%	6%	0%
Acertos: Erro= 0	31%	31%	31%	31%	32%	28%	35%	33%
Total erros positivos	22%	35%	20%	11%	51%	63%	44%	55%
Total erros negativos	47%	34%	49%	58%	17%	9%	21%	12%

**Tabela 8.5. Índice de erros e acertos da previsão considerando-se três classes de saturação.
Horizonte 6 meses.**

Código da previsão	1	2	3	7	4	5	6	8
Tipo de erro	Ensemble			Super-ensemble	Média			Ensemble das médias
	CCM3v6	ECPC	GFDL		CCM3v6	ECPC	GFDL	
Erro= 0	32%	26%	25%	26%	30%	28%	30%	32%
Erro= +1	16%	24%	33%	21%	37%	34%	37%	33%
Erro= -1	33%	20%	15%	33%	12%	10%	6%	7%
Erro = +2	7%	15%	17%	2%	20%	28%	27%	28%
Erro = -2	13%	15%	11%	17%	1%	0%	0%	0%
Acertos: Erro= 0	32%	26%	25%	26%	30%	28%	30%	32%
Total erros positivos	22%	39%	50%	23%	57%	62%	64%	61%
Total erros negativos	46%	35%	25%	50%	13%	10%	6%	7%

Estabelecendo-se uma tabela de contingência 2 X 2 para cada classe de saturação, conforme descrito no item 4.6, são analisadas as medidas de desempenho Probabilidade de Detecção (POD) e Probabilidade de Falsa Detecção (POFD), Bias e Razão de Alarme Falso (RAF), calculadas conforme as equações (17) a (20). Cada tabela de contingência é construída a partir da divisão a série simulada, quanto aos dados pseudo-observados, em três séries: uma relativa à classe seca, uma à classe normal, e outra à classe úmida. As figuras a seguir mostram os resultados de medidas de desempenho calculadas para cada uma das três classes de saturação do solo: seco, normal e úmido.

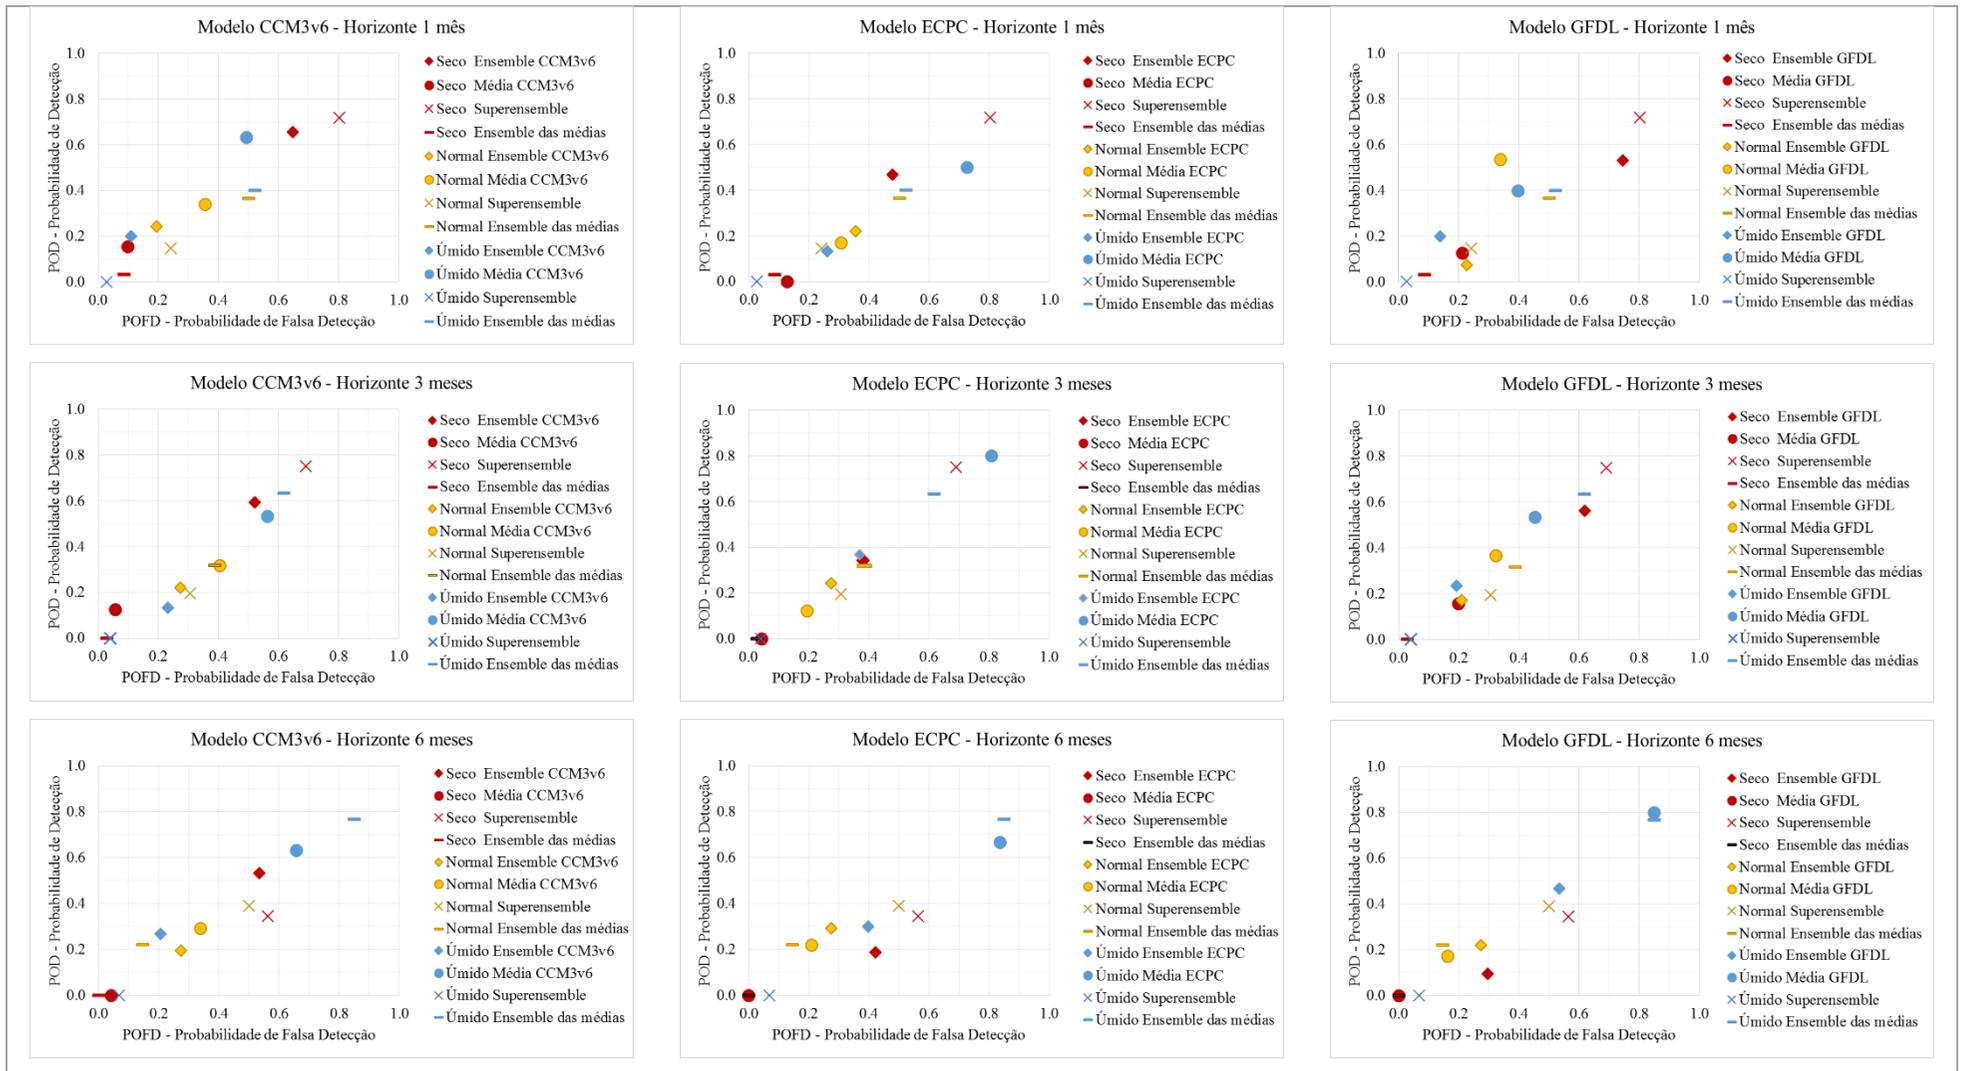


Figura 8.29. Probabilidade de Detecção e Probabilidade de Falsa Detecção para as classes seca, normal e úmida, para as diferentes previsões.

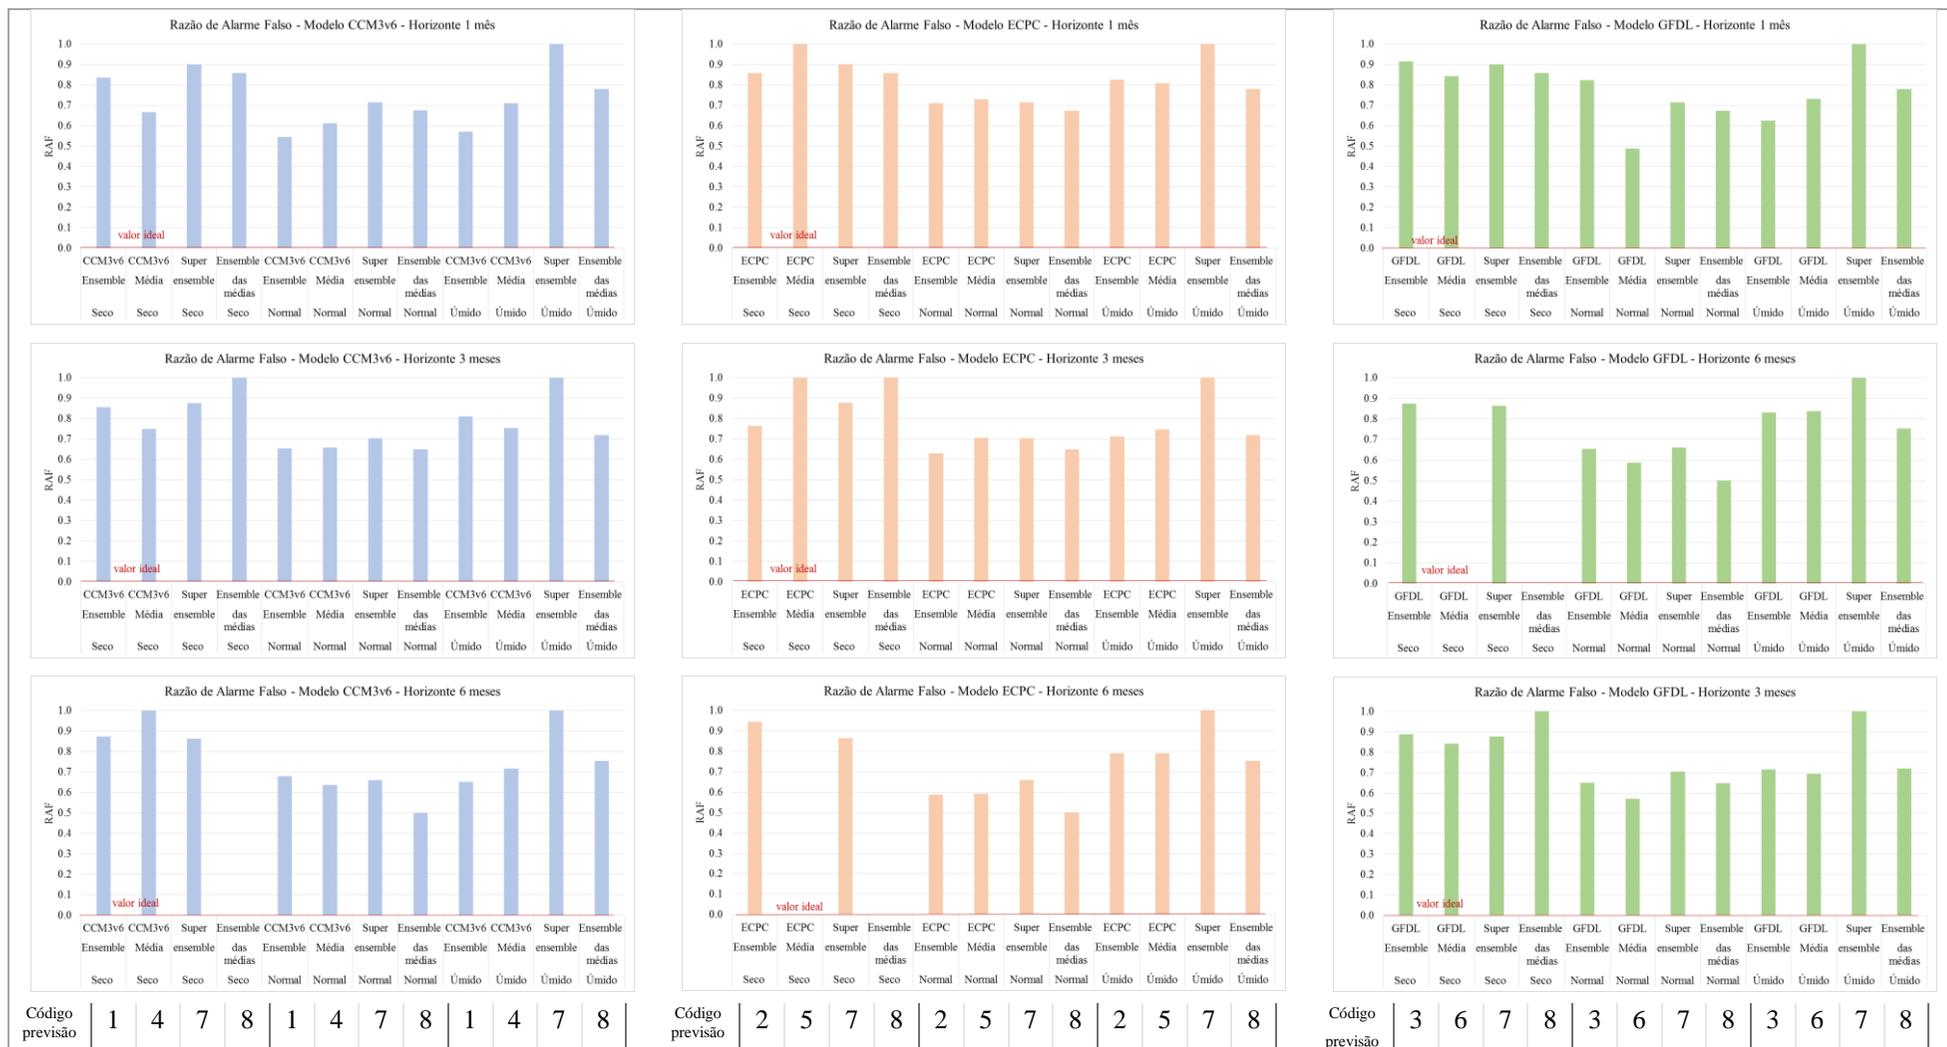


Figura 8.30. Razão de Falso Alarme para as classes seca, normal e úmida, para as diferentes previsões.

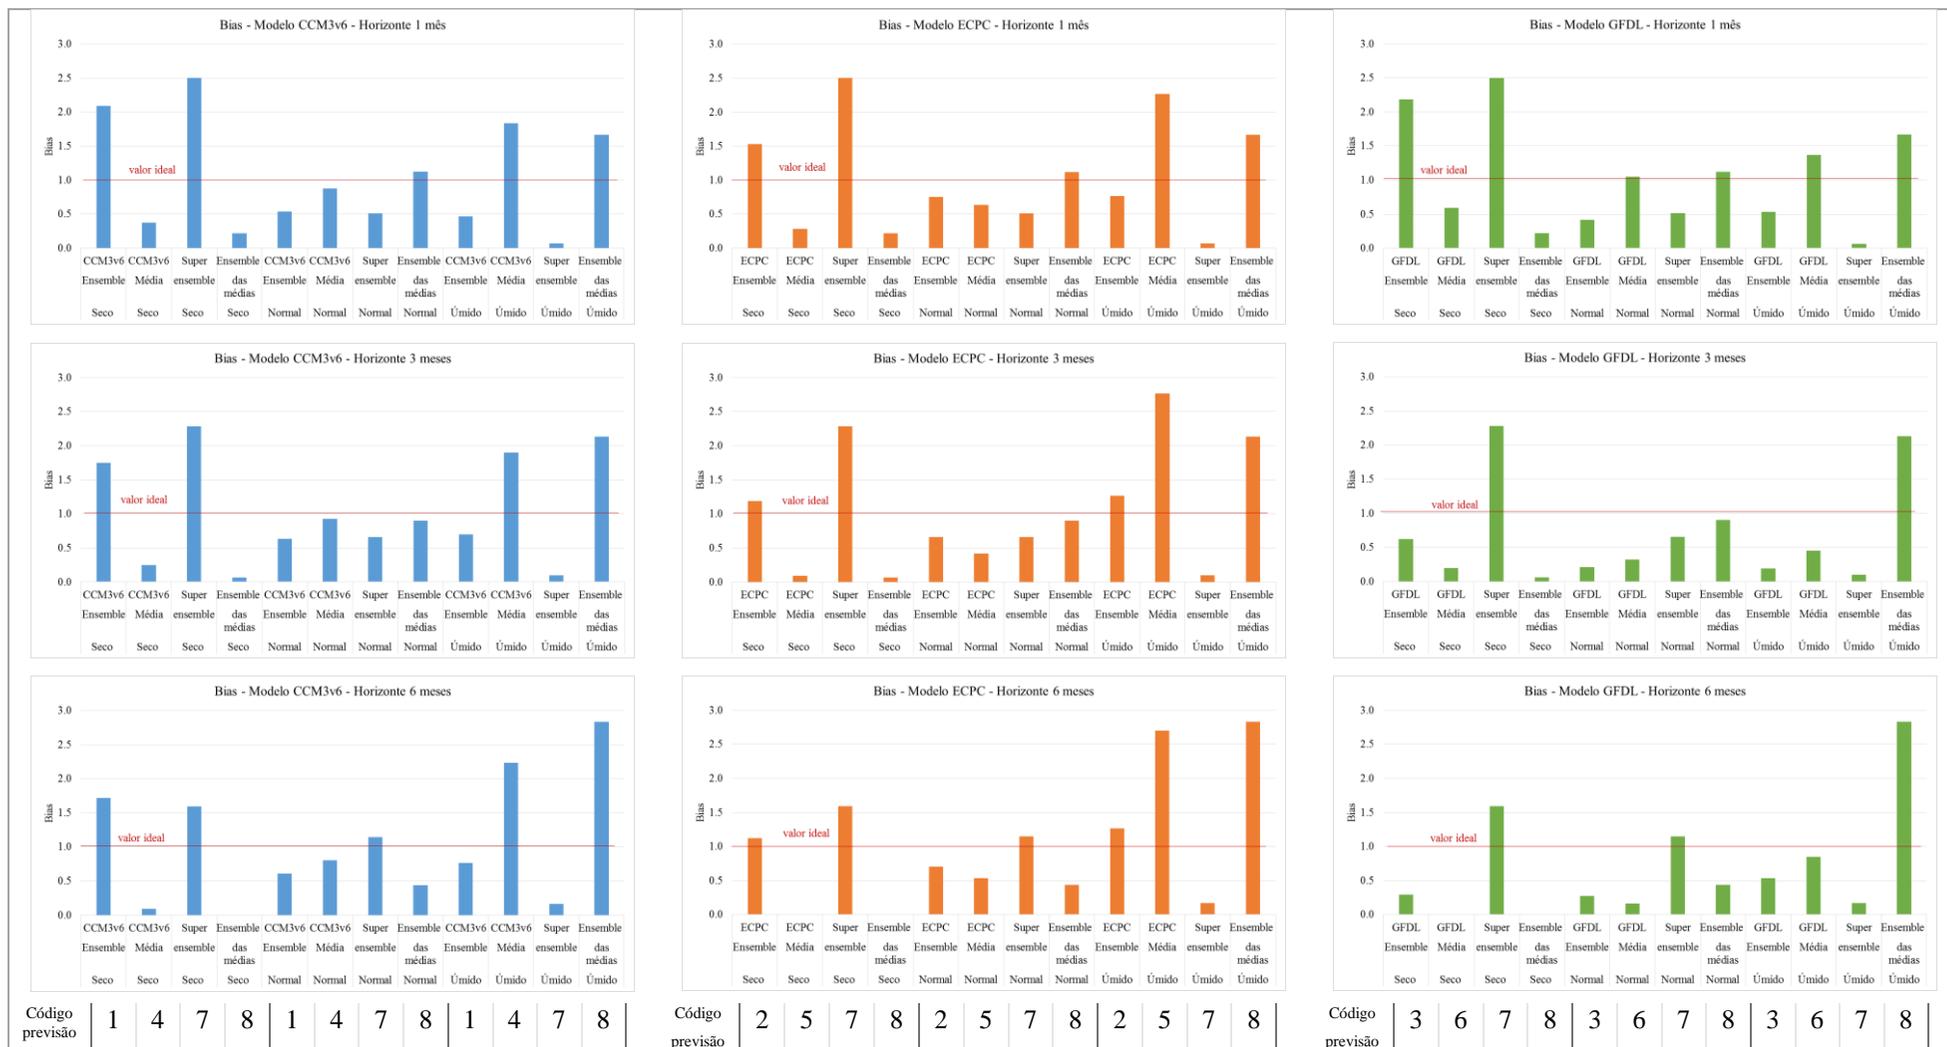


Figura 8.31. BIAS para as classes seca, normal e úmida, para as diferentes previsões.

Sabendo-se que o resultado ideal seria Probabilidade de Detecção (POD) igual a 1 e Probabilidade de Falsa Detecção (POFD) igual a 0, percebe-se que as previsões possuem um desempenho ainda distante do ideal. Para os três modelos, tanto a previsão com o conjunto completo (tipo A, códigos 1, 2 e 3) como a previsão da média do *ensemble* (tipo B, códigos 4, 5 e 6), assim como o *superensemble* (código 7) e o *ensemble* de modelos (código 8), tendem a ter POD semelhante à POFD.

Analisando-se o conjunto de gráficos demonstrativos das medidas RAF e BIAS, percebe-se que o desempenho tende a ser melhor para a classe normal, o que mostra a dificuldade de qualquer uma das previsões em detectar a ocorrência de eventos extremos.

Para todos os modelos, em todos os horizontes, as previsões para classe seca com o *ensemble* (tipo A) e com o *superensemble* (tipo C) tende a ter maiores valores de POD e POFD que as previsões com a média de conjunto de cada modelo (tipo B) e com o *ensemble* de modelos (tipo D). Isto está relacionado ao espalhamento dos membros e aos resultados da correção de viés. A previsão com todos os membros de um modelo (códigos 1, 2 e 3) tende a subestimar a classe prevista, e este efeito é intensificado ao realizar-se a previsão com o *superensemble*. Isso faz com que haja um maior número de eventos secos previstos, porém nem todos de fato ocorrem. Isto aumenta a POD, mas também aumenta a POFD. Este efeito pode também ser analisado sob o ponto de vista do BIAS, maior que 1,0 em quase todas as previsões realizadas com o *ensemble* dos membros (tipo A) ou com o *superensemble* (tipo C).

Já para classe úmida, a previsão com a média do *ensemble* (códigos 4, 5 e 6) e com o *ensemble* de médias (código 8) possui POD e POFD maiores que a realizada com o *ensemble* (códigos 1, 2 e 3) e com o *superensemble* (código 7). O BIAS, nestes casos, é quase sempre maior que 1,0, o que indica que houve mais eventos úmidos previstos que de fato observados. Isto pode estar relacionado à predominância de eventos La Niña ao longo do intervalo de tempo simulado, associado à ocorrência de estiagens na região de interesse.

Para o BIAS, nos horizontes de 1 e 3 meses o desempenho do *ensemble* de modelos (código 8) para classe normal é melhor que qualquer previsão, e bastante próximo ao valor ideal (1,0), indicando que não há tendência a subestimar ou superestimar a quantidade de meses em classe normal previstos. Analisando-se quanto às três classes,

percebe-se que a previsão com o *ensemble* das médias possui tendência a superestimar a quantidade de eventos úmidos e subestimar a quantidade de eventos secos. Isto pode estar relacionado com a ocorrência do fenômeno ENOS ao longo do período simulado, conforme discutido anteriormente.

Para o horizonte de previsão de 6 meses na categoria seco, a Razão de Falso Alarme, a Probabilidade de Falsa Detecção e BIAS são zero para o *ensemble* de modelos (código 8) porque não houve, para este horizonte, nenhuma previsão de mês seco.

O *superensemble* (previsão código 7), para os horizontes de 1 e 3 meses, possui POD maior que todas as demais previsões, à exceção de uma (a média do modelo ECPC para condição úmida, no horizonte de 3 meses). Em contrapartida, possui também as maiores POFDs. Isso ocorre pois, conforme já discutido, o *superensemble* apresenta uma forte tendência a subestimar a classe de saturação mensal. Essa tendência pode ser também confirmada através da BIAS, para classe seca nos três horizontes acima de 1,5, e chegando a 2,5 para o horizonte de 1 mês. A RAF mostra-se sempre em torno de 0,9, indicando que aproximadamente 90% dos eventos (meses de umidade do solo considerada abaixo do normal para o mês) previstos não são observados.

Para a classe úmida, em todos os horizontes, a previsão do *superensemble* possui POD, assim como POFD, próximas a zero, devido à baixa incidência de previsões de meses em classe úmida. O BIAS, nestes casos, está sempre abaixo de 0,16, indicando uma forte subestimativa da quantidade de eventos observados. RAF, também em todos os horizontes, é igual a 1,0, o que mostra que, além de subestimar a quantidade de eventos úmidos (meses onde a saturação do solo é considerada acima do normal para o mês), o *superensemble*, ao longo do período simulado, nunca acertou uma previsão de ocorrência de classe úmida.

Para a previsão de classe normal (umidade do solo dentro do esperado para o mês), o desempenho do *superensemble* é melhor que para classe seca ou úmida em termos de RAF e BIAS. Há ainda uma tendência a subestimar a quantidade de meses em classe normal, além de haver uma grande incidência de falsos alarmes. Para todos os horizontes, a POFD é maior que a POD.

Análise fora do período de saturação “normal”

A avaliação dos resultados para o período em que a saturação do solo pseudo-observada foi classificada como “seco” ou “úmido” permite avaliar o ganho na realização da previsão de umidade do solo com uma previsão de precipitação, e não a realização de uma estimativa com a precipitação média mensal. As tabelas 8.6 a 8.8 mostram o resultado quanto ao tipo de erro para os três horizontes de previsão, para o período fora dos meses normais.

As previsões com o conjunto completo de membros de cada modelo (códigos 1, 2 e 3) e com o *superensemble* (código 7) tendem a prever eventos secos, porém este viés é compensado pelo desvio na série pseudo-observada, que tem a predominância de eventos La Niña no intervalo de tempo simulado. A este fato deve-se o desempenho relativamente bom das previsões através do *ensemble* de cada modelo e do *superensemble*, quando comparado ao desempenho para o período completo (incluindo a condição normal) ou comparado ao desempenho da média de cada modelo (códigos 4, 5 e 6) ou do *ensemble* de modelos (código 8).

Tabela 8.6. Índice de erros e acertos da previsão fora dos meses de saturação pseudo-observada “normal”, considerando-se três classes de saturação. Horizonte 1 mês.

Código da previsão	1	2	3	7	4	5	6	8
Tipo de erro	Ensemble			Super-ensemble	Média			Ensemble das médias
	CCM3v6	ECPC	GFDL		CCM3v6	ECPC	GFDL	
Erro= 0	44%	31%	37%	37%	39%	24%	26%	18%
Erro= +1	10%	15%	15%	13%	21%	15%	18%	27%
Erro= -1	10%	21%	8%	11%	15%	16%	16%	29%
Erro = +2	8%	13%	10%	2%	23%	37%	27%	24%
Erro = -2	29%	21%	31%	37%	3%	8%	13%	2%
Acertos: Erro= 0	44%	31%	37%	37%	39%	24%	26%	18%
Total erros positivos	18%	27%	24%	15%	44%	52%	45%	52%
Total erros negativos	39%	42%	39%	48%	18%	24%	29%	31%

Tabela 8.7. Índice de erros e acertos da previsão fora dos meses de saturação pseudo-observada “normal”, considerando-se três classes de saturação. Horizonte 3 meses.

Código da previsão	1	2	3	7	4	5	6	8
Tipo de erro	Ensemble			Super-ensemble	Média			Ensemble das médias
	CCM3v6	ECPC	GFDL		CCM3v6	ECPC	GFDL	
Erro= 0	37%	35%	40%	39%	32%	39%	34%	29%
Erro= +1	10%	15%	11%	13%	19%	10%	19%	23%
Erro= -1	18%	13%	10%	18%	21%	10%	13%	19%
Erro = +2	11%	19%	11%	0%	26%	42%	24%	29%
Erro = -2	24%	18%	27%	31%	2%	0%	10%	0%
Acertos: Erro= 0	37%	35%	40%	39%	32%	39%	34%	29%
Total erros positivos	21%	34%	23%	13%	45%	52%	44%	52%
Total erros negativos	42%	31%	37%	48%	23%	10%	23%	19%

Tabela 8.8. Índice de erros e acertos da previsão fora dos meses de saturação pseudo-observada “normal”, considerando-se três classes de saturação. Horizonte 6 meses.

Código da previsão	1	2	3	7	4	5	6	8
Tipo de erro	Ensemble			Super-ensemble	Média			Ensemble das médias
	CCM3v6	ECPC	GFDL		CCM3v6	ECPC	GFDL	
Erro= 0	40%	24%	27%	18%	31%	32%	39%	37%
Erro= +1	13%	18%	19%	31%	18%	5%	6%	5%
Erro= -1	15%	10%	8%	19%	16%	16%	10%	11%
Erro = +2	11%	24%	27%	3%	34%	47%	45%	47%
Erro = -2	21%	24%	18%	29%	2%	0%	0%	0%
Acertos: Erro= 0	40%	24%	27%	18%	31%	32%	39%	37%
Total erros positivos	24%	42%	47%	34%	52%	52%	52%	52%
Total erros negativos	35%	34%	26%	48%	18%	16%	10%	11%

Saturação em cinco classes

A avaliação do ponto de vista das cinco classes de saturação é a análise mais rigorosa aqui realizada. Neste caso, diferentemente da análise por faixas (item 8.3.1), apenas erros iguais a zero são aceitos, ou seja, são contabilizados como acertos apenas meses em que a faixa de saturação prevista esteve exatamente na mesma faixa da saturação pseudo-observada. As tabelas 8.9 a 8.11 mostram o índice de acertos e o tipo de erro para as diferentes previsões realizadas, para os três horizontes de previsão. Para a análise em cinco classes de saturação, o maior índice de acertos encontrado foi 35%. Assim como na avaliação em três classes de saturação, grande parte dos erros é igual a ± 1 . Desta forma, os erros ocorrem, em sua maior, em identificar a diferença entre:

- Mês muito úmido e úmido;
- Mês úmido e normal;
- Mês normal e seco;
- Mês seco e muito seco.

Este resultado indica que a análise por faixas é uma alternativa interessante para contornar este erro. Apesar de não ser capaz de identificar a classe exata de umidade, o uso das faixas permite uma indicação da tendência de saturação do mês de interesse.

Tabela 8.9. Índice de erros e acertos da previsão considerando-se cinco classes de saturação. Horizonte 1 mês.

Código da previsão	1	2	3	7	4	5	6	8
Tipo de erro	Ensemble			Super-ensemble	Média			Ensemble das médias
	CCM3v6	ECPC	GFDL		CCM3v6	ECPC	GFDL	
Erro= 0	26%	19%	15%	14%	33%	19%	35%	26%
Erro= +1	10%	17%	8%	5%	31%	33%	20%	35%
Erro= -1	22%	34%	18%	27%	14%	15%	14%	18%
Erro = +2	5%	8%	8%	6%	14%	19%	14%	12%
Erro = -2	27%	13%	35%	34%	2%	5%	8%	3%
Erro = +3	1%	3%	3%	0%	6%	7%	6%	6%
Erro = -3	9%	6%	14%	15%	1%	0%	4%	0%
Erro = +4	0%	0%	0%	0%	0%	2%	0%	0%
Erro = -4	0%	0%	0%	0%	0%	0%	0%	0%
Acertos: Erro= 0	26%	19%	15%	14%	33%	19%	35%	26%
Total erros positivos	16%	28%	18%	11%	50%	61%	40%	52%
Total erros negativos	58%	52%	67%	76%	17%	19%	25%	21%

**Tabela 8.10. Índice de erros e acertos da previsão considerando-se cinco classes de saturação.
Horizonte 3 meses.**

Código da previsão	1	2	3	7	4	5	6	8
Tipo de erro	Ensemble			Super-ensemble	Média			Ensemble das médias
	CCM3v6	ECPC	GFDL		CCM3v6	ECPC	GFDL	
Erro= 0	20%	29%	19%	17%	28%	25%	32%	30%
Erro= +1	16%	24%	15%	12%	33%	35%	25%	35%
Erro= -1	23%	20%	19%	31%	15%	10%	17%	12%
Erro = +2	6%	9%	8%	1%	19%	21%	14%	17%
Erro = -2	24%	12%	27%	28%	2%	0%	6%	1%
Erro = +3	2%	4%	0%	0%	3%	8%	6%	6%
Erro = -3	9%	2%	12%	12%	0%	0%	1%	0%
Erro = +4	0%	0%	0%	0%	0%	1%	0%	0%
Erro = -4	0%	0%	0%	0%	0%	0%	0%	0%
Acertos: Erro= 0	20%	29%	19%	17%	28%	25%	32%	30%
Total erros positivos	23%	37%	22%	13%	55%	65%	45%	57%
Total erros negativos	56%	34%	58%	71%	17%	10%	23%	13%

**Tabela 8.11. Índice de erros e acertos da previsão considerando-se cinco classes de saturação.
Horizonte 6 meses.**

Código da previsão	1	2	3	7	4	5	6	8
Tipo de erro	Ensemble			Super-ensemble	Média			Ensemble das médias
	CCM3v6	ECPC	GFDL		CCM3v6	ECPC	GFDL	
Erro= 0	22%	21%	20%	22%	30%	25%	20%	29%
Erro= +1	18%	21%	26%	16%	29%	30%	25%	29%
Erro= -1	22%	21%	14%	25%	11%	11%	7%	8%
Erro = +2	4%	14%	18%	8%	21%	23%	29%	24%
Erro = -2	21%	14%	10%	21%	2%	0%	0%	0%
Erro = +3	3%	5%	4%	2%	7%	10%	11%	9%
Erro = -3	9%	4%	2%	6%	0%	0%	0%	0%
Erro = +4	0%	0%	6%	0%	0%	1%	8%	1%
Erro = -4	0%	0%	0%	0%	0%	0%	0%	0%
Acertos: Erro= 0	22%	21%	20%	22%	30%	25%	20%	29%
Total erros positivos	25%	40%	54%	25%	57%	64%	73%	63%
Total erros negativos	52%	39%	25%	52%	13%	11%	7%	8%

8.3.3 Análise de desempenho da previsão quanto à Probabilidade – Previsão tipo D - Ensemble de modelos

As figuras 8.32 a 8.34 mostram a quantidade de meses da simulação com cada tipo de erro, conforme a probabilidade da previsão, para o *ensemble* das médias. Assim como nas demais análises, o erro é determinado como a classe de saturação prevista *menos* a classe pseudo-verdadeira. O total de meses simulados é igual a 103, equivalente ao período entre junho/2005 e dezembro/2013.

A probabilidade associada ao *ensemble* das médias (previsão código 8) foi definida pela contagem de modelos com classe prevista igual à classe média, determinada pelo arredondamento da média das classes previstas pela média dos modelos. Este valor varia entre 0%, quando nenhum dos modelos previu aquela classe, e 100%, quando os três modelos previram a mesma classe de saturação. A probabilidade 0% é atingida, por exemplo, no caso de outubro/2005 para horizonte 1 mês, quando dois modelos previram classe +2 e um, classe 0. A previsão do *ensemble* das médias é classe +1 ($((2+0+2) / 3 = 1,333 \gg \text{classe } +1)$); porém nenhum dos modelos havia previsto, para aquele mês, esta classe.

Pelas figuras a seguir, observa-se que a maior parte de previsões tem probabilidade de 67%, o que equivale a dizer que a classe da média de dois dos três modelos foi igual a classe prevista pelo *ensemble* das médias. Ou seja, duas previsões do tipo B foram iguais à previsão do tipo D, para aquele mês. Para os três horizontes de previsão, entre as probabilidades 0% e 67% há um aumento da quantidade de previsões conforme aumenta a probabilidade. Ou seja, as previsões dos diferentes modelos tendem a convergir, porém menos vezes são capazes de entrar em consenso (a quantidade de previsões com probabilidade 0,67 é maior que com probabilidade 1). Da mesma forma, entre as probabilidades 0 e 0,67, há também um incremento na quantidade de previsões com erro zero, ou seja, acertos da classe de saturação.

Uma quantidade menor de previsões é consensual entre os modelos (probabilidade 100%) quando comparada com a probabilidade de 67% (dois modelos previram a classe prevista pelo *ensemble* de médias). Contudo, para os horizontes de 1 e 3 meses de antecedência, nas ocorrências de previsão com probabilidade 1, a quantidade de erros zero é maior em relação aos demais tipos de erro. Ou seja, quanto maior a probabilidade

de ocorrência de determinada classe, maior a quantidade de acertos na previsão pelo *ensemble* das médias dos modelos.

Quanto a distribuição dos erros, conforme analisado nos itens anteriores, os erros são em sua maior parte positivos, revelando uma tendência a superestimar a classe de saturação por parte do *ensemble* de modelos. Além disso, observa-se que os erros máximos (± 4) foram atingidos apenas uma vez, no horizonte de 6 meses.

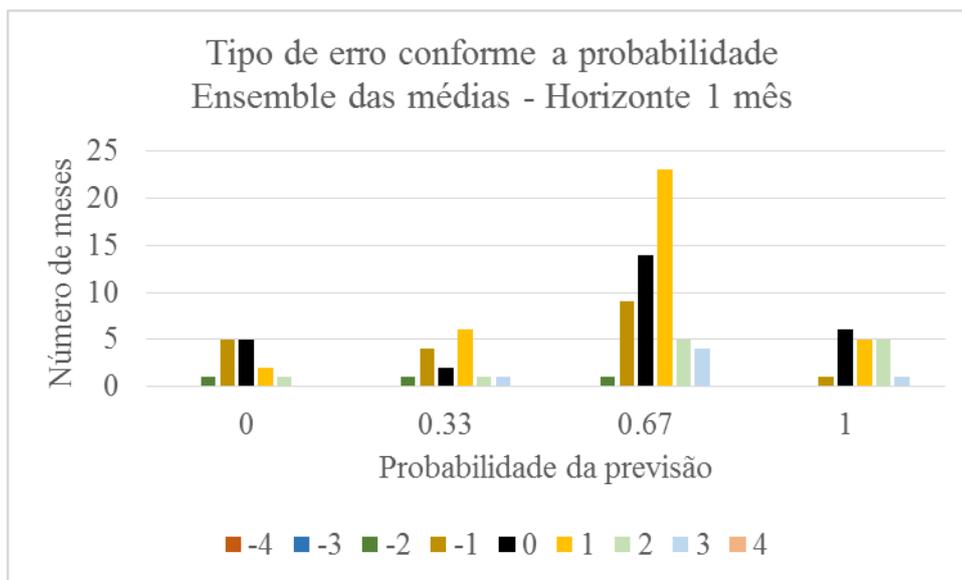


Figura 8.32. Tipo de erro conforme a probabilidade da previsão. Ensemble das médias. Horizonte de 1 mês.

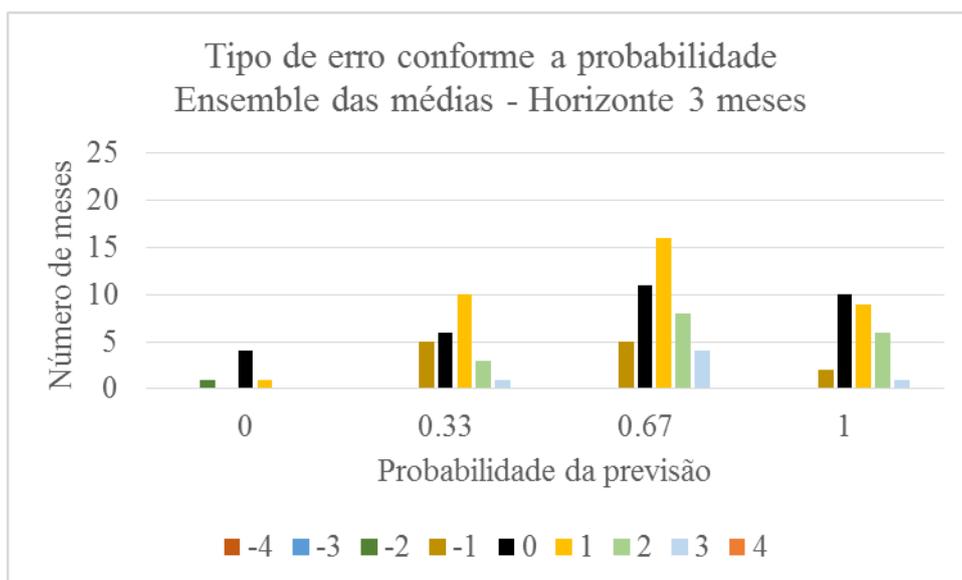


Figura 8.33. Tipo de erro conforme a probabilidade da previsão. Ensemble das médias. Horizonte de 3 meses.

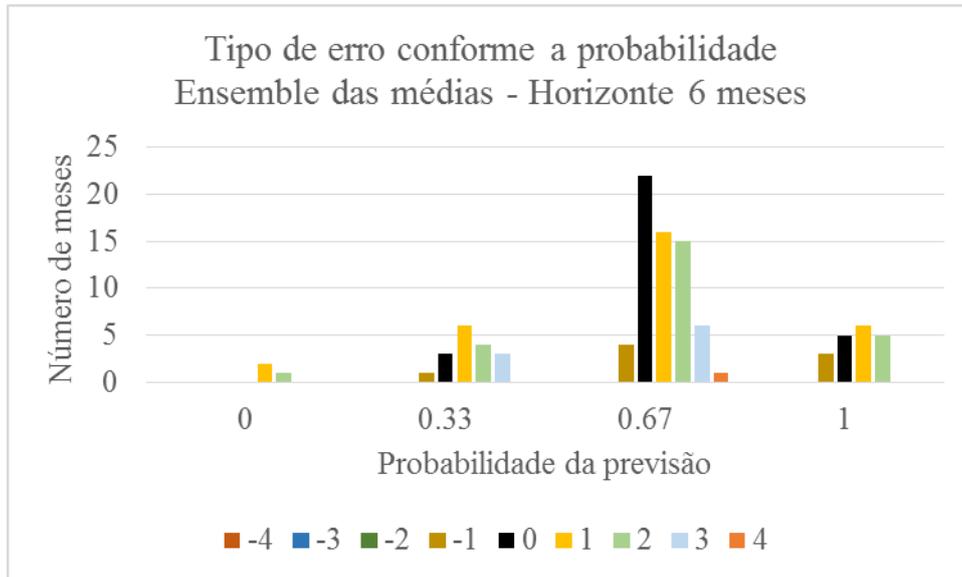


Figura 8.34. Tipo de erro conforme a probabilidade da previsão. Ensemble das médias. Horizonte de 6 meses.

8.3.4 Análise integrada do desempenho da previsão

A previsão com as médias (previsões tipo B) e o *ensemble* de médias (tipo D), para todos os horizontes, apresenta tendência maior à erros positivos, ou seja, previsão superestimada de saturação. Isto pode estar associado a dois motivos:

- 1) Alguns modelos, para alguns horizontes, após a correção de viés passaram a apresentar erro médio positivo, conforme pode ser analisado a partir da Tabela 7.4. Os maiores erros médios foram encontrados para o modelo ECPC, e este modelo é aquele que apresenta maior tendência a superestimar as classes de saturação, com erro total da umidade do solo positivo igual ou superior à 60%, para os três horizontes de previsão.
- 2) Durante o período de simulação, o fenômeno La Niña, associado a secas na região de interesse, foi observado em cinco períodos (2005/6, 2007/8, 2008/9, 2010/11, 2011/12), sendo três eventos considerados fracos, um moderado e um forte. No mesmo período, o fenômeno El Niño, ligado a precipitações intensas, foi observado duas vezes (2006/7 e 2009/10), uma ocorrência considerada fraca e uma moderada (NOAA, 2015; GGWEATHER, 2015). Esta predominância do fenômeno La Niña no período de simulação pode estar causando parte da superestimativa da saturação prevista pelas médias (tipo B) em relação à saturação pseudo-observada. Mesmo o modelo GFDL, cujo erro médio da precipitação corrigida mostra-se negativo para todos os horizontes de previsão (Tabela 7.4), apresenta uma tendência à erro positivo maior que à erro negativo.

A possibilidade de que o período de simulação tenha sido mais seco que o normal para a região é corroborada pela análise da Tabela 6.8, que mostra a qualidade do ajuste do modelo na etapa de verificação. Os valores de ΔV são, para quase todas as sub-bacias, bastante positivos, o que informa que as vazões simuladas foram maiores que as observadas no período entre 2005 e 2013.

A previsão com todos os membros do *ensemble* (tipo A), por outro lado, mostra-se mais propensa a erros negativos. As equações de correção de viés foram definidas para a média dos membros de cada modelo. O espalhamento dos membros, se não for homogêneo, faz com que a correção de viés resulte, por exemplo (e como observado

aqui), em muitos membros com precipitação baixa e apenas alguns com precipitação alta. Isso faz com que, apesar da média do *ensemble* apresentar resultados relativamente bons, a previsão de umidade do solo realizada com cada membro e posterior classificação resulte em muitos membros com classe baixa de saturação. Ao se fazer a contagem de membros em determinada classe e verificar qual a classe de saturação mais provável, há uma tendência a subestimar a classe de saturação. Esta tendência é intensificada quando a previsão é realizada com o *superensemble* (tipo C).

O índice de acertos da classe exata de saturação do solo é baixo. A alternativa existente, a utilização da precipitação média de longo período, teria resultados melhores que aqueles encontrados com a previsão de precipitação (41 dos 103 meses de simulação são classificados como tendo saturação normal. Desta forma, o índice de acertos seria de 40%). Contudo, esta alternativa não permite a identificação de anomalias, períodos secos ou úmidos. As tabelas 8.6 a 8.8 mostram o índice de acertos e o tipo de erro para os meses em que a saturação pseudo-observada foi diferente do “normal”. Para o *ensemble* de médias (previsão código 8), para o horizonte de 6 meses, por exemplo, 37% das vezes em que houve um período seco ou úmido, a metodologia aqui proposta foi capaz de identificar esta tendência.

Conforme observado através da análise de desempenho em classes de saturação, a maior parte dos erros das previsões são iguais à ± 1 . Consequentemente, o desempenho das previsões quanto às faixas de saturação, como mostrado na Figura 8.28, é bastante superior, atingindo índices de acerto satisfatórios.

De forma geral, não houve diferenças no desempenho das previsões conforme o horizonte de previsão, da mesma forma que o observado por Saldanha (2009). Isto indica que mesmo o horizonte mais curto de previsão, um mês, já é excessivamente distante para que o modelo climatológico possa indicar a classe exata de saturação do solo. Contudo, a tendência do comportamento da umidade do solo tende a ser respeitada, conforme pode ser observado nas figuras do item 8.1 e na análise por faixas.

Saldanha (2009) apresentou e analisou os resultados da previsão de umidade do solo em termos de lâmina d'água (variável W, no MGB-IPH), diferentemente do estudo aqui conduzido, onde trabalhou-se com saturação (calculada como W/W_m) classificada. Para a bacia do rio Ijuí, os resultados de Saldanha (2009) mostraram que a maior parte

dos erros está na faixa entre $\pm 20\text{mm}$. Um erro de 20mm , conforme o mês de ocorrência e a calibração adotada, pode significar uma variação de uma ou duas classes de saturação. Desta forma, a análise de desempenho em classes aqui realizada mostra-se bastante sensível mesmo à pequenos erros na previsão.

Pelos resultados obtidos no estudo aqui conduzido, entende-se que as previsões com melhor relação custo-benefício são as previsões com as médias (tipo B) e com o *ensemble* de modelos (tipo D). Estas previsões obtiveram resultados melhores ou semelhantes às demais (tipos A e C) e envolvem menos esforço para a sua realização, por empregarem uma menor quantidade de dados a ser manipulada e por envolverem um menor número de simulações do modelo hidrológico. Mais que isso, destaca-se que a abordagem multimodelos (tipo D) permite analisar a incerteza associada aos modelos climáticos, além da incerteza quanto às condições iniciais, característica básica da previsão por ensemble. As previsões tipo D permitem que seja analisada a concordância entre as previsões oriundas dos diferentes modelos, e são de mais fácil interpretação que uma previsão totalmente probabilística.

9. CONCLUSÕES E RECOMENDAÇÕES

9.1 Conclusões

A umidade do solo é uma variável de grande importância a agricultura, de tal forma que o conhecimento antecipado desta variável permite novas abordagens no planejamento agrícola. Neste sentido, a dissertação aqui conduzida buscou analisar a previsibilidade da umidade do solo em longo prazo através da simulação hidrológica, empregando como variável de entrada no modelo hidrológico de grandes bacias MGB-IPH previsões de precipitação originadas de modelos climáticos globais. Sabendo-se que a estimativa da precipitação com ampla antecedência é de grande dificuldade, o estudo aqui conduzido buscou considerar as incertezas na previsão ao realizar previsões por *ensemble*, em diferentes configurações.

A principal variável determinante do estado de umidade no solo é a precipitação. Desta forma, adotando-se o mesmo conjunto de parâmetros para o modelo MGB-IPH e a média de longo período das variáveis climáticas, empregaram-se diferentes previsões de precipitação para realizar previsões de longo prazo de umidade no solo. Para cada intervalo de tempo de previsão, foram realizadas oito previsões de umidade do solo, baseadas no *ensemble* de membros dos três modelos de previsão de precipitação selecionados. As oito previsões de umidade são:

- Três previsões obtidas com o *ensemble* de membros de cada um dos modelos (previsões do tipo A);
- Três previsões realizadas com a precipitação média dos membros do *ensemble* de cada modelo (previsões tipo B);
- Uma previsão baseada no superensemble, empregando todos os membros de todos os modelos em uma mesma previsão (previsão tipo C);
- Uma previsão considerando uma abordagem multimodelos (previsão tipo D), através do *ensemble* construído com a previsão média de cada modelo.

Foram realizadas previsões de umidade do solo com antecedência de um, três e seis meses. A área em estudo foi a bacia do rio Ijuí, sub-bacia do rio Uruguai, onde a

cultura de sequeiros desempenha um papel importante. A simulação hidrológica foi uma *hindcast* (previsão para um período passado), realizada para o período entre junho/2005 e dezembro/2013.

Os três modelos selecionados como fonte da previsão de precipitação, CCM3v6, ECPC e GFDL, preveem valores extremamente subestimados de precipitação total mensal. Desta forma, mostrou-se necessária a aplicação de uma correção de viés. Enquanto que para os modelos CCM3v6 e GFDL a correção de viés aplicada trouxe resultados claramente melhores para as previsões de precipitação, para o modelo ECPC a correção gerou valores exagerados de precipitação em grande parte do tempo (uma compreensão mais profunda das razões envolvidas neste processo está além do escopo deste estudo). Contudo, ainda que a média do modelo ECPC apresente uma leve tendência a superestimar a precipitação, a correção de viés aplicada corrigiu o modelo em termos de volume total, fazendo com que os totais anuais, antes bastante subestimados, fossem agora próximos aos valores observados na bacia.

Ainda que a média do *ensemble* de cada modelo tenha sido corrigida quanto ao viés, o espalhamento não uniforme entre os membros permite que alguns membros tenham precipitações muito altas, e outros, em maior quantidade, precipitações baixas. Isso faz com que, ao se realizar a previsão de umidade no solo independente para cada membro, haja muitos membros com previsão subestimada, e alguns superestimada. Fazendo-se a contagem da quantidade de membros em cada classe de saturação do solo, há um número alto de membros com umidade baixa. Esta tendência a subestimar a classe de saturação prevista foi observada nas previsões tipo A. Este efeito foi intensificado com a previsão a partir do *superensemble* (previsão tipo C), que apresentou alta tendência à previsão de níveis baixos de saturação. O uso da precipitação média dos membros de cada modelo, contudo, contorna este problema.

Considerando a metodologia usada neste trabalho, onde o viés foi removido apenas a partir da média, para a maioria dos modelos e horizontes, a realização da previsão de umidade do solo com a precipitação média do *ensemble* de cada modelo (previsões do tipo B) apresentou melhores resultados que a previsão com o conjunto de precipitações (tipo A), ou com o *superensemble* (tipo C). Este efeito pode ser percebido com a análise por faixas de saturação, mas é intensificado ao analisar-se o resultado por classes de umidade do solo. Isto indica que, não havendo a análise do espalhamento dos

membros, não há ganho na utilização de todo o *ensemble* na previsão em relação ao uso da precipitação média dos membros.

A análise do *ensemble* das médias (abordagem multimodelos, previsão tipo D), todavia, apresentou bons resultados, em geral superiores a qualquer uma das previsões empregando os membros dos conjuntos, seja com o conjunto dos membros de um modelo (tipo A) ou *superensemble* (tipo C). A previsão de umidade no solo baseada no *ensemble* de médias (previsões tipo D) envolve menos esforço quando comparada à previsão com o conjunto de membros (tipo A), e pode ser uma alternativa interessante na realização de previsões. O *ensemble* de médias, ao empregar diferentes modelos, leva em consideração diferentes características físicas, processos, resoluções espaciais horizontais e verticais, entre outros. Para a média do *ensemble* de membros de um mesmo modelo (previsões tipo B), isto pode não ser verdade, caso os membros sejam gerados apenas a partir de perturbações nos parâmetros ou nas condições iniciais.

O *ensemble* das médias (tipo D), por atenuar a previsão de valores extremos, não sendo capaz de identificá-los com tanta destreza, possui um desempenho pior que a previsão com a média (tipo B) do melhor modelo. Mais que isso, na identificação de períodos úmidos ou secos, o *ensemble* de modelos não apresentou um resultado superior às demais previsões. Entre eventos secos e úmidos, o desempenho é pior para períodos secos, o que está associado à questão de previsibilidade apropriada do fenômeno ENOS, conforme discutido logo a seguir.

Contudo, quanto à identificação das faixas de tendência (admitindo-se como aceitável uma previsão de classe imediatamente acima ou abaixo da classe de umidade pseudo-verdadeira), o *ensemble* de modelos (tipo D) obteve um desempenho superior a qualquer previsão. Sob este ponto de vista, a média de cada modelo (tipo B) obteve um desempenho superior ao *ensemble* (tipo A) do respectivo modelo, e o *ensemble* das médias (tipo D) apresentou um desempenho ainda melhor. A média do conjunto dos membros suaviza a previsão, ao minimizar o efeito de detalhes de difícil identificação. Nesse sentido, a média das médias intensifica este processo. Contudo, justamente por isso, o *ensemble* das médias (tipo D) possui melhor desempenho ao avaliar as faixas de umidade do solo, e não necessariamente a classe exata, uma vez que a média tem diminuída a capacidade de identificação de eventos extremos.

Na região sul do Brasil, a ocorrência do fenômeno La Niña está associada a ocorrência de secas intensas, enquanto o El Niño está ligado a precipitações abundantes (CPTEC, 2015). À predominância do fenômeno La Niña durante o intervalo de tempo de interesse pode estar associada a superestimativa da umidade do solo pelas médias do *ensemble* (previsões tipo B) dos modelos. Neste sentido, percebe-se que os modelos analisados não tiveram a sensibilidade necessária para apropriadamente identificar o efeito da ocorrência do fenômeno ENOS.

Analisando-se o conjunto dos resultados, infere-se que a quantidade maior de trabalho envolvida na realização das previsões dos tipos A e C (*ensemble* de cada modelo e *superensemble*) não se justifica para o objetivo deste estudo. As previsões realizadas com a média da precipitação prevista pelos membros de cada modelo (tipo B) envolve um menor esforço e trouxe resultados, para o caso aqui avaliado, na ampla maioria das vezes melhores. Adicionalmente, a abordagem multimodelos (previsão tipo D) permite uma análise ponderada dos resultados, levando-se em consideração a concordância entre os modelos, e não requer uma quantidade significativa de esforço a mais, uma vez realizadas as previsões do tipo B.

Entre os modelos climáticos provedores das previsões de precipitação aqui analisados, o modelo CCM3v6 foi aquele que apresentou desempenho um pouco melhor. Após a correção de viés, os índices de erro e coeficientes de correlação analisados para precipitação mostraram-se, ainda que de forma bastante tênue, favoráveis ao modelo CCM3v6 em relação aos demais. Após a realização das previsões de umidade do solo e posterior análise dos seus resultados, este desempenho um pouco melhor do modelo CCM3v6 pode ser mais claramente verificado. Contudo, a opção por apenas um modelo eliminaria a possibilidade da realização da previsão tipo D.

A ausência de sazonalidade nas precipitações da região em estudo dificulta o bom desempenho das previsões. Esta sazonalidade seria mais facilmente identificável pela previsão, trazendo melhores resultados. Ainda, o baixo desempenho dos modelos de previsão quanto à precipitação pode estar sendo influenciado por erros de fase no hietograma (por exemplo, uma previsão de xx mm prevista com um mês de antecedência ou atraso em relação à precipitação observada). Este erro de fase na previsão de precipitação pode prejudicar o desempenho da previsão de umidade no solo. Ainda que o solo atue como um reservatório, o erro na previsão é superior à capacidade de

amortecimento do solo. Contudo, a este erro está associada a resolução temporal da previsão (mensal) e ao processo de transformação em valores diários dos totais mensais previstos, que não necessariamente reflete a distribuição temporal observada. Mais que isso, a grade de pontos onde é disponibilizada a previsão de precipitação é bastante grosseira. Uma previsão de precipitação com melhor resolução espacial e temporal potencialmente traria um melhor desempenho das previsões de umidade no solo.

A análise dos resultados quanto às cinco classes de saturação mostra que parte significativa dos erros são de uma classe, ou seja, iguais a ± 1 . Consequentemente, o emprego das faixas de tendência, que permite que este tipo de erro seja aceito, apresentou bom desempenho. Ainda que a previsão de precipitação e, conseqüentemente, de umidade do solo ainda precise apresentar grande evolução, a alternativa disponível (uso da precipitação média mensal) não permite a identificação de anomalias. Ou seja, a utilização das previsões de precipitação, mesmo que com baixo índice de acertos da classe exata de umidade do solo, permite a identificação de períodos em que a umidade do solo esteja mais alta ou mais baixa que o normal para o mês, o que é impossível com o uso das precipitações médias mensais de longo período.

O estudo aqui conduzido, ao empregar previsões de precipitação por *ensemble*, considerou o efeito das incertezas da previsão de precipitação sobre a previsão de umidade do solo. Contudo, existem outras fontes de incerteza que podem afetar os resultados e conduzir à diferenças entre os resultados de umidade do solo aqui apresentados como “pseudo-observados” e a umidade do solo que de fato ocorre na bacia.

Os dados observados de vazão, precipitação e clima, utilizados para calibração do modelo e correção de viés da precipitação prevista, podem apresentar erros na série histórica, ou mesmo não possuir densidade de pontos de observação suficiente para representar a bacia. De forma semelhante, os dados de tipo e uso do solo podem não possuir resolução espacial suficiente para mostrar apropriadamente detalhes da bacia. Deve ser notada também a incerteza associada à consideração de que as condições de uso e cobertura do solo mantiveram-se constantes na bacia em relação ao período de calibração, o que pode levar a erros importantes conforme a bacia em estudo.

O modelo hidrológico, ao ser calibrado, busca representar apropriadamente todo o processo hidrológico na bacia. Contudo, um modelo é uma simplificação da realidade,

e não necessariamente reflete corretamente o que acontece na bacia. Desta forma, os resultados aqui encontrados estão atrelados ao modelo hidrológico utilizado, o MGB-IPH.

9.2 Recomendações

Estudos futuros envolvendo a simulação e previsão de umidade no solo podem voltar-se para:

- Analisar os efeitos da utilização de variáveis climáticas previstas, ao invés das médias de longo período, como aqui realizado;
- Avaliar diferentes métodos para correção de viés. Os modelos globais possuem viés, que no estudo aqui realizado foi corrigido através da análise do erro para a média dos membros, para a média da bacia. Outras formas de correção de viés podem ser analisadas, de forma a aproximar mais os dados previstos da precipitação observada, gerando melhores resultados;
- Analisar os resultados gerados a partir de perturbações nos parâmetros calibráveis do modelo com influência sobre a umidade do solo, tendo em vista levar em conta as incertezas associadas à sua calibração;
- Analisar os resultados em escala sazonal, ou seja, a média de precipitação e umidade do solo para três meses.

10.REFERÊNCIAS

ABBOTT, M.B.; BATHURST, J.C.; CUNGE, J.A.; O'CONNEL, P.E.; RASMUSSEN, J. An introduction to the European Hydrological Systems–Systeme Hydrologique Europeen, “SHE”. 2. Structure of a physically based distributed modelling system. J. Hydrol. 87, 61–77. 1986 (a),

ABBOTT, M.B.; BATHURST, J.C.; CUNGE, J.A.; O'CONNEL, P.E. RASMUSSEN, J. An introduction to the European Hydrological Systems–Systeme Hydrologique Europeen, “SHE”. 1. History and philosophy of a physically based distributed modelling system. J. Hydrol. 87, 45–59. 1986 (b).

AGEFLOR – Associação Gaúcha de Empresas Florestais. A Indústria de Base Florestal no RS. Dados e Fatos. Ano Base 2014. 2015. Disponível em: <http://www.ageflor.com.br/noticias/biblioteca/anuario-ageflor-2015-ano-base-2014.pdf>.

ALBERGEL, C.; RÜDIGER, C.; PELLARIN, T.; CALVET, J.-C.; FRITZ, N.; FROISSARD, F.; SUQUIA, D.; PETITPA, A.; PIGUET, B.; MARTIN, E. From near-surface to root-zone soil moisture using an exponential filter: an assessment of the method based on in situ observations and model simulations, Hydrol. Earth Syst. Sci., 12, 1323–1337, 2008.

ALLEN R. G.; PEREIRA, L.; RAES, D.; SMITH, M. Crop evapotranspiration: guidelines for computing crop water requirements. Rome: FAO, 1998. (Irrigation and Drainage Paper, 56).

AHMED, K. F.; WANG, G.; SILANDER, J.; WILSON, A. M.; ALLEN, J. M.; HORTON, R.; ANYAH R. Statistical downscaling and bias correction of climate model outputs for climate change impact assessment in the U.S. northeast. Global and Planetary Change 100 (2013) 320–332.

ALVES, J. M. B.; CAMPOS, J. N. B.; FILHO, F. A. S.; MONCUNNIL, D. F.; SILVA, E. M.; BARBOSA, W. L.; FERREIRA, A. G. SUN, L.; MOURA, A. D. Uma avaliação preliminar de simulações climáticas de um modelo regional espectral aninhado em um modelo global (ECHAM4.5) sobre o setor norte da região nordeste do Brasil (1971-2000). Revista Brasileira de Meteorologia, v.20, n.2, 191-206, 2005.

ANA - Agência Nacional de Águas (Brasil). Conjuntura dos Recursos Hídricos no Brasil. 2013. Brasília, 2013. 432 p.

ANA - Agência Nacional de Águas (Brasil). Região Hidrográfica do Uruguai. Disponível em: <http://www2.ana.gov.br/Paginas/portais/bacias/uruguai.aspx>.

ANDRADE, A. R. S., JADOSKI, S. O., GUERRA, H. C., GUERRINI, I. A. Influência do Tempo de Contagem na Determinação da Densidade de Nêutrons. Rev. bras. eng. agríc. ambient. [online]. 2001, vol.5, n.3, pp. 411-415.

ARDÖ, J. A 10-Year Dataset of Basic Meteorology and Soil Properties in Central Sudan, Dataset Papers in Geosciences, vol. 2013, Article ID 297973, 6 pages, 2013.

BARNSTON, A. G.; LI, S.; MASON, S. J.; DEWITT, D. G.; GODDARD, L; GONG, X. Verification of the First 11 Years of IRI's Seasonal Climate Forecasts. Journal of Applied Meteorology and Climatology. Vol 49. 493-520. Março 2010.

BELL, J. E.; PALECKI, M. A.; BAKER, C. B.; COLLINS, W. G.; LAWRYMORE, J. H.; LEEPER, R. D.; HALL, M. E.; KOCHENDORFER, J.; MEYERS, T. P.; WILSON, T.; DIAMOND, H. J. U.S. Climate Reference Network soil moisture and temperature observations. J. Hydrometeorol., 14, 977-988. doi: 10.1175/JHM-D-12-0146.1. 2013.

BEVEN, K. J.; KIRKBY, M. J., A physically based, variable contributing area model of basin hydrology. Hydrological Sciences Bulletin, n. 24, p. 43-69, 1979.

BEVEN, K. J; LAMB, R.; QUINN, P.; ROMANOWICIZ, R.; FREER, J. TOPMODEL. In: SINGH, V. P. (Ed.), Computer models of watershed hydrology. Water Resource Publication, p. 627- 668. 1995.

BEYRICH, F.; ADAM, W.K. Site and Data Report for the Lindenberg Reference Site in CEOP - Phase 1, Berichte des Deutschen Wetterdienstes, 230, Offenbach am Main, 2007; <http://www.eol.ucar.edu/projects/ceop/dm/insitu/sites/>

BIRCHER, S.; SKOU, N.; JENSEN, K.H.; WALKER, J.P.; RASMUSSEN, L. A soil moisture and temperature network for SMOS validation in Western Denmark. Hydrology and Earth System Sciences Discussions, 8, 9961-10006, doi:10.5194/hessd-8-9961. 2011.

BRASIL. Ministério do Meio Ambiente. i3geo. Download de dados geográficos. Disponível em: <http://mapas.mma.gov.br/i3geo/datadownload.htm>

BREMINCKER, M. 1998. Aufbau eines Wasserhaushaltsmodells für das Weser und das Ostsee Einzugsgebiet als Baustein eines Atmosphären-Hydrologie-Modells. Dissertion Doktorgrad, Geowissenschaftlicher Fakultät der Albert-Ludwigs-Universität. Freiburg. Juli.

BROCCA, L.; HASENAUER, S.; LACAVA, T.; MELONE, F.; MORAMARCO, T.; WAGNER, W.; DORIGO, W.; MATGEN, P.; MARTÍNEZ-FERNÁNDEZ, J.; LLORENS, P.; LATRON, J.; MARTIN, C.; BITTELLI, M. Soil moisture estimation through ASCAT and AMSR-E sensors: an intercomparison and validation study across Europe. *Remote Sensing of Environment*, 115, 3390-3408, doi: 10.1016/j.rse.2011.08.003. 2011.

BROCCA, L.; MELONE, F.; MORAMARCO, T.; MORBIDELLI, R. Antecedent wetness conditions based on ERS scatterometer data. *Journal of Hydrology*, 364 (1-2), 73-87. 2009.

BROCCA, L.; MELONE, F.; MORAMARCO, T. On the estimation of antecedent wetness condition in rainfall-runoff modelling. *Hydrological Processes*, 22 (5), 629-642. 2008.

BUIZZA, R. ECMWF - European Centre for Medium-Range Weather Forecasts. Ensemble Forecasts. 2005. Disponível em: http://old.ecmwf.int/staff/roberto_buizza/Work/Selected_articles/Ensemble_Prediction/index.html. Acesso em: 01/09/2014.

BURIOL, G. A.; ESTEFANEL, V.; SWROWSKY, A.; TODESCHINI, R. Espacialização da evapotranspiração potencial mensal e anual na bacia hidrográfica do rio Vacacaí – RS, Brasil. *Revista Brasileira de Climatologia*. Ano 10 – Vol. 14 – Jan/Jul 2014.

CALVET, J.-C.; FRITZ, N.; FROISSARD, F.; SUQUIA, D.; PETITPA, A.; PIGUET, B. In situ soil moisture observations for the CAL/VAL of SMOS: the SMOSMANIA network, *International Geoscience and Remote Sensing Symposium, IGARSS*, Barcelona, Spain, 23-28 July 2007, 1196-1199, doi:10.1109/IGARSS.2007.4423019, 2007.

CANAMARY, E. ; REIS, D. S. Jr ; MARTINS, Eduardo Sávio Passos Rodrigues . Evaluation of Ensemble SPI Forecasts for Ceará, Northeastern Brazil. In: Drought: Research and Science-Policy Interfacing, 2015, Valencia/Espanha. Proceedings of the International Conference on Drought: Research and Science-Policy Interfacing. Londres: CRC Press, 2015. p. 245-250.

CAPPELAERE, C.; DESCROIX, L.; LEBEL, T.; BOULAIN, N.; RAMIER, D.; LAURENT, J.-P.; LE BRETON, E.; BOUBKRAOUI, S.; BOUZOU MOUSSA, I. et al.,. The AMMA Catch observing system in the cultivated Sahel of South West Niger- Strategy, Implementation and Site conditions, 2009. Journal of Hydrology, 375(1-2): 34-51. 2009.

CASHION, J.; LAKSHMI, V.; BOSCH, D.; JACKSON, T. J. Microwave remote sensing of soil moisture: evaluation of the TRMM microwave imager (TMI) satellite for the Little River Watershed Tifton, Georgia. Journal of Hydrology, 307, 242-253. 2005.

CEOS - COMMITTEE ON EARTH OBSERVATION SATELLITES. ESA - EUROPEAN SPACE AGENCY. The Earth Observation Handbook. 2014. Disponível em: <http://www.eohandbook.com/index.html>.

CGIAR - CONSORTIUM FOR SPATIAL INFORMATION (CGIAR-CSI). SRTM 90m Digital Elevation Data. 2008. Disponível em: <http://srtm.csi.cgiar.org/>.

CHEN, Y. H. Mathematical modeling of water and sediment routing in natural channels. PhD dissertation, Colorado State University, USA. 1973.

COLA - Center for Ocean-Land-Atmosphere Studies. Science Review. January 2010 – April 2011. Disponível em:ftp://gradsusr.org/pub/kinter/COLA_SAC/2011/COLA_Science_Review_2011_final.pdf

COLLISCHONN, B., de PAIVA, R. C. D., COLLISCHONN, W.; MEIRELLES, F. S. C.; SCHETTINI, E. B. C.; FAN, F. M. Modelagem Hidrológica de Uma Bacia com Uso Intensivo de Água: Caso do Rio Quaraí-RS. RBRH – Revista Brasileira de Recursos Hídricos Volume 16 n.4 - Out/Dez 2011. 119-133.

COLLISCHONN, W. Simulação Hidrológica de Grandes Bacias. Tese (Doutorado). Instituto de Pesquisas Hidráulicas. Universidade Federal do Rio Grande do Sul. Porto Alegre. 2001.

COLLISCHONN, W.; ALLASIA, D. G.; SILVA, B. C.; TUCCI, C. E. M. The MGB-IPH model for large-scale rainfall-runoff modelling. *Hydrological Sciences Journal*, v. 52, p. 878-895, 2007.

COLLISCHONN, W.; BUARQUE, D. C.; PAIVA, R. C. D.; FAN, F. M.; KAYSER, R. Manual Introdutório para Aplicação do Modelo MGB-IPH. Versão 2.0. 2010. Disponível em: <http://www.ufrgs.br/hge/mgb-iph/downloads/>.

COLLISCHONN, W.; TUCCI, C. E. M. 2001. Simulação hidrológica de grandes bacias. *Revista Brasileira de Recursos Hídricos*. Vol. 6 No. 1.

CONCEIÇÃO, M. A. F. Balanço Hídrico em Fruteiras. Bento Gonçalves: Embrapa Uva e Vinho, 2010. 12 p. (Embrapa Uva e Vinho. Circular Técnica, 82). Disponível em: <http://www.cnpuv.embrapa.br/publica/circular/cir082.pdf>. Acesso em 30/07/2014.

CPC - Climate Prediction Center. NOAA - National Oceanic and Atmospheric Administration. 2014. Disponível em: <http://www.cpc.ncep.noaa.gov/>.

CPTEC - Centro de Previsão de Tempo e Estudos Climáticos. INPE - Instituto Nacional de Pesquisas Espaciais. El Niño e La Niña. Disponível em: <http://enos.cptec.inpe.br/>. Acesso em: Junho/2015.

CUNGE, J. A.; HOLLY, F. M.; VERNEY, A. Practical Aspects of Computational River Hydraulics. Pitman Advanced Publishing Program. 1980.

D'ANGIOLELLA, G. L. B.; NETO, M. T. C.; COELHO, E.F. Balanço hídrico em solos de Tabuleiros Costeiros do Recôncavo baiano. *Bahia Agrícola*, v3, n3, setembro 1999.

De HAAN, L. L.; KANAMITSU, M.; LU, C.-H.; ROADS, J. O. A Comparison of the Noah and OSU Land Surface Models in the ECPC Seasonal Forecast Model. *Journal of Hydrometeorology*. Vol 8. 1031-1048. Outubro 2007.

De JEU, R. A. M.; HOLMES, T. R. H.; PARINUSSA, R. M.; OWEC, M. A spatially coherent global soil moisture product with improved temporal resolution. *Journal of Hydrology* 516. 284–296. 2014.

De ROSNAY, P.; GRUHIER, C.; TIMOUK, F.; BAUP, F.; MOUGIN, E.; HIERNAUX, P.; KERGOAT, L.; LEDANTEC, V. Multi-scale soil moisture measurements at the Gourma meso-scale site in Mali, *Journal of Hydrology*, 375, 241-252, 2009.

DELWORTH, T. L. et al., GFDL's CM2 Global Coupled Climate Models. Part I: Formulation and Simulation Characteristics. *J. Climate*, 19, 643-674. 2006.

DEMARGNE, J.; BROWN, J. HEPEX Science and Challenges: Verification of Ensemble Forecasts (2/4). 2013. HEPEX. Disponível em: <http://hepex.irstea.fr/hepex-science-and-challenges-verification-of-ensemble-forecasts-24/>.

DEMARNE, J.; WU, L.; REGONDA, S. K.; BROWN, J. D.; LEE, H.; HE, M.; SEO, D.-J.; HARTMAN, R.; HERR, H. D.; FRESCH, M.; SCHAAKE, J.; ZHU, Y. The Science of NOAA's Operational Hydrologic Ensemble Forecast Service. American Meteorological Society. 2014.

DUNNE, T.; BLACK, R. D. Partial Area Contributions to Storage, Runoff in a Small New England Watershed. *Water Resources Research*. Vol 6, No 5. October 1970.

DEWITT, D. G.; SCHNEIDER, E. K. The Processes Determining the Annual Cycle of Equatorial Sea Surface Temperature: A Coupled General Circulation Model Perspective. American Meteorological Society. Vol 127. 381-395. Março 1999.

DORIGO, W. A.; WAGNER, W.; HOHENSINN, R.; HAHN, S.; PAULIK, C.; XAVER, A.; GRUBER, A.; DRUSCH, M.; MECKLENBURG, S.; VAN OEELEEN, P.; ROBOCK, A.; JACKSON, T. The International Soil Moisture Network: a data hosting facility for global in situ soil moisture measurements. *Hydrology and Earth System Sciences*. 15, 1675–1698, 2011. doi:10.5194/hess-15-1675-2011

EMATER/RS – ASCAR: Empresa de Assistência Técnica e Extensão Rural do Rio Grande do Sul – Associação Sulina de Crédito e Assistência Rural. Irrigação. 2009. Disponível em: http://www.emater.tche.br/site/area-tecnica/apoio-a-gestao-e-producao/irrigacao.php#.U_Ja8v15Meg.

ESA – EUROPEAN SPACE AGENCY. Soil Moisture Essential Climate Variable. 2010. Disponível em: <http://www.esa-soilmoisture-cci.org/>

ESA – EUROPEAN SPACE AGENCY. GLOBCOVER 2009 – Products Description and Validation Report. European Space Agency (ESA), Université Catholique de Louvain. 30 p, 2010.

ESA – EUROPEAN SPACE AGENCY. SMOS. 2014. Disponível em: <https://earth.esa.int/web/guest/missions/esa-operational-eo-missions/smos>.

FAN, F. M.; COLLISCHONN, W. Integração do Modelo MGB-IPH com Sistema de Informação Geográfica. RBRH – Revista Brasileira de Recursos Hídricos Volume 19 n.1 –Jan/Mar 2014, 243-254.

FENNESSY, M. J.; KINTER III, J. L. Climatic Feedbacks during the 2003 European Heatwave. Center for Ocean-Land-Atmosphere Studies. Institute of Global Environment and Society. COLA Technical Report 282. Calverton, Julho 2009.

FIETZ, C. R.; URCHEI, M. A.; FRIZZONE, J. A.. Probabilidade de ocorrência de déficit hídrico na região de Dourados, MS. Revista brasileira de engenharia agrícola e ambiental, Campina Grande , v. 5, n. 3, p. 558-562, Dezembro 2001. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1415-43662001000300031&lng=en&nrm=iso>.

FREAD, D. L. Flow Routing. In: Maidment, D. R. Handbook of Hydrology. McGraw-Hill New York. 1993.

GADM. Global Administrative Areas. Versão 2.0. Janeiro 2012. Disponível em: <http://www.gadm.org/>.

GAO, H., TANG, Q.; SHI, X.; ZHU, C.; BOHN, T. J.; SU, F.; SHEFFIELD, J.; PAN, M.; LETTENMAIER, D. P.; WOOD, E. F. Water Budget Record from Variable Infiltration Capacity (VIC) Model. In Algorithm Theoretical Basis Document for Terrestrial Water Cycle Data Records (in review). 2010.

GAVANDE, S. A. Física de Suelos: Principios y Aplicaciones. 1ª edição. México: Editorial Limusa-Wiley, S. A, 1972. 351 p.

GEORGAKAKOS, K.P.; KRZYSZTOFOWICZ, R. Probabilistic and ensemble forecasting. Journal of Hydrology., v 249, p 1. 2001.

GEVAERD, R.; FREITAS, S. Estimativa operacional da umidade do solo para iniciação de modelos de previsão numérica da atmosfera. Parte I: Descrição da metodologia e validação. *Revista Brasileira de Meteorologia*, v.21, n 3a, 59-73. 2006.

GFDL Global Atmospheric Model Development Team. The new GFDL global atmosphere and land model AM2/LM2: Evaluation with prescribed SST simulations. *J. Climate*, 17, 4641-4673. 2004.

GFDL - Geophysical Fluid Dynamics Laboratory. Princeton University. Global Atmospheric Models. 2014. Disponível em: <http://www.gfdl.noaa.gov/atmospheric-model>.

GOLDEN GATE WEATHER SERVICES. El Niño and La Niña Years and Intensities. 2015. Disponível em: <http://ggweather.com/enso/oni.htm>. Acesso em: Junho/2015.

GRUPO DE PESQUISA DE HIDROLOGIA DE GRANDE ESCALA. INSTITUTO DE PESQUISAS HIDRÁULICAS. Hidrologia de Grande Escala. Disponível em: <http://www.ufrgs.br/hge/>.

GUO, Z.; DIRMEYER, P. A.; GAO, X.; ZHAO, M. Improving the quality of simulated soil moisture with a multi-model ensemble approach. Center for Ocean-Land-Atmosphere Studies. 2005.

HACK, J. J., KIEHL, J. T.; HURRELL, J. W. The hydrologic and thermodynamic characteristics of the NCAR CCM3. *J. Climate*, 11, 1179–1206. 1998.

HILLEL, D. Solo e Água: Fenômenos e Princípios Físicos. Porto Alegre: Departamento de Solos – UFRGS, 1970. 231 p.

HOLLINGER, S. E., ISARD, S. A. A soil moisture climatology of Illinois. *J. Climate*, 7, 822-833. 1994.

HURRELL, J. W., HACK, J. J.; BOVILLE, B. A.; WILLIAMSON, D. L.; KIEHL, J. T. The dynamical simulation of the NCAR Community Climate Model version 3 (CCM3). *J. Climate*, 11, 1207–1236. 1998.

HUZA, J.; TEULING, A. J.; BRAUD, I.; GRAZIOLI, J.; MELSEN, L. A.; NORD, G.; RAUPACH, T. H.; UIJLENHOET, R. Precipitation, soil moisture and runoff variability

in a small river catchment (Ardèche, France) during HyMeX Special Observation Period. *Journal of Hydrology* 516. 330–342. 2014.

IBGE- Instituto Brasileiro de Geografia e Estatística. Mapas. Bases Cartográficas. Limites Municipais. 2010. Disponível em: <http://mapas.ibge.gov.br/bases-e-referenciais/bases-cartograficas/malhas-digitais>

IGES- Institute of Global Environment and Society. Center for Ocean-Land-Atmosphere Studies. Disponível em: <http://www.iges.org/aboutcola.html>.

INMET - Instituto Nacional de Meteorologia. BDMEP - Banco de Dados Meteorológicos para Ensino e Pesquisa. Disponível em: <http://www.inmet.gov.br/portal/index.php?r=bdmep/bdmep>.

IPCC - Intergovernmental Panel on Climate Change. What is a GCM?. 2013. Disponível em: http://www.ipcc-data.org/guidelines/pages/gcm_guide.html.

IRI - International Research Institute for Climate and Society. Earth Institute. Columbia University. The Science and Practice of Seasonal Climate Forecasting at the IRI. s.d. Disponível em: <http://iri.columbia.edu/climate/forecast/tutorial2/>.

IRI - International Research Institute for Climate and Society. Earth Institute. Columbia University. Forecast System. Disponível em: http://www.inmet.gov.br/documentos/cursoI_INMET_IRI/Climate_Information_Course/2007/IRI_forcst_system.ppt.

IRI - Internacional Research Institute for Climate and Society. Earth Institute. Columbia University. IRI Forecast Division. 2013. Disponível em: <http://iridl.ldeo.columbia.edu/SOURCES/.IRI/.FD/>.

ISMN - International Soil Moisture Network. Welcome to the International Soil Moisture Network. 2015. Disponível em: <https://ismn.geo.tuwien.ac.at/ismn/>

JACKSON, T.J.; COSH, M.H.; BINDLISH, R.; STARKS, P.J.; BOSCH, D.D.; SEYFRIED, M.S.; GOODRICH, D.C.; MORAN, M.S. Validation of Advanced Microwave Scanning Radiometer Soil Moisture Products. *IEEE Transactions on Geoscience and Remote Sensing*. 48: 4256-4272, 2010.

JARVIS, A.; REUTER, H.I.; NELSON, A.; Guevara, E. 2008. Hole-filled SRTM for the globe Version 4, available from the CGIAR-CSI SRTM 90m Database. Disponible em: <http://srtm.csi.cgiar.org>.

KIEHL, J. T., HACK, J. J.; BONAN, G. B.; BOVILLE, B. A.; WILLIAMSON, D. L.; RASCH, P. The National Center for Atmospheric Research Community Climate Model. *J. Climate*, 11, 1131–1149. 1998.

KIRTMAN, B.; PIRANI, A. The State of the Art of Seasonal Prediction. Outcomes and Recommendations from the First World Climate Research Program Workshop on Seasonal Prediction. In *Box Insights and Innovations*. American Meteorological Society. 455-458. April 2009. DOI:10.1175/2008BAMS2707.

KOUWEN, N. et al. 1993. Grouping Response Units for Distributed Hydrologic Modelling. *Journal of Water Resources Management and Planning, ASCE*, 119 (3), 289-305. 1993.

KRYSANOVA, V.; HATTERMANN, F.; WECHSUNG, F. Development of the Ecohydrological Model SWIM for Regional Impact Studies and Vulnerability Assessment. *Hydrological Processes*, 19, 763–783. 2005.

KWON, H.; DE SOUZA FILHO, F. A.; BLOCK, P. ; SUN, L. ; LALL, U. ; REIS, D. S.. Uncertainty assessment of hydrologic and climate forecast models in Northeastern Brazil. *Hydrological Processes (Print)*, v. 26, p. 3875-3885, 2012.

LAIO, F.; PORPORATO, A.; RIDOLF, L.; RODRIGUEZ-ITURBE, I. Plants in water-controlled ecosystems: active role in hydrologic process and response to water stress: II. Probabilistic soil moisture dynamics. *Advances in Water Resources*, 24, 707-723. 2001.

LARSON, K. M.; SMALL, E. E.; GUTMANN, E. D.; BILICH, A. L.; BRAUN, J. J.; ZAVOROTNY, V. U. Use of GPS receivers as a soil moisture network for water cycle studies. *Geophysical Research Letters*, Vol. 35, L24405, doi:10.1029/2008GL036013, 2008.

LEAVESLEY, G.; DAVID, O.; GAREN, D.; GOODBODY, A.; LEA, J.; MARRON, J.; PERKINS, T.; STROBEL, M.; TAMA, R. A Modelling Framework for Improved Agricultural Water-Supply Forecasting. 2010.

LEBEL, T.; CAPPELAERE, B.; GALLE, S.; HANAN, N.; KERGOAT, L.; LEVIS, S.; VIEUX, B.; DESCROIX, L.; GOSSET, M.; MOUGIN, E.; PEUGEOT, C.; SEGUIS, L. AMMA-CATCH studies in the Sahelian region of West-Africa: An overview. *JOURNAL OF HYDROLOGY*, 375, 3-13. 2009.

LEHNER, B., VERDIN, K., JARVIS, A. (2008): New global hydrography derived from spaceborne elevation data. *Eos, Transactions, AGU*, 89(10): 93-94.

LIANG, X.; LETTENMAIER, D. P.; WOOD, E. F.; BURGESS, S. J. A simple hydrologically based model of land surface water and energy fluxes for general circulation models. *Journal of Geophysical Research*, Vol 99, No D7, pp 14415-14428. 1994.

LIANG, X.; LETTENMAIER, D. P.; WOOD, E. F. One-dimensional Statistical Dynamic Representation of Subgrid Spatial Variability of Precipitation in the Two-Layer Variable Infiltration Capacity Model, *J. Geophys. Res.*, 101(D16) 21,403-21,422. 1996.

LIU, J. -G.; XIE, Z. -H. Improving Simulation of Soil Moisture in China Using a Multiple Meteorological Forcing Ensemble Approach. *Hydrology and Earth System Sciences*, 17, 3355-3369, doi: 10.5194/hess-17-3355-2-13. 2013.

LIU, S.; MO, X.; LI, H.; PENG, G.; ROBOCK, A. The spatial variation of soil moisture in China: Geostatistical Characteristics. *Journal of the Meteorological Society of Japan*, 79 (2B) 555-574. 2001.

LIU, Y.Y.; MCCABE, M.F.; EVANS, J.P.; VAN DIJK, A.I.J.M.; DE JEU, R.A.M.; SU, H. Comparison of soil moisture in GLDAS model simulations and satellite observations over the Murray Darling Basin, in *Proceedings International Congress on Modelling and Simulation*, Cairns, Australia, 13-17. 2009.

LOEW, A.; DALL'AMICO, J. T.; SCHLENZ, F.; MAUSER, W. (2009): The Upper Danube soil moisture validation site: measurements and activities, *Earth Observation and Water Cycle conference*, Frascati (Rome), 18 - 20 November 2009.

MARCZEWSKI, W.; SLOMINSKI, J.; SLOMINSKA, E.; USOWICZ, B.; USOWICZ, J.; ROMANOV, S.; MARYSKEVYCH, O.; NASTULA, J.; ZAWADZKI, J. Strategies

for validating and directions for employing SMOS data, in the Cal-Val project SWEX (3275) for wetlands, *Hydrol. Earth Syst. Sci. Discuss.*, 7, 7007–7057. 2010.

MAROVELLI, W. A.; SILVA, H. R.; SILVA, W. L. C.; CARRIJO, O. A. Tensiômetros para Manejo da Irrigação em Hortaliças. EMBRAPA. Disponível em: <http://www.cnph.embrapa.br/public/folders/tensiometro.html>. Acesso em: 31/07/2014.

MATTAR, C.; SANTAMARÍA-ARTIGAS, A.; DURÁN-ALARCÓN, C.; OLIVERA-GUERRA, L.; FUSTER, R. LAB-net the First Chilean soil moisture network for Remote Sensing Applications. *Procd. IV Recent Advances in Quantitative Remote Sensing Symposium (RAQRS)*. 22 - 25 September, Valencia, Spain. 2014.

MEADE, R. H.; RAYOL, J. M.; Da CONCEIÇÃO, S. C.; NATIVIDADE, J. R. G. Backwater effects in the Amazon River basin of Brazil. *Environmental Geology and Water Sciences*, 18 (2), 105-114. 1991.

MELLER, A. Previsão de cheias por conjunto em curto prazo. Tese de Doutorado. Instituto de Pesquisas Hidráulicas. Universidade Federal do Rio Grande do Sul. 2012. 224p.

MENDES, P. C. S. Caracterização de um Sensor para Medição de Umidade do Solo com Termo-Resistor a Temperatura Constante. 2006. 159 p. Dissertação (Mestrado em Engenharia Elétrica). Universidade Federal da Bahia, Salvador. 2006.

MET OFFICE. Ensemble Forecasting. Disponível em: <http://www.metoffice.gov.uk/research/areas/data-assimilation-and-ensembles/ensemble-forecasting>. Acesso em: 11/09/2014.

MIKE Powered by DHI. MIKE SHE. s. d. Disponível em: <http://www.mikepoweredbydhi.com/products/mike-she>.

MMA – Ministério do Meio Ambiente. Caderno da Região Hidrográfica do Uruguai. Secretaria de Recursos Hídricos. Brasília. 2006.

MOGHADDAM, M.; ENTEKHABI, D.; GOYKHMANN, Y.; LI, K.; LIU, M.; MAHAJAN, A.; NAYYAR, A.; SHUMAN, D.; TENEKETZIS, D. A wireless soil moisture smart sensor web using physics-based optimal control: concept and initial demonstration *IEEE-JSTARS*, vol. 3, no. 4, pp. 522-535, December 2010.

MOORE, R. J.; CLARKE, R. T. A distribution function approach to rainfall-runoff modelling. *Water Resources Research*. Vol 17. No. 5, 1367-1382. 1981.

MORBIDELLI, R.; SALTALIPPI, C.; FLAMMINI, A.; ROSSI, E.; CORRADINI, C. Soil water content vertical profiles under natural conditions: Matching of experiments and simulations by a conceptual model. *Hydrological Processes*. 28(17), 4732-4742, doi: 10.1002/hyp.9973. 2014.

MOUGIN, E., HIERNAUX, P., KERGOAT, L., GRIPPA, M., DE ROSNAY, P., TIMOUK, F., LE DANTEC, V., DEMAREZ, V., LAVENU, F., ARJOUNIN, M., LEBEL, T. et al. The AMMA-CATCH Gourma observatory site in Mali: Relating climatic variations to changes in vegetation, surface in press, hydrology, fluxes and natural resources. *Journal of Hydrology*, 375(1-2): 14-33. 2009.

NASA – NATIONAL AERONAUTICS AND SPACE ADMINISTRATION. Jet Propulsion Laboratory. California Institute of Technology. SMAP – Soil Moisture Active Passive. 2014. Disponível em: <http://smap.jpl.nasa.gov/mission/>

NCAR - National Center for Atmospheric Research. The NCAR Community Climate Model (CCM3). 1998. Disponível em: <http://www.cgd.ucar.edu/cms/ccm3/news/ccm3.6.shtml>.

NIJSSEM, B.; LETTENMAIER, D. P.; LIANG, X.; WETZEL, S. W.; WOOD, E. F. Streamflow simulation for continental-scale river basins. *Water Resources Research*, Vol 33, No 4, pp 711-724, April 1997.

NIJSSEN, B.; SCHNUR, R.; LETTENMAIER, D. P. Global Retrospective Estimation of Soil Moisture Using the Variable Infiltration Capacity Land Surface Model, 1980–93. *Journal of Climate*. Volume 14. 1790-1808. 2001.

NOAA - National Oceanic and Atmospheric Administration. NATIONAL WEATHER SERVICE. A Model Based on Ocean and Atmosphere Interactions. 2012. Disponível em: http://celebrating200years.noaa.gov/breakthroughs/climate_model/

NOAA - National Oceanic and Atmospheric Administration. NATIONAL WEATHER SERVICE. Disponível em: <http://www.weather.gov/>. Acesso em: Abril-Setembro/2014.

NOAA - National Oceanic and Atmospheric Administration. NATIONAL WEATHER SERVICE.. Climate Prediction Center. Cold & Warm Episodes by Season. 2015. Disponível em: http://www.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ensoyears.shtml. Acesso em: Junho/2015.

PAIVA, R.C.D. Modelagem hidrológica e hidrodinâmica de grandes bacias. Estudo de caso: Bacia do Rio Solimões. 2009. 182 p. Dissertação (Mestrado em Recursos Hídricos e Saneamento Ambiental). Instituto de Pesquisas Hidráulicas; Universidade Federal do Rio Grande do Sul, 2009.

PAIVA, R. C. D.; COLLISCHONN, W.; TUCCI, C. E. M. Large scale hydrologic and hydrodynamic modeling using limited data and a GIS based approach. *Journal of Hydrology (Amsterdam)*, v. 406, p. 170-181, 2011.

PAZ, A.R., COLLISCHONN, W., BRAVO, J.M., BATES, P.D., BAUGH, C. 2014 The influence of vertical water balance on modelling Pantanal (Brazil) spatio-temporal inundation dynamics. *Hydrological Processes* 28 (10), pp. 3539-3553.

PEISCHL, S.; WALKER, J. P.; RÜDIGER, C.; YE, N.; KERR, Y. H.; KIM, E.; BANDARA, R; ALLAHMORADI, M.: The AACES field experiments: SMOS calibration and validation across the Murrumbidgee River catchment, *Hydrology and Earth System Sciences, Discuss.*, 9, 2763-2795, 2012.doi:10.5194/hessd-9-2763-2012

PELLARIN T.; LAURENT, J.P.; CAPPELAERE, B.; DECHARME, B.; DESCROIX, L.; RAMIER, D. Hydrological modelling and associated microwave emission of a semi-arid region in South-western Niger. *Journal of Hydrology*, vol. 375, 1-2, 262-272, 2009.

PENG, G.; LESLIE, L. M.; SHAO, Y. *Environmental Modelling and Prediction*. Springer. 480 p. 2001.

PEREIRA, R. P. Simplificando o Balanço Hídrico de Thornthwaite-Mather. *Bragantia*. 2005, vol.64, n.2, pp. 311-313.

PONCE, V. M. *Engineering Hydrology: Principles and Practices*. Prentice Hall. 1989.

PRINCETON UNIVERSITY. Drought Monitoring and Hydrologic Forecasting with VIC. Disponível em: <http://hydrology.princeton.edu/forecast/current.php>.

- RAWLS, W. J.; AHUJA, L. R.; BRAKENSIEK, D. L.; SHIRMOHAMMADI, A. Infiltration and soil water movement. In: Maidment, D. Handbook of Hydrology. 1993.
- REICHARDT, K. Processos de Transferência no Sistema Solo-Planta-Atmosfera. 4ª edição. Campinas: Fundação Cargill, 1985. 466 p.
- REICHARDT, K.; TIMM, L. C. Solo, Planta e Atmosfera: Conceitos, Processos e Aplicações. 1ª edição. Barueri, SP: Manole, 2004. 478 p.
- RIBEIRO NETO, A.; SILVA, R. C. V.; COLLISCHONN, W.; TUCCI, C. E. M. Simulação na bacia Amazônica com dados limitados: Rio Madeira. Revista Brasileira de Recursos Hídricos, v. 13, p. 47-58, 2008.
- RICHARDS, L.A.; WADLEIGH, C.H. Soil water and plant growth. Academic Press, Inc., New York. 1952.
- ROBOCK, A., SCHLOSSER, C. A., VINNIKOV, K. Y., SPERANSKAYA, N. A., ENTIN, J. K., QIU, S. Evaluation of the AMIP soil moisture simulations, Global and Planetary Change, 19, 181–208, 1998.
- ROBOCK, A.; VINNIKOV, K. Y.; SRINIVASAN, G.; ENTIN, J. K.; HOLLINGER, S. E.; SPERANSKAYA, N. A.; NAMKHAI, A. The Global Soil Moisture Data Bank. Bulletin of the American Meteorological Society. Vol. 81, No. 6, 1281-1299. June 2000.
- ROECKNER, E.; ARPE, K.; BENGTSSON, L.; CHRISTOPH, M.; CLAUSSEN, M.; DÜMENIL, L.; ESCH, M.; GIORGETTA, M.; SCHLESE, U.; SCHULZWEIDA, U. The atmospheric general circulation model ECHAM4: model description and simulation of the present-day climate. Max Planck Institut für Meteorologie, Report n.28, Hamburg, Germany, p90. 1996.
- ROECKNER, E.; BÄUML, G.; BONAVENTURA, L.; BROKOPF, R.; ESCH, M.; GIORGETTA, M.; HAGEMANN, S.; KIRCHNER, I.; KORNBLUEH, L.; MANZINI, E.; RHODIN, A.; SCHLESE, U.; SCHULZWEIDA, U.; TOMPKINS, A. The Atmospheric General Circulation model ECHAM5 – Part I: Model Description. Max Planck Institut für Meteorologie, Report n.349, Hamburg, Germany, p140. 2003.

ROMANO, N.; PALLADINO, M.; CHIRICO, G. B. Parameterization of a bucket model for soil-vegetation-atmosphere modeling under seasonal climatic regimes. *Hydrology and Earth System Sciences*, 15, 3877–3893, 2011.

ROSSATO, L. Estimativa da umidade superficial do solo a partir de sensoriamento remoto por microondas passiva sobre a América do Sul. Tese (Doutorado em Meteorologia) – Instituto Nacional de Pesquisas Espaciais, xxx + 147 p. São José dos Campos: INPE, 2010.

RUHOFF, A.L., PAZ, A.R., ARAGAO, L.E.O.C., MU, Q., MALHI, Y., COLLISCHONN, W., ROCHA, H.R., RUNNING, S.W., 2013. Assessment of the MODIS global evapotranspiration algorithm using eddy covariance measurements and hydrological modelling in the Rio Grande basin. *Hydrological Sciences Journal*, 58 (8), 1658–1676, 2013.

SALDANHA, C. B. Previsão de Longo Prazo da Umidade do Solo na Bacia do Rio Uruguai. 2009. 161 f. Tese (Doutorado em Recursos Hídricos e Saneamento Ambiental) – Instituto de Pesquisas Hidráulicas (IPH), Universidade Federal do Rio Grande do Sul (UFRGS). Porto Alegre, 2009.

SALDANHA, C. B.; TUCCI, C. E. M.; WOOD, E. F.; LI, H. Previsão de Longo Prazo de Umidade do Solo no rio Uruguai. *RBRH-Revista Brasileira de Recursos Hídricos*. Volume 17, n. 4, 39-47, Out/Dez 2012.

SANTOS, H. G. dos; CARVALHO JUNIOR, W. de; DART, R. de O.; ÁGLIO, M. L. D.; SOUZA, J. da S.; PARES, J. G.; FONTANA, A.; MARTIN, A. L. da S.; OLIVEIRA, A. P. de. EMBRAPA Solos Núcleo de Geomatica – NGENO. 2011. Disponível em: mapoteca.cnps.embrapa.br/geoacervo/.

SCHLENZ, F.; DALL'AMICO, J.; LOEW, A.; MAUSER, W. Uncertainty Assessment of the SMOS Validation in the Upper Danube Catchment. *IEEE Transactions on Geoscience and Remote Sensing*, 50(5), pp.1517–1529. doi: 10.1109/TGRS.2011.2171694. 2012.

SCHNEIDER, E. K. Understanding Differences between the Equatorial Pacific as Simulated by Two Coupled GCMs. *Journal of Climate*. Vol 15. No. 5. Março 2002.

SCHNEIDER, E. K.; DEWITT, D. G.; ROSATI, A.; KIRTMAN, B. P.; JI, L.; TRIBBIA, J. J. Retrospective ENSO Forecasts: Sensitivity to Atmospheric Model and Ocean Resolution. *Monthly Weather Review*. Vol 131. pp 3038-3060. 2003.

SHUTTLEWORTH, W. J. 1993. Evaporation. In: Maidment, D. R. *Handbook of Hydrology*. McGraw-Hill. New York.

SILVA, B. C.; COLLISCHONN, W.; TUCCI, C. E. M.; CLARKE, R. T.; CORBO, M. D. Previsão Hidroclimática de Vazão de Curto Prazo na Bacia do Rio São Francisco. *RBRH — Revista Brasileira de Recursos Hídricos*. Volume 12 n.3. Jul/Set 2007. 31-41.

SILVA, R. V.; KOBIYAMA, M. TOPMODEL: Teoria Integrada e Revisão. *R. RA'EGA*, Curitiba, n. 14, p. 97-110, Editora UFPR. 2007.

SILVA, F. H. B. B. EMBRAPA-Empresa Brasileira de Pesquisa Agropecuária. Centro Nacional de Pesquisa de Solos. Método de Determinação do Escoamento Superficial de Bacias Hidrográfica a partir de Levantamentos Pedológicos. Rio de Janeiro. 2000. Disponível em: <http://www.cnps.embrapa.br/publicacoes/pdfs/doc212000/metodeterminacao.pdf>.

SÍPEK, V.; TESAR, M. Soil moisture simulation using two different modelling approaches. *Die Bodenkultur*, 64, 99-103 2013.

SMITH, A. B.; WALKER, J. P.; WESTERN, A. W.; YOUNG, R. I.; ELLETT, K. M.; PIPUNIC, R. C.; GRAYSON, R. B.; SIRIWIDENA, L.; CHIEW, F. H. S.; RICHTER, H. The Murrumbidgee Soil Moisture Monitoring Network Data Set. *Water Resources Research*, vol. 48, W07701, 6pp. doi:10.1029/2012WR011976. 2012.

SOLDEVILLA-MARTINEZ, M.; LÓPEZ-URREA, R.; MARTÍNEZ-MOLINA, L.; LIZASO, J. I.; QUEMADA, M. Improving Simulation of Soil Water Balance using Lysimeter Observations in a Semiarid Climate. *Estudios en la Zona no Saturada del Suelo*. Vol XI. 2013.

SU, Z.; WEN, J.; DENTE, L.; VAN DER VELDE, R.; WANG, L.; MA, Y.; YANG, K.; HU, Z. The Tibetan Plateau observatory of plateau scale soil moisture and soil temperature (Tibet-Obs) for quantifying uncertainties in coarse resolution satellite and model products, *Hydrol. Earth Syst. Sci.*, 15, 2303–2316, 2011.

SUAREZ, A; MAHMOOD, R.; QUINTANAR, A. I.; BELTRÁN-PRZEKURAT, A.; PIELKE, R. A comparison of the MM5 and the Regional Atmospheric Modeling System simulations for land-atmosphere interactions under varying soil moisture. International Meteorological Institute. Stockholm. Tellus. Series A Dynamic Meteorology and Oceanography. 66, 21486, <http://dx.doi.org/10.3402/tellusa.v66.21486>.

TAGESSON, T.; FENSHOLT, R.; GUIRO, I.; RASMUSSEN, M. O.; HUBER, S.; MBOW, C.; GARCIA, M.; HORION, S.; SANDHOLT, I.; HOLM-RASMUSSEN, B.; GÖTTSCHE, F. M.; RIDLER, M. E.; OLÉN, N.; OLSEN, J. L.; EHAMMER, A.; MADSEN, M.; OLESEN, F. S. ; ARDÖ, J. Ecosystem properties of semiarid savanna grassland in West Africa and its relationship with environmental variability. *Global Change Biology*. Jan; 21(1):250-64. doi: 10.1111/gcb.12734. 2015.

TIPPETT, M. K. Filtering of GCM simulated Sahel precipitation. *Geophysical Research Letters*, Vol. 33, L01804, doi:10.1029/2005GL024923, 2006

THORNTHWAITE, C. W. An approach toward a rational classification of climate. *Geographical Review*, Nova Iorque, v.38, n.1, p.55-94, 1948.

THORNTHWAITE, C. W. & MATHER, J. R. The water balance. *Publications in Climatology*, New Jersey, Drexel Inst. of Technology, 1955. 104p.

TODINI, E. The ARNO Rainfall-Runoff Model. *Journal of Hydrology*. 175, 339-382, 1996.

TUCCI, C. E. M. Hydraulic and Water Quality Model for a River Network. PhD dissertation, Colorado State University, Fort Collins, USA. 1978.

TUCCI, C. E. M. Modelos Hidrológicos. Porto Alegre, RS: Editora da UFRGS, 1998. 669 p.

TUCCI, C. E. M. Modelos Hidrológicos. 2ª edição. Porto Alegre, RS: Editora da UFRGS, 2005. 678 p.

TUDeft - DELFT UNIVERSITY OF TECHNOLOGY. Remote Sensing. 2014. Disponível em: <http://www.citg.tudelft.nl/en/about-faculty/departments/watermanagement/sections/water-resources/leerstoelen/wrm/research/tools/remote-sensing/>.

UNIVERSITY OF WASHINGTON. Land Surface Hydrology Research Group. University of Washington. Experimental Surface Water Monitor for the Continental U.S. Disponível em: <http://www.hydro.washington.edu/forecast/monitor/outlook/index.shtml>.

VESTENA, L.R.; WEBER, J.F. STEHLI, P.T.; JORQUERA, E. Uso dos Modelos Hidrológicos TOPMODEL e TREX para Simulação do Processo Chuva-Vazão da Bacia do Rio Caeté, Região Serrana do Estado de Santa Catarina, Brasil. *Mecânica Computacional* Vol XXXII, págs. 2837-2854. 2013.

WEBER, E.; HASENACK, H.; FERREIRA, C.J.S. 2004. Adaptação do modelo digital de elevação do SRTM para o sistema de referência oficial brasileiro e recorte por unidade da federação. Porto Alegre. UFRGS Centro de Ecologia. ISBN 978-85-63843-02-9. Disponível em <http://www.ecologia.ufrgs.br/labgeo>.

WHITE, R. E.; HELYAR, K. R.; RIDLEY, A. M.; CHEN, D.; HENG, L. K.; EVANS, J.; FISHER, R.; HIRTH, J. R.; MELE, P. M.; MORRISON, G. R.; CRESSWELL, H. P.; PAYDAR, Z.; DUNIN, F. X.; DOVE, H.; SIMPSON, R. J. Soil factors affecting the sustainability and productivity of perennial and annual pastures in the high rainfall zone of south-eastern Australia. *Australian Journal of Experimental Agriculture* 40 , 267–283. 2000.

WIGMOSTA, M. S.; VAIL, L. W.; LETTENMAIER, D. P. A distributed hydrology-vegetation model for complex terrain. *Water Resources Research*. Vol 30, No. 6, pp 1665-1679. 1994.

WILKS, D. S. *Statistical Methods in the Atmospheric Sciences*. Second Edition. San Diego, California. 2006.

WMO – World Meteorological Organization. *Guide to Hydrological Practices. Management of Water Resources and Application of Hydrological Practices*. 6ª edição. Genebra, Suíça. 2009. Volume II. WMO-N. 168.

WMO – World Meteorological Organization. *Guidelines on Ensemble Prediction Systems and Forecasting*. Genebra, Suíça. 2012. WMO-N. 1091.

WOOD, A.W. The University of Washington Surface Water Monitor: An experimental platform for national hydrologic assessment and prediction, in *Proceedings of the AMS 22nd Conference on Hydrology*, New Orleans, LA, January 20-24, 2008.

YANG, K.; QIN, J.; ZHAO, L.; CHEN, Y. Y.; TANG, W. J.; HAN, M. L.; LAZHU; CHEN, Z. Q.; LV, N.; DING, B. H.; WU, H.; LIN, C. G.. A Multi-Scale Soil Moisture and Freeze-Thaw Monitoring Network on the Third Pole, *Bulletin of the American Meteorological Society*, 94, 1907–1916. doi: 10.1175/BAMS-D-12-00203.1. 2013.

YAPO, P. O.; GUPTA, H. V. SOROOSHIAN, S. Multi-objective optimization for hydrologic models. *Journal of Hydrology*, 204, 83-97 pp. 1998.

YOUNG, R.; WALKER, J.; YEOH, N.; SMITH, A.; ELLETT, K.; MERLIN, O.; WESTERN, A. Soil moisture and meteorological observations from the murrumbidgee catchment. Department of Civil and Environmental Engineering, The University of Melbourne. 2008. URL: http://www.civenv.unimelb.edu.au/oznet/documentation/Soil_Moisture_Meteorological_Observation_of_Murrumbidgee_Catchment.pdf

ZACHARIAS, S.; BOGENA, H.R.; SAMANIEGO, L.; MAUDER, M.; FUß, R.; PÜTZ, T.; FRENZEL, M.; SCHWANK, M.; BAESSLER, C.; BUTTERBACH-BAHL, K.; BENS, O.; BORG, E.; BRAUER, A.; DIETRICH, P.; HAJNSEK, I.; HELLE, G.; KIESE, R.; KUNSTMANN, H.; KLOTZ, S.; MUNCH, J.C.; PAPEN, H.; PRIESACK, E.; SCHMID, H. P.; STEINBRECHER, R.; ROSENBAUM, U.; TEUTSCH, G.; VEREECKEN, H. A Network of Terrestrial Environmental Observatories in Germany. *Vadose Zone J.* 10. 955–973. doi:10.2136/vzj2010.0139. 2011.

ZHANG, L.; WALKER, G.R.; DAWES, W.R. Water balance modelling: concepts and applications. In: McVicar, T.R., Li Rui, Walker, J., Fitzpatrick, R.W. and Liu Changming (eds), *Regional Water and Soil Assessment for Managing Sustainable Agriculture in China and Australia*, ACIAR Monograph No. 84, 31–47. 2002.

ZHAO, R.-J., et al.. The Xinanjiang model, *Hydrological Forecasting Proceedings Oxford Symposium*, IASH 129, 351-356. 1980.

ZREDA, M.; DESILETS, D.; FERRÉ, T. P. A.; SCOTT, R. L. Measuring soil moisture content non-invasively at intermediate spatial scale using cosmic-ray neutrons, *Geophysical Research Letters* 35(21), 2008.

ZREDA, M.; SHUTTLEWORTH, W. J.; ZENG, X.; ZWECK, C.; DESILETS, D.; FRANZ, T.; ROSOLEM, R.; FERRE, T. P. A. COSMOS: The COsmic-ray Soil Moisture

Observing System, Hydrol. Earth Syst. Sci. Discuss., 9, 4505-4551, doi:10.5194/hessd-9-4505-2012, 2012.

ANEXO A

Estimativas de umidade no solo

A.1 Bases de dados de umidade no solo

A *International Soil Moisture Network* (ISMN) (DORIGO *et al.*, 2011) é uma iniciativa internacional para criação e manutenção de uma base de dados de umidade do solo *in situ* global. A rede completa contribuinte para a ISMN pode ser vista na Tabela A.1. São atualmente ao todo 2001 estações, distribuídas em 48 redes. Não há contribuição do Brasil para esta iniciativa. Da América do Sul, apenas o Chile participa da rede, porém, dispondo de apenas uma estação para medições em campo. A maior parte das bases contribuintes, e com maior número de estações, encontra-se nos Estados Unidos (1206 estações), antiga União Soviética (337 estações), Europa (184 estações), China (117 estações) e Austrália (101 estações). Contribuem também Mongólia (44 estações), Índia (uma estação), Coreia (duas estações), havendo também algumas redes (ainda que com poucas estações) na África (8 estações ao todo). Os dados encontram-se disponíveis para visualização e download em <https://ismn.geo.tuwien.ac.at/data-access/>.

Tabela A.1. Bases de dados contribuintes para a International Soil Moisture Network.

US= Umidade do solo; TS= Temperatura do solo; P= Precipitação; TA= Temperatura do ar; Tsup=Temperatura da superfície; TsS= Tensão do solo; EAN=Equivalente em água da neve; PN=Profundidade de neve.

Nome	País	Estações	Organização	Variáveis medidas								Profundidade máxima das medições	Profundidades medidas	Disponibilidade de dados	Website	Referências
				US	TS	P	TA	Tsup	TsS	EAN	PN					
AACES	Austrália	49	Monash University	X	X	X						0.25 m	3	09/05/2005 a 24/09/2010	http://www.moisturemap.monash.edu.au/	Smith <i>et al.</i> , 2012; Peischl <i>et al.</i> , 2012
AMMA-CATCH	Benin, Niger, Mali	6	CNRS	X								1.20 m	12	01/01/2006 a 31/12/2011	http://www.amma-catch.org	Pellarin <i>et al.</i> , 2009; Mouglin <i>et al.</i> , 2009; Cappelaere, <i>et al.</i> , 2009; de Rosnay, <i>et al.</i> , 2009; Lebel <i>et al.</i> , 2009
ARM	Estados Unidos	29	U.S. Department of Energy as part of the Atmospheric Radiation Measurement Climate Research Facility	X	X	X	X					1.75 m	10	29/06/1993 a 26/03/2015	http://www.arm.gov/	
AWDN	Estados Unidos	50	HPRCC - High Plains Regional Climate Center	X								1.00 m	4	31/12/1997 a 30/12/2010	http://www.hprcc.unl.edu/awdn/	
CALABRIA	Itália	5	Centro Funzionale Multirischi - ARPACAL	X		X	X					0.90 m	3	01/01/2001 a 31/12/2012	http://www.cfc Calabria.it	
CAMPANIA	Itália	2	Centro funzionale per la previsione meteorologica e il Monitoraggio meteo-Pluvio-Idrometrico e delle frane, Settore Programmazione Interventi di Protezione Civile sul Territorio, Regione Campania	X		X	X					0.30 m	1	27/07/2000 a 2012/12/31	http://www.regione.campania.it/	
CARBO-AFRICA	Sudão	1	Lund University, Sweden Agricultural Research Corporation (ARC)	X	X	X	X					2.00 m	7	08/02/2002 a 20/01/2010	http://dx.doi.org/10.7167/2013/297973	Ardö, 2013.
CHINA	China	40	Institute of Geographical Sciences and Natural Resources Research, Chinese Academy of Sciences, Beijing, China	X								1.00 m	11	08/01/1981 a 28/12/1999	-	Liu <i>et al.</i> , 2001; Robock, <i>et al.</i> , 2000.

Nome	País	Estações	Organização	Variáveis medidas								Profundidade máxima das medições	Profundidades medidas	Disponibilidade de dados	Website	Referências
				US	TS	P	TA	Tsup	TsS	EAN	PN					
COSMOS	Estados Unidos	102	University of Arizona	X								0.69 m	39	28/04/2008 a 08/04/2015	http://cosmos.hwr.arizona.edu/	Zreda <i>et al.</i> , 2008; Zreda <i>et al.</i> , 2012
CTP_SMTMN	China	57	Institute of Tibetan Plateau Research, Chinese Academy of Science	X	X							0.40 m	4	01/08/2010 a 01/01/2013	http://dam.itpcas.ac.cn/rs/?q=data#CTP-SMTMN	Yang <i>et al.</i> , 2013
DAHRA	Senegal	1	-	X	X	X	X					1.00 m	5	04/07/2002 a 01/01/2014	http://ign.ku.dk/earthobservation/research/document4/CaLM/	Tagesson <i>et al.</i> , 2015
FLUXNET-AMERI-FLUX	Estados Unidos	2	Department of Environmental Science, University of California, Berkeley	X	X	X	X					0.50 m	8	22/10/2000 a 01/01/2013	http://www.fluxnet.ornl.gov http://ameriflux.lbl.gov/Pages/default.aspx	
FMI	Finlandia	24	Finnish Meteorological Institute	X	X		X					0.80 m	6	25/01/2007 a 16/08/2014	http://fmiarc.fmi.fi/	
GTK	Finlandia	7	Geological Survey of Finland	X	X		X					0.90 m	5	16/05/2001 a 29/05/2012	-	
HOBE	Dinamarca	32	Hydrological Observatory	X	X							0.55 m	3	08/09/2009 a 03/02/2014	http://www.hobe.dk/	Bircher <i>et al.</i> , 2011
HSC_SELMA-JCHEON	Coréia	1	Hydrological Survey Center (HSC)/Water Resources & Remote Sensing Lab-Hanyang University	X								0.10 m	1	01/01/2008 a 01/01/2009	http://www.hsc.re.kr	
HYDROL-NET-PERUGIA	Itália	2	Dept. of Civil and Environmental Engineering of Perugia	X	X	X	X					0.35 m	4	01/01/2008 a 31/12/2013	http://www.dica.unipg.it/DICA	Morbidegli <i>et al.</i> , 2014
HYU_CHEONG-MICHEON	Coréia	1	Hanyang University (HYU);Water Resources & Remote Sensing Lab (WRRSL)	X								0.10 m	1	25/08/2011 a 20/09/2011	http://wrrsl.hanyang.ac.kr/html/introduction.htm	
ICN	Estados Unidos	19	Illinois State Water Survey	X	X	X						2.00 m	11	03/01/1983 a 21/11/2010	http://www.isws.illinois.edu/warm/	Hollinger e Isard, 1994
IIT_KANPUR	India	1	Indian Institute of Technology Kanpur	X								0.80 m	4	16/06/2011 a 22/11/2012	http://www.iitk.ac.in/	

Nome	País	Estações	Organização	Variáveis medidas								Profundidade máxima das medições	Profundidades medidas	Disponibilidade de dados	Website	Referências
				US	TS	P	TA	Tsup	TsS	EAN	PN					
IOWA	Estados Unidos	6	United States Department of Agriculture, Agricultural Research Service	X								2.59 m	12	04/04/1972 a 15/11/1994	-	Robock <i>et al.</i> , 2000.
LAB-net	Chile	1	Laboratory for Analysis of the Biosphere - University of Chile	X	X	X	X					0.20 m	2	25/10/2014 a 06/03/2015	http://www.biosfera.uchile.cl/LAB-net.html	Mattar <i>et al.</i> , 2014
MAQU	China	20	University of Twente, Faculty of Geo-Information Science and Earth Observation (ITC) Chinese Academy of Science - Cold and Arid Regions Environmental and Engineering Research Institute (CAS-CAREERI)	X	X							0.05 m	1	30/06/2008 a 31/07/2010	-	Su <i>et al.</i> , 2011.
METER-OBS	Itália	1	Met European Research Observatory	X								0.50 m	5	23/10/2011 a 09/05/2012	http://mistrals.sedoo.fr/HyMeX/Platform-search?datsId=532	
MOL-RAO	Alemanha	2	German Meteorological Service, Germany	X	X	X	X					1.50 m	9	01/01/2003 a 01/01/2009	http://www.dwd.de/mol	Beyrich <i>et al.</i> , 2007.
MONGOLIA	Mongolia	44	National Agency of Meteorology, Hydrology and Environment Monitoring (NAMHEM), Ulaanbaatar, Mongolia	X								1.00 m	10	08/04/1964 a 18/10/2002	-	Robock <i>et al.</i> , 2000.
ORACLE	França	6	Institut national de recherche en sciences et technologies pour l'environnement et l'agriculture	X	X	X	X					1.55 m	26	18/10/1985 a 09/09/2013	http://gisoracle.irstea.fr https://bdoh.irstea.fr/ORACLE/	
OZNET	Australia	38	The University of Melbourne, Melbourne, Australia	X	X	X			X			0.90 m	7	12/09/2001 a 31/05/2011	http://www.oznet.org.au/	Young <i>et al.</i> , 2008.
PBO_H2O	Estados Unidos	109	University of Colorado	X		X	X					0.50 m	2	01/01/2007 a 06/04/2015	http://xenon.colorado.edu/portal/index.php?product=soil_moisture	Larson <i>et al.</i> , 2008.
REMEDHUS	Espanha	24	Centro Hispano Luso de Investigaciones Agrarias	X	X							0.05 m	1	15/03/2005 a 01/01/2015	http://campus.usal.es/~hidrus/	

Nome	País	Estações	Organização	Variáveis medidas								Profundidade máxima das medições	Profundidades medidas	Disponibilidade de dados	Website	Referências
				US	TS	P	TA	Tsup	TsS	EAN	PN					
			(CIALE)Universidad de Salamanca													
RUSWET-AGRO	Antiga União Soviética	212	State Hydrological Institute, St. Petersburg, Russia University of Maryland, USA Rutgers University, New Jersey, USA	X								1.00 m	2	08/04/1958 a 28/06/2002	-	Robock <i>et al.</i> , 2000.
RUSWET-GRASS	Antiga União Soviética	122	State Hydrological Institute, St. Petersburg, Russia University of Maryland, USA Rutgers University, New Jersey, USA	X								1.00 m	2	08/06/1952 a 28/12/1985	-	Robock <i>et al.</i> , 2000.
RUSWET-VALDAI	Antiga União Soviética	3	State Hydrological Institute, St. Petersburg, Russia University of Maryland, USA Rutgers University, New Jersey, USA	X	X	X	X					1.00 m	3	15/01/1960 a 15/12/1990	-	Robock <i>et al.</i> , 2000.
SASMAS	Australia	14	-	X	X							0.30 m	2	31/12/2005 a 31/12/2007	http://www.oznet.org.au/	Young <i>et al.</i> , 2008.
SCAN	Estados Unidos	215	U.S. Department of Agriculture, Natural Resources Conservation Service (NRCS)	X	X	X				X	X	2.03 m	24	01/01/1996 a 29/10/2014	http://www.wcc.nrcs.usda.gov/	
SMOS-MANIA	França	21	CNRM/GAME, METEO-FRANCE, CRNS	X	X							0.30 m	4	01/01/2007 a 01/01/2014	http://www.hymex.org	Albergel <i>et al.</i> , 2007; Calvet <i>et al.</i> , 2007.
SNOTEL	Estados Unidos	420	U.S. Department of Agriculture, Natural Resources Conservation Service (NRCS)	X	X	X	X			X	X	1.01 m	16	11/09/1996 a 27/10/2014	http://www.wcc.nrcs.usda.gov/	Leavesley <i>et al.</i> , 2010,
SOILS-CAPE	Estados Unidos	136	-	X	X							0.90 m	28	26/08/2011 a 17/02/2015	http://soilscape.usc.edu/	Moghaddam <i>et al.</i> , 2010.
SWEX_POLAND	Polônia	6	Inst. of Agrophysics PAS (IA PAN), Lublin, Poland	X	X	X						1.00 m	10	01/01/2000 a 06/05/2013	-	Marczewskil <i>et al.</i> , 2010.

Nome	País	Estações	Organização	Variáveis medidas								Profundidade máxima das medições	Profundidades medidas	Disponibilidade de dados	Website	Referências	
				US	TS	P	TA	Tsup	TsS	EAN	PN						
TERENO	Alemanha	5	Helmholtz Gemeinschaft Forschungszentrum Jülich	X	X	X							0.50 m	3	01/04/2013 a 04/10/2014	http://teodoor.icg.kfa-juelich.de/overview-de	Zacharias <i>et al.</i> , 2011.
UDC_SMOS	Alemanha	11	University of Munich, Department of Geography, Munich, Germany	X									0.40 m	5	08/11/2007 a 18/11/2011	http://www.geographie.uni-muenchen.de/departament/fiona/forschung/projekte/index.php?projekt_id=103	Schlenz <i>et al.</i> , 2012; Loew <i>et al.</i> , 2009.
UMBRIA	Itália	13	Civil Protection Functional Centre Research Institute for Geo-Hydrological Protection Consiglio Nazionale delle Ricerca (CNR), Perugia	X		X	X						0.55 m	5	09/10/2002 a 01/08/2014	http://www.cfumbria.it/ http://hydrology.irpi.cnr.it/	Brocca <i>et al.</i> , 2011; Brocca <i>et al.</i> , 2008; Brocca <i>et al.</i> , 2009.
UMSUOL	Itália	1	Agenzia Regionale Prevenzione Ambiente - Servizio Idro-Meteo-Clima (ARPA - SIMC)	X									1.80 m	7	12/06/2009 a 30/09/2010	http://www.arpa.emr.it/sim/	
USCRN	Estados Unidos	114	National Oceanic and Atmospheric Administration's National Climatic Data Center (NOAA's NCDC)	X	X	X	X	X					1.00 m	5	15/11/2000 a 08/04/2015	http://www.ncdc.noaa.gov/cm/	Bell <i>et al.</i> , 2013.
USDA-ARS	Estados Unidos	4	-	X	X								0.05 m	1	01/06/2002 a 31/07/2009	http://www.ipf.tuwien.ac.at/insitu/data_viewer/metadata/USDA_ARS_ISMN_Readme.pdf	Jackson <i>et al.</i> , 2010.
VAS	Espanha	3	Climatology from Satellites Group (GCS) - University of Valencia	X	X		X						0.05 m	1	01/01/2010 a 01/01/2012	http://nimbus.uv.es/	
WEGENERNET	Áustria	12	Wegener Center for Climate and Global Change, University of Graz	X	X	X	X						0.30 m	2	01/01/2007 a 03/05/2015	http://www.wegener.net/ http://www.wegcenter.at/wegener.net	
WSMN	Reino Unido	7	Aberystwyth University	X	X								0.10 m	3	02/09/2011 a 12/02/2015	http://www.aber.ac.uk/wsmn	

Fonte: Construído a partir de <https://ismn.geo.tuwien.ac.at/networks/>.

A.2 Estimativa de umidade no solo por Sensoriamento Remoto

A Tabela A.2. traz dados sobre todas as missões, atuais e futuras, através das quais é possível obter informações sobre a umidade do solo. Esta tabela foi construída com dados disponibilizados pelo Committee on Earth Observation Satellites, através de sua base de dados. Mais informações sobre cada uma das missões podem ser obtidas em <http://www.eohandbook.com/>. A Figura A.1. mostra ao longo do tempo o período de duração das missões atualmente em órbita. A Figura A.2 mostra as missões futuras.

SOIL MOISTURE

Current Missions

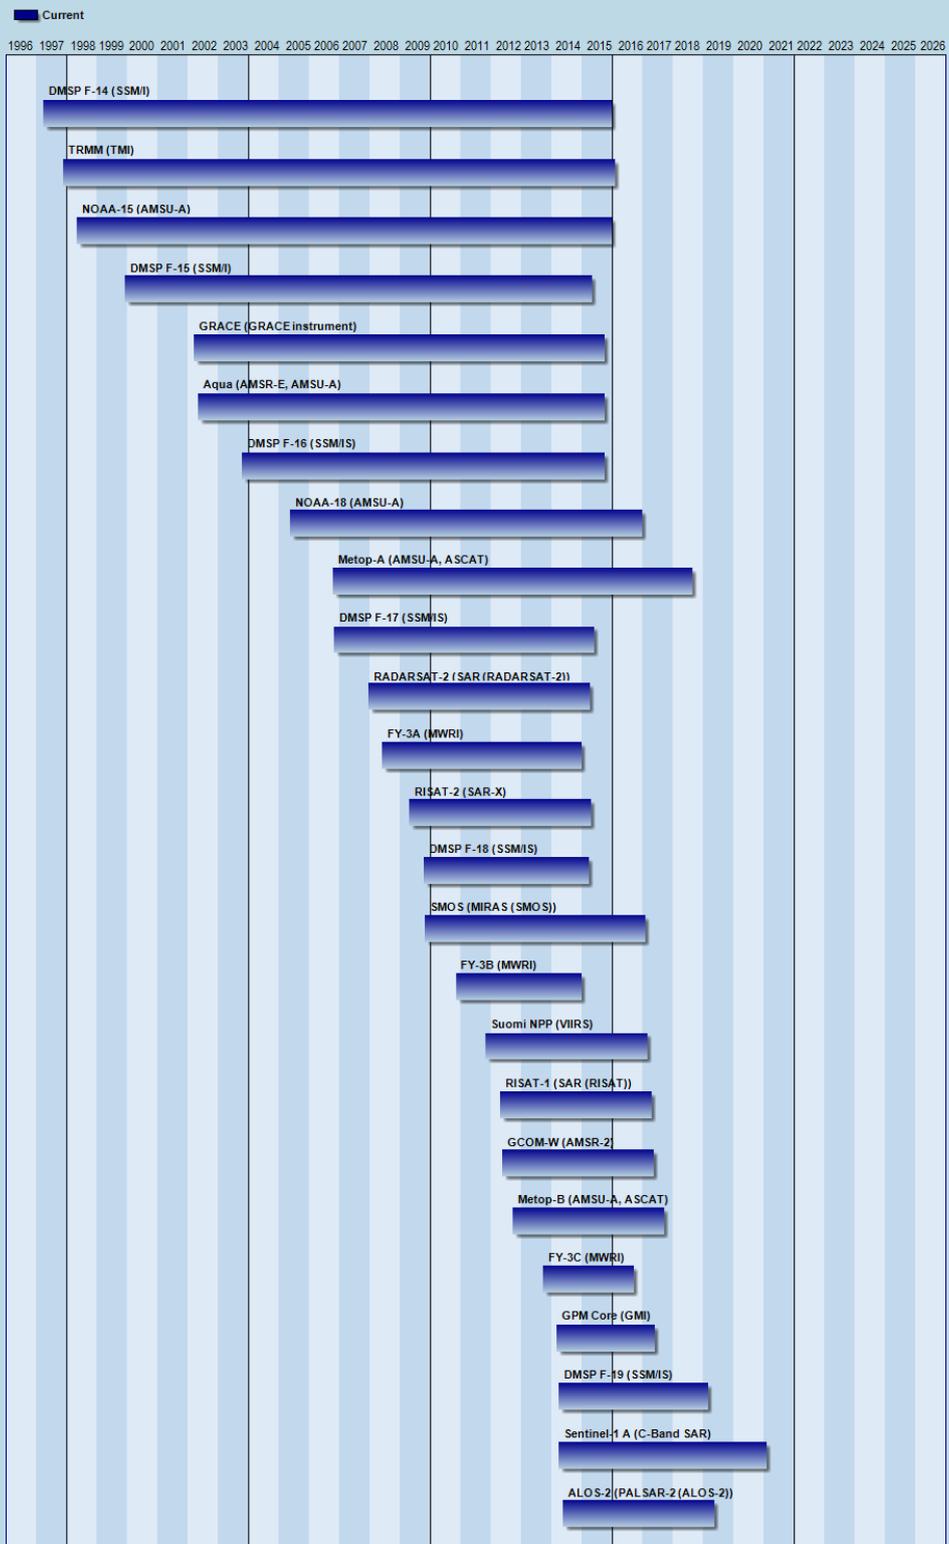


Figura A.1. Missões atuais com medição de umidade do solo.

Fonte: CEOS, 2014.

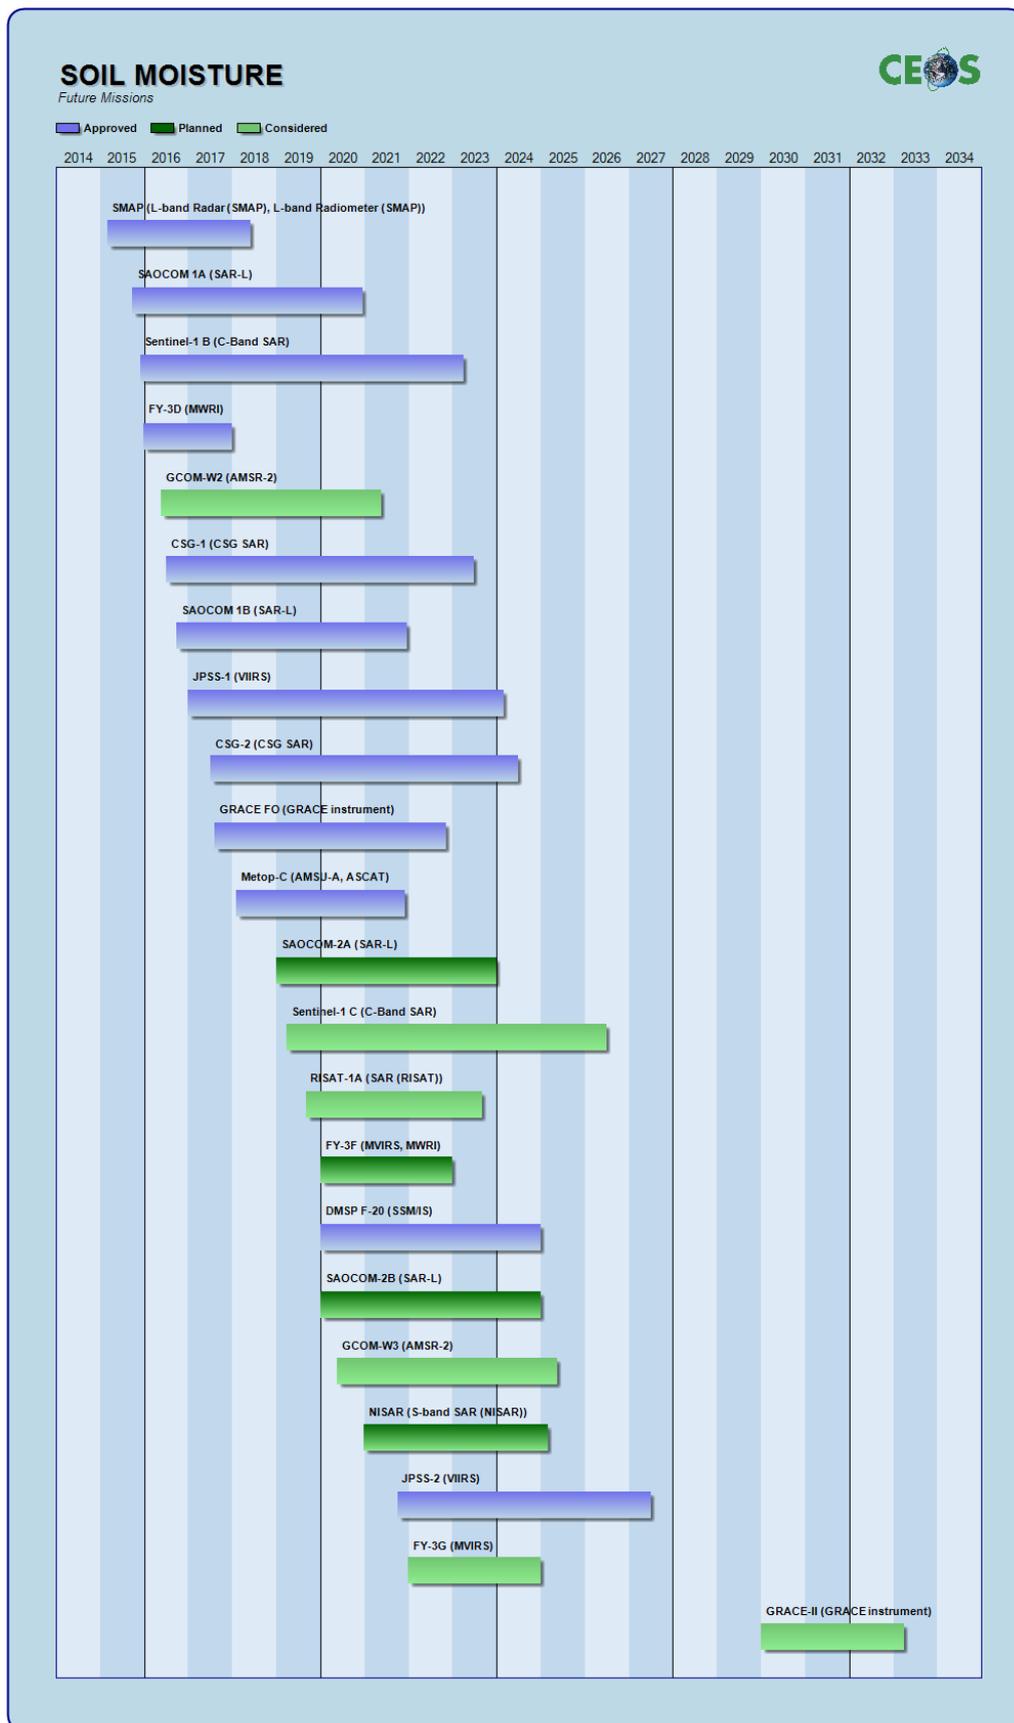


Figura A.2. Missões atuais com medição de umidade do solo.
Fonte: CEOS, 2014.

Tabela A.2. Missões atuais e futuras com observação de umidade do solo.

Nome da missão	Nome completo da missão	Agências líder (L) e colaboradoras	Data de lançamento e fim da operação	Situação da missão	Instrumentos da missão*	Tipo de instrumento*	Resolução do instrumento*	Bandas do instrumento*
DMSP F-14	Defense Meteorological Satellite Program F-14	NOAA (L), USAF	04/abr/97 31/dez/15	Em órbita	SSM/I: Special Sensor Microwave Imager	Radiômetros imageadores multiespectrais (micro-ondas passivo) com múltiplos propósitos	15,7 x 13,9km até 68,9x 44,3km (conforme a frequência)	Micro-ondas: 19,35 GHz, 22,235 GHz, 37 GHz, 85 GHz
TRMM	Tropical Rainfall Measuring Mission	NASA (L), JAXA	27/nov/97 01/fev/16	Em órbita	TMI: TRMM Microwave Imager	Radiômetros imageadores multiespectrais (micro-ondas passivo) com múltiplos propósitos	Vertical: 2,5 km aproximadamente; Horizontal: 18 km	Micro-ondas: 10,7 GHz, 19,4 GHz, 21,3 GHz, 37 GHz, e 85,5 GHz
NOAA-15	National Oceanic and Atmospheric Administration - 15	NOAA (L)	01/mai/98 31/dez/15	Em órbita	AMSU-A: Advanced Microwave Sounding Unit-A	Sondas de temperatura atmosférica e umidade – Radiômetros/espectrômetros de micro-ondas	48 km	Micro-ondas: 15 canais, 23,8 - 89,0 GHz
DMSP F-15	Defense Meteorological Satellite Program F-15	NOAA (L), USAF	12/dez/99 01/mai/15	Em órbita	SSM/I: Special Sensor Microwave Imager	Radiômetros imageadores multiespectrais (micro-ondas passivo) com múltiplos propósitos	15,7 x 13,9 km até 68,9 x 44,3 km (conforme a frequência)	Micro-ondas: 19,35 GHz, 22,235 GHz, 37 GHz, 85 GHz
GRACE	Gravity Recovery and Climate Experiment	NASA (L), DLR	17/mar/02 02/out/15	Em órbita	GRACE instrument	Instrumentos gravitacionais – Sistema satélite a satélite	400 km horizontal	Micro-ondas: 24 GHz e 32 GHz
Aqua	Aqua (oficialmente EOS PM-1) (EOS PM-1)	NASA (L), INPE, JAXA	04/mai/02 02/out/15	Em órbita	AMSR-E: Advanced Microwave Scanning Radiometer-EOS	Radiômetros imageadores multiespectrais (micro-ondas passivo) com múltiplos propósitos	5 - 50 km (conforme a frequência)	Micro-ondas: 6,925 GHz, 10,65 GHz, 18,7 GHz, 23,8 GHz, 36,5 GHz, 89,0 GHz
					AMSU-A: Advanced Microwave Sounding Unit-A	Sondas de temperatura atmosférica e umidade – Radiômetros/espectrômetros de micro-ondas	48 km	Micro-ondas: 15 canais, 23,8 - 89,0 GHz
DMSP F-16	Defense Meteorological Satellite Program F-16	NOAA (L), USAF	18/out/03 01/out/15	Em órbita	SSM/IS: Special Sensor Microwave Imager Sounder	Sondas de temperatura atmosférica e umidade – Radiômetro imageador de micro-ondas com múltiplos propósitos	25 x 17 km até 70 x 42 km (variável com a frequência)	Micro-ondas: 19 - 183 GHz (24 frequências)
NOAA-18	National Oceanic and Atmospheric Administration - 18	NOAA (L)	20/mai/05 31/dez/16	Em órbita	AMSU-A: Advanced Microwave Sounding Unit-A	Sondas de temperatura atmosférica e umidade – Radiômetros/espectrômetros de micro-ondas	48 km	Micro-ondas: 15 canais, 23,8 - 89,0 GHz
Metop-A	Meteorological Operational Polar Satellite - A	EUMETSAT (L), CNES, ESA, NOAA	19/out/06 31/ago/18	Em órbita	AMSU-A: Advanced Microwave Sounding Unit-A	Sondas de temperatura atmosférica e umidade – Radiômetros/espectrômetros de micro-ondas	48 km	Micro-ondas: 15 canais, 23,8 - 89,0 GHz
					ASCAT: Advanced Scatterometer	Escaterômetros – Radars escaterômetros	Modo de alta resolução: 25 - 37 km, Modo nominal: 50 km	Micro-ondas: Banda C, 5,256 GHz
DMSP F-17	Defense Meteorological Satellite Program F-17	NOAA (L), USAF	04/nov/06 01/jun/15	Em órbita	SSM/IS: Special Sensor Microwave Imager Sounder	Sondas de temperatura atmosférica e umidade – Radiômetro imageador de micro-ondas com múltiplos propósitos	25 x 17 km até 70 x 42 km (variável com a frequência)	Micro-ondas: 19 - 183 GHz (24 frequências)

Nome da missão	Nome completo da missão	Agências líder (L) e colaboradoras	Data de lançamento e fim da operação	Situação da missão	Instrumentos da missão*	Tipo de instrumento*	Resolução do instrumento*	Bandas do instrumento*
RADARS AT-2	RADARSAT-2	CSA (L), MDA	14/dez/07 17/abr/15	Em órbita	SAR (RADARSAT-2): Synthetic Aperture Radar (CSA) C band	Radar imageador de micro-ondas – SAR	Variável [Melhor resolução: 0,8m]	Banda C 5,405 GHz. Polarização HH, VV, HV, VH
FY-3A	FY-3A Polar-orbiting Meteorological Satellite	NSMC-CMA (L), NRSCC	27/mai/08 31/dez/14	Em órbita	MWRI: MicroWave Radiation Imager	Radiômetros imageadores multiespectrais (micro-ondas passivo) com múltiplos propósitos	7,5 x 12 km em 150 GHz até 51 x 85 km em 10,65 GHz	12 canais, 6 frequências: 10,65 GHz, 18,7 GHz, 23,8 GHz, 36,5 GHz, 89 GHz, 150 GHz
RISAT-2	Radar Imaging Satellite	ISRO (L)	20/abr/09 20/abr/15	Em órbita	SAR-X: Synthetic Aperture Radiometer (RISAT-2)	Radar imageador de micro-ondas – SAR	3 - 8 m	Banda X (9,0 Ghz)
DMSP F-18	Defense Meteorological Satellite Program F-18	NOAA (L), USAF	18/out/09 01/abr/15	Em órbita	SSM/IS: Special Sensor Microwave Imager Sounder	Sondas de temperatura atmosférica e umidade – Radiômetro imageador de micro-ondas com múltiplos propósitos	25 x 17 km até 70 x 42 km (variável com a frequência)	Micro-ondas: 19 - 183 GHz (24 frequências)
SMOS	Soil Moisture and Ocean Salinity (Earth Explorer Opportunity Mission)	ESA (L), CDTI, CNES	02/nov/09 01/fev/17	Em órbita	MIRAS (SMOS): Microwave Imaging Radiometer using Aperture Synthesis (MIRAS)	Radiômetros imageadores multiespectrais (micro-ondas passivo) e radiômetros de múltiplas direções/polarizações – Radiômetro imageador de micro-ondas com múltiplos propósitos	33 - 50 km dependendo da posição - reamostrado para grade de 15 km	Banda L 1,41 GHz
FY-3B	FY-3B Polar-orbiting Meteorological Satellite	NSMC-CMA (L), NRSCC	05/nov/10 31/dez/14	Em órbita	MWRI: MicroWave Radiation Imager	Radiômetros imageadores multiespectrais (micro-ondas passivo) com múltiplos propósitos	7,5 x 12 km em 150 GHz até 51 x 85 km em 10,65 GHz	12 canais, 6 frequências: 10,65 GHz, 18,7 GHz, 23,8 GHz, 36,5 GHz, 89 GHz, 150 GHz
Suomi NPP	Suomi National Polar-orbiting Partnership (NPP, S-NPP)	NASA (L), NOAA	28/out/11 09/mar/17	Em órbita	VIIRS: Visible/Infrared Imager Radiometer Suite	Radiômetro imageador multiespectral (VIS/IV) e instrumentos de coloração oceânica – Radiômetro imageador VIS/IV com múltiplos propósitos	400 m - 1,6 km	VIS - IVT: 0,4 - 12,5 µm (22 canais)
RISAT-1	Radar Imaging Satellite	ISRO (L)	26/abr/12 26/abr/17	Em órbita	SAR (RISAT): Synthetic Aperture Radiometer (RISAT)	Radar imageador de micro-ondas – SAR	Variável entre 3 m e 50 m	Banda C (5,350 Ghz)
GCOM-W	Global Change Observation Mission-W1 (Shizuku)	JAXA (L)	18/mar/12 18/mar/17	Em órbita	AMSR-2: Advanced Microwave Scanning Radiometer -2	Radiômetros imageadores multiespectrais (micro-ondas passivo) com múltiplos propósitos	5 - 50 km (conforme a frequência)	Micro-ondas: 6,925 GHz, 7,3 GHz, 10,65 GHz, 18,7 GHz, 23,8 GHz, 36,5 GHz, 89,0 GHz
Metop-B	Meteorological Operational Polar Satellite – B (Metop-1)	EUMETSAT (L), CNES, ESA, NOAA	17/set/12 17/set/17	Em órbita	AMSU-A: Advanced Microwave Sounding Unit-A	Sondas de temperatura atmosférica e umidade – Radiômetros/espectrômetros de micro-ondas	48 km	Micro-ondas: 15 canais, 23,8 - 89,0 GHz
					ASCAT: Advanced Scatterometer	Escaterômetros – Radares escaterômetros	Modo de alta resolução: 25 - 37 km, Modo nominal: 50 km	Micro-ondas: Banda C, 5,256 GHz

Nome da missão	Nome completo da missão	Agências líder (L) e colaboradoras	Data de lançamento e fim da operação	Situação da missão	Instrumentos da missão*	Tipo de instrumento*	Resolução do instrumento*	Bandas do instrumento*
FY-3C	FY-3C Polar-orbiting Meteorological Satellite	NSMC-CMA (L), NRSCC	23/set/13 23/set/16	Em órbita	MWRI: MicroWave Radiation Imager	Radiômetros imageadores multiespectrais (micro-ondas passivo) com múltiplos propósitos	7,5 x 12 km em 150 GHz até 51 x 85 km em 10,65 GHz	12 canais, 6 frequências: 10,65 GHz, 18,7 GHz, 23,8 GHz, 36,5 GHz, 89 GHz, 150 GHz
GPM Core	Global Precipitation Measurement Mission Core spacecraft	NASA (L), JAXA	27/fev/14 29/mar/17	Em órbita	GMI: GPM Microwave Imager	Radiômetros imageadores multiespectrais (micro-ondas passivo) com múltiplos propósitos	10-36 km	Micro-ondas: 10,65 GHz, 18,7 GHz, 23,8 GHz, 36,5 GHz, 89,0 GHz, 165,5 GHz, 183,31 ± 3 GHz, 183,31 ± 8 GHz
DMSP F-19	Defense Meteorological Satellite Program F-19	NOAA (L), USAF	03/abr/14 01/mar/19	Em órbita	SSM/IS: Special Sensor Microwave Imager Sounder	Sondas de temperatura atmosférica e umidade – Radiômetro imageador de micro-ondas com múltiplos propósitos	25 x 17 km até 70 x 42 km (variável com a frequência)	Micro-ondas: 19 - 183 GHz (24 frequências)
Sentinel-1 A	Sentinel-1 A	ESA (L), EC	03/abr/14 31/jan/21	Em órbita	C-Band SAR: C-Band Synthetic Aperture Radar	Radar imageador de micro-ondas – SAR	Variável entre 9 m e 50 m	Banda C: 5,405 GHz; HH, VV, HH+HV, VV+VH; Ângulo de incidência: 20-45
ALOS-2	Advanced Land Observing Satellite-2 <i>aka</i> DAICHI-2	JAXA (L)	24/mar/14 23/mar/19	Em órbita	PALSAR-2 (ALOS-2): Phased Array type L-band Synthetic Aperture Radar-2	Radar imageador de micro-ondas – SAR	Spotlight mode (1 a 3 m), stripmap mode (3 a 10 m).	Micro-ondas: Banda L 1270 MHz
SMAP	Soil Moisture Active Passive	NASA (L), CSA	28/fev/15 05/jun/18	Aprovada	L-band Radar (SMAP): L-band Synthetic Aperture Radar (SMAP)	Radar imageador de micro-ondas – SAR	Resolução espacial <3 km em 70% da faixa; res. temporal 3 dias. Umidade do solo é estimada com res. de 10 km e estado de congelamento/degelado com res. de 1-3 km.	Banda L (1,2 GHz)
					L-band Radiometer (SMAP)	Radiômetros imageadores multiespectrais (micro-ondas passivo) com múltiplos propósitos	Resolução espacial de 40km; resolução temporal de 3 dias	Banda L (1,4 GHz)
SAOCOM 1A	Satélite Argentino de Observación CON Microondas 1A	CONAE (L), ASI	23/set/15 21/dez/20	Aprovada	SAR-L: L-Band Synthetic Aperture Radar	Radar imageador de micro-ondas – SAR	10 x 10 m – 100 x 100 m	Banda L (1,275 GHz)
Sentinel-1 B	Sentinel-1 B	ESA (L), EC	30/nov/15 01/abr/23	Aprovada	C-Band SAR: C-Band Synthetic Aperture Radar	Radar imageador de micro-ondas – SAR	Variável entre 9 m e 50 m	Banda C: 5,405 GHz; HH, VV, HH+HV, VV+VH; Ângulo de incidência: 20-45
FY-3D	FY-3D Polar-orbiting Meteorological Satellite	NSMC-CMA (L), NRSCC	31/dez/15 31/dez/17	Aprovada	MWRI: MicroWave Radiation Imager	Radiômetros imageadores multiespectrais (micro-ondas passivo) com múltiplos propósitos	7,5 x 12 km em 150 GHz até 51 x 85 km em 10,65 GHz	12 canais, 6 frequências: 10,65 GHz, 18,7 GHz, 23,8 GHz, 36,5 GHz, 89 GHz, 150 GHz
GCOM-W2	Global Climate Observation Mission-W2	JAXA (L)	18/mar/16 18/mar/21	Considerada	AMSR-2: Advanced Microwave Scanning Radiometer -2	Radiômetros imageadores multiespectrais (micro-ondas passivo) com múltiplos propósitos	5 - 50 km (conforme a frequência)	Micro-ondas: 6,925 GHz, 7,3 GHz, 10,65 GHz, 18,7 GHz, 23,8 GHz, 36,5 GHz, 89,0 GHz

Nome da missão	Nome completo da missão	Agências líder (L) e colaboradoras	Data de lançamento e fim da operação	Situação da missão	Instrumentos da missão*	Tipo de instrumento*	Resolução do instrumento*	Bandas do instrumento*
CSG-1	COSMO-SkyMed Seconda Generazione - 1	ASI (L), MoD (Italy)	30/jun/16 30/jun/23	Aprovada	CSG SAR: COSMO Seconda Generazione SAR	Radar imageador de micro-ondas – SAR	Variável entre 0,8x0,8 m e 6x40 m	Micro-ondas: Banda X (9,6 GHz). Polarização single, dual e quad
SAOCOM 1B	Satélite Argentino de Observación CON Microondas 1B	CONAE (L), ASI	23/set/16 21/dez/21	Aprovada	SAR-L: L-Band Synthetic Aperture Radar	Radar imageador de micro-ondas – SAR	10 x 10 m – 100 x 100 m	Banda L (1,275 GHz)
JPSS-1	Joint Polar Satellite System - 1	NOAA (L), EUMETSAT, NASA	01/jan/17 01/mar/24	Aprovada	VIIRS: Visible/Infrared Imager Radiometer Suite	Radiômetro imageador multiespectral (VIS/IV) e instrumentos de coloração oceânica – Radiômetro imageador VIS/IV com múltiplos propósitos	400 m - 1,6 km	VIS - IVT: 0,4 - 12,5 µm (22 canais)
CSG-2	COSMO-SkyMed Seconda Generazione - 2	ASI (L), MoD (Italy)	30/jun/17 30/jun/24	Aprovada	CSG SAR: COSMO Seconda Generazione SAR	Radar imageador de micro-ondas – SAR	Variável entre 0,8x0,8 m e 6x40 m	Micro-ondas: Banda X (9,6 GHz). Polarização single-, dual- e quad-
GRACE FO	Gravity Recovery and Climate Experiment - Follow-on	NASA (L), GFZ	05/ago/17 05/nov/22	Aprovada	GRACE instrument	Instrumentos gravitacionais – Sistema satélite a satélite	400 km horizontal	Micro-ondas: 24 GHz e 32 GHz
Metop-C	Meteorological Operational Polar Satellite – C (Metop-3)	EUMETSAT (L), CNES, ESA, NOAA	01/fev/18 01/dez/21	Aprovada	AMSU-A: Advanced Microwave Sounding Unit-A	Sondas de temperatura atmosférica e umidade – Radiômetros/espectrômetros de micro-ondas	48 km	Micro-ondas: 15 canais, 23,8 - 89,0 GHz
					ASCAT: Advanced Scatterometer	Escaterômetros – Radares escaterômetros	Modo de alta resolução: 25 - 37 km, Modo nominal: 50 km	Micro-ondas: Banda C, 5,256 GHz
SAOCOM-2A	Satélite Argentino de Observación CON Microondas 2A	CONAE (L)	01/jan/19 01/jan/24	Planejada	SAR-L: L-Band Synthetic Aperture Radar	Radar imageador de micro-ondas – SAR	10 x 10 m – 100 x 100 m	Banda L (1,275 GHz)
Sentinel-1 C	Sentinel-1 C	ESA (L), EC	31/mar/19 30/jun/26	Considerada	C-Band SAR: C-Band Synthetic Aperture Radar	Radar imageador de micro-ondas – SAR	Variável entre 9 m e 50 m	Banda C: 5,405 GHz; HH, VV, HH+HV, VV+VH; ângulo de incidência: 20-45
RISAT-1A	Radar Imaging Satellite	ISRO (L)	01/set/19 01/set/23	Considerada	SAR (RISAT): Synthetic Aperture Radiometer (RISAT)	Radar imageador de micro-ondas – SAR	Variável entre 3 m e 50 m	Banda C (5,350 GHz)
FY-3F	FY-3F Polar-orbiting Meteorological Satellite	NSMC-CMA (L), NRSCC	31/dez/19 31/dez/22	Planejada	MVIRS: Moderate Resolution Visible and Infrared Imaging Spectroradiometer	Radiômetro imageador multiespectral (VIS/IV) – Radiômetro imageador VIS/IV com múltiplos propósitos	-	VIS - IVT: 0,47 - 12,5 µm (20 canais)
					MWRI: MicroWave Radiation Imager	Radiômetros imageadores multiespectrais (micro-ondas passivo) com múltiplos propósitos	7,5 x 12 km em 150 GHz até 51 x 85 km em 10,65 GHz	12 canais, 6 frequências: 10,65 GHz, 18,7 GHz, 23,8 GHz, 36,5 GHz, 89 GHz, 150 GHz

Nome da missão	Nome completo da missão	Agências líder (L) e colaboradoras	Data de lançamento e fim da operação	Situação da missão	Instrumentos da missão*	Tipo de instrumento*	Resolução do instrumento*	Bandas do instrumento*
DMSP F-20	Defense Meteorological Satellite Program F-20	NOAA (L), USAF	01/jan/20 01/jan/25	Aprovada	SSM/IS: Special Sensor Microwave Imager Sounder	Sondas de temperatura atmosférica e umidade – Radiômetro imageador de micro-ondas com múltiplos propósitos	25 x 17 km até 70 x 42 km (variável com a frequência)	Micro-ondas: 19 - 183 GHz (24 frequências)
SAOCOM-2B	Satélite Argentino de Observación CON Microondas 2B	CONAE (L)	01/jan/20 01/jan/25	Planejada	SAR-L: L-Band Synthetic Aperture Radar	Radar imageador de micro-ondas – SAR	10 x 10 m – 100 x 100 m	Banda L (1,275 GHz)
GCOM-W3	Global Change Observation Mission-W3	JAXA (L)	18/mai/20 18/mai/25	Considerada	AMSR-2: Advanced Microwave Scanning Radiometer -2	Radiômetros imageadores multiespectrais (micro-ondas passivo) com múltiplos propósitos	5 - 50 km (conforme a frequência)	Micro-ondas: 6,925 GHz, 7,3 GHz, 10,65 GHz, 18,7 GHz, 23,8 GHz, 36,5 GHz, 89,0 GHz
NISAR	NASA ISRO - Synthetic Aperture Radar (Dual Frequency SAR Mission)	NASA (L), ISRO	29/dez/20 01/mar/25	Planejada	S-band SAR (NISAR): S-band Synthetic Aperture Radar (SAR) (NISAR)	Radar imageador de micro-ondas – SAR	10 m, com revisita em 12 dias, cobertura global [Melhor resolução: 1m]	Banda S: 4-2 GHz
JPSS-2	Joint Polar Satellite System - 2	NOAA (L), EUMETSAT, NASA	01/out/21 01/jul/27	Aprovada	VIIRS: Visible/Infrared Imager Radiometer Suite	Radiômetro imageador multiespectral (VIS/IV) e instrumentos de coloração oceânica – Radiômetro imageador VIS/IV com múltiplos propósitos	400 m - 1,6 km	VIS - IVT: 0,4 - 12,5 µm (22 canais)
FY-3G	FY-3G Polar-orbiting Meteorological Satellite	NSMC-CMA (L), NRSCC	31/dez/21 31/dez/24	Considerada	MVIRS: Moderate Resolution Visible and Infrared Imaging Spectroradiometer	Radiômetro imageador multiespectral (VIS/IV) – Radiômetro imageador VIS/IV com múltiplos propósitos	-	VIS - IVT: 0,47 - 12,5 µm (20 canais)
GRACE-II	Gravity Recovery and Climate Experiment	NASA (L)	03/jan/30 03/abr/33	Considerada	GRACE instrument	Instrumentos gravitacionais – Sistema satélite a satélite	400 km horizontal	Micro-ondas: 24 GHz e 32 GHz

ANEXO B

Neste anexo é apresentada uma descrição do modelo de grandes bacias MGB-IPH, baseada na descrição original de Collischonn (2001) e na descrição atualizada de Paiva (2009).

Modelo Hidrológico de Grandes Bacias: MGB-IPH

B.1 Introdução

O modelo MGB-IPH (COLLISCHONN, 2001) é um modelo hidrológico distribuído de grande escala baseado em processos que utilizam equações físicas e conceituais para simular, com passo de tempo diário ou horário, os processos hidrológicos na superfície terrestre, divididos em quatro módulos: balanço hídrico no solo; balanço de energia e evapotranspiração; interceptação, geração e propagação de escoamentos superficial, subsuperficial e subterrâneo nos elementos de discretização da bacia hidrográfica; e propagação de vazão na rede de drenagem.

Desenvolvido por Collischonn (2001) com base nos modelos LARSIM, apresentado por Bremicker (1998), e VIC-2L (WIGMOSTA *et al.*, 1994; LIANG *et al.*, 1994; NIJSSEM *et al.*, 1997), o modelo MGB-IPH trabalha com uma discretização em minibacias, as quais são ainda subdivididas em Unidades de Respostas Hidrológicas (URH) (Figura B.1), que são áreas de comportamento hidrológico similar definidas por uma combinação de mapas de cobertura da terra e de tipo do solo (KOUWEN *et al.*, 1993). Em cada minibacia as características de uso de solo, cobertura vegetal e tipo de solo são sintetizadas nas URH.

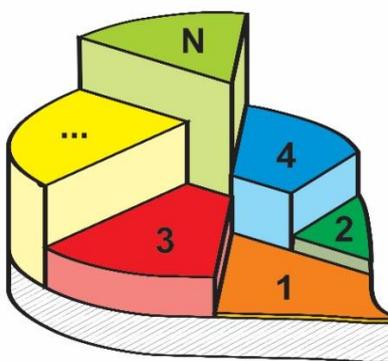


Figura B.1. Minibacia do modelo MGB-IPH dividida em N classes de uso, tipo e cobertura do solo (URH).

Para a aplicação do modelo são necessários dados hidrológicos e meteorológicos; os quais consistem em arquivos que contenham informações de vazão, chuva e clima, sendo este último constituído de dados de temperatura, pressão, insolação, umidade relativa do ar e velocidade do vento. Estes dados são associados aos centróides das minibacias por interpolação dos postos com dados mais próximos.

O balanço vertical de água e de energia são computados independentemente para cada URH em cada minibacia. A interceptação d'água pela cobertura vegetal é representada por um reservatório cuja capacidade máxima é função do índice de área foliar. O balanço de água no solo é realizado em uma camada, considerando o solo como um reservatório único de água. O conceito de área de contribuição variável do modelo ARNO (TODINI, 1996) é utilizado para computar a infiltração de água no solo e o escoamento superficial. Este mesmo conceito tem sido utilizado em modelos como o PDM (MOORE & CLARKE, 1981), VIC2L e LARSIM. Para o balanço de energia o modelo utiliza variáveis meteorológicas de superfície, sendo a evaporação do solo, da vegetação e do dossel na atmosfera estimada com base na equação de Penman-Monteith (SHUTTLEWORTH, 1993).

Em cada URH das minibacias são determinados os volumes de escoamento superficial, subsuperficial (ou interno) e subterrâneo. Para a determinação do escoamento subsuperficial é usada uma equação semelhante a equação de condutividade hidráulica não-saturada de Brooks e Corey (RAWLS *et al.*, 1993), enquanto o volume percolado da camada superficial do solo ao lençol freático é estimado por uma relação linear simples entre o armazenamento atual e o máximo de armazenamento de água no solo. Os volumes de escoamentos gerados a nível das URH dentro de cada minibacia são propagados para a rede de drenagem usando três reservatórios lineares simples, sendo um para cada tipo de escoamento: subterrâneo, interno (subsuperficial) e superficial. Na rede de drenagem, o volume total de escoamento gerado em cada minibacia é propagado utilizando o método de Muskingum-Cunge ou uma propagação mista composta por este método e o modelo hidrodinâmico introduzido por Paiva (2009). Para o transporte na rede de drenagem, independentemente do método de propagação, cada trecho de rio é subdividido, segundo critérios específicos, e os hidrogramas de vazão podem ser avaliados no exutório das minibacias bem como em qualquer outro ponto ao longo da rede de drenagem representada. A seguir, são apresentados os processos hidrológicos e hidráulicos

simulados pelo modelo MGB-IPH, com base na descrição original de Collischonn (2001) e na descrição atualizada de Paiva (2009).

B.2 Processos Hidrológicos Verticais

O balanço de água no solo e o de energia são feitos independentemente em cada URH das minibacias, utilizando suas características e parâmetros associados. Os processos verticais simulados pelo modelo MGB-IPH envolvem o balanço de água no solo, a interceptação, a percolação da água para o aquífero e o fluxo ascendente e a geração dos escoamentos superficial, subsuperficial e subterrâneo. Este processos estão apresentados no esquema da Figura B.2.

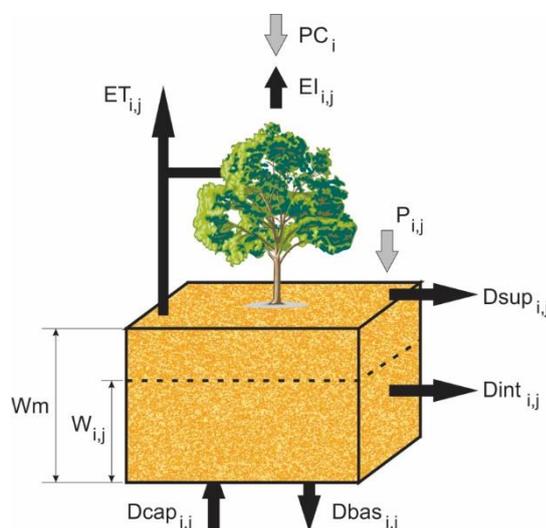


Figura B.2. Esquema do balanço de água no solo do modelo MGB-IPH para uma Unidade de Resposta Hidrológica. Adaptado de Collischonn (2001).

B.2.1 Interceptação

A interceptação é o processo de retenção de água da chuva pela vegetação antes da sua chegada à superfície do solo. No modelo, esse processo é representado por um reservatório de volume máximo (S_{max}) dependente da densidade de vegetação que cobre o solo, a qual é indicada pelo Índice de Área Foliar (IAF). Este índice expressa a relação entre a área total das folhas da vegetação e a área superficial do solo e o seu valor depende do tipo de vegetação (menor que 1,0 em vegetação rasteira e 6,0 ou mais em florestas), podendo variar ao longo do ano em casos como o de culturas agrícolas. O valor de S_{max} do reservatório de interceptação é dado por:

$$Smax_j = \alpha \cdot IAF_j \quad (24)$$

Onde:

$Smax_j$ [mm]: Volume máximo de interceptação;

IAF_j [$m \cdot m^{-1}$]: Índice de Área Foliar da URH j de uma minibacia.

α [mm]: Parâmetro da lâmina de interceptação. Possui valor fixo e igual a 0,2 mm.

No reservatório de interceptação, o balanço hídrico é dados pelas seguintes equações:

$$S_{i,j}^t = \min(S_{i,j}^{t-1} + PC_i, Smax_j) \quad (25)$$

$$P_{i,j} = PC_i - (S_{i,j}^t + S_{i,j}^{t-1}) \quad (26)$$

$$S_{i,j}^t = S_{i,j}^t - EI_{i,j} \quad (27)$$

$$EI_{i,j} = \min(S_{i,j}^t, EPI_{i,j}) \quad (28)$$

Onde:

$S_{i,j}$ [mm]: Lâmina de água interceptada na URH j da minibacia i ;

PC_i [mm]: Precipitação no topo da cobertura vegetal em qualquer minibacia i ;

$P_{i,j}$ [mm]: Precipitação sobre a camada superficial do solo na URH j , da minibacia i ;

$EI_{i,j}$ [mm]: Evaporação real da lâmina d'água interceptada na URH j , da minibacia i ;

$EPI_{i,j}$ [mm]: Evaporação potencial da lâmina d'água interceptada na URH j , da minibacia i .

A evaporação potencial da lâmina d'água interceptada é calculada pela equação de Penman-Monteith com o parâmetro resistência superficial igual a zero. Os índices $t-1$, e t correspondem ao início e ao final do intervalo de tempo de cálculo, respectivamente.

B.2.2 Balanço hídrico no solo

O balanço da água no solo, computado para cada URH j da minibacia i , é descrito pelo modelo através da equação abaixo:

$$W_{i,j}^t = W_{i,j}^{t-1} + (P_{i,j} - ET_{i,j} - Dsup_{i,j} - Dint_{i,j} - Dbas_{i,j} + Dcap_{i,j}) \quad (29)$$

Onde:

$W_{i,j}$ [mm]: Armazenamento de água na camada superficial do solo na URH j da minibacia i ;

$P_{i,j}$ [mm]: Parcela da precipitação que atinge a superfície do solo (Equação (26));

$ET_{i,j}$ [mm]: Evapotranspiração da água no solo;

$Dsup_{i,j}$ [mm]: Escoamento superficial;

$Dint_{i,j}$ [mm]: Escoamento subsuperficial ou interno;

$Dsub_{i,j}$ [mm]: Escoamento subterrâneo;

$Dcap_{i,j}$ [mm]: Escoamento ascendente do aquífero para a camada superficial do solo.

B.2.3 Evapotranspiração

O modelo calcula a evapotranspiração através da equação de Penman-Monteith (SHUTTLEWORTH, 1993), a qual utiliza dados meteorológicos e parâmetros relativos às características aerodinâmicas e dos estômatos das plantas:

$$ET = \frac{fc}{\lambda \cdot \rho_w} \left[\frac{\Delta \cdot (S_n - L_n - G) + \rho_a \cdot c_p \cdot \left(\frac{e_s - e_d}{r_a} \right)}{\Delta + \gamma \cdot \left(1 + \frac{r_s}{r_a} \right)} \right] \quad (30)$$

Onde:

ET [mm.dia⁻¹]: Taxa de evaporação da água;

λ [MJ.kg⁻¹]: Calor latente de vaporização;

ρ_w [kg.m⁻³]: Massa específica da água, igual a 1000 kg.m⁻³;

Δ [kPa.°C⁻¹]: Gradiente da pressão de saturação do vapor em relação à temperatura;

S_n [MJ.m⁻².s⁻¹]: Radiação líquida de onda curta;

L_n [MJ.m⁻².s⁻¹]: Radiação líquida de onda longa;

G [MJ.m⁻².s⁻¹]: Fluxo de energia para o solo;

ρ_a [kg.m⁻³]: Massa específica do ar;

c_p [MJ.kg⁻¹.°C⁻¹]: Calor específico do ar úmido, igual a 1,013.10⁻³ MJ.kg⁻¹.°C⁻¹;

e_s [kPa]: Pressão de saturação do vapor;

e_d [kPa]: Pressão do vapor;

γ [kPa.°C⁻¹]: Constante psicrométrica, igual a 0,66 kPa °C⁻¹;

r_a [s.m⁻¹]: Resistência aerodinâmica;

r_s [s.m⁻¹]: Resistência superficial da vegetação;

fc : um fator de conversão de unidades, igual a 3,6x10⁻⁶.

A energia disponível para a evapotranspiração é primeiramente utilizada para evaporar a água interceptada e o restante da energia, se ainda houver, fica disponível para atender a transpiração da vegetação. A evaporação potencial (*EPI*) é calculada utilizando a Equação (30) considerando a resistência superficial (r_s) nula e a resistência aerodinâmica dependente da velocidade do vento e da altura média da vegetação.

B.2.4 Escoamento superficial

O escoamento superficial gerado em cada URH é o escoamento direto efetivo, aquele que chega rapidamente à rede de drenagem. No modelo, considera-se que a ocorrência de escoamento superficial se dá apenas em áreas saturadas, as quais são variáveis em função do nível de saturação da bacia, seguindo um processo Dunniano (DUNNE & BLACK, 1970). Para a geração desse escoamento utiliza-se uma relação

probabilística entre umidade do solo e fração de área saturada (áreas onde a infiltração é nula) conforme apresentada por Moore & Clarke (1981):

$$X = 1 - \left(1 - \frac{W}{Wm}\right)^{\frac{b}{b+1}} \quad (31)$$

Onde:

X : Fração da área que está saturada;

W [mm]: Volume de água armazenada no solo;

Wm [mm]: Capacidade máxima de armazenamento de água no solo;

b [-]: um parâmetro do modelo associado à URH que define o grau de heterogeneidade da capacidade de armazenamento de água no solo.

O escoamento superficial $Dsup$ entre dois passos de tempo consecutivos ($t-1$ e t) é obtido para cada URH j de uma minibacia i por:

$$Dsup_{i,j} = P_{i,j} \cdot \Delta t - (Wm_j - W_{i,j}^{t-1}) \quad \text{se } A \leq 0 \quad (32)$$

$$Dsup_{i,j} = P_{i,j} \cdot \Delta t - (Wm_j - W_{i,j}^{t-1}) + Wm_j \cdot A^{b_j+1} \quad \text{se } A > 0 \quad (33)$$

Onde:

$P_{i,j}$ [mm]: Precipitação efetiva que chega à superfície do solo da URH j da minibacia i ;

$Dsup_{i,j}$ [mm]: Escoamento superficial da URH j da minibacia i ;

A : um limite dado pela expressão:

$$A = \left[\left(1 - \frac{W_{i,j}^{t-1}}{Wm_j}\right)^{\frac{b}{b+1}} - \frac{P_{i,j} \cdot \Delta t}{Wm_j \cdot (b_j + 1)} \right] \quad (34)$$

B.2.5 Escoamento subsuperficial

O escoamento subsuperficial é aquele mais lento que o superficial, porém mais rápido que o subterrâneo. Para descrever este escoamento o modelo utiliza uma equação não-linear com relação à umidade do solo que relaciona a condutividade hidráulica do solo com a sua textura, semelhante à equação apresentada por Brooks e Corey (RAWLS *et al.*, 1993). A equação é dada por:

$$Dint_{i,j} = Kint_j \cdot \left(\frac{W_{i,j}^{t-1} - W_{z_j}}{W_{m_j} - W_{z_j}} \right)^{3 + \frac{2}{\lambda_j}} \quad (35)$$

Onde:

$Dint_{i,j}$ [mm]: Volume de escoamento subsuperficial na URH j da minibacia i ;

$Kint_j$ [mm.dia⁻¹]: um parâmetro de drenagem subsuperficial;

W_{z_j} [mm]: Limite mínimo de armazenamento de água no solo a partir do qual haverá geração de escoamento superficial;

λ_j [-]: Índice de porosidade de solo.

B.2.6 Escoamento subterrâneo

O volume percolado ao aquífero é calculado por uma relação linear do volume de água armazenado no solo. Para cada intervalo de tempo, o volume de escoamento subterrâneo $Dbas_{i,j}$ de cada URH j da minibacia i é obtido por:

$$Dbas_{i,j} = Kbas_j \cdot \left(\frac{W_{i,j}^{t-1} - W_{c_j}}{W_{m_j} - W_{c_j}} \right) \quad (36)$$

Onde:

W_{c_j} [mm]: Limite mínimo de armazenamento de água no solo a partir do qual não há percolação;

$Kbas_j$ [mm]: Parâmetro que define a máxima percolação quando o solo está saturado.

B.2.7 Fluxo capilar ascendente

Em situações de estresse hídrico, quando a zona saturada do aquífero se encontra em baixas profundidades, pode ocorrer uma transferência de água do reservatório subterrâneo para a zona não saturada do solo. Este movimento ascendente ocorre por diferença de potencial ou pela existência de vegetação com raízes profundas o suficiente para retirar água diretamente do aquífero. No modelo, esse fluxo ascendente é determinado por:

$$Dcap_{i,j} = \left(\frac{Wc_j - W_{i,j}^{t-1}}{Wc_j} \right) \cdot DMcap_j \quad (37)$$

Onde:

Wc_j [mm]: Limite máximo de armazenamento de água no solo para haver fluxo ascendente;

$DMcap_j$ [mm]: Máximo fluxo ascendente no solo.

B.3 Processos Hidrológicos Horizontais

Nem todo o volume dos escoamentos gerados nas minibacias chega à sua correspondente rede de drenagem no mesmo passo de tempo, mas sofrem retardo e amortecimento. No modelo, esses retardo e amortecimento dos hidrogramas dos escoamentos são considerados através da passagem deles por três reservatórios lineares, sendo um para cada tipo de escoamento gerado: superficial, subsuperficial (ou interno) e subterrâneo. Os volumes armazenados nos três reservatórios são computados por:

$$Vsup_i^{t'} = Vsup_i^{t-1} + \sum_{j=1}^{N_{URH}} (1000 \cdot Dsup_{i,j} \cdot A_{i,j}) \quad (38)$$

$$Vint_i^{t'} = Vint_i^{t-1} + \sum_{j=1}^{N_{URH}} (1000 \cdot Dint_{i,j} \cdot A_{i,j}) \quad (39)$$

$$Vbas_i^{t'} = Vbas_i^{t-1} + \sum_{j=1}^{N_{URH}} (Dbas_{i,j} - Dcap_{i,j}) \cdot 1000 \cdot A_{i,j} \quad (40)$$

Onde:

$Vsup_i$ [m³]: Volume no reservatório superficial na minibacia i ;

$Vint_i$ [m³]: Volume no reservatório subsuperficial na minibacia i ;

$Vbas_i$ [m³]: Volume no reservatório subterrâneo na minibacia i ;

$A_{i,j}$ [km²]: Área da URH j da minibacia i .

O índice j indica o número da URH e N_{URH} é número de URHs existentes, ambos relacionados à minibacia i considerada.

A vazão de saída de cada reservatório com destino à rede de drenagem é computada como uma função linear do respectivo volume armazenado no reservatório e do tempo de concentração da minibacia. As equações que estimam as vazões de saídas são:

$$Qsup_i = \frac{1}{TKS_i} Vsup_i^{t'} \quad (41)$$

$$Qint_i = \frac{1}{TKI_i} Vint_i^{t'} \quad (42)$$

$$Qbas_i = \frac{1}{TKB_i} Vbas_i^{t'} \quad , \text{ com } TKB = CB * 3600 \quad (43)$$

Onde:

$Qsup_i$ [m³.s⁻¹]: Vazão de saída do reservatório superficial, na minibacia i ;

$Qint_i$ [m³.s⁻¹]: Vazão de saída do reservatório subsuperficial, na minibacia i ;

$Qsub_i$ [m³.s⁻¹]: Vazão de saída do reservatório subterrâneo, na minibacia i ;

TKS_i [s]: Tempo de retardo do reservatório superficial, na minibacia i ;

TKI_i [s]: Tempo de retardo do reservatório subsuperficial, na minibacia i ;

TKB_i [s]: Tempo de retardo do reservatório subterrâneo, na minibacia i ;

CB [h]: um parâmetro calibrável que controla o retardo do escoamento subterrâneo na minibacia e pode ser pré-estimado a partir dos dados de recessão dos hidrogramas.

Os valores de TKS e TKI são obtidos em função do tempo de concentração Tc_i [s] da minibacia e controlados pelos parâmetros calibráveis CS [-] e CI [-]:

$$TKS_i = CS \cdot Tc_i \quad (44)$$

$$TKI_i = CI \cdot Tc_i \quad (45)$$

O tempo de concentração Tc_i [s] da minibacia i calculado pela fórmula de Kirpich:

$$Tc_i = a \frac{L_i^b}{S_i^c} \quad (46)$$

Onde:

L_i [km]: Comprimento do maior afluente do rio principal da minibacia i .

S_i [m.m⁻¹]: Declividade do maior afluente do rio principal da minibacia i .

Os índices a , b e c são fixos com valores iguais a, respectivamente, 239,04, 0,77 e 0,385.

Finalmente, a vazão $Qmini_i$ [m³.s⁻¹] que chega ao trecho de rio da minibacia é o somatório das vazões dos escoamentos superficial, subsuperficial e subterrâneo:

$$Qmini_i = Qsup_i + Qint_i + Qbas_i . \quad (47)$$

B.3.1 Propagação de vazões na rede de drenagem

As minibacias da discretização são interligadas entre si pela sua rede de drenagem, de forma que cada uma escoar para uma minibacia de jusante através do seu próprio exutório. A vazão gerada em uma minibacia é somada às vazões de montante do seu rio principal para posterior propagação até seu exutório ou considerada diretamente como a vazão no seu exutório, conforme o caso. Nas minibacias de cabeceira, aquelas que não possuem escoamento vindo de montante, o modelo não realiza a propagação de vazão nos trechos de rios correspondentes, mas considera que toda vazão saindo dos reservatórios

lineares das minibacias é destinada diretamente ao exutório da mesma. Apenas nas minibacias internas, aquelas que recebem contribuição de montante, é realizada a propagação de vazão em seus respectivos trechos de rio. Um esquema dos processos de geração e propagação de escoamentos nas minibacias e de propagação de vazão na rede de drenagem está ilustrado na Figura B.3.

No modelo MGB-IPH, a propagação tradicional de vazões nos trechos de rios das minibacias é realizada utilizando o método de Muskingum-Cunge, conforme apresentado em Tucci (2005). Em cada trecho de rio são consideradas diversas seções de cálculo, as quais são definidas discretizando o trecho em sub-trechos de acordo com critérios de precisão numérica, de forma que os hidrogramas de saída podem ser avaliados tanto no exutório de cada minibacia (fim do sub-trecho mais de jusante do trecho) como em cada uma dessas seções. Para uma melhor precisão no tempo de viagem e no amortecimento do hidrograma, além da sub-divisão dos trechos de rios, o passo de tempo diário também é sub-dividido pelo modelo em intervalos menores durante a propagação (TUCCI, 2005).

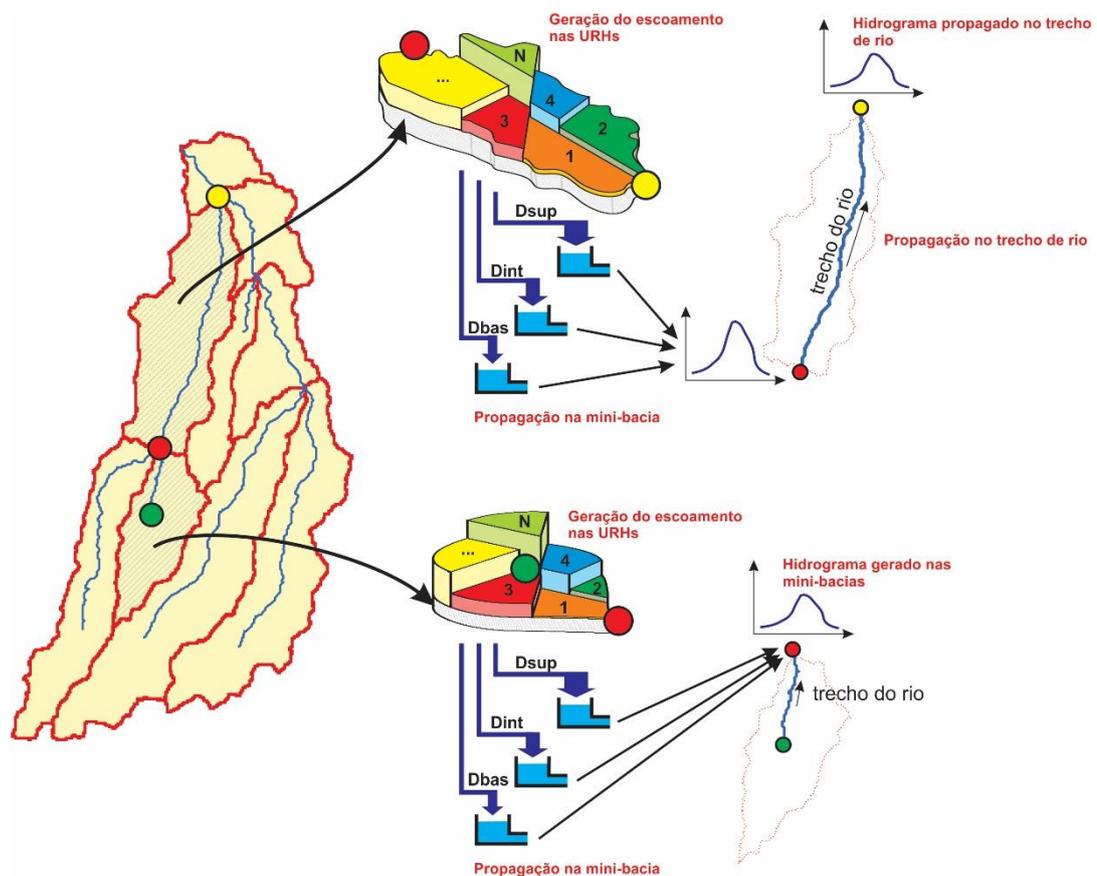


Figura B.3. Esquema dos processos de geração e propagação de escoamentos nas minibacias e propagação de vazão na rede de drenagem.

A vazão de saída de um trecho de rio em um intervalo de tempo qualquer é obtida em função das vazões de entrada e saída no intervalo de tempo anterior e da vazão de entrada no intervalo atual, como mostra a equação abaixo.

$$Q_{i+1}^{t+1} = C1 \cdot Q_i^t + C2 \cdot Q_i^{t+1} + C3 \cdot Q_{i+1}^t \quad (48)$$

Sendo Q [$m^3 \cdot s^{-1}$] a vazão; i e $i+1$ as seções de cálculo de montante (entrada) e jusante (saída) de determinado sub-trecho de rio; t e $t+1$ o início e o final do intervalo de tempo de cálculo Δt [s].

Os coeficientes $C1$, $C2$ e $C3$ são calculados pelas expressões:

$$C1 = \frac{2 \cdot K \cdot X + \Delta t}{2 \cdot K \cdot (1 - X) + \Delta t} \quad (49)$$

$$C2 = \frac{\Delta t - 2 \cdot K \cdot X}{2 \cdot K \cdot (1 - X) + \Delta t} \quad (50)$$

$$C3 = \frac{2 \cdot K \cdot (1 - X) - \Delta t}{2 \cdot K \cdot (1 - X) + \Delta t} \quad (51)$$

Com seus parâmetros de tempo K [s] e de espaço X [-] dados por:

$$K = \frac{\Delta t}{c_0} \quad (52)$$

$$X = 0,5 - \frac{Q_0}{B_0 \cdot S_0 \cdot c_0 \cdot \Delta x} \quad (53)$$

Onde Q_0 [$m^3 \cdot s^{-1}$] é uma vazão de referência; B_0 [m] a largura do rio; S_0 [$m \cdot m^{-1}$] a declividade do sub-trecho; c_0 [$m \cdot s^{-1}$] a celeridade cinemática; Δx [m] o comprimento do sub-trecho de rio.

Dada a escala de aplicação do modelo, a vazão de referência Q_0 e a largura do rio B_0 são estimados utilizando "relações geomorfológicas" construídas relacionando cada uma destas variáveis à área de contribuição da bacia a montante do trecho de rio. O comprimento e a declividade dos trechos podem ser obtidos através de Modelos Digitais de Elevação (MDE). A celeridade cinemática é obtida da equação de Manning, considerando o caso particular de um canal com seção retangular:

$$c_0 = \frac{5}{3} \cdot \frac{Q_0^{0,4} \cdot S_0^{0,3}}{n^{0,6} \cdot B_0} \quad (54)$$

Onde:

n [-]: Coeficiente de Manning do trecho.

Para minimizar os erros numéricos devido ao esquema de solução, o intervalo de tempo de cálculo Δt [s] e o comprimento do sub-trecho Δx [m] são dados por (FREAD, 1993):

$$\Delta t \leq \frac{Tr}{M} \quad (55)$$

$$\Delta x \leq 0,5 \cdot \Delta t \cdot \left[1 + \left(1 + \frac{3 \cdot Q_0}{2 \cdot B_0 \cdot S_0 \cdot c_0^2 \cdot \Delta t} \right) \right] \quad (56)$$

Sendo Tr [s] o tempo de subida da onda de cheia e M um parâmetro que deve ser sempre maior que 5.

B.3.2 Propagação de vazões na rede de drenagem com o modelo hidrodinâmico

Como já mencionado anteriormente, o método de Muskingum-Cunge, até então utilizado no processo de propagação de vazões na rede de drenagem do modelo MGB-IPH, é uma metodologia simplificada que nem sempre consegue representar todas as características da hidráulica fluvial presentes em grandes rios mantenedores de extensas planícies de inundação e significativos efeitos de remanso. Embora seja um aspecto importante no comportamento de muitas bacias hidrográficas de grandes escalas, particularmente naquelas que apresentam um sistema de drenagem relativamente plano, a hidrodinâmica do rio pode ser prejudicada com a utilizações de métodos simplificados de propagação. Na bacia do rio Amazonas, por exemplo, estes aspectos são importantes não só no rio principal como na maioria dos seus principais afluentes (Madeira, Solimões, Negro, Purus, Juruá e Japurá). A influência do rio Amazonas sobre seus afluentes, principalmente relacionada aos efeitos de remanso, já foi apresentada em diversos estudos (ex.: MEADE, 1991 e TRIGG *et al.*, 2009).

Recentemente, buscando considerar os casos citados acima, Paiva (2009) introduziu no modelo MGB-IPH um modelo de propagação hidrodinâmica unidimensional baseado no modelo IPH-IV (TUCCI, 1978; TUCCI, 2005). O modelo

incorporado possui base física e simula vazões e níveis em redes de canais com confluências e defluências, planícies de inundação e condições de contorno internas como vertedores ou descarregadores de fundo de barragens. Para possibilitar a sua aplicação em grandes bacias hidrográficas, que geralmente apresentam escassez de dados, o modelo considera dados usualmente encontrados em escalas globais e usa algoritmos baseados em GIS para extração dos parâmetros e das informações necessárias diretamente de Modelos Digitais de Elevação (MDE), como o do SRTM. Aqui será apresentada uma compilação da metodologia do modelo hidrodinâmico e maiores detalhes podem conseguidos em Paiva (2009) e Paiva *et al.* (2011b).

As equações fundamentais do modelo são as equações completas de Saint Venant (CUNGE *et al.*, 1980), compostas pelas equações da continuidade e dinâmica dadas por, respectivamente:

$$\frac{\partial Q}{\partial x} + B \frac{\partial h}{\partial t} = q_{mini} - q_{fl} \quad (57)$$

$$\frac{\partial Q}{\partial t} + 2v \frac{\partial Q}{\partial x} + (gA - v^2 B) \frac{\partial h}{\partial x} - v^2 \frac{\partial A}{\partial x} \Big|_{h=cte} = gA(S_0 - S_f) \quad (58)$$

Onde:

Q [$m^3 \cdot s^{-1}$]: Vazão do rio;

t [s]: Dimensão tempo;

x [m]: Dimensão espacial ao longo do eixo do rio;

B [m]: Largura da seção transversal do rio na elevação correspondente à superfície livre;

h [m]: Profundidade d'água;

q_{mini} [$m^2 \cdot s^{-1}$]: Contribuição lateral da minibacia (vazão total da minibacia que chega à drenagem dividida pelo comprimento do trecho);

q_{fl} [$m^2 \cdot s^{-1}$]: Vazão lateral de troca entre o rio e a planície de inundação;

v [$m \cdot s^{-1}$]: Velocidade média do escoamento na seção;

g [$\text{m}\cdot\text{s}^{-2}$]: Aceleração devido à gravidade;

A [m^2]: Área da seção transversal perpendicular à direção do escoamento;

S_0 e S_f : Declividades de fundo e de atrito, respectivamente. A declividade de atrito é estimada utilizando a equação de Manning.

O modelo discretiza cada trecho de rio em sub-trechos e seções transversais, onde as variáveis hidráulicas são computadas, e divide cada minibacia em "unidades de planícies de inundação", que são as áreas de drenagem entre duas seções de cálculo. São nessas unidades que ocorrem as trocas d'água entre o rio e a planície de inundação e onde são computados os armazenamentos de água da planície.

As planícies de inundação são simuladas considerando um modelo de armazenamento simples, no qual a velocidade longitudinal do escoamento na planície é nula e os seus níveis d'água são iguais ao nível d'água do canal principal. Apenas a troca de vazão lateral é permitida entre rios e planícies. Desta forma, as planícies funcionam apenas como áreas de armazenamento dos volumes d'água trocados com o rio principal, cuja vazão de troca q_{fl} por unidade de comprimento do trecho é dada por:

$$q_{fl} = \frac{A_{fl}(z)}{dx} \frac{\partial h}{\partial t} = L_{fl}(z) \frac{\partial h}{\partial t} \quad (59)$$

Sendo:

A_{fl} [m^2]: Área da superfície inundada na "unidade de planície";

L_{fl} [m]: Largura equivalente da unidade de planície, considerada igual a diferença entre a largura de um retângulo de comprimento igual ao do sub-trecho de rio e área igual à inundada e a largura B do rio.

O modelo permite trabalhar com um sistema de propagação mista, na qual o método de Muskingum-Cunge é utilizado nos trechos de rios de cabeceiras, ou em trechos onde a declividade é geralmente superior a 20 cm/km e não há significativos efeitos de remanso nem de planícies de inundações, enquanto o modelo hidrodinâmico 1D é adotado apenas nos demais trechos da rede de drenagem, caracterizados por declividades baixas (geralmente menores que 20 cm/km), extensas planícies de inundações e significativos efeitos de remanso. O limite de declividade sugerido para a separação é baseado no

critério de aplicabilidade de modelos de onda cinemática de Ponce (1989). Embora o modelo hidrodinâmico possa ser aplicado a todos os trechos de rios, a separação entre os dois métodos de propagação pode ser necessária para evitar o excessivo custo computacional despendido na sua aplicação a todos os trechos de rios de uma grande bacia.

O escoamento nas confluências é simulado usando a equação da continuidade de massa e a equação de energia, esta última desprezando os termos de perda de energia e de energia cinética. Singularidades hidráulicas como vertedores e descarregadores de fundo de barragens são representadas como condição de contorno interna no modelo.

As equações diferenciais parciais do modelo são resolvidas utilizando um esquema numérico de diferenças finitas implícito desenvolvido por Chen (1973). Devido à grande quantidade de confluências geralmente existentes nas complexas redes de drenagem das grandes bacias hidrográficas, essas equações formam um sistema com $2n$ equações lineares, sendo n o número de seções transversais do modelo hidrodinâmico. A solução do sistema adota uma variante do procedimento de eliminação de Gauss, que é baseado no método de armazenamento Skyline desenvolvido por Tucci (1978). Paiva (2009) propôs ainda uma modificação do método skyline que reduziu significativamente o tempo de cálculo da solução da matriz (PAIVA *et al.*, 2011a).

Para a aplicação do modelo hidrodinâmico são necessários dados das seções transversais dos rios e das possíveis planícies de inundações, os quais geralmente estão disponíveis apenas em pequenas bacias hidrográficas. Para sua aplicação na modelagem de grandes bacias estes dados são extraídos automaticamente a partir de Modelos Digitais de Elevação (MDE) utilizando algoritmos desenvolvidos especialmente para esta finalidade.

ANEXO C

Previsão de precipitação

C.1 Dados disponibilizados pelo *International Research Institute for Climate and Society (IRI)*

A principal fonte de dados de previsões de precipitação (entre outras variáveis) encontrada foi o IRI – *International Research Institute for Climate and Society*, parte do *Earth Institute*, na Universidade de Columbia, Estados Unidos. A previsão climática é realizada através de diferentes modelos de circulação geral atmosférica (AGCMs), sendo processada no instituto original e repassada ao IRI, ou no próprio IRI. Estes modelos são rodados diversas vezes, formando um *ensemble* (conjunto de previsões) para cada modelo, com um ou mais possíveis cenários para a temperatura da superfície do mar (*sea surface temperature - SST*) global.

O IRI possui disponíveis para download dados de 17 modelos ou versões de modelos. Em geral, os dados históricos diários ou aqueles gerados a cada 6h não são de livre acesso. Contudo, dados mensais são disponibilizados para consulta e download. Para as opções “*History*” e “*Climatology*”, as séries iniciam-se em torno de 1950. O sistema operacional de previsão a partir destes modelos (opção “*Forecast*”) de maneira geral inicia-se em 2004, e mantém-se em funcionamento. Nas três opções estão disponíveis para download os membros do conjunto de previsões, quando é o caso.

A Tabela C.1 a seguir mostra um levantamento dos dados disponíveis no IRI, de interesse para avaliação. Todos os modelos apresentados na tabela apresentam cobertura global. Após, é realizada uma breve descrição dos modelos (ou versões de modelos) disponibilizados nesta base de dados.

Tabela C.1. Bases de dados de interesse de previsões disponíveis no IRI e suas características.

Base de dados	Variáveis	Resolução espacial (°)	Membr os	SST	Horizonte (meses)		Período*		
					mínimo	máximo			
CCM3.2	Previsões por conjunto e simulações de taxa de precipitação, temperatura à 2 m e 500 mb de altura geopotencial, com o CCM3.2	2,8125 x 2,789328 (T42)	10	Acesso restrito à 'Forecast' - Apenas histórico disponível					
CCM3v6	Previsões por conjunto e simulações do CCM3.6	2,8125 x 2,789327 (T42)	24	ca-sst	0,5	6,5	Jan/57	Out/14	
				psst	-1,5	4,5	Dez/04	Out/14	
				ssst	-1,5	6,5	Dez/04	Out/14	
COLA	Previsões por conjunto e simulações de taxa de precipitação e temperatura na altura do dossel com o COLA C2.2	1,875 x 1,864678 (T63)	10	asst	0,5	6,5	Out/01	Mai/04	
			30	ssst	0,5	6,5	Jun/04	Out/14	
COLA2.2.6	COLA AGCM V2.2.6.	1,875 x 1,864678 (T63)	a-1 (12)	Apenas histórico disponível					
ECPC	Previsões por conjunto de precipitação e temperatura à 2m com UC Scripps ECPC	1,875 x 1,904128 (T62)	10	asst	0,5	6,5	Jun/03	Mai/04	
			10	psst	0,5	3,5	Jun/03	Jul/14	
			12	ssst	0,5	6,5	Jun/04	Jul/14	
ECHAM3	Previsões por conjunto e simulações do ECHAM3	2,8125 x 2,789328 (T42)	10	Acesso restrito à 'Forecast' - Apenas histórico disponível					

Base de dados	Variáveis	Resolução espacial (°)	Mem bros	SST	Horizonte (meses)		Período*	
					mínimo	máximo		
ECHAM4.5	Previsões por conjunto e simulações do ECHAM4.5	2,8125 x 2,789328 (T42)	24	asst	0,5	6,5	Set/01	Nov/04
				ca-sst	0,5	6,5	Jan/57	Mar/14
				ECMWF-sst	0,5	4,5	Fev/58	Mar/01
			24	psst	0,5	4,5	Jan/68	Out/03
				psst	0,5	3,5	Set/01	Out/14
				ssst	0,5	6,5	Jun/04	Out/14
ECHAM5	Previsões com ECHAM5 realizadas pelo IRI nas resoluções T85 e T42	2,8125 x 2,789206 (T42)	24	ca-sst	0,5	6,5	Jan/57	Dez/04
		(T85)	16	Apenas histórico disponível				
GFDL	Previsões por conjunto de precipitação e temperatura à 2m	2,5x2	10	psst	0,5	6,5	Out/04	Out/14
			30	ssst	0,5	6,5	Out/04	Out/14
NCEP MRF9	Previsões por conjunto e simulações de taxa de precipitação, temperatura à 2m e 500mb de altura geopotencial	2,8125 x 2,789328 (T40)	10	asst	0,5	6,5	Jul/98	Mai/04
			30	ssst	0,5	6,5	Jun/04	Set/09
NOAA	Previsão sazonal por conjuntos do NOAA-CPC			Apenas Estados Unidos dentro do IRI				

Base de dados	Variáveis	Resolução espacial (°)	Mem bros	SST	Horizonte (meses)		Período*	
					mínimo	máximo		
NSIPP-1	Previsões por conjunto e simulações de taxa de precipitação, temperatura à 2m e 500mb de altura geopotencial do NASA GSFC NSIPP-1	2,5x2,5	9	asst	0,5	6,5	Jan/01	Mai/04
			12	ssst	0,5	6,5	Jun/04	Jul/12

ca-sst: Constructed analogue SST.

asst: Anticipated SST – Anomalia de SST prevista, resultado da média de diferentes modelos.

psst: Persisted SST – Anomalia de SST observada no mês anterior ao início da previsão e somada à SST média climatológica dos meses previstos.

ssst: Scenarios SST – Anomalia de SST prevista.

*** Período de previsão disponível em outubro de 2014.**

CCM3.2: Modelo de circulação geral atmosférica desenvolvido pelo *National Centers for Atmospheric Research* (NCAR), nos Estados Unidos. Possui resolução espacial horizontal de aproximadamente $2,8^\circ \times 2,8^\circ$ (T42), com 18 camadas verticais. (IRI, 2013).

CCM3.6: O CCM3.6 é uma versão do *Community Climate Model* (CCM) do NCAR pertence à mesma família do CCM3.0, e não apresenta diferenças significativas em relação ao CCM3.2. As principais mudanças estão relacionadas à interface do usuário, correção de bugs na rotina, arquivos de entrada e saída, e algumas mudanças físicas, porém sem mudanças relevantes ao clima (NCAR, 1998). As principais referências para o modelo CCM3v6 são os trabalhos de Hack *et al.* (1998), Hurrell *et al.* (1998) e Kiehl *et al.* (1998).

COLA: COLA2.2 é um AGCM produzido pelo *Center for Ocean-Land-Atmosphere Studies* (COLA), localizado em Maryland, Estados Unidos, instituição dedicada à pesquisa quanto à variabilidade e previsão do clima (IGES, s.d.). A instituição conta com o apoio de três agências federais norte americanas, NSF (*National Science Foundation*), NOAA (*National Oceanic and Atmospheric Administration*) e NASA (*National Aeronautics and Space Administration*).

COLA2.2.6: COLA2.2.6 é uma versão do modelo do *Center for Ocean-Land-Atmosphere Studies* (COLA). O modelo tem uma resolução espacial horizontal T63, ou seja, aproximadamente $1,87^\circ \times 1,86^\circ$, e 18 níveis verticais (FENNESSY e KINTER III, 2009).

ECHAM3: O modelo *European Community - Hamburg* (ECHAM) foi desenvolvido no *Max Plank Institut fur Meteorolgi*, na Alemanha, baseado no modelo de previsão de tempo do *European Centre for Medium Range Weather Forecasts* (ECMWF). A resolução do modelo é T42 (aproximadamente $2,8^\circ \times 2,8^\circ$), com 19 camadas verticais (IRI, 2013).

ECHAM4.5: O modelo ECHAM4.5 é uma versão do modelo posterior ao ECHAM3.6, baseado no modelo de previsão de tempo do *European Centre for Medium Range Weather Forecasts* (ECMWF). O modelo vem sofrendo várias modificações significativas, realizadas pelo *Max Planck Institute for Meteorology and German Climate Computing Centre*. Estas modificações vêm sendo feitas para melhorar a previsão

climática. Uma detalhada descrição do ECHAM4.5 pode ser encontrada em Roeckner et al. (1996). Esta versão do modelo possui também resolução espacial T42 e 19 níveis verticais (SCHNEIDER et al., 2003).

ECHAM5: Mais uma versão do modelo ECHAM, o ECHAM5 apresenta, em relação ao ECHAM4, uma série de mudanças significativas tanto sobre a parte física como sobre a parte numérica do modelo. Uma descrição do modelo pode ser encontrada em Roeckner et al. (2003).

ECPC: Este é o modelo do *Experimental Climate Prediction Center* (ECPC), desenvolvido e rodado no *Scripps Institution of Oceanography*, Universidade da Califórnia, Estados Unidos (IRI, s.d.). O modelo possui resolução horizontal T62 (grade global de 192 X 94), e 28 níveis verticais (de HAAN et al., 2007).

GFDL: O *Geophysical Fluid Dynamics Laboratory* (GFDL), da Universidade de Princeton, possui dois modelos atmosféricos globais, o AM3 e o HiRAM (*High Resolution Atmospheric Model*). No IRI, estão disponíveis as previsões do AM2, versão anterior ao AM3. Mudanças significativas foram realizadas no AM3, tanto quanto a parte física, como a resolução vertical (GFDL, 2014). As principais referências para os modelo GFDL são Delworth *et al.* (2006) e GFDL Global Atmospheric Model Development Team (2004).

NCEP-MRF9: Este modelo climático atmosférico foi desenvolvido no *National Centers for Environmental Prediction* (NCEP), Estados Unidos. É baseado em uma versão do modelo de previsão de médio prazo usado pelo *National Weather Service*. É resolução do modelo é T40 (aproximadamente 2,8° X 2,8°), com 18 camadas verticais (IRI, 2013).

NOAA: O *Climate Prediction Center* (CPC) do NOAA (*National Oceanic and Atmospheric Administration*) possui um sistema de previsão bastante amplo e bem estruturado. Contudo, na base de dados do IRI, estão disponíveis previsões apenas para a área dos Estados Unidos.

NSIPP: O modelo foi desenvolvido no *Goddard Space Flight Center*, no âmbito do projeto *NASA's Seasonal to Interannual Prediction Project* (NSIPP). Possui resolução espacial de 2,5° X 2,5° com 34 camadas verticais (IRI, 2013).

C.2 Correção de viés da precipitação prevista

As figuras C.1 a C.6 a seguir referem-se ao conteúdo apresentado no item 7.2, e mostram, para todos os meses, as precipitações totais mensais médias da bacia do rio Ijuí, observada, média do *ensemble* sem e com correção, e o erro antes e após a correção de viés. As figuras mostram os resultados da correção realizada com base nos dados do período de 1980-2000, escolhido como o período de análise e anterior à previsão de umidade do solo.

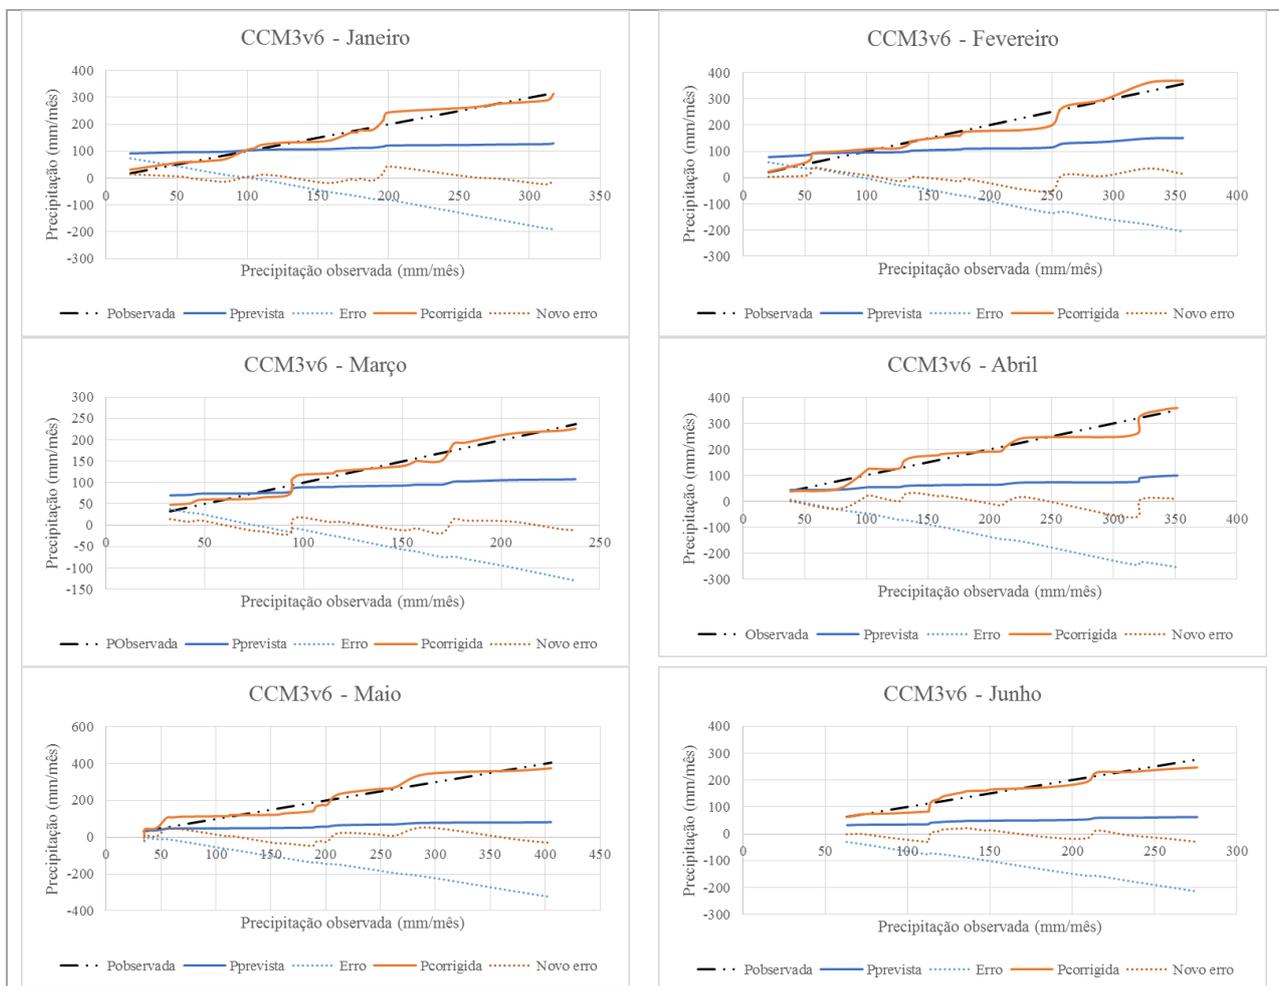


Figura C.1. Correção de viés do modelo CCM3v6 para os meses de janeiro a junho.

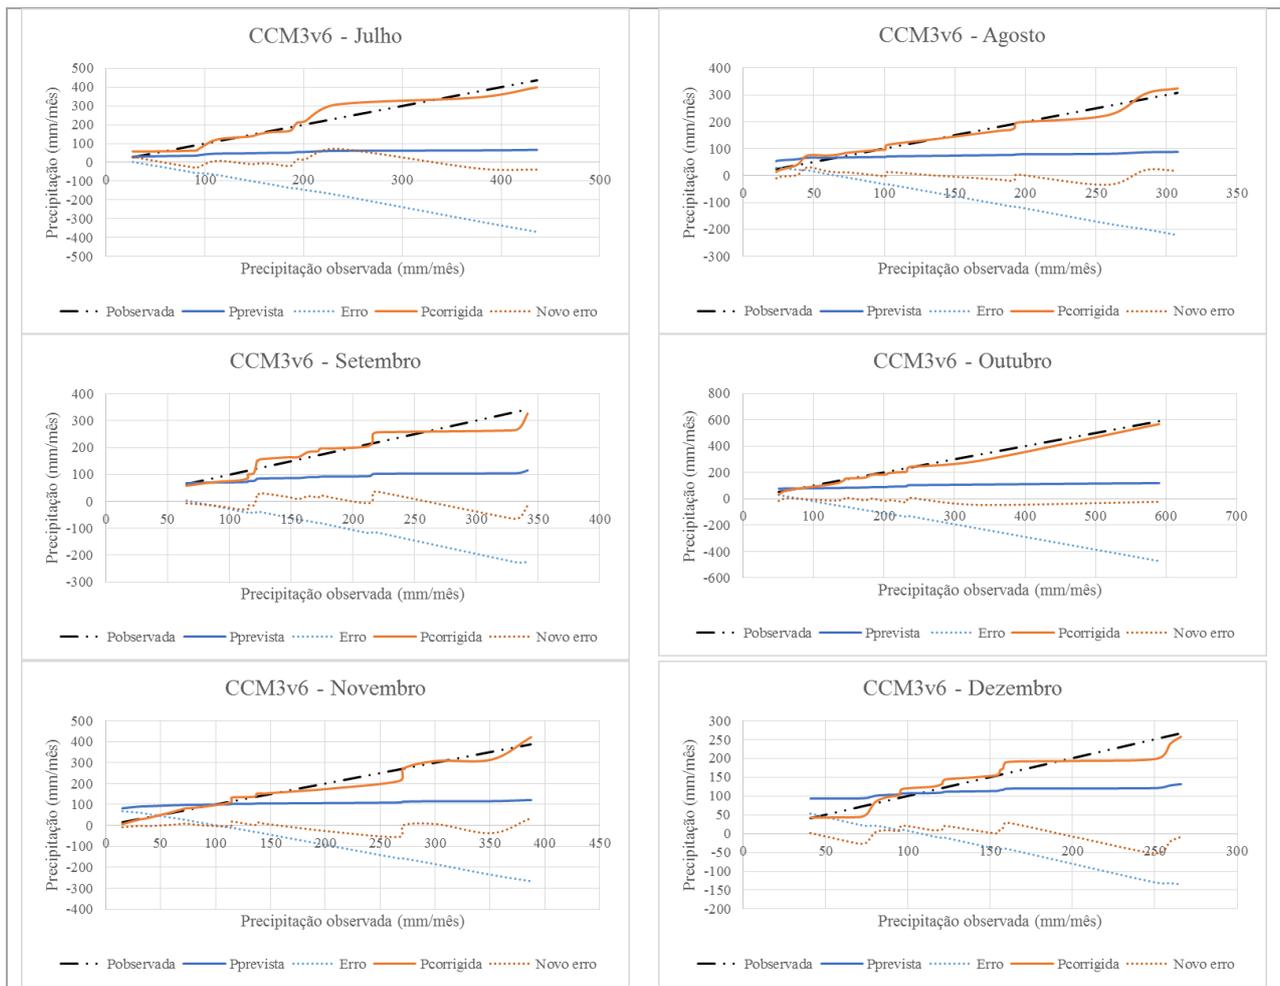


Figura C.2. Correção de viés do modelo CCM3v6 para os meses de julho a dezembro.

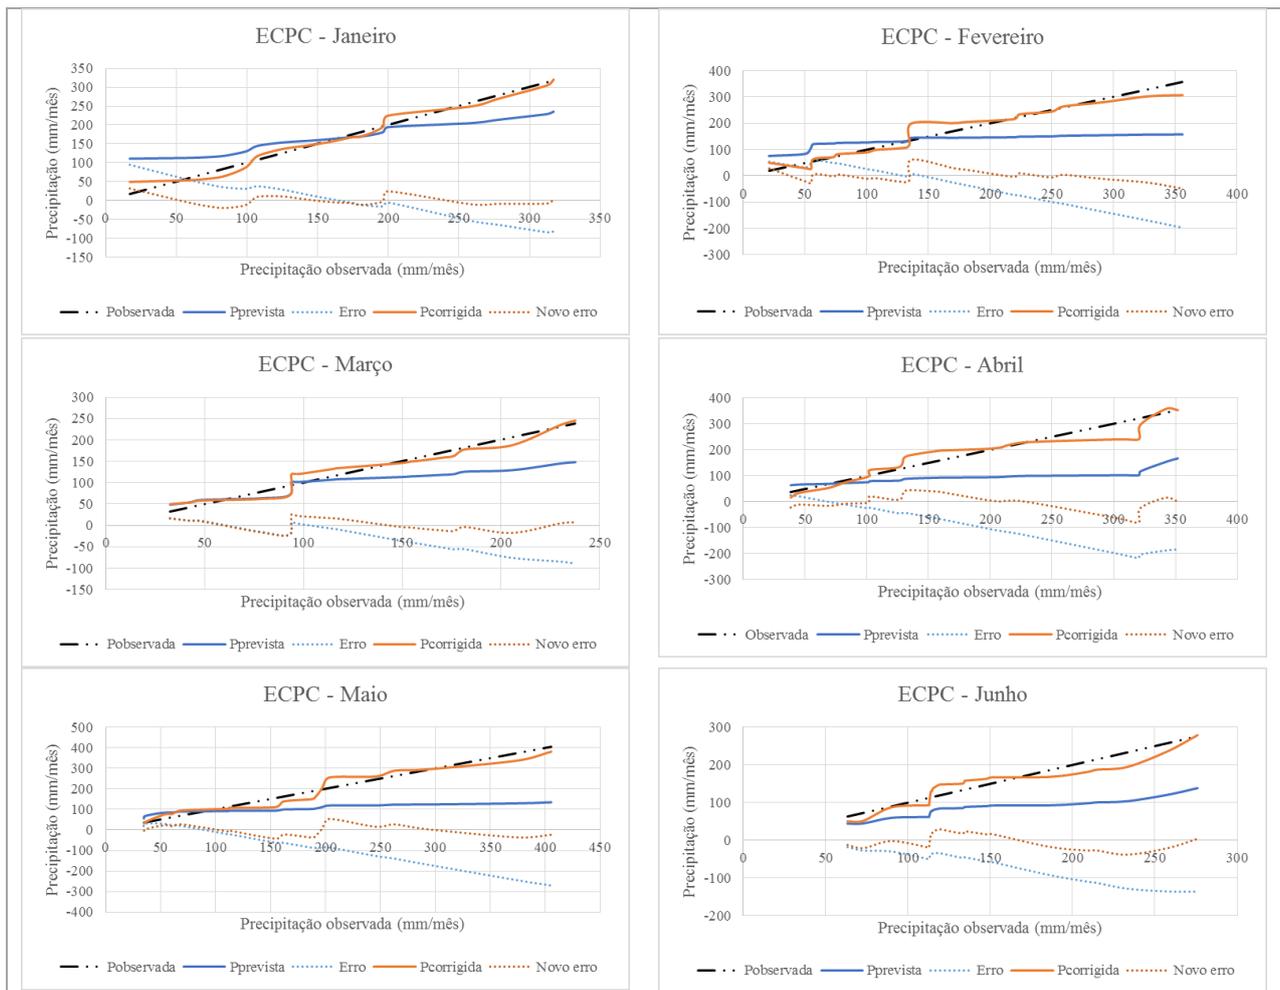


Figura C.3. Correção de viés do modelo ECPC para os meses de janeiro a junho.

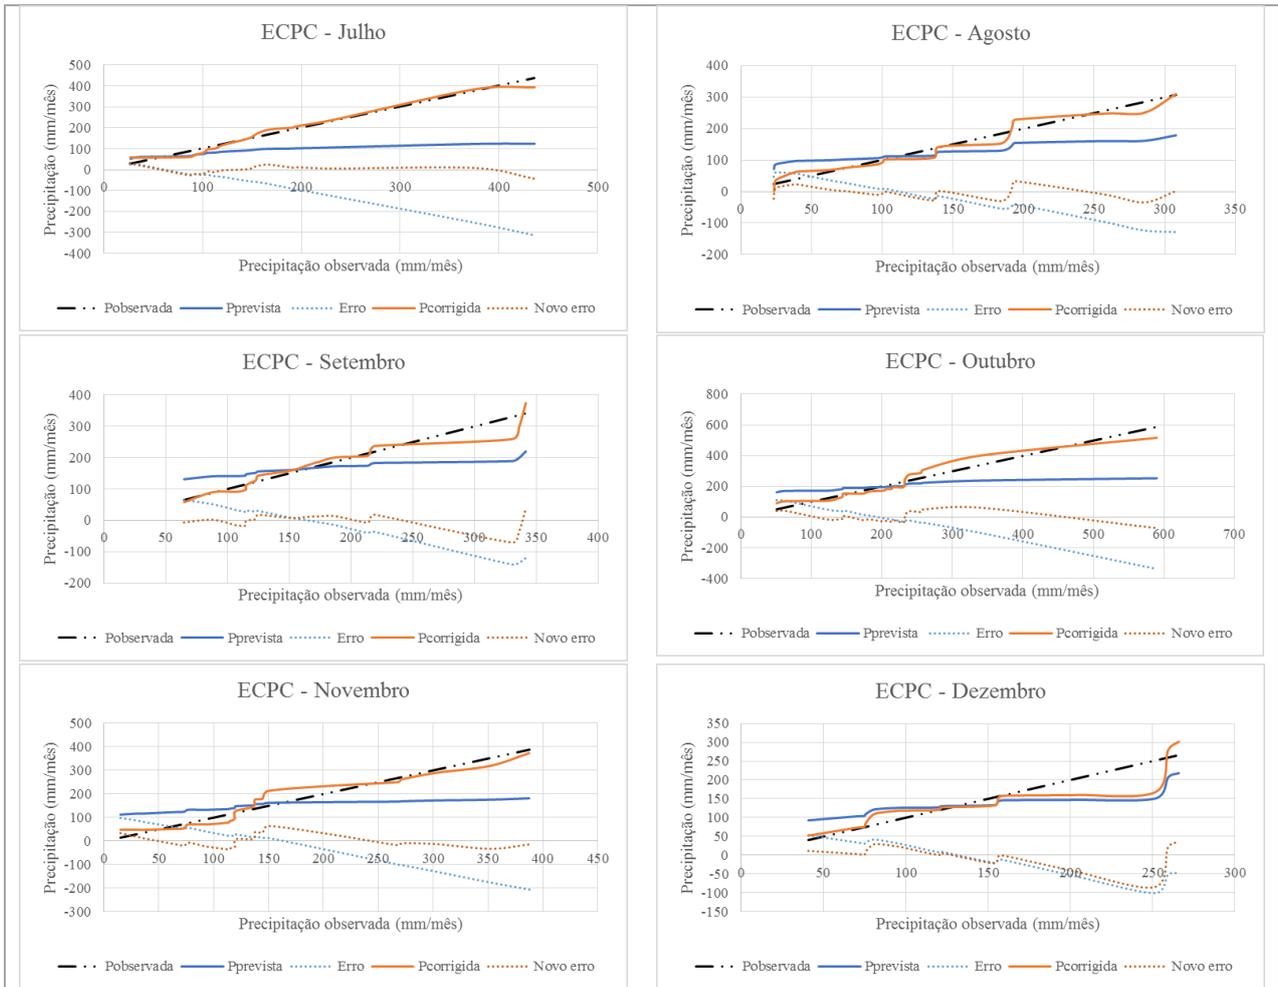


Figura C.4. Correção de viés do modelo ECPC para os meses de julho a dezembro.

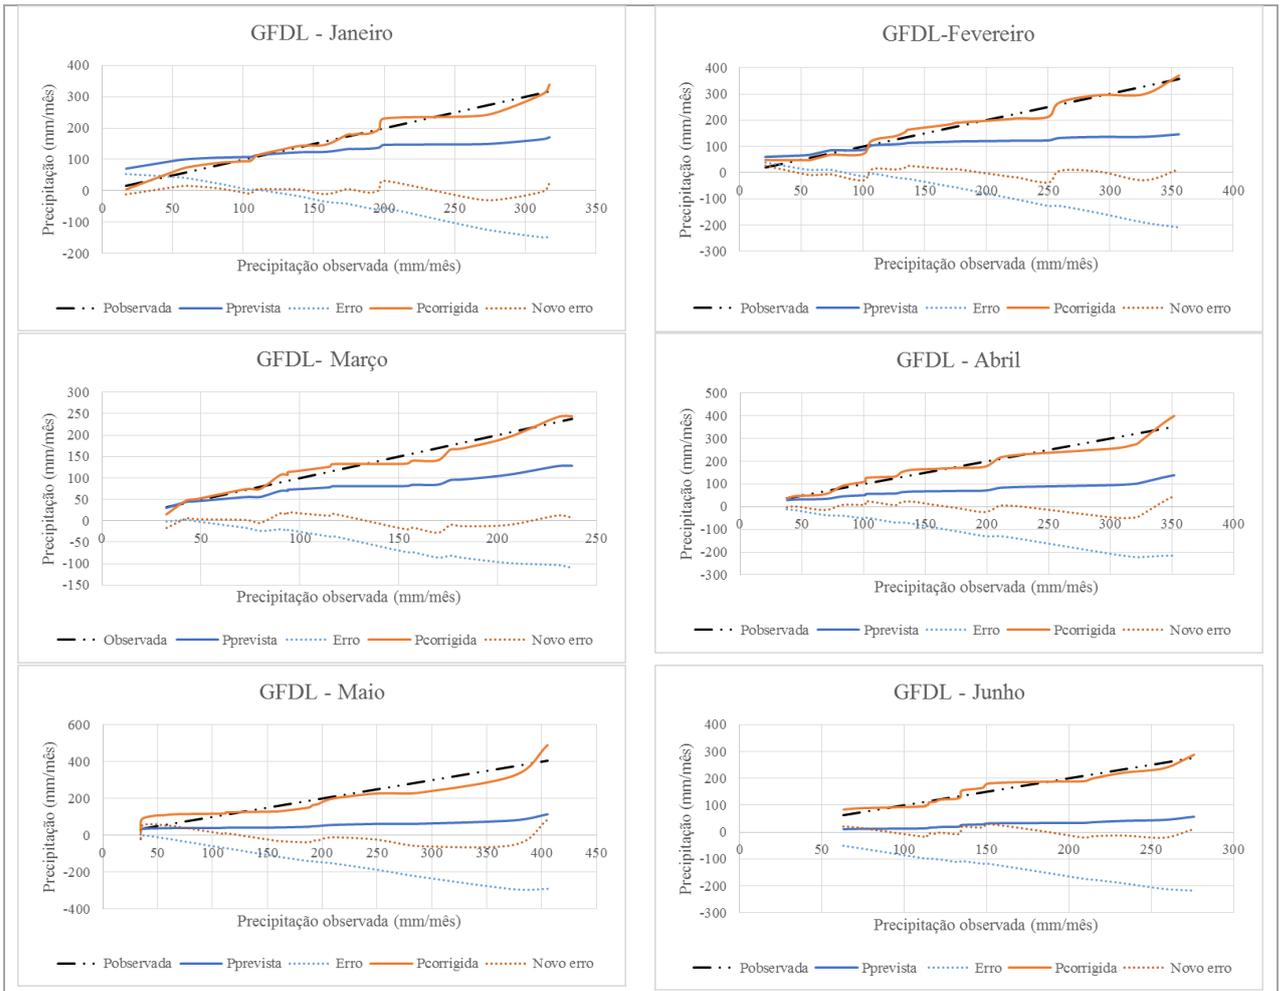


Figura C.5. Correção de viés do modelo GFDL para os meses de janeiro a junho.

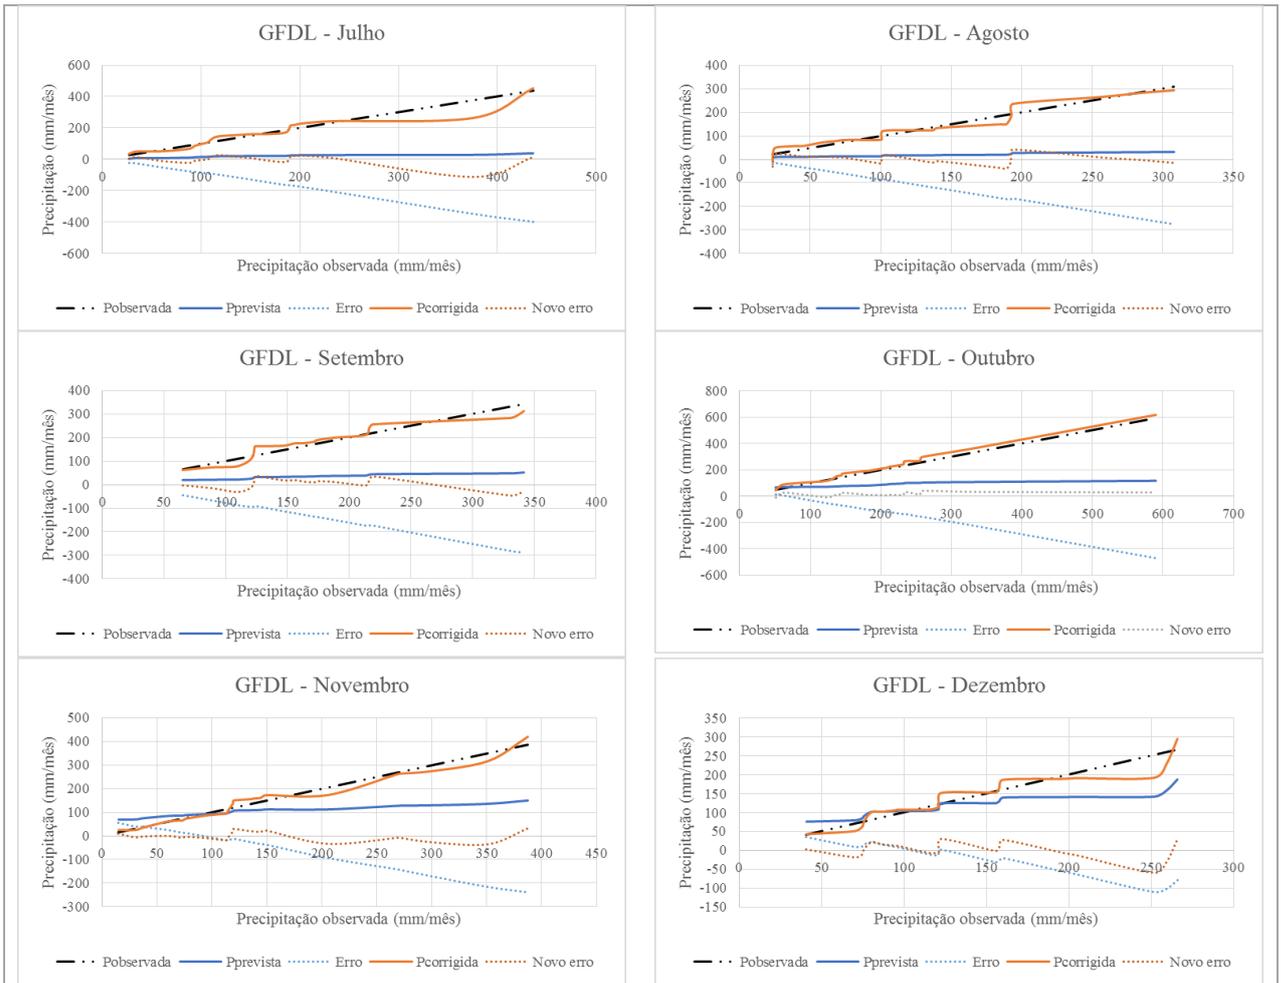


Figura C.6. Correção de viés do modelo GFDL para os meses de julho a dezembro.

ANEXO D

Parametrização adotada no modelo hidrológico

As tabelas a seguir mostram os conjuntos de parâmetros calibráveis adotados para cada Unidade de Resposta Hidrológica (URH), em cada sub-bacia. É apresentado também o conjunto de parâmetros fixos empregado, sem distinção entre solo profundo e solo raso, e adotado como constante ao longo do ano.

Tabela D.1. Parâmetros fixos do MGB-IPH.

URH	Albedo	IAF	Z	r_s
		Índice de Área Foliar	Altura do dossel (m)	Resistência Superficial (s/m)
Agricultura	0,22	2,00	0,70	70,0
Campo	0,23	2,00	0,50	70,0
Floresta	0,12	6,00	12,0	100,0
Água	0,08	1,00	0,50	0,00

Tabela D.2. Parâmetros calibráveis do MGB-IPH – Sub-bacia 1.

Sub-bacia 1							
URH	Wm	b	Kbas	Kint	XL	CAP	Wc
Agricultura em solo raso	70,00	0,60	0,50	28,50	0,77	0,00	0,09
Agricultura em solo profundo	150,00	0,15	1,20	35,50	0,77	0,00	0,09
Campo em solo raso	50,00	0,80	0,30	18,00	0,77	0,00	0,09
Campo em solo profundo	130,00	0,20	1,00	26,00	0,77	0,00	0,09
Floresta em solo raso	120,00	0,35	0,55	18,00	0,77	0,00	0,09
Floresta em solo profundo	280,00	0,10	1,70	40,00	0,77	0,00	0,09
Água	0,00	0,00	0,00	0,00	0,00	0,00	0,00
CS	9,50						
CI	108,50						
CB	1150,00						
QB (m³/s.km²)	0,01						

Tabela D.3. Parâmetros calibráveis do MGB-IPH – Sub-bacia 2.

Sub-bacia 2							
URH	Wm	b	Kbas	Kint	XL	CAP	Wc
Agricultura em solo raso	130,00	0,65	0,35	10,00	0,90	0,00	0,15
Agricultura em solo profundo	190,00	0,13	1,00	35,00	0,90	0,00	0,35
Campo em solo raso	120,00	0,70	0,30	10,00	0,67	0,00	0,15
Campo em solo profundo	180,00	0,15	0,90	35,00	0,67	0,00	0,35
Floresta em solo raso	150,00	0,45	0,55	20,00	0,67	0,00	0,15
Floresta em solo profundo	350,00	0,10	1,20	50,00	0,67	0,00	0,55
Água	0,00	0,00	0,00	0,00	0,00	0,00	0,00
CS	20,50						
CI	350,00						
CB	6000,00						
QB (m ³ /s.km ²)	0,01						

Tabela D.4. Parâmetros calibráveis do MGB-IPH – Sub-bacia 3.

Sub-bacia 3							
URH	Wm	b	Kbas	Kint	XL	CAP	Wc
Agricultura em solo raso	70,00	0,40	0,10	8,50	0,67	0,00	0,30
Agricultura em solo profundo	200,00	0,10	1,00	18,50	0,57	0,00	0,40
Campo em solo raso	50,00	0,55	0,10	8,00	0,67	0,00	0,30
Campo em solo profundo	180,00	0,11	0,90	15,00	0,67	0,00	0,40
Floresta em solo raso	150,00	0,35	0,20	20,00	0,67	0,00	0,40
Floresta em solo profundo	350,00	0,09	2,00	25,00	0,67	0,00	0,50
Água	0,00	0,00	0,00	0,00	0,00	0,00	0,00
CS	18,50						
CI	300,00						
CB	5500,00						
QB (m ³ /s.km ²)	0,01						

Tabela D.5. Parâmetros calibráveis do MGB-IPH – Sub-bacia 4.

Sub-bacia 4							
URH	Wm	b	Kbas	Kint	XL	CAP	Wc
Agricultura em solo raso	50,00	0,70	0,75	18,50	0,87	0,00	0,20
Agricultura em solo profundo	100,00	0,15	1,30	26,50	0,87	0,00	0,40
Campo em solo raso	40,00	0,92	0,20	18,00	0,87	0,00	0,20
Campo em solo profundo	90,00	0,20	1,20	26,00	0,87	0,00	0,40
Floresta em solo raso	80,00	0,45	0,85	20,00	0,87	0,00	0,20
Floresta em solo profundo	200,00	0,10	1,70	40,00	0,87	0,00	0,40
Água	0,00	0,00	0,00	0,00	0,00	0,00	0,00
CS	22,50						
CI	180,50						
CB	2550,00						
QB (m ³ /s.km ²)	0,01						

Tabela D.6. Parâmetros calibráveis do MGB-IPH – Sub-bacia 5.

Sub-bacia 5							
URH	Wm	b	Kbas	Kint	XL	CAP	Wc
Agricultura em solo raso	50,00	0,70	0,75	25,50	0,79	0,00	0,20
Agricultura em solo profundo	100,00	0,15	1,30	36,50	0,79	0,00	0,40
Campo em solo raso	40,00	0,82	0,20	18,00	0,79	0,00	0,20
Campo em solo profundo	90,00	0,20	1,20	26,00	0,79	0,00	0,40
Floresta em solo raso	80,00	0,45	0,85	27,00	0,79	0,00	0,20
Floresta em solo profundo	280,00	0,10	1,70	40,00	0,79	0,00	0,40
Água	0,00	0,00	0,00	0,00	0,00	0,00	0,00
CS	17,50						
CI	180,50						
CB	2550,00						
QB (m ³ /s.km ²)	0,01						

Tabela D.7. Parâmetros calibráveis do MGB-IPH – Sub-bacia 6.

Sub-bacia 6							
URH	Wm	b	Kbas	Kint	XL	CAP	Wc
Agricultura em solo raso	110,00	0,70	0,55	20,50	0,47	0,00	0,30
Agricultura em solo profundo	180,00	0,23	1,20	26,50	0,97	0,00	0,90
Campo em solo raso	100,00	0,62	0,30	18,00	0,47	0,00	0,30
Campo em solo profundo	175,00	0,25	1,00	24,00	0,97	0,00	0,90
Floresta em solo raso	140,00	0,55	0,55	27,00	0,47	0,00	0,30
Floresta em solo profundo	300,00	0,10	1,70	40,00	0,97	0,00	0,90
Água	0,00	0,00	0,00	0,00	0,00	0,00	0,00
CS	8,50						
CI	188,50						
CB	1050,00						
QB (m ³ /s.km ²)	0,01						

Tabela D.8. Parâmetros calibráveis do MGB-IPH – Sub-bacia 7.

Sub-bacia 7							
URH	Wm	b	Kbas	Kint	XL	CAP	Wc
Agricultura em solo raso	90,00	0,70	0,40	18,50	0,67	0,00	0,20
Agricultura em solo profundo	180,00	0,13	1,20	26,50	0,67	0,00	0,40
Campo em solo raso	80,00	0,62	0,30	16,00	0,67	0,00	0,20
Campo em solo profundo	175,00	0,15	1,00	24,00	0,67	0,00	0,40
Floresta em solo raso	130,00	0,55	0,55	27,00	0,67	0,00	0,20
Floresta em solo profundo	280,00	0,10	1,70	40,00	0,67	0,00	0,40
Água	0,00	0,00	0,00	0,00	0,00	0,00	0,00
CS	11,50						
CI	108,50						
CB	1150,00						
QB (m ³ /s.km ²)	0,01						

ANEXO E

Qualidade do ajuste da simulação hidrológica para as vazões

E.1 Etapa de calibração do modelo

As figuras a seguir mostram as curvas de permanência e hidrogramas representativos da qualidade do ajuste entre as vazões simuladas com o modelo hidrológico de grandes bacias MGB-IPH e as vazões observadas pelos postos fluviométricos da bacia do rio Ijuí. O período de calibração estende-se de 01/01/1980 à 31/12/2004.

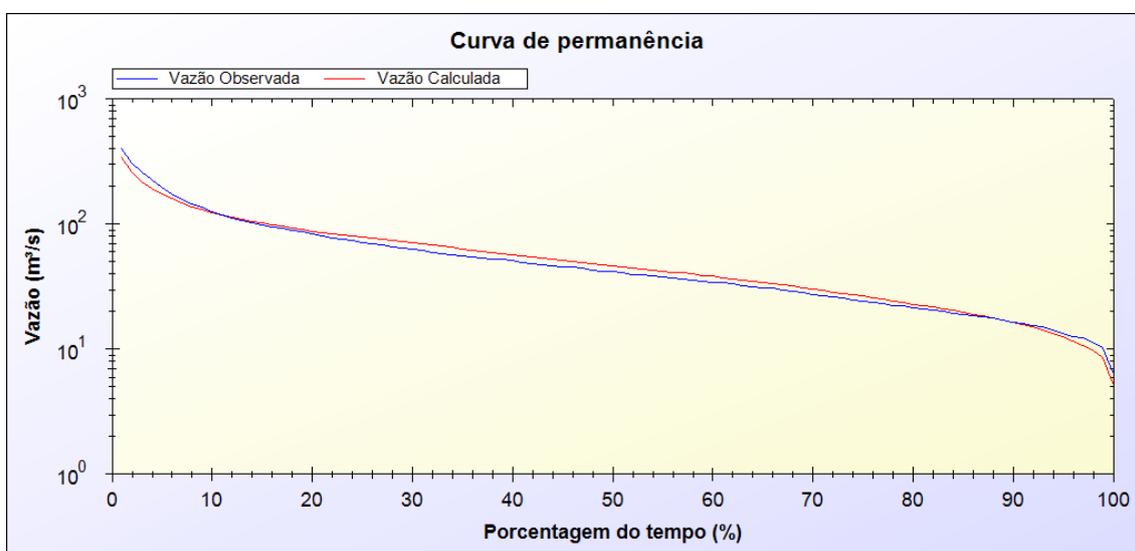


Figura E.1. Curva de permanência do posto fluviométrico 75155000, na sub-bacia 1, obtida na etapa de calibração do MGB-IPH.

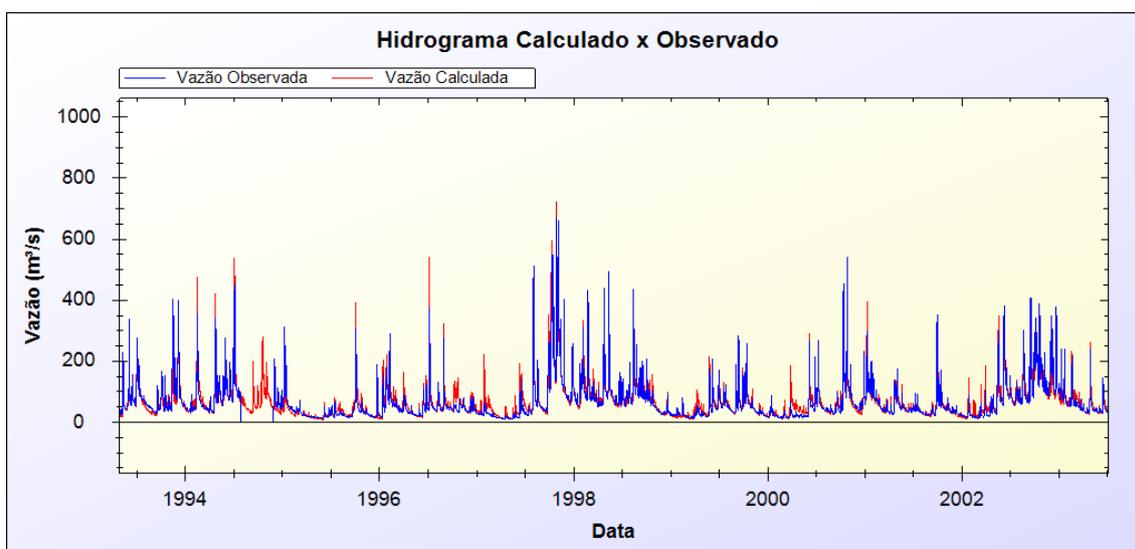


Figura E.2. Detalhe do hidrograma do posto fluviométrico 75155000, na sub-bacia 1, obtido na etapa de calibração do MGB-IPH.

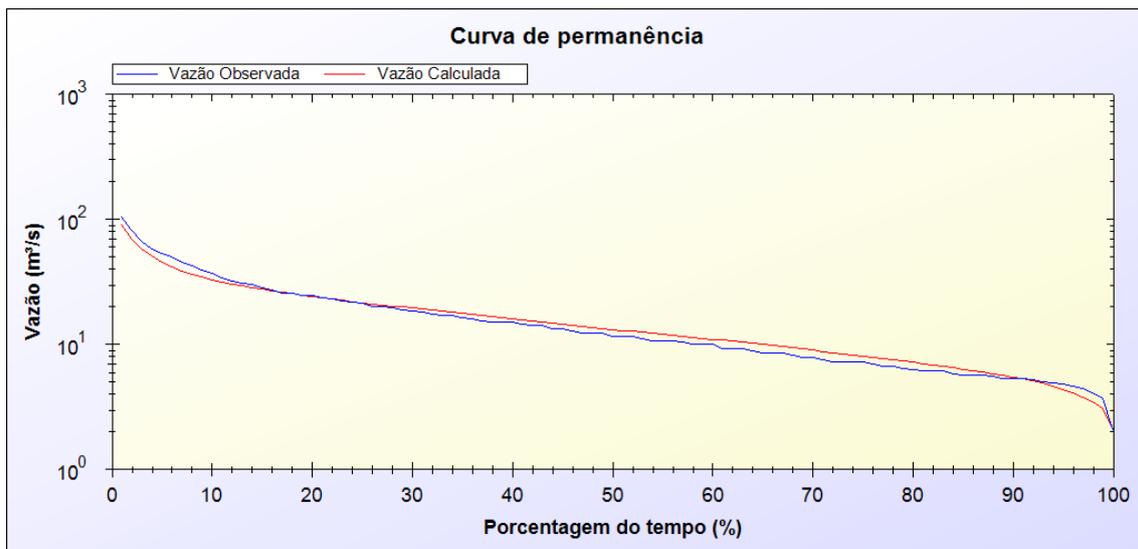


Figura E.3. Curva de permanência do posto fluviométrico 75185000, na sub-bacia 2, obtida na etapa de calibração do MGB-IPH.

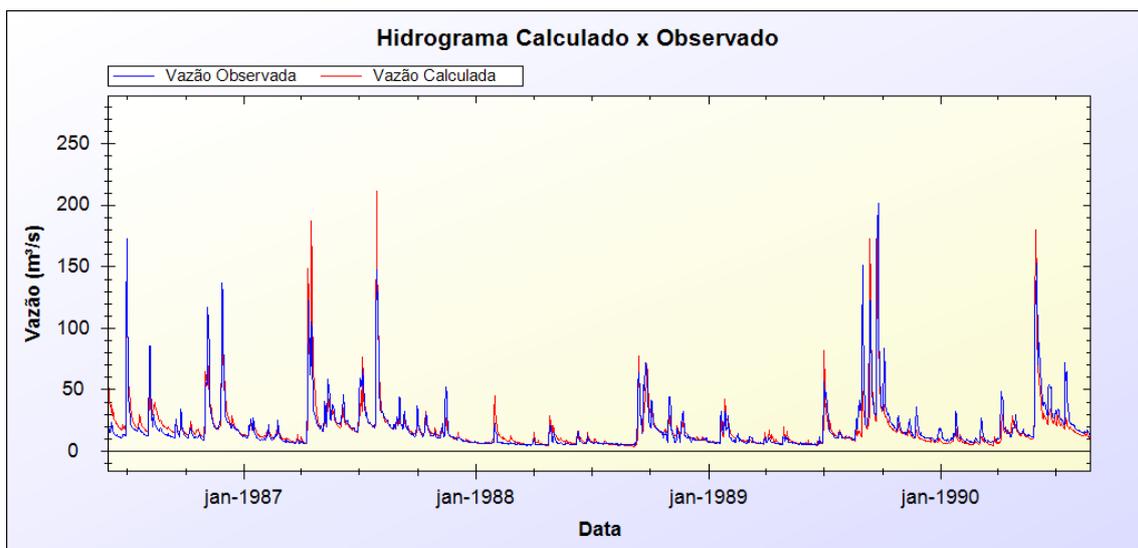


Figura E.4. Detalhe do hidrograma do posto fluviométrico 75185000, na sub-bacia 2, obtido na etapa de calibração do MGB-IPH.

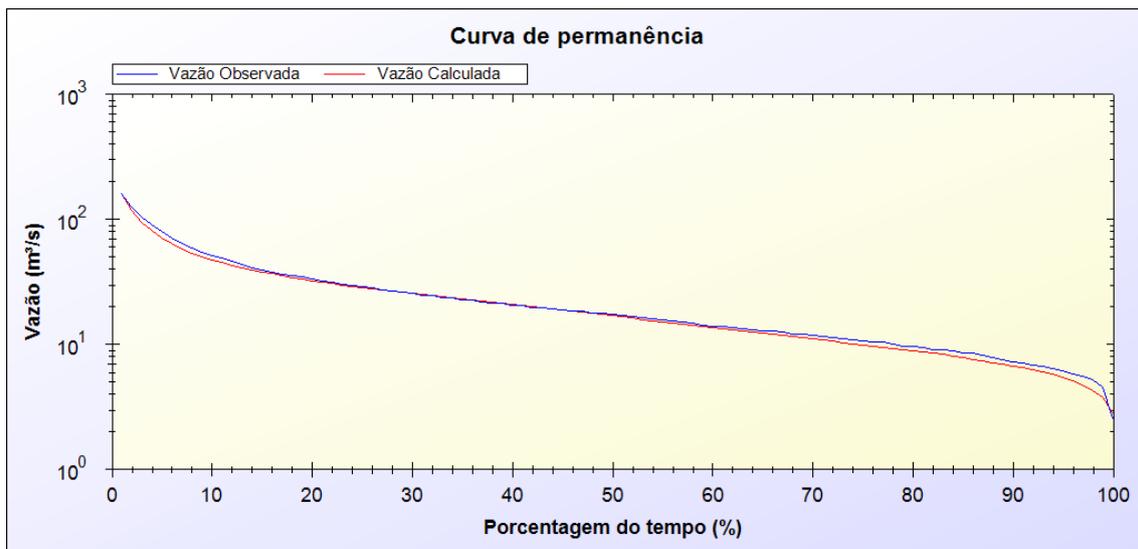


Figura E.5. Curva de permanência do posto fluviométrico 75200000, na sub-bacia 3, obtida na etapa de calibração do MGB-IPH.

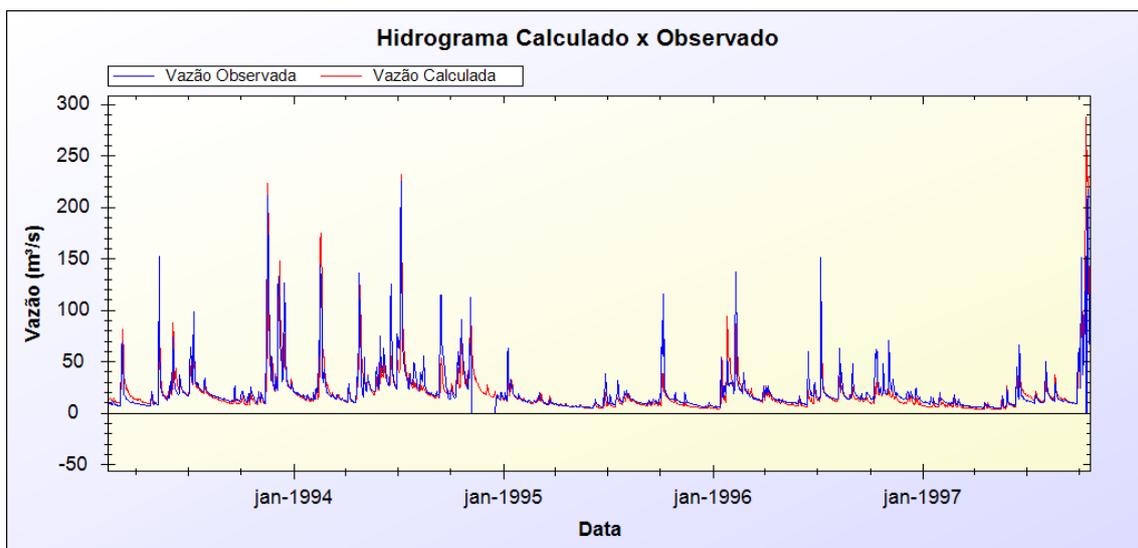


Figura E.6. Detalhe do hidrograma do posto fluviométrico 75200000, na sub-bacia 3, obtida na etapa de calibração do MGB-IPH.

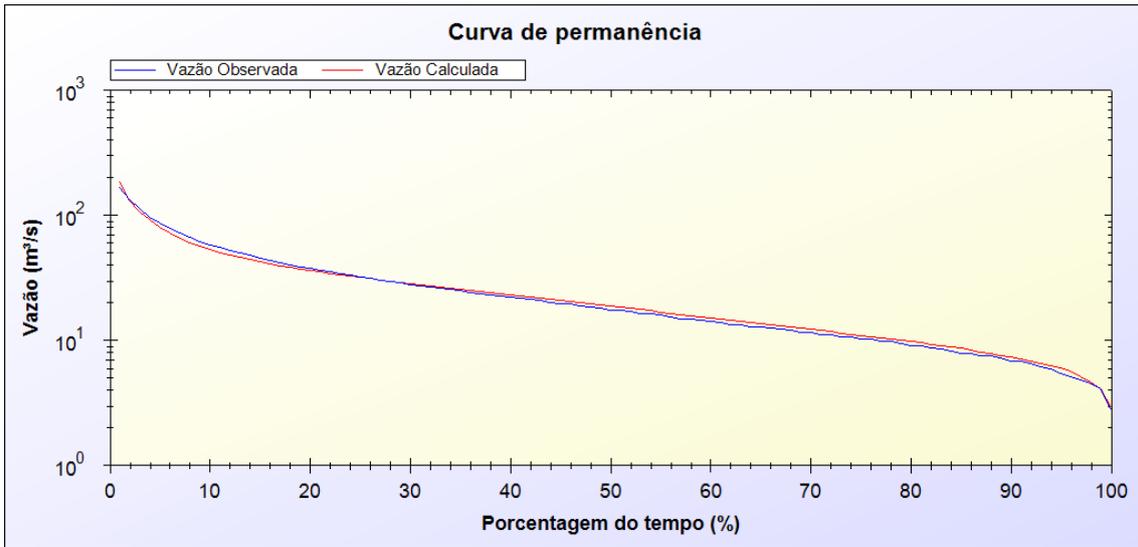


Figura E.7. Curva de permanência do posto fluviométrico 75205000, na sub-bacia 3, obtida na etapa de calibração do MGB-IPH.

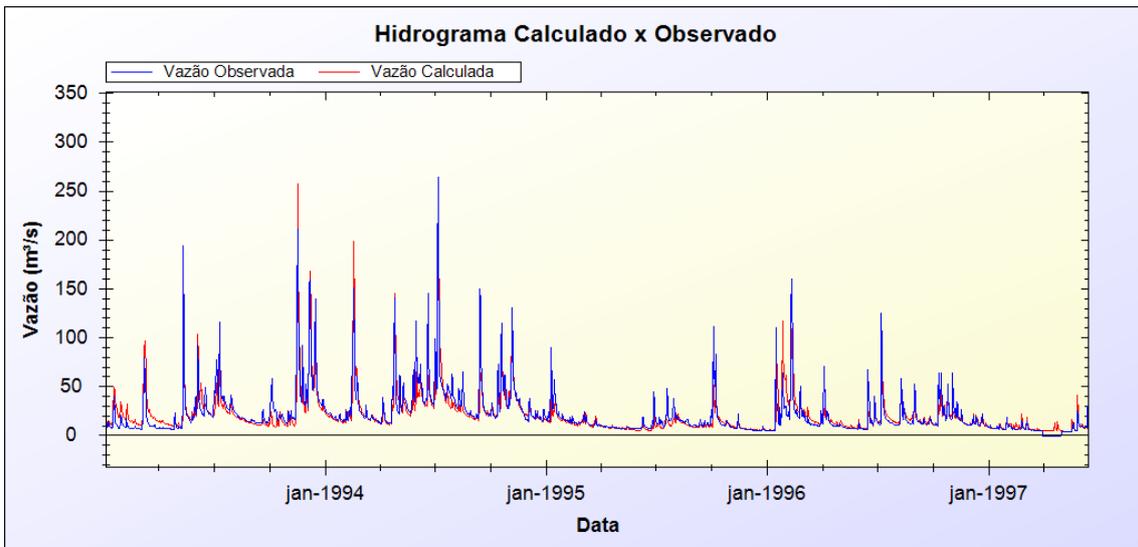


Figura E.8. Detalhe do hidrograma do posto fluviométrico 75205000, na sub-bacia 3, obtida na etapa de calibração do MGB-IPH.

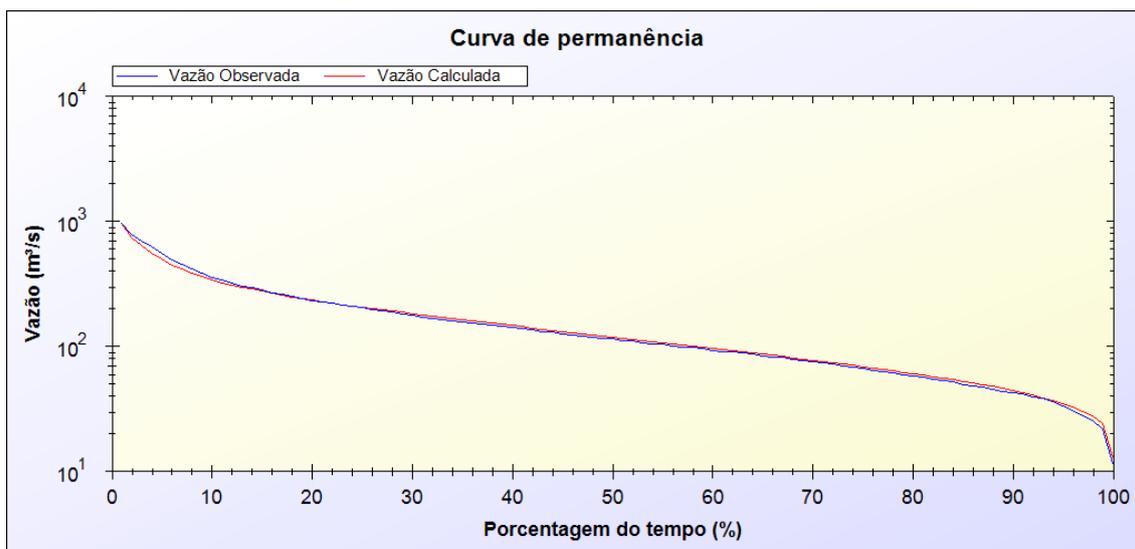


Figura E.9. Curva de permanência do posto fluviométrico 75230000, na sub-bacia 4, obtida na etapa de calibração do MGB-IPH.

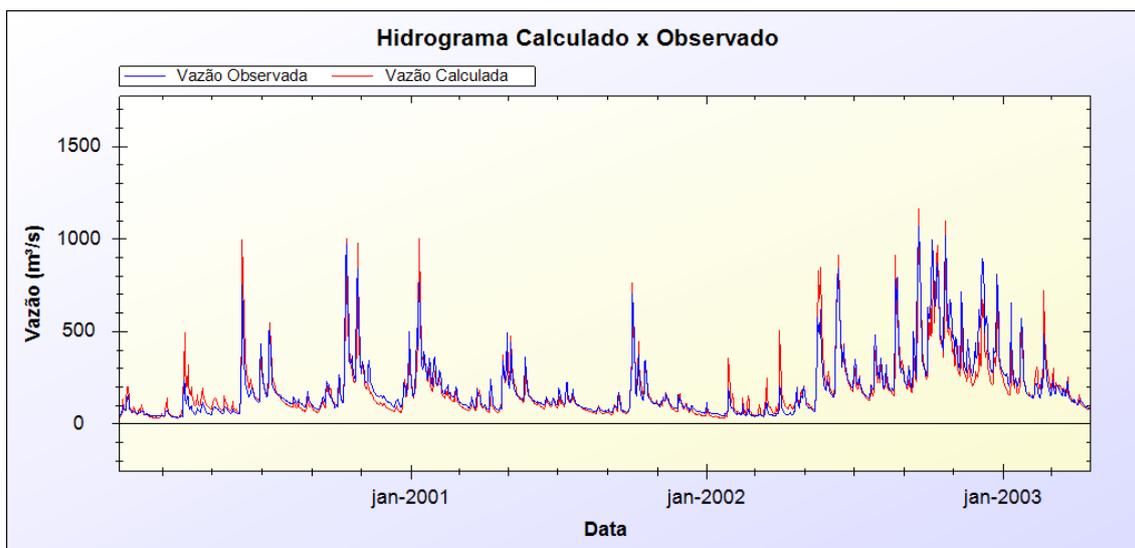


Figura E.10. Detalhe do hidrograma do posto fluviométrico 75230000, na sub-bacia 4, obtida na etapa de calibração do MGB-IPH.

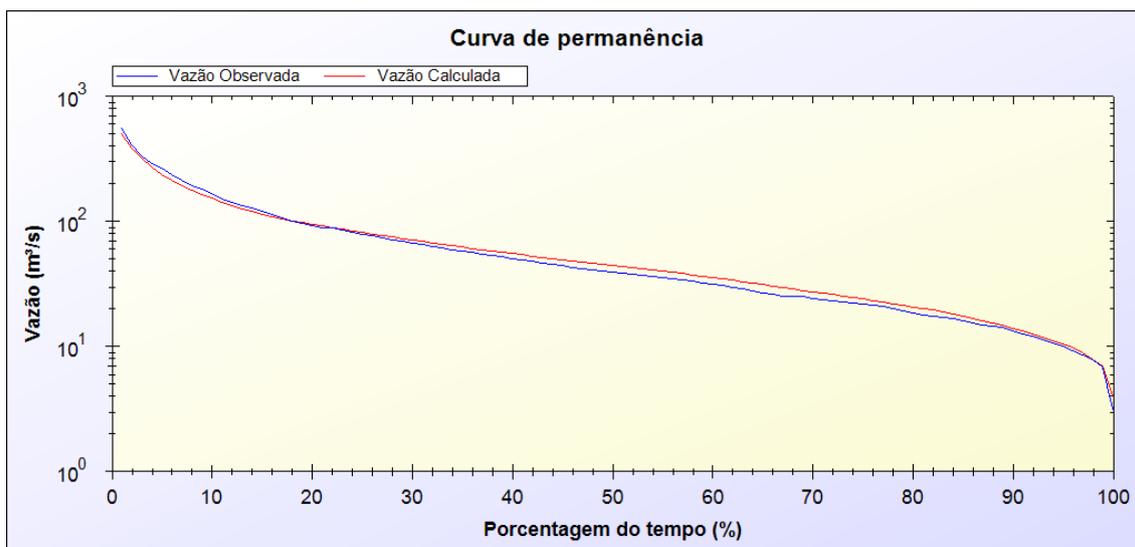


Figura E.11. Curva de permanência do posto fluviométrico 75295000, na sub-bacia 5, obtida na etapa de calibração do MGB-IPH.

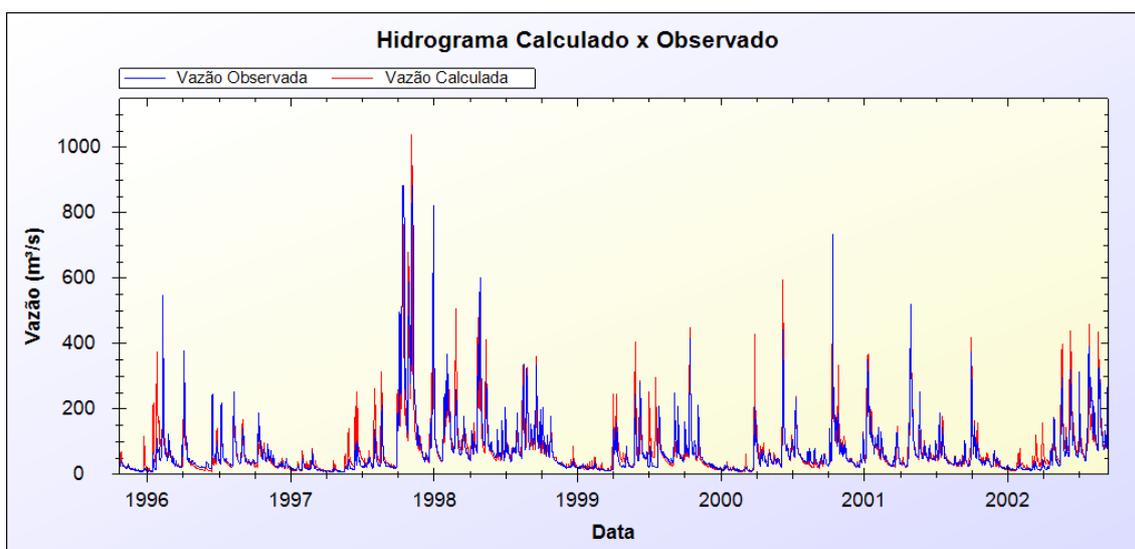


Figura E.12. Detalhe do hidrograma do posto fluviométrico 75295000, na sub-bacia 5, obtida na etapa de calibração do MGB-IPH.

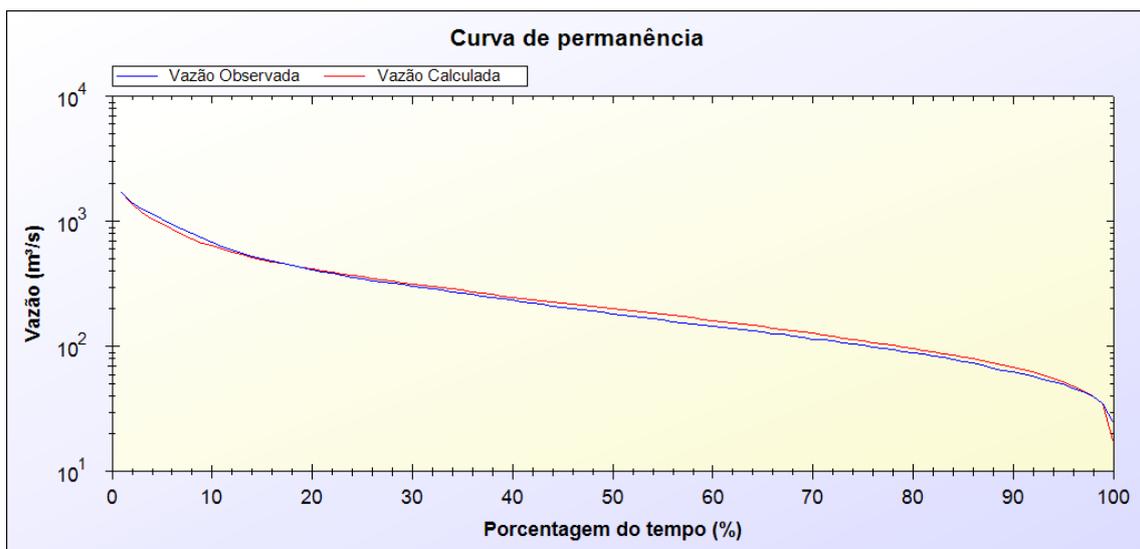


Figura E.13. Curva de permanência do posto fluviométrico 75320000, na sub-bacia 6, obtida na etapa de calibração do MGB-IPH.

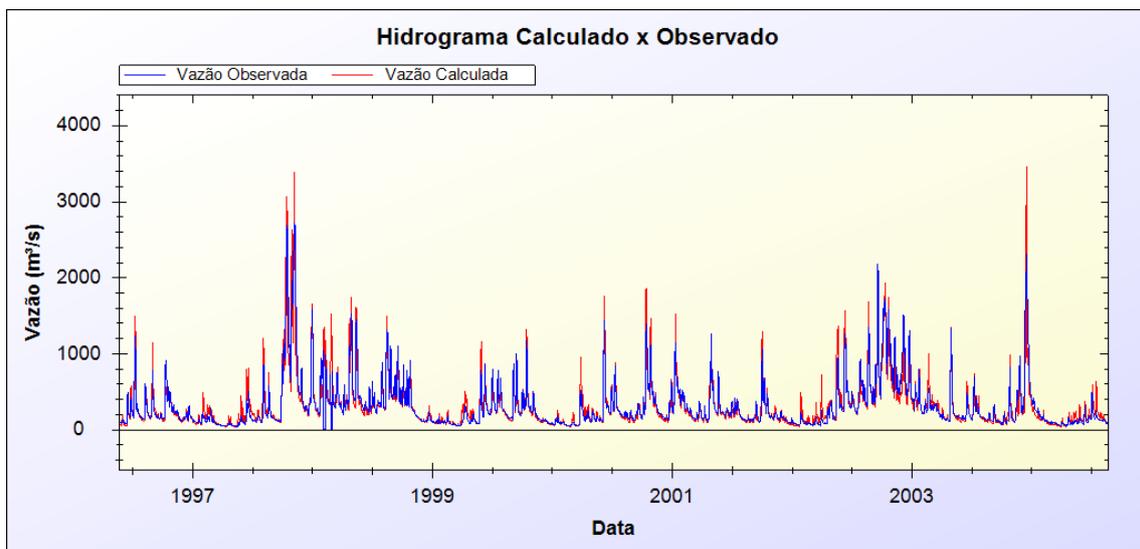


Figura E.14. Detalhe do hidrograma do posto fluviométrico 75320000, na sub-bacia 6, obtida na etapa de calibração do MGB-IPH.

E.2 Etapa de verificação do modelo

As figuras a seguir mostram as curvas de permanência e hidrogramas representativos da qualidade do ajuste entre as vazões simuladas com o modelo hidrológico de grandes bacias MGB-IPH e as vazões observadas pelos postos fluviométricos da bacia do rio Ijuí para a etapa de verificação do modelo. O período de verificação estende-se de 01/01/2005 à 31/12/2013.

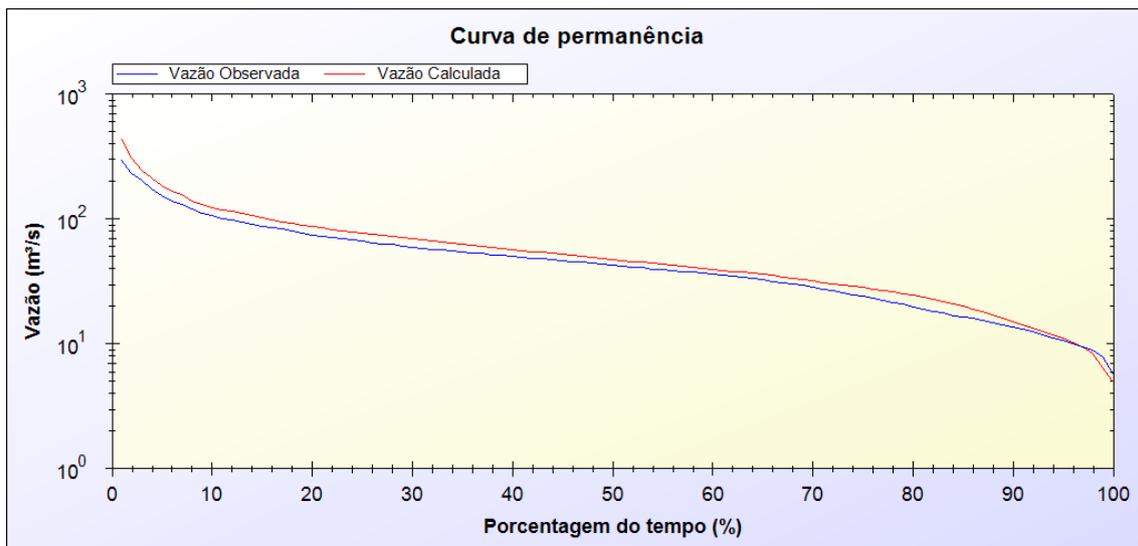


Figura E.15. Curva de permanência do posto fluviométrico 75155000, na sub-bacia 1, obtida na etapa de verificação da calibração do MGB-IPH.

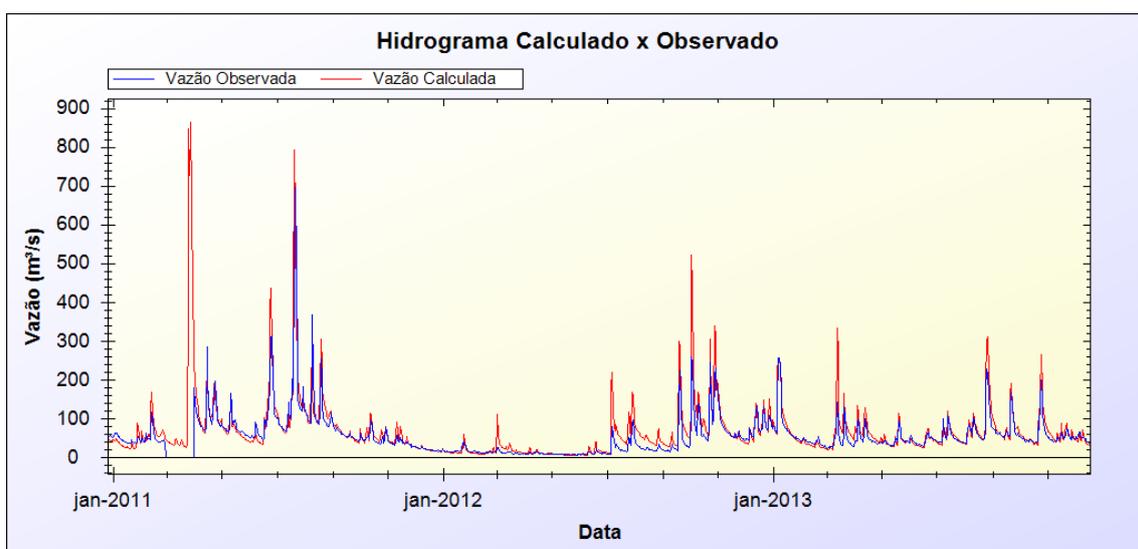


Figura E.16. Detalhe do hidrograma do posto fluviométrico 75155000, na sub-bacia 1, obtido na etapa de verificação da calibração do MGB-IPH.

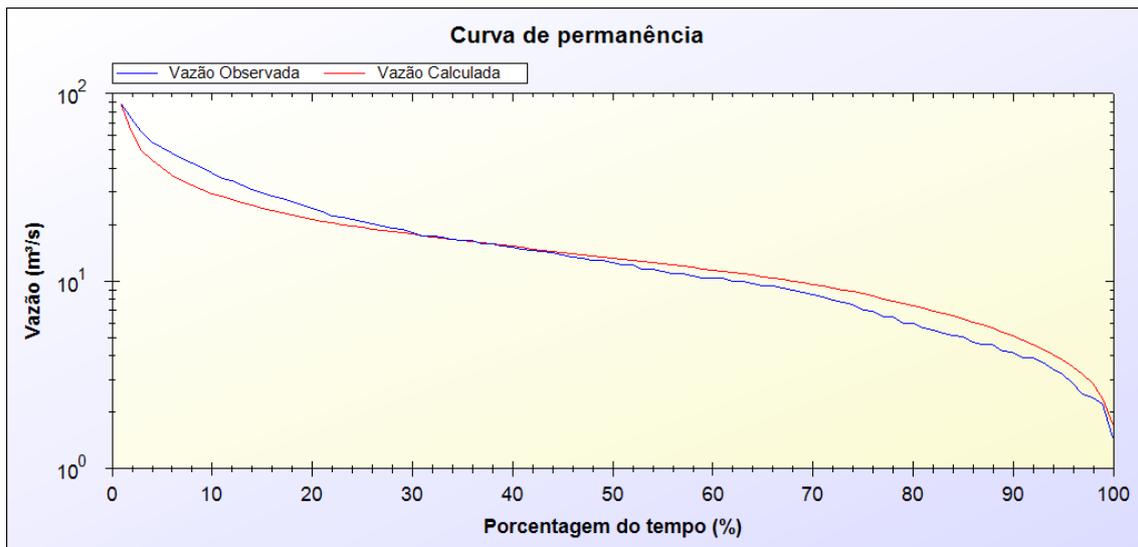


Figura E.17. Curva de permanência do posto fluviométrico 75186000, na sub-bacia 2, obtida na etapa de verificação da calibração do MGB-IPH.

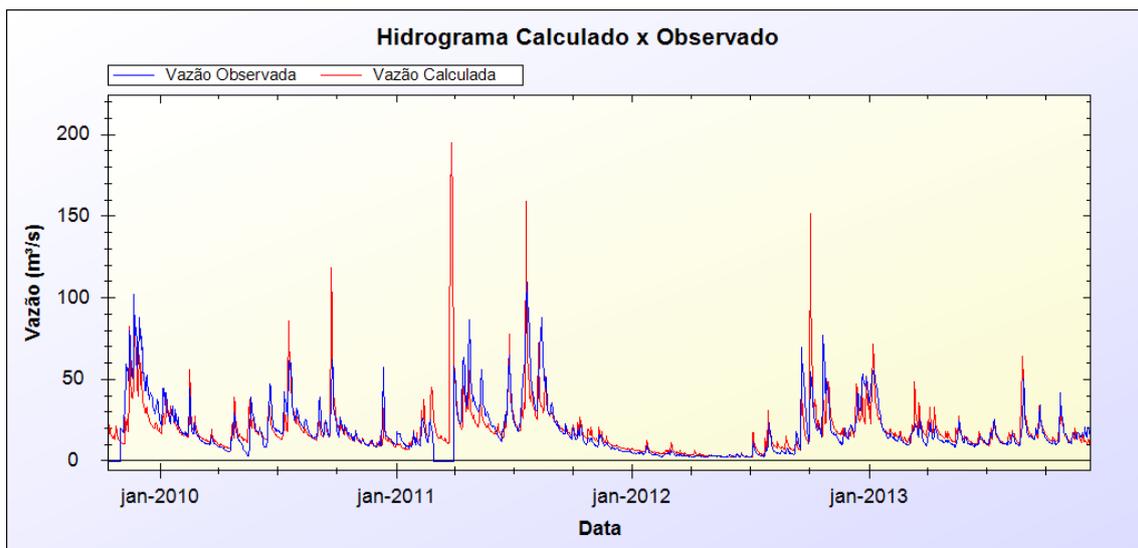


Figura E.18. Detalhe do hidrograma do posto fluviométrico 75186000, na sub-bacia 2, obtido na etapa de verificação da calibração do MGB-IPH.

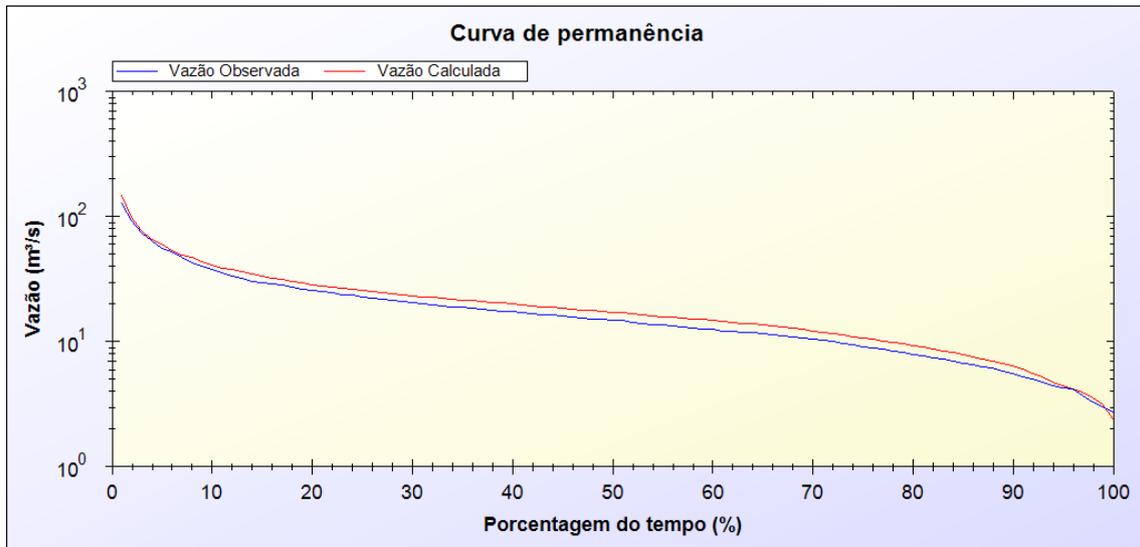


Figura E.19. Curva de permanência do posto fluviométrico 75200000, na sub-bacia 3, obtida na etapa de verificação da calibração do MGB-IPH.

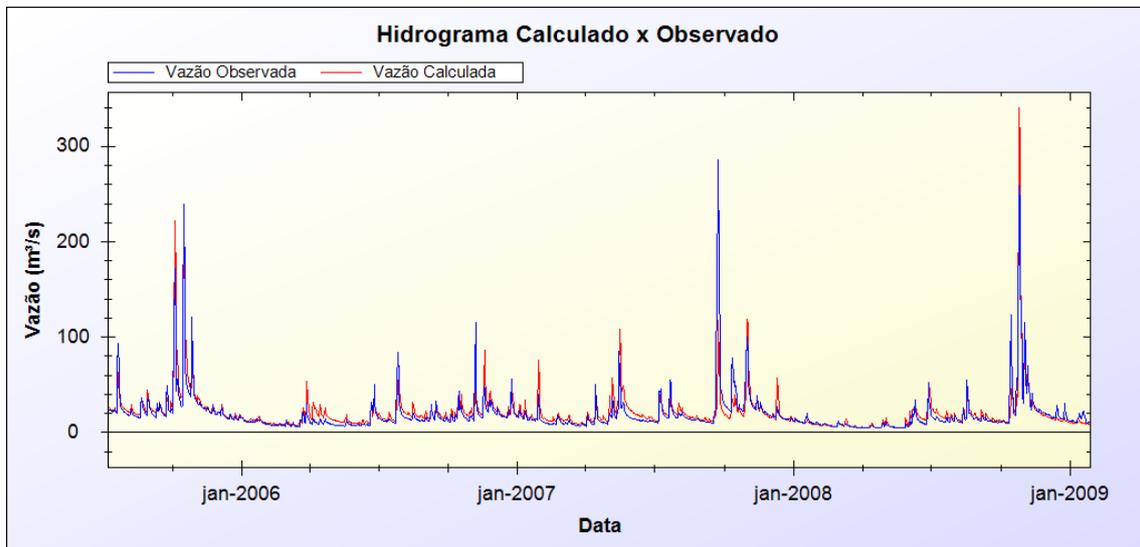


Figura E.20. Detalhe do hidrograma do posto fluviométrico 75200000, na sub-bacia 3, obtido na etapa de verificação da calibração do MGB-IPH.

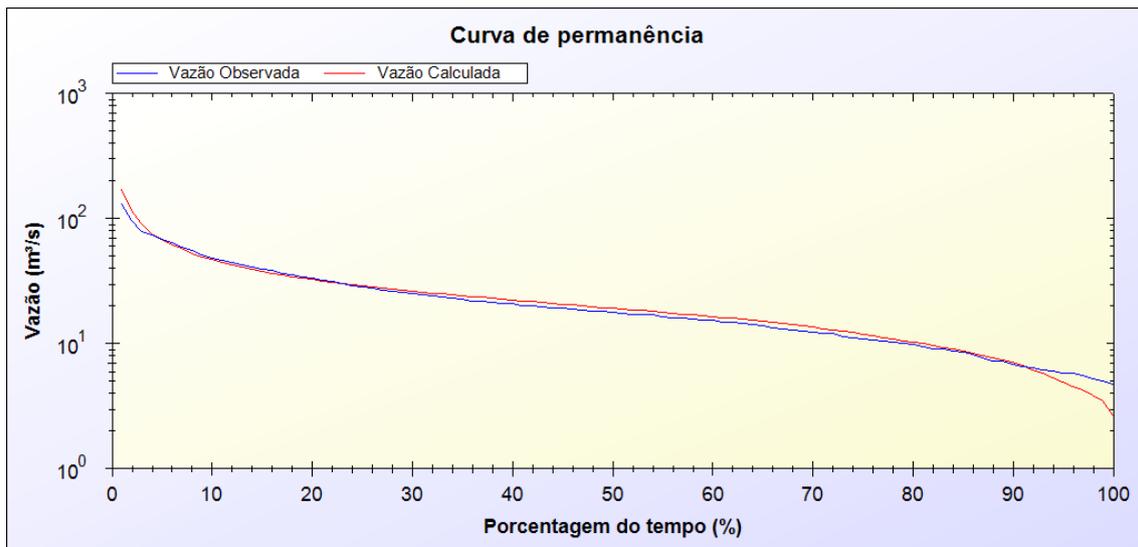


Figura E.21. Curva de permanência do posto fluviométrico 75205000, na sub-bacia 3, obtida na etapa de verificação da calibração do MGB-IPH.

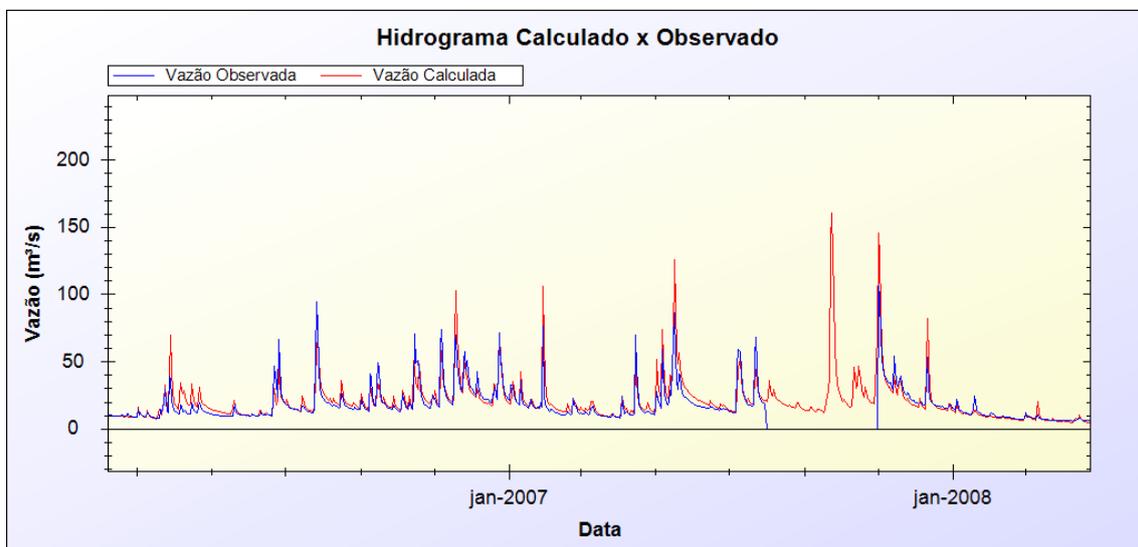


Figura E.22. Detalhe do hidrograma do posto fluviométrico 75205000, na sub-bacia 3, obtido na etapa de verificação da calibração do MGB-IPH.

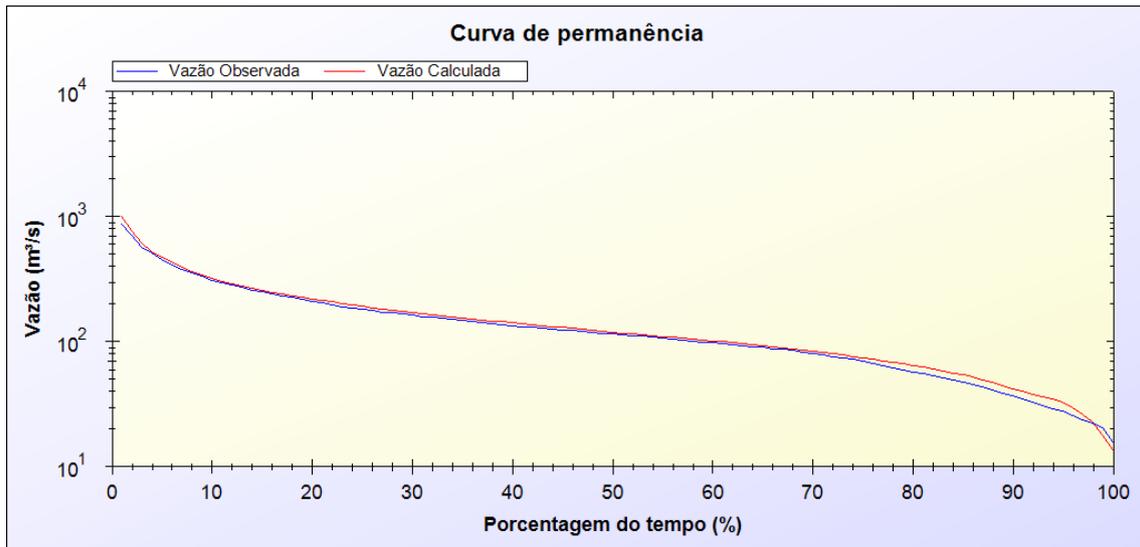


Figura E.23. Curva de permanência do posto fluviométrico 75230000, na sub-bacia 4, obtida na etapa de verificação da calibração do MGB-IPH.

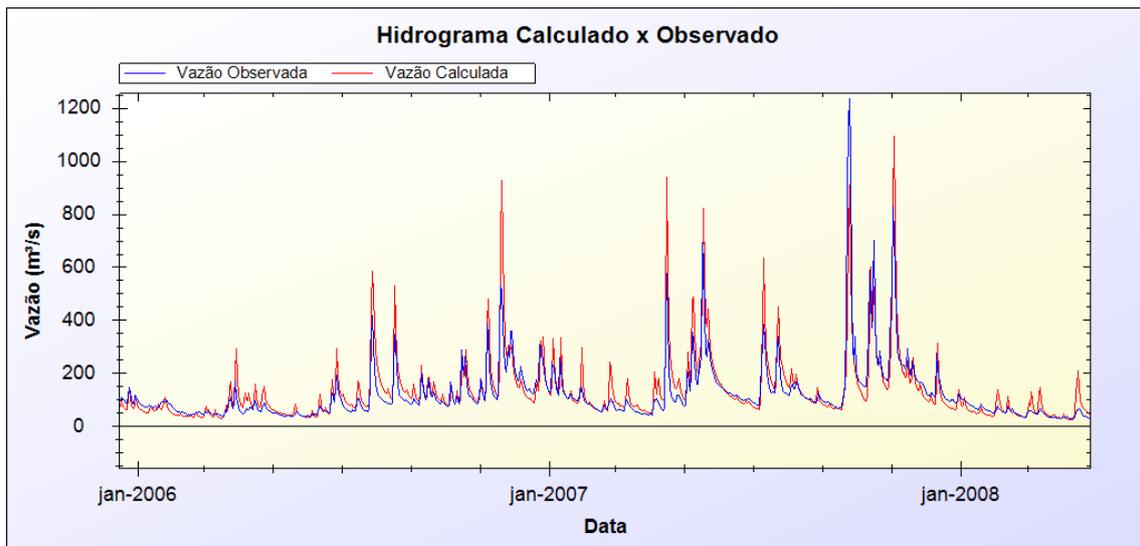


Figura E.24. Detalhe do hidrograma do posto fluviométrico 75230000, na sub-bacia 4, obtido na etapa de verificação da calibração do MGB-IPH.

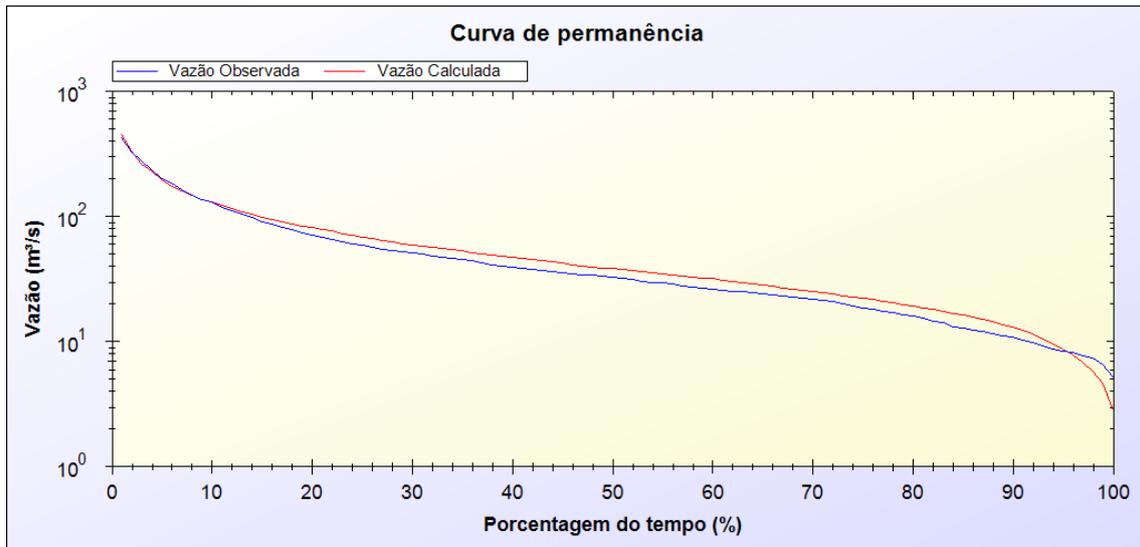


Figura E.25. Curva de permanência do posto fluviométrico 75295000, na sub-bacia 5, obtida na etapa de verificação da calibração do MGB-IPH.

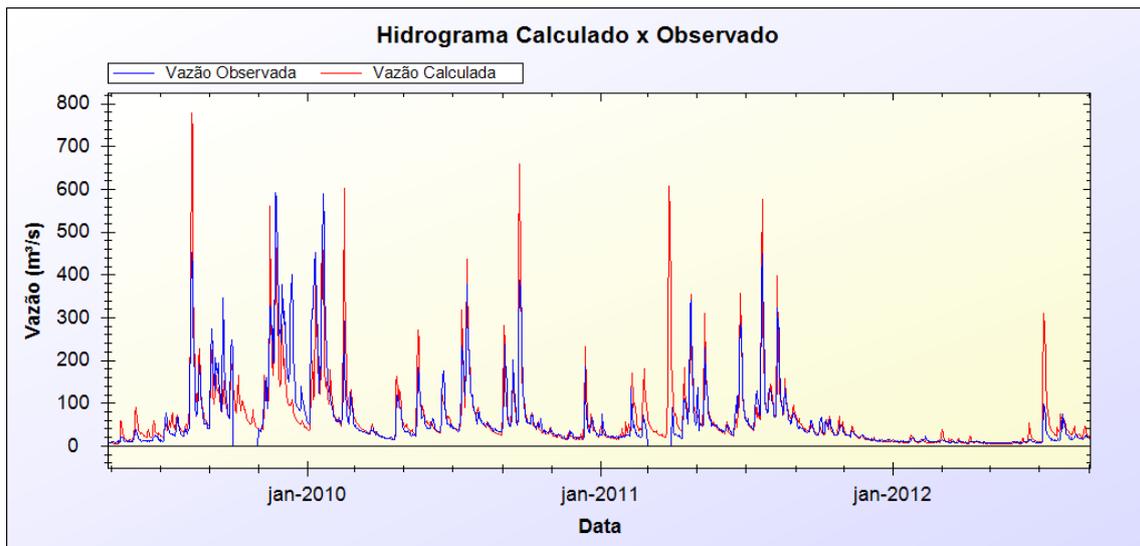


Figura E.26. Detalhe do hidrograma do posto fluviométrico 75295000, na sub-bacia 5, obtido na etapa de verificação da calibração do MGB-IPH.

ANEXO F

Resultados da previsão de umidade do solo

F.1 Previsões tipo A: Ensemble - Classe mais provável de saturação do solo

As tabelas a seguir mostram os resultados da previsão de umidade do solo quanto a classe de saturação mais provável do *ensemble* de cada modelo (previsões tipo A). Cada tabela traz a informação de classe de saturação pseudo-observada (simulada com a precipitação observada); a classe mais provável de saturação conforme os resultados do *ensemble* de cada modelo; a probabilidade referente à esta previsão, calculada conforme a Equação (23); e o erro referente à previsão. O erro é definido como a classe prevista *menos* a classe pseudo-verdadeira de saturação do solo.

Tabela F.1. Classe de saturação pseudo-observada, prevista pelo ensemble de cada modelo (previsões tipo A), probabilidade da previsão e erro da previsão para o horizonte de 1 mês.

Mês	Classe pseudo-observada	Classe mais provável (Previsão tipo A)			Probabilidade			Erro		
		CCM3v6	ECPC	GFDL	CCM3v6	ECPC	GFDL	CCM3v6	ECPC	GFDL
jun/05	0	-2	0	-2	58%	58%	60%	-2	0	-2
jul/05	-1	-1	1	-2	29%	58%	73%	0	2	-1
ago/05	0	-1	2	-2	25%	42%	67%	-1	2	-2
set/05	1	1	0	-2	33%	100%	83%	0	-1	-3
out/05	1	-2	0	-2	50%	50%	37%	-3	-1	-3
nov/05	0	-1	-1	1	29%	50%	40%	-1	-1	1
dez/05	0	-1	0	0	29%	25%	30%	-1	0	0
jan/06	0	-1	0	-2	38%	25%	33%	-1	0	-2
fev/06	-2	1	0	1	38%	50%	33%	3	2	3
mar/06	0	0	-1	-1	38%	50%	47%	0	-1	-1
abr/06	0	-2	1	-2	42%	83%	37%	-2	1	-2
mai/06	-2	-2	-1	-2	42%	67%	47%	0	1	0
jun/06	-1	-2	-2	-2	63%	33%	70%	-1	-1	-1
jul/06	0	-2	-1	-2	54%	50%	60%	-2	-1	-2
ago/06	0	-2	1	-2	42%	50%	47%	-2	1	-2
set/06	1	-1	-1	-2	33%	42%	63%	-2	-2	-3
out/06	0	-2	-1	-2	38%	83%	50%	-2	-1	-2
nov/06	1	1	-1	1	38%	50%	50%	0	-2	0
dez/06	1	1	0	0	38%	42%	43%	0	-1	-1
jan/07	1	-1	0	-1	29%	42%	33%	-2	-1	-2
fev/07	0	0	-2	-2	29%	42%	33%	0	-2	-2
mar/07	1	-1	-1	0	38%	58%	33%	-2	-2	-1
abr/07	1	0	-2	0	42%	67%	33%	-1	-3	-1
mai/07	1	0	-2	0	38%	58%	27%	-1	-3	-1
jun/07	-2	-2	-2	0	58%	42%	40%	0	0	2
jul/07	0	-2	1	-2	33%	42%	53%	-2	1	-2

Mês	Classe pseudo-observada	Classe mais provável (Previsão tipo A)			Probabilidade			Erro		
		CCM3v6	ECPC	GFDL	CCM3v6	ECPC	GFDL	CCM3v6	ECPC	GFDL
ago/07	0	1	1	-2	38%	42%	43%	1	1	-2
set/07	-1	0	1	-2	25%	42%	67%	1	2	-1
out/07	0	-2	-1	-2	46%	42%	47%	-2	-1	-2
nov/07	1	-2	-1	1	54%	50%	37%	-3	-2	0
dez/07	0	-1	-1	-1	46%	42%	33%	-1	-1	-1
jan/08	-1	-1	0	1	29%	25%	27%	0	1	2
fev/08	-1	1	-2	0	42%	42%	33%	2	-1	1
mar/08	-1	0	-1	-1	46%	42%	43%	1	0	0
abr/08	-1	-2	-2	-1	58%	50%	43%	-1	-1	0
mai/08	0	-2	-1	-2	63%	33%	57%	-2	-1	-2
jun/08	1	-2	1	-2	71%	42%	73%	-3	0	-3
jul/08	-1	-2	0	-2	63%	42%	60%	-1	1	-1
ago/08	1	-2	0	-2	38%	33%	60%	-3	-1	-3
set/08	0	-1	-1	-2	33%	42%	87%	-1	-1	-2
out/08	0	-2	-1	-2	50%	42%	53%	-2	-1	-2
nov/08	0	-1	1	1	38%	50%	43%	-1	1	1
dez/08	-1	-1	1	-1	38%	33%	40%	0	2	0
jan/09	0	-1	-1	-2	29%	58%	37%	-1	-1	-2
fev/09	-1	1	-2	1	33%	42%	37%	2	-1	2
mar/09	-1	0	0	0	42%	33%	43%	1	1	1
abr/09	-2	-2	-2	1	38%	58%	40%	0	0	3
mai/09	-2	-1	-2	0	42%	50%	43%	1	0	2
jun/09	0	-2	0	-2	58%	33%	37%	-2	0	-2
jul/09	0	-2	1	-2	38%	58%	40%	-2	1	-2
ago/09	1	-1	0	-2	33%	42%	43%	-2	-1	-3
set/09	1	0	0	-2	33%	50%	43%	-1	-1	-3
out/09	0	-2	-1	-2	38%	83%	50%	-2	-1	-2
nov/09	1	-2	1	1	33%	58%	40%	-3	0	0
dez/09	1	1	0	1	29%	33%	37%	0	-1	0
jan/10	1	-1	0	-1	50%	42%	37%	-2	-1	-2
fev/10	0	0	1	-2	38%	75%	40%	0	1	-2
mar/10	0	0	1	0	46%	50%	27%	0	1	0
abr/10	-1	1	1	0	38%	75%	43%	2	2	1
mai/10	1	0	0	1	46%	58%	33%	-1	-1	0
jun/10	0	1	0	-2	33%	50%	63%	1	0	-2
jul/10	0	-2	-1	-2	46%	42%	73%	-2	-1	-2
ago/10	-1	-1	-2	-2	33%	42%	67%	0	-1	-1
set/10	1	-2	1	-2	42%	42%	73%	-3	0	-3
out/10	-1	-2	0	-2	75%	25%	53%	-1	1	-1
nov/10	-1	-2	0	-2	67%	33%	33%	-1	1	-1
dez/10	1	-2	1	-1	33%	33%	53%	-3	0	-2
jan/11	0	0	1	-2	33%	42%	50%	0	1	-2
fev/11	1	1	-2	1	54%	33%	37%	0	-3	0
mar/11	0	0	-2	1	29%	50%	33%	0	-2	1
abr/11	1	-1	-2	-2	46%	50%	30%	-2	-3	-3
mai/11	0	-2	-2	-1	46%	42%	43%	-2	-2	-1
jun/11	0	-2	-2	-2	71%	67%	80%	-2	-2	-2
jul/11	1	-2	-2	-2	58%	67%	87%	-3	-3	-3

Mês	Classe pseudo-observada	Classe mais provável (Previsão tipo A)			Probabilidade			Erro		
		CCM3v6	ECPC	GFDL	CCM3v6	ECPC	GFDL	CCM3v6	ECPC	GFDL
ago/11	1	-1	-2	-2	33%	50%	80%	-2	-3	-3
set/11	-1	0	-2	-2	33%	42%	53%	1	-1	-1
out/11	0	-2	0	-2	58%	25%	57%	-2	0	-2
nov/11	0	-2	0	-2	42%	42%	33%	-2	0	-2
dez/11	-1	-1	1	-1	42%	50%	50%	0	2	0
jan/12	-1	-1	-1	-1	46%	33%	30%	0	0	0
fev/12	-2	0	-2	1	33%	33%	27%	2	0	3
mar/12	-1	-2	-2	0	38%	33%	27%	-1	-1	1
abr/12	-2	-2	1	0	54%	50%	33%	0	3	2
mai/12	-2	-2	0	0	38%	42%	40%	0	2	2
jun/12	-2	-1	1	0	33%	67%	40%	1	3	2
jul/12	-1	1	0	-2	29%	33%	47%	2	1	-1
ago/12	0	0	1	-2	33%	58%	43%	0	1	-2
set/12	0	0	0	-2	29%	33%	37%	0	0	-2
out/12	1	0	0	-2	33%	42%	80%	-1	-1	-3
nov/12	0	0	-1	-2	29%	42%	37%	0	-1	-2
dez/12	2	0	0	-1	29%	42%	40%	-2	-2	-3
jan/13	1	-1	-1	-1	38%	33%	37%	-2	-2	-2
fev/13	-1	0	2	1	38%	50%	23%	1	3	2
mar/13	1	-1	0	-1	42%	75%	27%	-2	-1	-2
abr/13	1	-2	-1	0	50%	42%	30%	-3	-2	-1
mai/13	0	0	-1	1	46%	33%	43%	0	-1	1
jun/13	-1	-2	0	-2	46%	42%	47%	-1	1	-1
jul/13	0	-2	-2	-2	58%	50%	37%	-2	-2	-2
ago/13	1	1	-1	-2	42%	50%	43%	0	-2	-3
set/13	0	1	0	-2	38%	50%	47%	1	0	-2
out/13	-1	-2	-1	-2	33%	58%	50%	-1	0	-1
nov/13	0	-1	-1	-2	29%	42%	30%	-1	-1	-2
dez/13	0	-1	-1	0	38%	50%	33%	-1	-1	0

Tabela F.2. Classe de saturação pseudo-observada, prevista pelo *ensemble* de cada modelo (previsões tipo A), probabilidade da previsão e erro da previsão para o horizonte de 3 meses.

Mês	Classe pseudo-observada	Classe mais provável (Previsão tipo A)			Probabilidade			Erro		
		CCM3v6	ECPC	GFDL	CCM3v6	ECPC	GFDL	CCM3v6	ECPC	GFDL
jun/05	0	-2	0	-2	58%	75%	77%	-2	0	-2
jul/05	-1	-2	1	-2	46%	42%	87%	-1	2	-1
ago/05	0	1	1	-2	29%	58%	53%	1	1	-2
set/05	1	-1	1	-2	33%	58%	53%	-2	0	-3
out/05	1	0	-1	-2	29%	58%	47%	-1	-2	-3
nov/05	0	1	-1	1	38%	58%	30%	1	-1	1
dez/05	0	-1	-1	-1	33%	58%	50%	-1	-1	-1
jan/06	0	0	-1	-2	29%	50%	47%	0	-1	-2
fev/06	-2	1	-2	-2	33%	33%	40%	3	0	0
mar/06	0	0	1	0	46%	42%	33%	0	1	0
abr/06	0	0	1	0	42%	42%	33%	0	1	0
mai/06	-2	-2	-1	-1	50%	33%	33%	0	1	1
jun/06	-1	-2	1	-2	63%	42%	67%	-1	2	-1
jul/06	0	-2	1	-2	50%	50%	70%	-2	1	-2
ago/06	0	-2	1	-2	29%	33%	47%	-2	1	-2
set/06	1	-1	0	-2	33%	50%	47%	-2	-1	-3
out/06	0	-2	-1	-2	46%	42%	50%	-2	-1	-2
nov/06	1	-2	-1	1	33%	42%	37%	-3	-2	0
dez/06	1	1	-1	0	42%	42%	37%	0	-2	-1
jan/07	1	-1	-1	0	46%	42%	27%	-2	-2	-1
fev/07	0	1	-2	1	38%	42%	43%	1	-2	1
mar/07	1	1	0	1	33%	42%	37%	0	-1	0
abr/07	1	0	1	1	29%	33%	43%	-1	0	0
mai/07	1	-1	-1	-1	38%	58%	40%	-2	-2	-2
jun/07	-2	-2	-2	-2	50%	33%	60%	0	0	0
jul/07	0	0	-1	-2	38%	33%	60%	0	-1	-2
ago/07	0	1	1	-2	29%	42%	40%	1	1	-2
set/07	-1	1	-1	-2	33%	33%	60%	2	0	-1
out/07	0	-2	-1	-2	38%	33%	47%	-2	-1	-2
nov/07	1	1	-1	-1	38%	58%	37%	0	-2	-2
dez/07	0	0	0	-1	38%	33%	33%	0	0	-1
jan/08	-1	-1	1	1	38%	42%	33%	0	2	2
fev/08	-1	0	-1	1	33%	33%	33%	1	0	2
mar/08	-1	0	0	-1	38%	33%	33%	1	1	0
abr/08	-1	-2	0	-2	46%	42%	47%	-1	1	-1
mai/08	0	-2	1	-2	42%	42%	50%	-2	1	-2
jun/08	1	-2	1	-2	75%	50%	70%	-3	0	-3
jul/08	-1	-2	0	-2	58%	50%	83%	-1	1	-1
ago/08	1	-2	0	-2	38%	25%	67%	-3	-1	-3
set/08	0	-2	1	-2	46%	42%	57%	-2	1	-2
out/08	0	-2	0	-2	33%	42%	37%	-2	0	-2
nov/08	0	-2	-1	1	38%	33%	43%	-2	-1	1
dez/08	-1	0	0	1	29%	33%	33%	1	1	2
jan/09	0	0	0	0	25%	42%	27%	0	0	0
fev/09	-1	1	1	0	42%	33%	37%	2	2	1
mar/09	-1	1	0	0	29%	42%	40%	2	1	1

Mês	Classe pseudo-observada	Classe mais provável (Previsão tipo A)			Probabilidade			Erro		
		CCM3v6	ECPC	GFDL	CCM3v6	ECPC	GFDL	CCM3v6	ECPC	GFDL
abr/09	-2	0	1	0	42%	67%	30%	2	3	2
mai/09	-2	-1	-1	-2	42%	33%	33%	1	1	0
jun/09	0	0	1	-2	38%	58%	57%	0	1	-2
jul/09	0	-1	0	-2	38%	42%	40%	-1	0	-2
ago/09	1	0	1	-2	38%	33%	43%	-1	0	-3
set/09	1	0	1	-2	29%	50%	40%	-1	0	-3
out/09	0	-2	-1	-2	29%	50%	37%	-2	-1	-2
nov/09	1	-2	1	1	33%	42%	47%	-3	0	0
dez/09	1	0	-1	-1	38%	50%	30%	-1	-2	-2
jan/10	1	0	1	0	25%	58%	30%	-1	0	-1
fev/10	0	1	1	-1	46%	42%	33%	1	1	-1
mar/10	0	1	-1	0	33%	25%	33%	1	-1	0
abr/10	-1	0	1	1	29%	50%	53%	1	2	2
mai/10	1	-1	0	1	38%	33%	37%	-2	-1	0
jun/10	0	-2	1	-2	58%	50%	60%	-2	1	-2
jul/10	0	-2	1	-2	50%	42%	53%	-2	1	-2
ago/10	-1	-2	-1	-2	38%	42%	53%	-1	0	-1
set/10	1	-2	-1	-2	46%	50%	60%	-3	-2	-3
out/10	-1	-2	-1	-2	67%	42%	43%	-1	0	-1
nov/10	-1	-2	-1	1	38%	33%	27%	-1	0	2
dez/10	1	-2	0	-1	33%	42%	33%	-3	-1	-2
jan/11	0	-1	1	1	38%	33%	33%	-1	1	1
fev/11	1	1	1	1	42%	25%	40%	0	0	0
mar/11	0	1	0	0	38%	25%	27%	1	0	0
abr/11	1	0	-2	0	38%	33%	33%	-1	-3	-1
mai/11	0	-2	0	-1	58%	42%	40%	-2	0	-1
jun/11	0	-2	-2	-2	71%	50%	77%	-2	-2	-2
jul/11	1	-2	-2	-2	50%	42%	80%	-3	-3	-3
ago/11	1	-2	-1	-2	29%	58%	60%	-3	-2	-3
set/11	-1	1	-1	-2	33%	33%	70%	2	0	-1
out/11	0	-2	0	-2	58%	42%	50%	-2	0	-2
nov/11	0	1	-1	1	25%	42%	37%	1	-1	1
dez/11	-1	1	-1	0	54%	58%	27%	2	0	1
jan/12	-1	-1	1	0	38%	50%	30%	0	2	1
fev/12	-2	1	1	-1	50%	33%	33%	3	3	1
mar/12	-1	0	0	0	46%	33%	37%	1	1	1
abr/12	-2	-2	1	-2	58%	33%	40%	0	3	0
mai/12	-2	-2	0	-2	58%	42%	40%	0	2	0
jun/12	-2	-2	1	-2	42%	50%	43%	0	3	0
jul/12	-1	-2	0	1	50%	42%	27%	-1	1	2
ago/12	0	-2	0	-2	38%	42%	37%	-2	0	-2
set/12	0	0	-1	-2	42%	42%	33%	0	-1	-2
out/12	1	-2	1	-2	38%	25%	43%	-3	0	-3
nov/12	0	1	1	1	38%	58%	37%	1	1	1
dez/12	2	0	0	1	38%	42%	33%	-2	-2	-1
jan/13	1	0	0	-1	29%	33%	30%	-1	-1	-2
fev/13	-1	-1	1	0	29%	42%	37%	0	2	1
mar/13	1	0	0	0	46%	42%	40%	-1	-1	-1

Mês	Classe pseudo-observada	Classe mais provável (Previsão tipo A)			Probabilidade			Erro		
		CCM3v6	ECPC	GFDL	CCM3v6	ECPC	GFDL	CCM3v6	ECPC	GFDL
abr/13	1	0	1	0	50%	58%	43%	-1	0	-1
mai/13	0	-2	1	0	46%	50%	37%	-2	1	0
jun/13	-1	-2	1	1	42%	50%	37%	-1	2	2
jul/13	0	-2	0	-2	33%	42%	50%	-2	0	-2
ago/13	1	-1	1	-2	33%	58%	40%	-2	0	-3
set/13	0	1	-1	-2	42%	50%	43%	1	-1	-2
out/13	-1	-2	0	-2	29%	25%	47%	-1	1	-1
nov/13	0	-1	-1	1	38%	67%	27%	-1	-1	1
dez/13	0	0	-1	0	29%	50%	30%	0	-1	0

Tabela F.3. Classe de saturação pseudo-observada, prevista pelo *ensemble* de cada modelo (previsões tipo A), probabilidade da previsão e erro da previsão para o horizonte de 6 meses.

Mês	Classe pseudo-observada	Classe mais provável (Previsão tipo A)			Probabilidade			Erro		
		CCM3v6	ECPC	GFDL	CCM3v6	ECPC	GFDL	CCM3v6	ECPC	GFDL
jun/05	0	-2	0	1	42%	67%	40%	-2	0	1
jul/05	-1	-2	2	0	54%	25%	40%	-1	3	1
ago/05	0	-1	0	-1	33%	42%	27%	-1	0	-1
set/05	1	0	1	1	38%	50%	40%	-1	0	0
out/05	1	-2	0	1	50%	25%	30%	-3	-1	0
nov/05	0	1	-1	2	29%	42%	33%	1	-1	2
dez/05	0	0	0	-1	38%	33%	40%	0	0	-1
jan/06	0	0	-1	1	29%	50%	30%	0	-1	1
fev/06	-2	-1	1	2	29%	33%	30%	1	3	4
mar/06	0	-2	1	1	38%	33%	40%	-2	1	1
abr/06	0	-2	1	2	46%	67%	43%	-2	1	2
mai/06	-2	-1	1	2	33%	33%	43%	1	3	4
jun/06	-1	0	-2	2	29%	42%	43%	1	-1	3
jul/06	0	-1	-1	1	33%	42%	33%	-1	-1	1
ago/06	0	-1	1	-1	29%	33%	30%	-1	1	-1
set/06	1	1	-1	0	38%	33%	37%	0	-2	-1
out/06	0	-2	-1	1	38%	42%	30%	-2	-1	1
nov/06	1	-2	1	1	33%	42%	33%	-3	0	0
dez/06	1	1	-1	-1	38%	33%	33%	0	-2	-2
jan/07	1	-1	1	1	33%	58%	30%	-2	0	0
fev/07	0	1	0	2	42%	33%	43%	1	0	2
mar/07	1	0	0	1	50%	50%	43%	-1	-1	0
abr/07	1	1	-2	2	46%	42%	43%	0	-3	1
mai/07	1	0	-2	2	42%	42%	40%	-1	-3	1
jun/07	-2	1	0	0	29%	42%	30%	3	2	2
jul/07	0	-2	1	0	46%	25%	30%	-2	1	0
ago/07	0	-2	-1	-1	50%	42%	27%	-2	-1	-1
set/07	-1	0	0	1	38%	50%	30%	1	1	2
out/07	0	-2	0	2	50%	25%	30%	-2	0	2
nov/07	1	0	-1	2	46%	50%	33%	-1	-2	1
dez/07	0	0	1	-1	38%	42%	37%	0	1	-1
jan/08	-1	-2	2	-1	33%	33%	33%	-1	3	0
fev/08	-1	0	1	2	38%	33%	37%	1	2	3
mar/08	-1	1	0	1	33%	42%	30%	2	1	2
abr/08	-1	-1	1	1	29%	58%	30%	0	2	2
mai/08	0	-1	0	0	38%	50%	30%	-1	0	0
jun/08	1	-2	-2	0	58%	50%	40%	-3	-3	-1
jul/08	-1	-2	-2	-1	67%	42%	40%	-1	-1	0
ago/08	1	0	1	-1	29%	33%	40%	-1	0	-2
set/08	0	1	1	0	38%	50%	27%	1	1	0
out/08	0	-2	-1	-1	38%	50%	33%	-2	-1	-1
nov/08	0	1	-1	0	33%	75%	30%	1	-1	0
dez/08	-1	-1	-1	0	42%	50%	30%	0	0	1
jan/09	0	1	-1	1	38%	42%	30%	1	-1	1
fev/09	-1	1	0	2	38%	33%	33%	2	1	3
mar/09	-1	0	1	0	42%	42%	47%	1	2	1

Mês	Classe pseudo-observada	Classe mais provável (Previsão tipo A)			Probabilidade			Erro		
		CCM3v6	ECPC	GFDL	CCM3v6	ECPC	GFDL	CCM3v6	ECPC	GFDL
abr/09	-2	1	0	2	38%	42%	37%	3	2	4
mai/09	-2	-2	0	2	42%	42%	33%	0	2	4
jun/09	0	-2	-1	1	58%	33%	27%	-2	-1	1
jul/09	0	-2	1	1	58%	42%	33%	-2	1	1
ago/09	1	0	-1	-1	33%	50%	27%	-1	-2	-2
set/09	1	1	0	0	42%	50%	27%	0	-1	-1
out/09	0	-2	0	2	38%	33%	37%	-2	0	2
nov/09	1	-2	-1	2	29%	58%	40%	-3	-2	1
dez/09	1	-1	1	-1	38%	33%	43%	-2	0	-2
jan/10	1	0	-1	1	33%	50%	30%	-1	-2	0
fev/10	0	1	1	2	54%	42%	37%	1	1	2
mar/10	0	1	0	1	38%	25%	40%	1	0	1
abr/10	-1	1	0	1	42%	42%	47%	2	1	2
mai/10	1	1	1	2	33%	33%	47%	0	0	1
jun/10	0	-2	1	2	42%	58%	40%	-2	1	2
jul/10	0	0	1	1	38%	50%	30%	0	1	1
ago/10	-1	-1	1	0	50%	42%	40%	0	2	1
set/10	1	0	0	-2	46%	50%	30%	-1	-1	-3
out/10	-1	-2	0	1	42%	42%	27%	-1	1	2
nov/10	-1	-2	1	0	50%	50%	30%	-1	2	1
dez/10	1	-2	0	-1	46%	50%	43%	-3	-1	-2
jan/11	0	0	1	-1	33%	50%	40%	0	1	-1
fev/11	1	1	-1	-1	54%	58%	30%	0	-2	-2
mar/11	0	-1	0	-1	33%	33%	30%	-1	0	-1
abr/11	1	-1	1	1	42%	58%	33%	-2	0	0
mai/11	0	-2	0	2	50%	33%	33%	-2	0	2
jun/11	0	-2	-2	0	63%	58%	33%	-2	-2	0
jul/11	1	-2	-1	-1	50%	50%	37%	-3	-2	-2
ago/11	1	-2	-1	-2	38%	42%	47%	-3	-2	-3
set/11	-1	1	1	0	38%	33%	30%	2	2	1
out/11	0	-2	-1	0	38%	33%	30%	-2	-1	0
nov/11	0	0	-1	-1	25%	50%	27%	0	-1	-1
dez/11	-1	-1	1	0	38%	33%	27%	0	2	1
jan/12	-1	0	1	1	29%	42%	37%	1	2	2
fev/12	-2	1	1	2	50%	50%	37%	3	3	4
mar/12	-1	0	0	0	38%	42%	40%	1	1	1
abr/12	-2	-1	-1	0	29%	50%	37%	1	1	2
mai/12	-2	-2	0	0	38%	42%	37%	0	2	2
jun/12	-2	-2	-2	2	54%	58%	27%	0	0	4
jul/12	-1	-2	0	1	38%	42%	37%	-1	1	2
ago/12	0	0	0	0	33%	25%	23%	0	0	0
set/12	0	1	1	1	42%	50%	27%	1	1	1
out/12	1	-2	-1	-1	50%	33%	30%	-3	-2	-2
nov/12	0	-2	1	0	38%	50%	27%	-2	1	0
dez/12	2	-1	1	0	38%	50%	50%	-3	-1	-2
jan/13	1	-1	-1	-1	38%	42%	33%	-2	-2	-2
fev/13	-1	0	1	0	29%	42%	33%	1	2	1
mar/13	1	0	1	1	33%	42%	33%	-1	0	0

Mês	Classe pseudo-observada	Classe mais provável (Previsão tipo A)			Probabilidade			Erro		
		CCM3v6	ECPC	GFDL	CCM3v6	ECPC	GFDL	CCM3v6	ECPC	GFDL
abr/13	1	1	0	1	33%	42%	37%	0	-1	0
mai/13	0	-1	1	2	54%	50%	53%	-1	1	2
jun/13	-1	0	1	2	33%	67%	60%	1	2	3
jul/13	0	-2	-2	1	46%	42%	37%	-2	-2	1
ago/13	1	1	-2	0	29%	50%	30%	0	-3	-1
set/13	0	0	-2	1	38%	42%	33%	0	-2	1
out/13	-1	-2	-2	-1	33%	42%	30%	-1	-1	0
nov/13	0	-2	0	-1	33%	33%	23%	-2	0	-1
dez/13	0	-1	-1	0	38%	50%	33%	-1	-1	0

F.2 Previsões tipo A: Ensemble - Previsão completa - Probabilidade de cada classe de umidade do solo

As tabelas F.4 a F.12 mostram o resultado completo da previsão de umidade do solo. Cada tabela traz a informação de classe de saturação pseudo-verdadeira e probabilidade de ocorrência de cada classe de saturação conforme o *ensemble* de cada modelo. A probabilidade referente a cada classe é calculada pela Equação (23).

Tabela F.4. Classe de saturação pseudo-observada e probabilidade associada a cada classe de saturação conforme o *ensemble* do modelo CCM3v6 (tipo A) para o horizonte de 1 mês.

Mês	Classe pseudo-observada	Previsão tipo A: Modelo CCM3v6 - Horizonte 1 mês				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
jun/05	0	58%	4%	38%	0%	0%
jul/05	-1	29%	29%	25%	17%	0%
ago/05	0	25%	25%	21%	13%	17%
set/05	1	29%	17%	21%	33%	0%
out/05	1	50%	8%	29%	0%	13%
nov/05	0	25%	29%	25%	21%	0%
dez/05	0	21%	29%	25%	21%	4%
jan/06	0	13%	38%	29%	17%	4%
fev/06	-2	21%	8%	25%	38%	8%
mar/06	0	13%	25%	38%	21%	4%
abr/06	0	42%	21%	17%	21%	0%
mai/06	-2	42%	8%	38%	13%	0%
jun/06	-1	63%	17%	8%	13%	0%
jul/06	0	54%	25%	13%	8%	0%
ago/06	0	42%	38%	13%	4%	4%
set/06	1	33%	33%	21%	13%	0%
out/06	0	38%	17%	33%	8%	4%
nov/06	1	17%	25%	21%	38%	0%
dez/06	1	0%	38%	17%	38%	8%
jan/07	1	4%	29%	25%	17%	25%
fev/07	0	21%	13%	29%	29%	8%
mar/07	1	13%	38%	29%	17%	4%
abr/07	1	29%	13%	42%	17%	0%
mai/07	1	25%	25%	38%	13%	0%
jun/07	-2	58%	4%	21%	17%	0%
jul/07	0	33%	21%	17%	25%	4%
ago/07	0	21%	17%	13%	38%	13%
set/07	-1	21%	25%	25%	25%	4%
out/07	0	46%	8%	25%	8%	13%
nov/07	1	54%	13%	21%	13%	0%

Mês	Classe pseudo-observada	Previsão tipo A: Modelo CCM3v6 - Horizonte 1 mês				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
dez/07	0	21%	46%	21%	13%	0%
jan/08	-1	25%	29%	21%	25%	0%
fev/08	-1	8%	13%	25%	42%	13%
mar/08	-1	13%	33%	46%	8%	0%
abr/08	-1	58%	17%	17%	8%	0%
mai/08	0	63%	25%	8%	4%	0%
jun/08	1	71%	13%	8%	8%	0%
jul/08	-1	63%	17%	13%	8%	0%
ago/08	1	38%	25%	17%	13%	8%
set/08	0	29%	33%	25%	13%	0%
out/08	0	50%	0%	25%	8%	17%
nov/08	0	29%	38%	25%	8%	0%
dez/08	-1	21%	38%	21%	21%	0%
jan/09	0	29%	29%	25%	13%	4%
fev/09	-1	25%	8%	29%	33%	4%
mar/09	-1	17%	21%	42%	17%	4%
abr/09	-2	38%	13%	29%	21%	0%
mai/09	-2	33%	42%	8%	17%	0%
jun/09	0	58%	8%	17%	17%	0%
jul/09	0	38%	17%	25%	21%	0%
ago/09	1	21%	33%	29%	17%	0%
set/09	1	17%	17%	33%	33%	0%
out/09	0	38%	0%	25%	13%	25%
nov/09	1	33%	13%	21%	21%	13%
dez/09	1	29%	25%	13%	29%	4%
jan/10	1	13%	50%	29%	8%	0%
fev/10	0	17%	8%	38%	33%	4%
mar/10	0	13%	21%	46%	21%	0%
abr/10	-1	17%	17%	29%	38%	0%
mai/10	1	8%	25%	46%	21%	0%
jun/10	0	33%	8%	25%	33%	0%
jul/10	0	46%	25%	8%	17%	4%
ago/10	-1	33%	33%	25%	4%	4%
set/10	1	42%	13%	21%	21%	4%
out/10	-1	75%	4%	17%	4%	0%
nov/10	-1	67%	13%	17%	4%	0%
dez/10	1	33%	29%	29%	8%	0%
jan/11	0	29%	21%	33%	17%	0%
fev/11	1	17%	8%	21%	54%	0%
mar/11	0	25%	21%	29%	21%	4%
abr/11	1	17%	46%	25%	13%	0%
mai/11	0	46%	42%	8%	4%	0%

Mês	Classe pseudo-observada	Previsão tipo A: Modelo CCM3v6 - Horizonte 1 mês				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
jun/11	0	71%	8%	21%	0%	0%
jul/11	1	58%	8%	13%	17%	4%
ago/11	1	25%	33%	25%	17%	0%
set/11	-1	29%	25%	33%	13%	0%
out/11	0	58%	0%	29%	0%	13%
nov/11	0	42%	33%	13%	13%	0%
dez/11	-1	13%	42%	25%	17%	4%
jan/12	-1	17%	46%	8%	8%	21%
fev/12	-2	25%	8%	33%	21%	13%
mar/12	-1	38%	29%	25%	8%	0%
abr/12	-2	54%	8%	29%	8%	0%
mai/12	-2	38%	33%	25%	4%	0%
jun/12	-2	33%	33%	21%	13%	0%
jul/12	-1	29%	17%	21%	29%	4%
ago/12	0	13%	29%	33%	8%	17%
set/12	0	21%	25%	29%	17%	8%
out/12	1	25%	13%	33%	4%	25%
nov/12	0	13%	13%	29%	25%	21%
dez/12	2	25%	17%	29%	25%	4%
jan/13	1	17%	38%	21%	21%	4%
fev/13	-1	21%	8%	38%	29%	4%
mar/13	1	29%	42%	17%	8%	4%
abr/13	1	50%	17%	13%	21%	0%
mai/13	0	21%	29%	46%	4%	0%
jun/13	-1	46%	4%	25%	25%	0%
jul/13	0	58%	13%	13%	17%	0%
ago/13	1	21%	21%	17%	42%	0%
set/13	0	13%	17%	33%	38%	0%
out/13	-1	33%	21%	17%	13%	17%
nov/13	0	29%	29%	17%	21%	4%
dez/13	0	25%	38%	25%	13%	0%

Tabela F.5. Classe de saturação pseudo-observada e probabilidade associada a cada classe de saturação conforme o *ensemble* do modelo ECPC (tipo A) para o horizonte de 1 mês.

Mês	Classe pseudo-observada	Previsão tipo A: Modelo ECPC - Horizonte 1 mês				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
jun/05	0	8%	33%	58%	0%	0%
jul/05	-1	0%	17%	25%	58%	0%
ago/05	0	0%	0%	25%	33%	42%
set/05	1	0%	0%	100%	0%	0%
out/05	1	25%	25%	50%	0%	0%
nov/05	0	0%	50%	0%	25%	25%
dez/05	0	25%	25%	25%	25%	0%
jan/06	0	25%	25%	25%	25%	0%
fev/06	-2	25%	0%	50%	25%	0%
mar/06	0	0%	50%	25%	25%	0%
abr/06	0	17%	0%	0%	83%	0%
mai/06	-2	8%	67%	8%	17%	0%
jun/06	-1	33%	25%	17%	25%	0%
jul/06	0	25%	50%	0%	25%	0%
ago/06	0	0%	50%	0%	50%	0%
set/06	1	25%	42%	8%	25%	0%
out/06	0	0%	83%	0%	0%	17%
nov/06	1	17%	50%	17%	17%	0%
dez/06	1	17%	25%	42%	17%	0%
jan/07	1	0%	42%	42%	17%	0%
fev/07	0	42%	8%	17%	33%	0%
mar/07	1	42%	58%	0%	0%	0%
abr/07	1	67%	8%	17%	8%	0%
mai/07	1	58%	25%	17%	0%	0%
jun/07	-2	42%	25%	25%	8%	0%
jul/07	0	0%	25%	33%	42%	0%
ago/07	0	0%	17%	33%	42%	8%
set/07	-1	17%	17%	8%	42%	17%
out/07	0	8%	42%	17%	17%	17%
nov/07	1	8%	50%	25%	8%	8%
dez/07	0	17%	42%	33%	8%	0%
jan/08	-1	25%	25%	25%	25%	0%
fev/08	-1	42%	8%	8%	25%	17%
mar/08	-1	42%	42%	8%	8%	0%
abr/08	-1	50%	0%	42%	8%	0%
mai/08	0	33%	33%	17%	17%	0%
jun/08	1	33%	17%	8%	42%	0%
jul/08	-1	8%	8%	42%	42%	0%
ago/08	1	8%	25%	33%	25%	8%

Mês	Classe pseudo-observada	Previsão tipo A: Modelo ECPC - Horizonte 1 mês				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
set/08	0	0%	42%	25%	25%	8%
out/08	0	8%	42%	25%	8%	17%
nov/08	0	8%	25%	17%	50%	0%
dez/08	-1	33%	17%	8%	33%	8%
jan/09	0	25%	58%	8%	8%	0%
fev/09	-1	42%	0%	17%	17%	25%
mar/09	-1	25%	17%	33%	25%	0%
abr/09	-2	58%	8%	17%	17%	0%
mai/09	-2	50%	25%	0%	25%	0%
jun/09	0	17%	25%	33%	25%	0%
jul/09	0	8%	8%	17%	58%	8%
ago/09	1	8%	33%	42%	17%	0%
set/09	1	0%	25%	50%	25%	0%
out/09	0	0%	83%	17%	0%	0%
nov/09	1	8%	33%	0%	58%	0%
dez/09	1	17%	8%	33%	33%	8%
jan/10	1	8%	33%	42%	17%	0%
fev/10	0	0%	0%	17%	75%	8%
mar/10	0	0%	0%	33%	50%	17%
abr/10	-1	25%	0%	0%	75%	0%
mai/10	1	8%	25%	58%	8%	0%
jun/10	0	17%	25%	50%	8%	0%
jul/10	0	25%	42%	8%	25%	0%
ago/10	-1	42%	25%	17%	0%	17%
set/10	1	42%	0%	17%	42%	0%
out/10	-1	17%	17%	25%	25%	17%
nov/10	-1	8%	25%	33%	25%	8%
dez/10	1	17%	33%	17%	33%	0%
jan/11	0	8%	17%	33%	42%	0%
fev/11	1	33%	25%	25%	17%	0%
mar/11	0	50%	33%	8%	8%	0%
abr/11	1	50%	25%	8%	17%	0%
mai/11	0	42%	0%	25%	33%	0%
jun/11	0	67%	25%	8%	0%	0%
jul/11	1	67%	0%	17%	17%	0%
ago/11	1	50%	25%	8%	17%	0%
set/11	-1	42%	33%	8%	17%	0%
out/11	0	25%	25%	25%	8%	17%
nov/11	0	8%	8%	42%	25%	17%
dez/11	-1	0%	17%	25%	50%	8%
jan/12	-1	0%	33%	25%	17%	25%

Mês	Classe pseudo-observada	Previsão tipo A: Modelo ECPC - Horizonte 1 mês				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
fev/12	-2	33%	25%	17%	17%	8%
mar/12	-1	33%	17%	25%	25%	0%
abr/12	-2	0%	8%	42%	50%	0%
mai/12	-2	0%	8%	42%	42%	8%
jun/12	-2	8%	8%	17%	67%	0%
jul/12	-1	17%	25%	33%	25%	0%
ago/12	0	17%	17%	8%	58%	0%
set/12	0	17%	17%	33%	25%	8%
out/12	1	8%	8%	42%	17%	25%
nov/12	0	0%	42%	8%	33%	17%
dez/12	2	8%	17%	42%	25%	8%
jan/13	1	8%	33%	25%	17%	17%
fev/13	-1	25%	8%	8%	8%	50%
mar/13	1	17%	0%	75%	8%	0%
abr/13	1	42%	42%	17%	0%	0%
mai/13	0	33%	33%	25%	8%	0%
jun/13	-1	33%	0%	42%	25%	0%
jul/13	0	50%	25%	8%	8%	8%
ago/13	1	0%	50%	25%	17%	8%
set/13	0	0%	25%	50%	17%	8%
out/13	-1	8%	58%	0%	0%	33%
nov/13	0	8%	42%	25%	17%	8%
dez/13	0	25%	50%	17%	8%	0%

Tabela F.6. Classe de saturação pseudo-observada e probabilidade associada a cada classe de saturação conforme o *ensemble* do modelo GFDL (tipo A) para o horizonte de 1 mês.

Mês	Classe pseudo-observada	Previsão tipo A: Modelo GFDL - Horizonte 1 mês				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
jun/05	0	60%	17%	20%	3%	0%
jul/05	-1	73%	7%	3%	13%	3%
ago/05	0	67%	27%	7%	0%	0%
set/05	1	83%	3%	10%	3%	0%
out/05	1	37%	23%	20%	0%	20%
nov/05	0	20%	23%	17%	40%	0%
dez/05	0	30%	30%	30%	10%	0%
jan/06	0	33%	17%	23%	20%	7%
fev/06	-2	30%	7%	30%	33%	0%
mar/06	0	27%	47%	23%	3%	0%
abr/06	0	37%	27%	20%	17%	0%
mai/06	-2	47%	27%	13%	13%	0%
jun/06	-1	70%	7%	17%	7%	0%
jul/06	0	60%	33%	7%	0%	0%
ago/06	0	47%	20%	23%	10%	0%
set/06	1	63%	13%	17%	7%	0%
out/06	0	50%	13%	23%	0%	13%
nov/06	1	10%	20%	20%	50%	0%
dez/06	1	3%	23%	43%	27%	3%
jan/07	1	30%	33%	10%	17%	10%
fev/07	0	33%	20%	17%	27%	3%
mar/07	1	23%	30%	33%	13%	0%
abr/07	1	13%	27%	33%	27%	0%
mai/07	1	27%	20%	27%	23%	3%
jun/07	-2	37%	3%	40%	20%	0%
jul/07	0	53%	17%	10%	13%	7%
ago/07	0	43%	17%	20%	20%	0%
set/07	-1	67%	10%	3%	20%	0%
out/07	0	47%	17%	17%	3%	17%
nov/07	1	27%	23%	13%	37%	0%
dez/07	0	13%	33%	27%	23%	3%
jan/08	-1	20%	20%	13%	27%	20%
fev/08	-1	23%	13%	33%	30%	0%
mar/08	-1	13%	43%	27%	17%	0%
abr/08	-1	23%	43%	17%	17%	0%
mai/08	0	57%	17%	17%	10%	0%
jun/08	1	73%	7%	17%	3%	0%
jul/08	-1	60%	30%	3%	7%	0%
ago/08	1	60%	33%	7%	0%	0%
set/08	0	87%	3%	10%	0%	0%

Mês	Classe pseudo-observada	Previsão tipo A: Modelo GFDL - Horizonte 1 mês				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
out/08	0	53%	20%	10%	3%	13%
nov/08	0	23%	27%	7%	43%	0%
dez/08	-1	23%	40%	20%	17%	0%
jan/09	0	37%	20%	23%	17%	3%
fev/09	-1	17%	17%	20%	37%	10%
mar/09	-1	7%	20%	43%	27%	3%
abr/09	-2	7%	17%	37%	40%	0%
mai/09	-2	17%	27%	43%	13%	0%
jun/09	0	37%	13%	30%	20%	0%
jul/09	0	40%	20%	20%	17%	3%
ago/09	1	43%	10%	20%	27%	0%
set/09	1	43%	23%	23%	10%	0%
out/09	0	50%	27%	13%	0%	10%
nov/09	1	20%	23%	17%	40%	0%
dez/09	1	13%	17%	30%	37%	3%
jan/10	1	17%	37%	10%	23%	13%
fev/10	0	40%	20%	20%	13%	7%
mar/10	0	27%	23%	27%	23%	0%
abr/10	-1	7%	13%	43%	37%	0%
mai/10	1	23%	17%	27%	33%	0%
jun/10	0	63%	7%	17%	13%	0%
jul/10	0	73%	10%	7%	10%	0%
ago/10	-1	67%	23%	10%	0%	0%
set/10	1	73%	13%	10%	3%	0%
out/10	-1	53%	10%	17%	7%	13%
nov/10	-1	33%	20%	13%	27%	7%
dez/10	1	30%	53%	13%	3%	0%
jan/11	0	50%	23%	20%	3%	3%
fev/11	1	30%	13%	20%	37%	0%
mar/11	0	27%	23%	17%	33%	0%
abr/11	1	30%	23%	27%	20%	0%
mai/11	0	40%	43%	7%	10%	0%
jun/11	0	80%	7%	10%	3%	0%
jul/11	1	87%	7%	7%	0%	0%
ago/11	1	80%	3%	13%	3%	0%
set/11	-1	53%	30%	17%	0%	0%
out/11	0	57%	17%	13%	3%	10%
nov/11	0	33%	17%	20%	23%	7%
dez/11	-1	13%	50%	10%	27%	0%
jan/12	-1	30%	30%	13%	17%	10%
fev/12	-2	27%	17%	23%	27%	7%
mar/12	-1	27%	17%	27%	27%	3%

Mês	Classe pseudo-observada	Previsão tipo A: Modelo GFDL - Horizonte 1 mês				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
abr/12	-2	13%	23%	33%	30%	0%
mai/12	-2	13%	20%	40%	27%	0%
jun/12	-2	27%	10%	40%	23%	0%
jul/12	-1	47%	23%	13%	13%	3%
ago/12	0	43%	30%	23%	3%	0%
set/12	0	37%	23%	27%	13%	0%
out/12	1	80%	7%	10%	0%	3%
nov/12	0	37%	30%	17%	17%	0%
dez/12	2	7%	40%	30%	23%	0%
jan/13	1	13%	37%	23%	20%	7%
fev/13	-1	23%	20%	13%	23%	20%
mar/13	1	20%	27%	23%	23%	7%
abr/13	1	20%	23%	30%	27%	0%
mai/13	0	13%	20%	23%	43%	0%
jun/13	-1	47%	3%	27%	23%	0%
jul/13	0	37%	30%	17%	13%	3%
ago/13	1	43%	30%	17%	10%	0%
set/13	0	47%	13%	23%	17%	0%
out/13	-1	50%	13%	17%	3%	17%
nov/13	0	30%	23%	20%	27%	0%
dez/13	0	23%	27%	33%	13%	3%

Tabela F.7. Classe de saturação pseudo-observada e probabilidade associada a cada classe de saturação conforme o *ensemble* do modelo CCM3v6 (tipo A) para o horizonte de 3 meses.

Mês	Classe pseudo-observada	Previsão tipo A: Modelo CCM3v6 - Horizonte 3 meses				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
jun/05	0	58%	17%	25%	0%	0%
jul/05	-1	46%	25%	13%	13%	4%
ago/05	0	21%	25%	21%	29%	4%
set/05	1	8%	33%	29%	29%	0%
out/05	1	29%	8%	29%	21%	13%
nov/05	0	17%	21%	21%	38%	4%
dez/05	0	17%	33%	13%	29%	8%
jan/06	0	8%	29%	29%	25%	8%
fev/06	-2	29%	8%	17%	33%	13%
mar/06	0	17%	25%	46%	13%	0%
abr/06	0	25%	17%	42%	17%	0%
mai/06	-2	50%	25%	21%	4%	0%
jun/06	-1	63%	13%	17%	8%	0%
jul/06	0	50%	21%	17%	13%	0%
ago/06	0	29%	25%	21%	17%	8%
set/06	1	17%	33%	21%	25%	4%
out/06	0	46%	13%	33%	8%	0%
nov/06	1	33%	17%	25%	25%	0%
dez/06	1	13%	25%	17%	42%	4%
jan/07	1	8%	46%	17%	25%	4%
fev/07	0	21%	21%	17%	38%	4%
mar/07	1	25%	8%	29%	33%	4%
abr/07	1	17%	25%	29%	29%	0%
mai/07	1	25%	38%	25%	13%	0%
jun/07	-2	50%	21%	17%	13%	0%
jul/07	0	13%	21%	38%	29%	0%
ago/07	0	17%	25%	8%	29%	21%
set/07	-1	17%	29%	17%	33%	4%
out/07	0	38%	8%	13%	21%	21%
nov/07	1	17%	17%	13%	38%	17%
dez/07	0	8%	33%	38%	21%	0%
jan/08	-1	29%	38%	17%	13%	4%
fev/08	-1	21%	17%	33%	13%	17%
mar/08	-1	17%	29%	38%	13%	4%
abr/08	-1	46%	21%	8%	25%	0%
mai/08	0	42%	33%	21%	4%	0%
jun/08	1	75%	21%	4%	0%	0%
jul/08	-1	58%	21%	4%	17%	0%
ago/08	1	38%	21%	21%	17%	4%

Mês	Classe pseudo-observada	Previsão tipo A: Modelo CCM3v6 - Horizonte 3 meses				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
set/08	0	46%	13%	21%	17%	4%
out/08	0	33%	17%	29%	17%	4%
nov/08	0	38%	13%	21%	25%	4%
dez/08	-1	25%	29%	29%	13%	4%
jan/09	0	25%	21%	25%	17%	13%
fev/09	-1	29%	17%	8%	42%	4%
mar/09	-1	21%	21%	25%	29%	4%
abr/09	-2	21%	21%	42%	17%	0%
mai/09	-2	29%	42%	8%	21%	0%
jun/09	0	38%	21%	38%	4%	0%
jul/09	0	33%	38%	17%	13%	0%
ago/09	1	13%	29%	38%	21%	0%
set/09	1	25%	17%	29%	29%	0%
out/09	0	29%	25%	17%	4%	25%
nov/09	1	33%	8%	21%	25%	13%
dez/09	1	25%	17%	38%	21%	0%
jan/10	1	25%	21%	25%	17%	13%
fev/10	0	17%	13%	21%	46%	4%
mar/10	0	13%	17%	29%	33%	8%
abr/10	-1	21%	21%	29%	29%	0%
mai/10	1	33%	38%	25%	4%	0%
jun/10	0	58%	17%	21%	4%	0%
jul/10	0	50%	17%	21%	13%	0%
ago/10	-1	38%	21%	33%	8%	0%
set/10	1	46%	25%	17%	13%	0%
out/10	-1	67%	4%	17%	8%	4%
nov/10	-1	38%	25%	8%	17%	13%
dez/10	1	33%	29%	29%	8%	0%
jan/11	0	33%	38%	13%	8%	8%
fev/11	1	17%	4%	33%	42%	4%
mar/11	0	8%	25%	25%	38%	4%
abr/11	1	33%	17%	38%	13%	0%
mai/11	0	58%	25%	13%	4%	0%
jun/11	0	71%	8%	17%	4%	0%
jul/11	1	50%	29%	0%	21%	0%
ago/11	1	29%	25%	21%	21%	4%
set/11	-1	25%	4%	29%	33%	8%
out/11	0	58%	4%	17%	4%	17%
nov/11	0	21%	25%	8%	25%	21%
dez/11	-1	8%	17%	21%	54%	0%
jan/12	-1	17%	38%	17%	17%	13%
fev/12	-2	13%	4%	25%	50%	8%

Mês	Classe pseudo-observada	Previsão tipo A: Modelo CCM3v6 - Horizonte 3 meses				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
mar/12	-1	13%	21%	46%	21%	0%
abr/12	-2	58%	13%	13%	17%	0%
mai/12	-2	58%	25%	4%	13%	0%
jun/12	-2	42%	25%	17%	17%	0%
jul/12	-1	50%	29%	21%	0%	0%
ago/12	0	38%	21%	21%	21%	0%
set/12	0	25%	17%	42%	17%	0%
out/12	1	38%	13%	13%	8%	29%
nov/12	0	21%	13%	21%	38%	8%
dez/12	2	13%	29%	38%	17%	4%
jan/13	1	29%	21%	29%	13%	8%
fev/13	-1	8%	29%	25%	25%	13%
mar/13	1	8%	13%	46%	25%	8%
abr/13	1	13%	21%	50%	17%	0%
mai/13	0	46%	29%	21%	4%	0%
jun/13	-1	42%	25%	21%	13%	0%
jul/13	0	33%	25%	21%	21%	0%
ago/13	1	25%	33%	25%	17%	0%
set/13	0	13%	17%	29%	42%	0%
out/13	-1	29%	8%	21%	17%	25%
nov/13	0	17%	38%	29%	17%	0%
dez/13	0	25%	25%	29%	21%	0%

Tabela F.8. Classe de saturação pseudo-observada e probabilidade associada a cada classe de saturação conforme o *ensemble* do modelo ECPC (tipo A) para o horizonte de 3 meses.

Mês	Classe pseudo-observada	Previsão tipo A: Modelo ECPC - Horizonte 3 meses				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
jun/05	0	8%	8%	75%	8%	0%
jul/05	-1	0%	25%	25%	42%	8%
ago/05	0	8%	17%	8%	58%	8%
set/05	1	25%	8%	8%	58%	0%
out/05	1	17%	58%	8%	17%	0%
nov/05	0	8%	58%	25%	8%	0%
dez/05	0	17%	58%	17%	8%	0%
jan/06	0	25%	50%	25%	0%	0%
fev/06	-2	33%	17%	17%	25%	8%
mar/06	0	8%	17%	17%	42%	17%
abr/06	0	8%	25%	25%	42%	0%
mai/06	-2	17%	33%	17%	25%	8%
jun/06	-1	25%	25%	8%	42%	0%
jul/06	0	8%	25%	17%	50%	0%
ago/06	0	17%	25%	25%	33%	0%
set/06	1	17%	17%	50%	17%	0%
out/06	0	25%	42%	8%	8%	17%
nov/06	1	8%	42%	8%	33%	8%
dez/06	1	0%	42%	25%	33%	0%
jan/07	1	17%	42%	17%	25%	0%
fev/07	0	42%	8%	8%	25%	17%
mar/07	1	33%	0%	42%	8%	17%
abr/07	1	17%	25%	25%	33%	0%
mai/07	1	25%	58%	8%	0%	8%
jun/07	-2	33%	17%	25%	25%	0%
jul/07	0	25%	33%	25%	17%	0%
ago/07	0	25%	17%	17%	42%	0%
set/07	-1	8%	33%	25%	25%	8%
out/07	0	17%	33%	25%	8%	17%
nov/07	1	0%	58%	8%	25%	8%
dez/07	0	8%	33%	33%	25%	0%
jan/08	-1	17%	17%	17%	42%	8%
fev/08	-1	25%	33%	0%	17%	25%
mar/08	-1	25%	17%	33%	17%	8%
abr/08	-1	8%	17%	42%	33%	0%
mai/08	0	8%	25%	25%	42%	0%
jun/08	1	25%	17%	8%	50%	0%
jul/08	-1	17%	8%	50%	25%	0%
ago/08	1	17%	25%	25%	25%	8%
set/08	0	0%	33%	8%	42%	17%

Mês	Classe pseudo-observada	Previsão tipo A: Modelo ECPC - Horizonte 3 meses				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
out/08	0	17%	42%	42%	0%	0%
nov/08	0	33%	33%	8%	17%	8%
dez/08	-1	25%	25%	33%	8%	8%
jan/09	0	8%	17%	42%	33%	0%
fev/09	-1	17%	17%	17%	33%	17%
mar/09	-1	8%	42%	42%	8%	0%
abr/09	-2	8%	0%	25%	67%	0%
mai/09	-2	0%	33%	25%	25%	17%
jun/09	0	8%	8%	25%	58%	0%
jul/09	0	8%	8%	42%	42%	0%
ago/09	1	8%	25%	25%	33%	8%
set/09	1	8%	8%	25%	50%	8%
out/09	0	0%	50%	33%	17%	0%
nov/09	1	8%	42%	0%	42%	8%
dez/09	1	0%	50%	33%	17%	0%
jan/10	1	0%	33%	8%	58%	0%
fev/10	0	8%	25%	17%	42%	8%
mar/10	0	25%	25%	17%	17%	17%
abr/10	-1	25%	0%	25%	50%	0%
mai/10	1	17%	17%	33%	25%	8%
jun/10	0	0%	8%	42%	50%	0%
jul/10	0	8%	33%	17%	42%	0%
ago/10	-1	17%	42%	17%	25%	0%
set/10	1	33%	50%	8%	8%	0%
out/10	-1	17%	42%	8%	0%	33%
nov/10	-1	17%	33%	25%	25%	0%
dez/10	1	0%	25%	42%	33%	0%
jan/11	0	0%	25%	25%	33%	17%
fev/11	1	25%	17%	17%	25%	17%
mar/11	0	25%	17%	25%	25%	8%
abr/11	1	33%	25%	17%	25%	0%
mai/11	0	33%	17%	42%	8%	0%
jun/11	0	50%	17%	25%	8%	0%
jul/11	1	42%	25%	25%	8%	0%
ago/11	1	25%	58%	0%	17%	0%
set/11	-1	33%	33%	17%	17%	0%
out/11	0	8%	25%	42%	8%	17%
nov/11	0	8%	42%	25%	25%	0%
dez/11	-1	8%	58%	17%	8%	8%
jan/12	-1	25%	17%	8%	50%	0%
fev/12	-2	17%	17%	8%	33%	25%
mar/12	-1	17%	17%	33%	25%	8%

Mês	Classe pseudo-observada	Previsão tipo A: Modelo ECPC - Horizonte 3 meses				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
abr/12	-2	17%	25%	25%	33%	0%
mai/12	-2	17%	17%	42%	25%	0%
jun/12	-2	17%	17%	17%	50%	0%
jul/12	-1	8%	8%	42%	42%	0%
ago/12	0	8%	8%	42%	33%	8%
set/12	0	8%	42%	25%	17%	8%
out/12	1	25%	25%	17%	25%	8%
nov/12	0	8%	25%	8%	58%	0%
dez/12	2	0%	8%	42%	42%	8%
jan/13	1	0%	25%	33%	25%	17%
fev/13	-1	17%	33%	8%	42%	0%
mar/13	1	17%	17%	42%	25%	0%
abr/13	1	17%	17%	8%	58%	0%
mai/13	0	8%	8%	33%	50%	0%
jun/13	-1	8%	8%	33%	50%	0%
jul/13	0	0%	42%	42%	17%	0%
ago/13	1	8%	25%	8%	58%	0%
set/13	0	17%	50%	33%	0%	0%
out/13	-1	25%	17%	25%	17%	17%
nov/13	0	0%	67%	8%	25%	0%
dez/13	0	17%	50%	33%	0%	0%

Tabela F.9. Classe de saturação pseudo-observada e probabilidade associada a cada classe de saturação conforme o *ensemble* do modelo GFDL (tipo A) para o horizonte de 3 meses.

Mês	Classe pseudo-observada	Previsão tipo A: Modelo GFDL - Horizonte 3 meses				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
jun/05	0	77%	13%	7%	3%	0%
jul/05	-1	87%	7%	0%	7%	0%
ago/05	0	53%	20%	20%	7%	0%
set/05	1	53%	33%	13%	0%	0%
out/05	1	47%	20%	3%	10%	20%
nov/05	0	17%	23%	20%	30%	10%
dez/05	0	10%	50%	30%	3%	7%
jan/06	0	47%	23%	23%	3%	3%
fev/06	-2	40%	20%	30%	7%	3%
mar/06	0	23%	27%	33%	13%	3%
abr/06	0	17%	23%	33%	27%	0%
mai/06	-2	27%	33%	27%	13%	0%
jun/06	-1	67%	0%	23%	10%	0%
jul/06	0	70%	17%	10%	3%	0%
ago/06	0	47%	23%	17%	13%	0%
set/06	1	47%	23%	10%	20%	0%
out/06	0	50%	10%	7%	13%	20%
nov/06	1	30%	20%	13%	37%	0%
dez/06	1	10%	27%	37%	20%	7%
jan/07	1	20%	20%	27%	27%	7%
fev/07	0	10%	23%	17%	43%	7%
mar/07	1	10%	20%	27%	37%	7%
abr/07	1	13%	17%	27%	43%	0%
mai/07	1	17%	40%	20%	20%	3%
jun/07	-2	60%	3%	17%	20%	0%
jul/07	0	60%	17%	17%	7%	0%
ago/07	0	40%	20%	17%	23%	0%
set/07	-1	60%	13%	13%	13%	0%
out/07	0	47%	13%	27%	7%	7%
nov/07	1	23%	37%	20%	20%	0%
dez/07	0	33%	33%	17%	10%	7%
jan/08	-1	27%	17%	23%	33%	0%
fev/08	-1	30%	10%	20%	33%	7%
mar/08	-1	30%	33%	20%	17%	0%
abr/08	-1	47%	7%	33%	13%	0%
mai/08	0	50%	30%	17%	3%	0%
jun/08	1	70%	10%	7%	13%	0%
jul/08	-1	83%	3%	7%	7%	0%
ago/08	1	67%	13%	17%	3%	0%

Mês	Classe pseudo-observada	Previsão tipo A: Modelo GFDL - Horizonte 3 meses				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
set/08	0	57%	17%	27%	0%	0%
out/08	0	37%	23%	13%	10%	17%
nov/08	0	17%	17%	20%	43%	3%
dez/08	-1	17%	27%	23%	33%	0%
jan/09	0	20%	23%	27%	20%	10%
fev/09	-1	10%	30%	37%	13%	10%
mar/09	-1	17%	23%	40%	20%	0%
abr/09	-2	20%	23%	30%	27%	0%
mai/09	-2	33%	30%	17%	20%	0%
jun/09	0	57%	13%	20%	10%	0%
jul/09	0	40%	17%	20%	17%	7%
ago/09	1	43%	20%	23%	13%	0%
set/09	1	40%	17%	33%	10%	0%
out/09	0	37%	17%	17%	7%	23%
nov/09	1	20%	20%	13%	47%	0%
dez/09	1	17%	30%	23%	27%	3%
jan/10	1	23%	27%	30%	10%	10%
fev/10	0	27%	33%	17%	17%	7%
mar/10	0	17%	23%	33%	23%	3%
abr/10	-1	3%	10%	33%	53%	0%
mai/10	1	13%	33%	17%	37%	0%
jun/10	0	60%	7%	20%	13%	0%
jul/10	0	53%	20%	23%	3%	0%
ago/10	-1	53%	23%	20%	3%	0%
set/10	1	60%	10%	17%	13%	0%
out/10	-1	43%	10%	23%	13%	10%
nov/10	-1	23%	27%	23%	27%	0%
dez/10	1	33%	33%	17%	17%	0%
jan/11	0	23%	17%	17%	33%	10%
fev/11	1	13%	17%	13%	40%	17%
mar/11	0	13%	27%	27%	27%	7%
abr/11	1	20%	17%	33%	30%	0%
mai/11	0	30%	40%	20%	10%	0%
jun/11	0	77%	0%	20%	3%	0%
jul/11	1	80%	13%	3%	3%	0%
ago/11	1	60%	13%	10%	17%	0%
set/11	-1	70%	17%	3%	10%	0%
out/11	0	50%	13%	20%	0%	17%
nov/11	0	20%	17%	20%	37%	7%
dez/11	-1	23%	23%	27%	27%	0%
jan/12	-1	7%	27%	30%	27%	10%

Mês	Classe pseudo-observada	Previsão tipo A: Modelo GFDL - Horizonte 3 meses				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
fev/12	-2	10%	33%	10%	30%	17%
mar/12	-1	20%	23%	37%	20%	0%
abr/12	-2	40%	10%	33%	17%	0%
mai/12	-2	40%	33%	10%	17%	0%
jun/12	-2	43%	13%	17%	27%	0%
jul/12	-1	20%	27%	23%	27%	3%
ago/12	0	37%	13%	23%	23%	3%
set/12	0	33%	20%	23%	23%	0%
out/12	1	43%	3%	23%	7%	23%
nov/12	0	20%	27%	17%	37%	0%
dez/12	2	10%	23%	27%	33%	7%
jan/13	1	13%	30%	20%	20%	17%
fev/13	-1	17%	20%	37%	20%	7%
mar/13	1	20%	10%	40%	27%	3%
abr/13	1	10%	13%	43%	33%	0%
mai/13	0	20%	10%	37%	33%	0%
jun/13	-1	33%	3%	27%	37%	0%
jul/13	0	50%	17%	17%	13%	3%
ago/13	1	40%	20%	30%	10%	0%
set/13	0	43%	17%	13%	27%	0%
out/13	-1	47%	7%	20%	3%	23%
nov/13	0	23%	27%	20%	27%	3%
dez/13	0	20%	23%	30%	23%	3%

Tabela F.10. Classe de saturação pseudo-observada e probabilidade associada a cada classe de saturação conforme o *ensemble* do modelo CCM3v6 (tipo A) para o horizonte de 6 meses.

Mês	Classe pseudo-observada	Previsão tipo A: Modelo CCM3v6 - Horizonte 6 meses				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
jun/05	0	42%	8%	38%	13%	0%
jul/05	-1	54%	8%	21%	17%	0%
ago/05	0	13%	33%	25%	25%	4%
set/05	1	13%	21%	38%	25%	4%
out/05	1	50%	8%	25%	8%	8%
nov/05	0	29%	8%	25%	29%	8%
dez/05	0	8%	33%	38%	21%	0%
jan/06	0	8%	29%	29%	21%	13%
fev/06	-2	17%	29%	25%	21%	8%
mar/06	0	38%	25%	29%	8%	0%
abr/06	0	46%	4%	38%	13%	0%
mai/06	-2	25%	33%	25%	17%	0%
jun/06	-1	21%	29%	29%	21%	0%
jul/06	0	29%	33%	21%	8%	8%
ago/06	0	25%	29%	13%	25%	8%
set/06	1	25%	21%	17%	38%	0%
out/06	0	38%	21%	25%	4%	13%
nov/06	1	33%	17%	21%	25%	4%
dez/06	1	25%	21%	17%	38%	0%
jan/07	1	17%	33%	25%	21%	4%
fev/07	0	17%	13%	17%	42%	13%
mar/07	1	8%	13%	50%	21%	8%
abr/07	1	17%	4%	33%	46%	0%
mai/07	1	0%	29%	42%	29%	0%
jun/07	-2	29%	17%	25%	29%	0%
jul/07	0	46%	13%	17%	25%	0%
ago/07	0	50%	21%	17%	8%	4%
set/07	-1	29%	17%	38%	17%	0%
out/07	0	50%	8%	17%	13%	13%
nov/07	1	21%	13%	46%	17%	4%
dez/07	0	17%	33%	38%	13%	0%
jan/08	-1	33%	25%	13%	17%	13%
fev/08	-1	8%	17%	38%	33%	4%
mar/08	-1	17%	33%	17%	33%	0%
abr/08	-1	29%	29%	21%	21%	0%
mai/08	0	33%	38%	13%	17%	0%
jun/08	1	58%	4%	25%	13%	0%
jul/08	-1	67%	8%	21%	4%	0%
ago/08	1	17%	21%	29%	29%	4%
set/08	0	13%	17%	33%	38%	0%

Mês	Classe pseudo-observada	Previsão tipo A: Modelo CCM3v6 - Horizonte 6 meses				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
out/08	0	38%	8%	25%	8%	21%
nov/08	0	25%	17%	17%	33%	8%
dez/08	-1	13%	42%	29%	13%	4%
jan/09	0	13%	13%	25%	38%	13%
fev/09	-1	13%	17%	13%	38%	21%
mar/09	-1	0%	21%	42%	29%	8%
abr/09	-2	21%	21%	21%	38%	0%
mai/09	-2	42%	38%	4%	17%	0%
jun/09	0	58%	13%	21%	8%	0%
jul/09	0	58%	13%	8%	21%	0%
ago/09	1	21%	25%	33%	8%	13%
set/09	1	13%	13%	33%	42%	0%
out/09	0	38%	4%	25%	8%	25%
nov/09	1	29%	13%	21%	21%	17%
dez/09	1	17%	38%	25%	21%	0%
jan/10	1	8%	33%	33%	4%	21%
fev/10	0	13%	17%	17%	54%	0%
mar/10	0	21%	13%	21%	38%	8%
abr/10	-1	13%	13%	33%	42%	0%
mai/10	1	8%	33%	25%	33%	0%
jun/10	0	42%	17%	21%	21%	0%
jul/10	0	29%	13%	38%	13%	8%
ago/10	-1	13%	50%	21%	17%	0%
set/10	1	8%	21%	46%	25%	0%
out/10	-1	42%	8%	33%	8%	8%
nov/10	-1	50%	17%	13%	17%	4%
dez/10	1	46%	13%	29%	13%	0%
jan/11	0	21%	29%	33%	17%	0%
fev/11	1	17%	17%	13%	54%	0%
mar/11	0	21%	33%	29%	13%	4%
abr/11	1	33%	42%	8%	17%	0%
mai/11	0	50%	33%	13%	4%	0%
jun/11	0	63%	4%	25%	8%	0%
jul/11	1	50%	13%	21%	17%	0%
ago/11	1	38%	29%	17%	13%	4%
set/11	-1	25%	4%	29%	38%	4%
out/11	0	38%	13%	25%	13%	13%
nov/11	0	17%	25%	25%	21%	13%
dez/11	-1	13%	38%	21%	25%	4%
jan/12	-1	17%	29%	29%	17%	8%
fev/12	-2	4%	4%	38%	50%	4%
mar/12	-1	4%	33%	38%	25%	0%

Mês	Classe pseudo-observada	Previsão tipo A: Modelo CCM3v6 - Horizonte 6 meses				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
abr/12	-2	29%	29%	25%	17%	0%
mai/12	-2	38%	25%	25%	13%	0%
jun/12	-2	54%	13%	17%	17%	0%
jul/12	-1	38%	17%	17%	29%	0%
ago/12	0	29%	8%	33%	17%	13%
set/12	0	13%	25%	21%	42%	0%
out/12	1	50%	8%	38%	4%	0%
nov/12	0	38%	21%	4%	29%	8%
dez/12	2	21%	38%	25%	17%	0%
jan/13	1	13%	38%	25%	21%	4%
fev/13	-1	21%	21%	29%	25%	4%
mar/13	1	21%	17%	33%	17%	13%
abr/13	1	25%	13%	29%	33%	0%
mai/13	0	4%	54%	29%	13%	0%
jun/13	-1	33%	8%	33%	25%	0%
jul/13	0	46%	4%	33%	17%	0%
ago/13	1	21%	29%	17%	29%	4%
set/13	0	8%	25%	38%	29%	0%
out/13	-1	33%	13%	29%	8%	17%
nov/13	0	33%	25%	13%	17%	13%
dez/13	0	21%	38%	17%	21%	4%

Tabela F.11. Classe de saturação pseudo-observada e probabilidade associada a cada classe de saturação conforme o *ensemble* do modelo ECPC (tipo A) para o horizonte de 6 meses.

Mês	Classe pseudo-observada	Previsão tipo A: Modelo ECPC - Horizonte 6 meses				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
jun/05	0	25%	8%	67%	0%	0%
jul/05	-1	25%	17%	17%	17%	25%
ago/05	0	8%	8%	42%	42%	0%
set/05	1	8%	0%	33%	50%	8%
out/05	1	8%	17%	25%	25%	25%
nov/05	0	8%	42%	8%	33%	8%
dez/05	0	8%	33%	33%	17%	8%
jan/06	0	0%	50%	17%	17%	17%
fev/06	-2	33%	8%	8%	33%	17%
mar/06	0	17%	17%	8%	33%	25%
abr/06	0	8%	0%	25%	67%	0%
mai/06	-2	17%	33%	17%	33%	0%
jun/06	-1	42%	25%	17%	17%	0%
jul/06	0	25%	42%	17%	17%	0%
ago/06	0	8%	33%	25%	33%	0%
set/06	1	25%	33%	25%	17%	0%
out/06	0	17%	42%	8%	17%	17%
nov/06	1	8%	8%	25%	42%	17%
dez/06	1	0%	33%	25%	25%	17%
jan/07	1	8%	17%	0%	58%	17%
fev/07	0	8%	33%	33%	17%	8%
mar/07	1	17%	25%	50%	8%	0%
abr/07	1	42%	8%	25%	25%	0%
mai/07	1	42%	8%	17%	33%	0%
jun/07	-2	25%	25%	42%	8%	0%
jul/07	0	25%	17%	8%	25%	25%
ago/07	0	17%	42%	33%	8%	0%
set/07	-1	8%	17%	50%	25%	0%
out/07	0	8%	25%	25%	17%	25%
nov/07	1	0%	50%	17%	25%	8%
dez/07	0	0%	25%	33%	42%	0%
jan/08	-1	0%	17%	25%	25%	33%
fev/08	-1	17%	33%	17%	33%	0%
mar/08	-1	8%	8%	42%	42%	0%
abr/08	-1	17%	17%	8%	58%	0%
mai/08	0	17%	17%	50%	17%	0%
jun/08	1	50%	8%	25%	17%	0%
jul/08	-1	42%	25%	8%	25%	0%
ago/08	1	33%	25%	0%	33%	8%

Mês	Classe pseudo-observada	Previsão tipo A: Modelo ECPC - Horizonte 6 meses				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
set/08	0	17%	25%	8%	50%	0%
out/08	0	8%	50%	42%	0%	0%
nov/08	0	0%	75%	8%	17%	0%
dez/08	-1	0%	50%	33%	17%	0%
jan/09	0	0%	42%	25%	25%	8%
fev/09	-1	8%	17%	33%	25%	17%
mar/09	-1	0%	33%	25%	42%	0%
abr/09	-2	0%	33%	42%	25%	0%
mai/09	-2	8%	42%	42%	8%	0%
jun/09	0	25%	33%	25%	17%	0%
jul/09	0	8%	8%	25%	42%	17%
ago/09	1	0%	50%	25%	17%	8%
set/09	1	17%	8%	50%	25%	0%
out/09	0	8%	33%	33%	17%	8%
nov/09	1	8%	58%	17%	17%	0%
dez/09	1	17%	25%	17%	33%	8%
jan/10	1	0%	50%	25%	17%	8%
fev/10	0	25%	8%	0%	42%	25%
mar/10	0	25%	25%	25%	25%	0%
abr/10	-1	33%	17%	42%	8%	0%
mai/10	1	25%	33%	0%	33%	8%
jun/10	0	17%	8%	17%	58%	0%
jul/10	0	8%	33%	8%	50%	0%
ago/10	-1	25%	17%	17%	42%	0%
set/10	1	8%	17%	50%	25%	0%
out/10	-1	17%	33%	42%	0%	8%
nov/10	-1	0%	25%	17%	50%	8%
dez/10	1	0%	8%	50%	33%	8%
jan/11	0	0%	17%	8%	50%	25%
fev/11	1	8%	58%	0%	33%	0%
mar/11	0	25%	17%	33%	25%	0%
abr/11	1	8%	17%	17%	58%	0%
mai/11	0	8%	33%	33%	25%	0%
jun/11	0	58%	8%	0%	33%	0%
jul/11	1	33%	50%	0%	8%	8%
ago/11	1	25%	42%	8%	25%	0%
set/11	-1	25%	8%	25%	33%	8%
out/11	0	25%	33%	17%	8%	17%
nov/11	0	8%	50%	17%	17%	8%
dez/11	-1	17%	17%	25%	33%	8%
jan/12	-1	8%	17%	0%	42%	33%
fev/12	-2	0%	17%	8%	50%	25%

Mês	Classe pseudo-observada	Previsão tipo A: Modelo ECPC - Horizonte 6 meses				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
mar/12	-1	8%	8%	42%	42%	0%
abr/12	-2	8%	50%	17%	25%	0%
mai/12	-2	25%	33%	42%	0%	0%
jun/12	-2	58%	0%	17%	25%	0%
jul/12	-1	17%	25%	42%	17%	0%
ago/12	0	25%	25%	25%	8%	17%
set/12	0	17%	8%	17%	50%	8%
out/12	1	0%	33%	25%	17%	25%
nov/12	0	0%	25%	25%	50%	0%
dez/12	2	8%	25%	17%	50%	0%
jan/13	1	8%	42%	33%	8%	8%
fev/13	-1	33%	0%	17%	42%	8%
mar/13	1	8%	17%	33%	42%	0%
abr/13	1	8%	17%	42%	33%	0%
mai/13	0	8%	33%	0%	50%	8%
jun/13	-1	25%	0%	8%	67%	0%
jul/13	0	42%	8%	25%	25%	0%
ago/13	1	50%	25%	8%	17%	0%
set/13	0	42%	17%	25%	17%	0%
out/13	-1	42%	33%	8%	0%	17%
nov/13	0	17%	25%	33%	17%	8%
dez/13	0	17%	50%	33%	0%	0%

Tabela F.12. Classe de saturação pseudo-observada e probabilidade associada a cada classe de saturação conforme o *ensemble* do modelo GFDL (tipo A) para o horizonte de 6 meses.

Mês	Classe pseudo-observada	Previsão tipo A: Modelo GFDL - Horizonte 6 meses				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
jun/05	0	0%	30%	3%	40%	27%
jul/05	-1	10%	7%	40%	23%	20%
ago/05	0	20%	27%	20%	23%	10%
set/05	1	10%	23%	23%	40%	3%
out/05	1	17%	13%	13%	30%	27%
nov/05	0	7%	23%	13%	23%	33%
dez/05	0	13%	40%	23%	13%	10%
jan/06	0	30%	30%	10%	30%	0%
fev/06	-2	10%	13%	23%	23%	30%
mar/06	0	10%	13%	27%	40%	10%
abr/06	0	10%	3%	17%	27%	43%
mai/06	-2	3%	13%	23%	17%	43%
jun/06	-1	13%	0%	30%	13%	43%
jul/06	0	7%	13%	20%	33%	27%
ago/06	0	17%	30%	23%	20%	10%
set/06	1	17%	27%	37%	10%	10%
out/06	0	17%	13%	23%	30%	17%
nov/06	1	13%	23%	7%	33%	23%
dez/06	1	13%	33%	23%	27%	3%
jan/07	1	27%	30%	13%	30%	0%
fev/07	0	17%	10%	13%	17%	43%
mar/07	1	7%	13%	23%	43%	13%
abr/07	1	0%	13%	13%	30%	43%
mai/07	1	7%	0%	37%	17%	40%
jun/07	-2	3%	13%	30%	23%	30%
jul/07	0	3%	20%	30%	30%	17%
ago/07	0	17%	27%	23%	23%	10%
set/07	-1	7%	30%	27%	30%	7%
out/07	0	10%	17%	20%	23%	30%
nov/07	1	3%	20%	30%	13%	33%
dez/07	0	10%	37%	30%	23%	0%
jan/08	-1	17%	33%	27%	7%	17%
fev/08	-1	10%	23%	17%	13%	37%
mar/08	-1	10%	30%	20%	30%	10%
abr/08	-1	13%	17%	13%	30%	27%
mai/08	0	17%	20%	30%	27%	7%
jun/08	1	27%	7%	40%	13%	13%
jul/08	-1	13%	40%	13%	23%	10%
ago/08	1	30%	40%	13%	10%	7%
set/08	0	20%	27%	27%	13%	13%

Mês	Classe pseudo-observada	Previsão tipo A: Modelo GFDL - Horizonte 6 meses				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
out/08	0	7%	33%	13%	27%	20%
nov/08	0	17%	23%	30%	7%	23%
dez/08	-1	20%	30%	30%	20%	0%
jan/09	0	27%	17%	23%	30%	3%
fev/09	-1	10%	7%	30%	20%	33%
mar/09	-1	10%	13%	47%	23%	7%
abr/09	-2	10%	10%	27%	17%	37%
mai/09	-2	7%	13%	27%	20%	33%
jun/09	0	20%	3%	23%	27%	27%
jul/09	0	7%	13%	27%	33%	20%
ago/09	1	20%	27%	20%	17%	17%
set/09	1	27%	17%	27%	7%	23%
out/09	0	7%	13%	20%	23%	37%
nov/09	1	10%	20%	17%	13%	40%
dez/09	1	17%	43%	17%	17%	7%
jan/10	1	20%	20%	27%	30%	3%
fev/10	0	10%	10%	20%	23%	37%
mar/10	0	0%	10%	37%	40%	13%
abr/10	-1	0%	10%	7%	47%	37%
mai/10	1	3%	10%	17%	23%	47%
jun/10	0	7%	7%	27%	20%	40%
jul/10	0	3%	17%	23%	30%	27%
ago/10	-1	20%	27%	40%	10%	3%
set/10	1	30%	17%	13%	23%	17%
out/10	-1	13%	10%	23%	27%	27%
nov/10	-1	7%	23%	30%	30%	10%
dez/10	1	10%	43%	30%	17%	0%
jan/11	0	20%	40%	13%	27%	0%
fev/11	1	10%	30%	20%	13%	27%
mar/11	0	17%	30%	27%	20%	7%
abr/11	1	17%	13%	27%	33%	10%
mai/11	0	20%	20%	27%	0%	33%
jun/11	0	27%	13%	33%	10%	17%
jul/11	1	20%	37%	13%	20%	10%
ago/11	1	47%	17%	10%	10%	17%
set/11	-1	23%	20%	30%	17%	10%
out/11	0	13%	17%	30%	20%	20%
nov/11	0	13%	27%	20%	13%	27%
dez/11	-1	23%	27%	27%	20%	3%
jan/12	-1	0%	23%	33%	37%	7%
fev/12	-2	3%	10%	17%	33%	37%
mar/12	-1	13%	10%	40%	27%	10%

Mês	Classe pseudo-observada	Previsão tipo A: Modelo GFDL - Horizonte 6 meses				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
abr/12	-2	7%	13%	37%	23%	20%
mai/12	-2	3%	7%	37%	30%	23%
jun/12	-2	13%	17%	23%	20%	27%
jul/12	-1	7%	17%	20%	37%	20%
ago/12	0	23%	23%	23%	13%	17%
set/12	0	20%	23%	20%	27%	10%
out/12	1	20%	30%	17%	23%	10%
nov/12	0	20%	17%	27%	17%	20%
dez/12	2	7%	20%	50%	23%	0%
jan/13	1	13%	33%	20%	27%	7%
fev/13	-1	10%	17%	33%	13%	27%
mar/13	1	10%	23%	20%	33%	13%
abr/13	1	3%	7%	20%	37%	33%
mai/13	0	3%	3%	13%	27%	53%
jun/13	-1	0%	3%	17%	20%	60%
jul/13	0	0%	3%	23%	37%	37%
ago/13	1	7%	27%	30%	27%	10%
set/13	0	10%	27%	27%	33%	3%
out/13	-1	20%	30%	13%	20%	17%
nov/13	0	17%	23%	20%	17%	23%
dez/13	0	20%	30%	33%	13%	3%

F.3 Previsões tipo C: Superensemble - Classe mais provável de saturação do solo

Nas tabelas F.13 a F.15 são apresentados os resultados de umidade do solo quanto à classe de saturação mais provável do *superensemble*. Cada tabela traz a informação de classe de saturação pseudo-observada (simulada com a precipitação observada); a classe mais provável de saturação conforme os resultados do *superensemble*; a probabilidade referente à esta previsão, calculada conforme a Equação (23); e o erro referente à previsão. O erro é definido como a classe prevista *menos* a classe pseudo-verdadeira de saturação do solo.

Tabela F.13. Classe de saturação pseudo-observada, prevista pelo superensemble (tipo C) e erro da previsão para o horizonte de 1 mês.

Mês	Classe pseudo-observada	Classe mais provável conforme o superensemble (Previsão tipo C)	Probabilidade	Erro (classe prevista – classe pseudo-observada)
jun/05	0	-2	50%	-2
jul/05	-1	-2	44%	-1
ago/05	0	-2	39%	-2
set/05	1	-2	48%	-3
out/05	1	-2	39%	-3
nov/05	0	1	30%	1
dez/05	0	-1	29%	-1
jan/06	0	0	26%	0
fev/06	-2	0	32%	2
mar/06	0	-1	39%	-1
abr/06	0	-2	35%	-2
mai/06	-2	-2	38%	0
jun/06	-1	-2	61%	-1
jul/06	0	-2	52%	-2
ago/06	0	-2	36%	-2
set/06	1	-2	45%	-3
out/06	0	-2	36%	-2
nov/06	1	-1	27%	-2
dez/06	1	0	33%	-1
jan/07	1	-1	33%	-2
fev/07	0	-2	30%	-2
mar/07	1	-1	38%	-2
abr/07	1	0	33%	-1
mai/07	1	-2	32%	-3
jun/07	-2	-2	45%	0
jul/07	0	-2	36%	-2
ago/07	0	-2	27%	-2

Mês	Classe pseudo-observada	Classe mais provável conforme o superensemble (Previsão tipo C)	Probabilidade	Erro (classe prevista – classe pseudo-observada)
set/07	-1	-2	41%	-1
out/07	0	-2	39%	-2
nov/07	1	-2	33%	-3
dez/07	0	-1	39%	-1
jan/08	-1	-1	24%	0
fev/08	-1	0	26%	1
mar/08	-1	-1	39%	0
abr/08	-1	-2	41%	-1
mai/08	0	-2	55%	-2
jun/08	1	-2	65%	-3
jul/08	-1	-2	52%	-1
ago/08	1	-2	42%	-3
set/08	0	-2	50%	-2
out/08	0	-2	44%	-2
nov/08	0	-1	30%	-1
dez/08	-1	-1	35%	0
jan/09	0	-2	32%	-2
fev/09	-1	-2	24%	-1
mar/09	-1	0	41%	1
abr/09	-2	0	30%	2
mai/09	-2	-1	32%	1
jun/09	0	-2	41%	-2
jul/09	0	-2	33%	-2
ago/09	1	-2	29%	-3
set/09	1	0	32%	-1
out/09	0	-2	36%	-2
nov/09	1	-2	23%	-3
dez/09	1	0	24%	-1
jan/10	1	-1	41%	-2
fev/10	0	0	26%	0
mar/10	0	0	35%	0
abr/10	-1	0	30%	1
mai/10	1	0	39%	-1
jun/10	0	-2	44%	-2
jul/10	0	-2	55%	-2
ago/10	-1	-2	50%	-1
set/10	1	-2	56%	-3
out/10	-1	-2	55%	-1
nov/10	-1	-2	41%	-1
dez/10	1	-1	41%	-2
jan/11	0	-2	35%	-2
fev/11	1	-2	26%	-3
mar/11	0	-2	30%	-2

Mês	Classe pseudo-observada	Classe mais provável conforme o superensemble (Previsão tipo C)	Probabilidade	Erro (classe prevista – classe pseudo-observada)
abr/11	1	-1	32%	-2
mai/11	0	-2	42%	-2
jun/11	0	-2	74%	-2
jul/11	1	-2	73%	-3
ago/11	1	-2	55%	-3
set/11	-1	-2	42%	-1
out/11	0	-2	52%	-2
nov/11	0	-2	32%	-2
dez/11	-1	-1	41%	0
jan/12	-1	-1	36%	0
fev/12	-2	-2	27%	0
mar/12	-1	-2	32%	-1
abr/12	-2	0	33%	2
mai/12	-2	0	35%	2
jun/12	-2	0	29%	2
jul/12	-1	-2	35%	-1
ago/12	0	-1	27%	-1
set/12	0	0	29%	0
out/12	1	-2	47%	-3
nov/12	0	-1	26%	-1
dez/12	2	0	32%	-2
jan/13	1	-1	36%	-2
fev/13	-1	1	23%	2
mar/13	1	0	30%	-1
abr/13	1	-2	35%	-3
mai/13	0	0	32%	0
jun/13	-1	-2	44%	-1
jul/13	0	-2	47%	-2
ago/13	1	-1	30%	-2
set/13	0	0	32%	0
out/13	-1	-2	36%	-1
nov/13	0	-1	29%	-1
dez/13	0	-1	35%	-1

Tabela F.14. Classe de saturação pseudo-observada, prevista pelo superensemble (tipo C) e erro da previsão para o horizonte de 3 meses.

Mês	Classe pseudo-observada	Classe mais provável conforme o superensemble (Previsão tipo C)	Probabilidade	Erro (classe prevista – classe pseudo-observada)
jun/05	0	-2	58%	-2
jul/05	-1	-2	56%	-1
ago/05	0	-2	33%	-2
set/05	1	-2	32%	-3
out/05	1	-2	35%	-3
nov/05	0	1	29%	1
dez/05	0	-1	45%	-1
jan/06	0	-1	30%	-1
fev/06	-2	-2	35%	0
mar/06	0	0	35%	0
abr/06	0	0	35%	0
mai/06	-2	-2	33%	0
jun/06	-1	-2	58%	-1
jul/06	0	-2	52%	-2
ago/06	0	-2	35%	-2
set/06	1	-2	30%	-3
out/06	0	-2	44%	-2
nov/06	1	-2	27%	-3
dez/06	1	-1	29%	-2
jan/07	1	-1	33%	-2
fev/07	0	-1	20%	-1
mar/07	1	0	30%	-1
abr/07	1	0	27%	-1
mai/07	1	-1	42%	-2
jun/07	-2	-2	52%	0
jul/07	0	-2	36%	-2
ago/07	0	1	29%	1
set/07	-1	-2	35%	-1
out/07	0	-2	38%	-2
nov/07	1	-1	33%	-2
dez/07	0	-1	33%	-1
jan/08	-1	-2	26%	-1
fev/08	-1	-2	26%	-1
mar/08	-1	0	29%	1
abr/08	-1	-2	39%	-1
mai/08	0	-2	39%	-2
jun/08	1	-2	64%	-3
jul/08	-1	-2	62%	-1
ago/08	1	-2	47%	-3
set/08	0	-2	42%	-2
out/08	0	-2	32%	-2

Mês	Classe pseudo-observada	Classe mais provável conforme o superensemble (Previsão tipo C)	Probabilidade	Erro (classe prevista – classe pseudo-observada)
nov/08	0	-2	27%	-2
dez/08	-1	0	27%	1
jan/09	0	0	29%	0
fev/09	-1	0	23%	1
mar/09	-1	0	35%	1
abr/09	-2	0	33%	2
mai/09	-2	-1	35%	1
jun/09	0	-2	41%	-2
jul/09	0	-2	32%	-2
ago/09	1	0	29%	-1
set/09	1	0	30%	-1
out/09	0	-2	27%	-2
nov/09	1	-2	23%	-3
dez/09	1	0	30%	-1
jan/10	1	-1	26%	-2
fev/10	0	-1	24%	-1
mar/10	0	0	29%	0
abr/10	-1	0	30%	1
mai/10	1	-1	32%	-2
jun/10	0	-2	48%	-2
jul/10	0	-2	44%	-2
ago/10	-1	-2	41%	-1
set/10	1	-2	50%	-3
out/10	-1	-2	47%	-1
nov/10	-1	-1	27%	0
dez/10	1	-1	30%	-2
jan/11	0	-1	26%	-1
fev/11	1	0	21%	-1
mar/11	0	0	26%	0
abr/11	1	0	32%	-1
mai/11	0	-2	41%	-2
jun/11	0	-2	70%	-2
jul/11	1	-2	62%	-3
ago/11	1	-2	42%	-3
set/11	-1	-2	47%	-1
out/11	0	-2	45%	-2
nov/11	0	-1	24%	-1
dez/11	-1	-1	27%	0
jan/12	-1	-1	29%	0
fev/12	-2	-1	20%	1
mar/12	-1	0	39%	1
abr/12	-2	-2	42%	0
mai/12	-2	-2	42%	0

Mês	Classe pseudo-observada	Classe mais provável conforme o superensemble (Previsão tipo C)	Probabilidade	Erro (classe prevista – classe pseudo-observada)
jun/12	-2	-2	38%	0
jul/12	-1	-2	29%	-1
ago/12	0	-2	32%	-2
set/12	0	0	30%	0
out/12	1	-2	38%	-3
nov/12	0	-1	21%	-1
dez/12	2	0	33%	-2
jan/13	1	0	26%	-1
fev/13	-1	0	27%	1
mar/13	1	0	42%	-1
abr/13	1	0	39%	-1
mai/13	0	0	30%	0
jun/13	-1	-2	32%	-1
jul/13	0	-2	35%	-2
ago/13	1	-2	29%	-3
set/13	0	1	27%	1
out/13	-1	-2	36%	-1
nov/13	0	-1	38%	-1
dez/13	0	0	30%	0

Tabela F.15. Classe de saturação pseudo-observada, prevista pelo superensemble (tipo C) e erro da previsão para o horizonte de 6 meses.

Mês	Classe pseudo-observada	Classe mais provável conforme o superensemble (Previsão tipo C)	Probabilidade	Erro (classe prevista – classe pseudo-observada)
jun/05	0	0	27%	0
jul/05	-1	0	29%	1
ago/05	0	0	26%	0
set/05	1	0	30%	-1
out/05	1	-2	27%	-3
nov/05	0	-1	21%	-1
dez/05	0	-1	36%	-1
jan/06	0	-1	33%	-1
fev/06	-2	0	21%	2
mar/06	0	0	24%	0
abr/06	0	0	26%	0
mai/06	-2	-1	24%	1
jun/06	-1	0	27%	1
jul/06	0	-1	26%	-1
ago/06	0	-1	30%	-1
set/06	1	0	27%	-1
out/06	0	-2	24%	-2
nov/06	1	-2	20%	-3
dez/06	1	-1	29%	-2
jan/07	1	-1	29%	-2
fev/07	0	1	26%	1
mar/07	1	0	38%	-1
abr/07	1	0	23%	-1
mai/07	1	0	35%	-1
jun/07	-2	0	30%	2
jul/07	0	-2	23%	-2
ago/07	0	-2	29%	-2
set/07	-1	0	35%	1
out/07	0	-2	24%	-2
nov/07	1	0	33%	-1
dez/07	0	0	33%	0
jan/08	-1	-1	27%	0
fev/08	-1	0	24%	1
mar/08	-1	-1	27%	0
abr/08	-1	-1	21%	0
mai/08	0	0	27%	0
jun/08	1	-2	42%	-3
jul/08	-1	-2	38%	-1
ago/08	1	-1	30%	-2
set/08	0	0	26%	0
out/08	0	-1	27%	-1

Mês	Classe pseudo-observada	Classe mais provável conforme o superensemble (Previsão tipo C)	Probabilidade	Erro (classe prevista – classe pseudo-observada)
nov/08	0	-1	30%	-1
dez/08	-1	-1	38%	0
jan/09	0	0	24%	0
fev/09	-1	2	26%	3
mar/09	-1	0	41%	1
abr/09	-2	0	27%	2
mai/09	-2	-1	27%	1
jun/09	0	-2	35%	-2
jul/09	0	-2	26%	-2
ago/09	1	-1	30%	-2
set/09	1	0	33%	-1
out/09	0	2	27%	2
nov/09	1	-1	24%	-2
dez/09	1	-1	38%	-2
jan/10	1	-1	30%	-2
fev/10	0	2	21%	2
mar/10	0	0	29%	0
abr/10	-1	0	23%	1
mai/10	1	-1	23%	-2
jun/10	0	0	23%	0
jul/10	0	0	26%	0
ago/10	-1	-1	33%	0
set/10	1	0	32%	-1
out/10	-1	0	30%	1
nov/10	-1	0	21%	1
dez/10	1	0	33%	-1
jan/11	0	-1	32%	-1
fev/11	1	-1	30%	-2
mar/11	0	0	29%	0
abr/11	1	-1	24%	-2
mai/11	0	-2	29%	-2
jun/11	0	-2	45%	-2
jul/11	1	-2	33%	-3
ago/11	1	-2	39%	-3
set/11	-1	0	29%	1
out/11	0	0	26%	0
nov/11	0	-1	30%	-1
dez/11	-1	-1	29%	0
jan/12	-1	0	26%	1
fev/12	-2	0	23%	2
mar/12	-1	0	39%	1
abr/12	-2	0	29%	2
mai/12	-2	0	33%	2

Mês	Classe pseudo-observada	Classe mais provável conforme o superensemble (Previsão tipo C)	Probabilidade	Erro (classe prevista – classe pseudo-observada)
jun/12	-2	-2	36%	0
jul/12	-1	0	23%	1
ago/12	0	0	27%	0
set/12	0	-1	21%	-1
out/12	1	-2	27%	-3
nov/12	0	-2	23%	-2
dez/12	2	0	35%	-2
jan/13	1	-1	36%	-2
fev/13	-1	0	29%	1
mar/13	1	0	27%	-1
abr/13	1	0	27%	-1
mai/13	0	-1	27%	-1
jun/13	-1	2	27%	3
jul/13	0	0	27%	0
ago/13	1	-1	27%	-2
set/13	0	0	30%	0
out/13	-1	-2	29%	-1
nov/13	0	-1	24%	-1
dez/13	0	-1	36%	-1

F.4 Previsões tipo C: Superensemble - Previsão completa – Probabilidade de cada classe de umidade do solo

As tabelas F.16 a F.18 mostram o resultado completo da previsão de umidade do solo. Cada tabela traz a informação de classe de saturação pseudo-verdadeira e probabilidade de ocorrência de cada classe de saturação conforme o *superensemble*. A probabilidade referente a cada classe é calculada pela Equação (23), considerando-se todos os 66 membros como pertencentes à um mesmo conjunto, ou modelo.

Tabela F.16. Classe de saturação pseudo-observada e probabilidade associada a cada classe de saturação conforme o *superensemble* (tipo C) para o horizonte de 1 mês.

Mês	Classe pseudo-observada	Previsão tipo C: Superensemble - Horizonte 1 mês				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
jun/05	0	50%	15%	33%	2%	0%
jul/05	-1	44%	17%	15%	23%	2%
ago/05	0	39%	21%	15%	11%	14%
set/05	1	48%	8%	30%	14%	0%
out/05	1	39%	18%	29%	0%	14%
nov/05	0	18%	30%	17%	30%	5%
dez/05	0	26%	29%	27%	17%	2%
jan/06	0	24%	26%	26%	20%	5%
fev/06	-2	26%	6%	32%	33%	3%
mar/06	0	17%	39%	29%	14%	2%
abr/06	0	35%	20%	15%	30%	0%
mai/06	-2	38%	27%	21%	14%	0%
jun/06	-1	61%	14%	14%	12%	0%
jul/06	0	52%	33%	8%	8%	0%
ago/06	0	36%	32%	15%	15%	2%
set/06	1	45%	26%	17%	12%	0%
out/06	0	36%	27%	23%	3%	11%
nov/06	1	14%	27%	20%	39%	0%
dez/06	1	5%	29%	33%	29%	5%
jan/07	1	15%	33%	21%	17%	14%
fev/07	0	30%	15%	21%	29%	5%
mar/07	1	23%	38%	26%	12%	2%
abr/07	1	29%	18%	33%	20%	0%
mai/07	1	32%	23%	29%	15%	2%
jun/07	-2	45%	8%	30%	17%	0%
jul/07	0	36%	20%	17%	23%	5%
ago/07	0	27%	17%	20%	30%	6%
set/07	-1	41%	17%	12%	26%	5%

Mês	Classe pseudo-observada	Previsão tipo C: Superensemble - Horizonte 1 mês				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
out/07	0	39%	18%	20%	8%	15%
nov/07	1	33%	24%	18%	23%	2%
dez/07	0	17%	39%	26%	17%	2%
jan/08	-1	23%	24%	18%	26%	9%
fev/08	-1	21%	12%	26%	33%	8%
mar/08	-1	18%	39%	30%	12%	0%
abr/08	-1	41%	26%	21%	12%	0%
mai/08	0	55%	23%	14%	9%	0%
jun/08	1	65%	11%	12%	12%	0%
jul/08	-1	52%	21%	14%	14%	0%
ago/08	1	42%	29%	15%	9%	5%
set/08	0	50%	21%	18%	9%	2%
out/08	0	44%	17%	18%	6%	15%
nov/08	0	23%	30%	15%	32%	0%
dez/08	-1	24%	35%	18%	21%	2%
jan/09	0	32%	30%	21%	14%	3%
fev/09	-1	24%	11%	23%	32%	11%
mar/09	-1	14%	20%	41%	23%	3%
abr/09	-2	27%	14%	30%	29%	0%
mai/09	-2	29%	32%	23%	17%	0%
jun/09	0	41%	14%	26%	20%	0%
jul/09	0	33%	17%	21%	26%	3%
ago/09	1	29%	23%	27%	21%	0%
set/09	1	26%	21%	32%	21%	0%
out/09	0	36%	27%	18%	5%	14%
nov/09	1	23%	21%	15%	36%	5%
dez/09	1	20%	18%	24%	33%	5%
jan/10	1	14%	41%	23%	17%	6%
fev/10	0	24%	12%	26%	32%	6%
mar/10	0	17%	18%	35%	27%	3%
abr/10	-1	14%	12%	30%	44%	0%
mai/10	1	15%	21%	39%	24%	0%
jun/10	0	44%	11%	26%	20%	0%
jul/10	0	55%	21%	8%	15%	2%
ago/10	-1	50%	27%	17%	2%	5%
set/10	1	56%	11%	15%	17%	2%
out/10	-1	55%	9%	18%	9%	9%
nov/10	-1	41%	18%	18%	18%	5%
dez/10	1	29%	41%	20%	11%	0%
jan/11	0	35%	21%	27%	15%	2%
fev/11	1	26%	14%	21%	39%	0%
mar/11	0	30%	24%	20%	24%	2%

Mês	Classe pseudo-observada	Previsão tipo C: Superensemble - Horizonte 1 mês				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
abr/11	1	29%	32%	23%	17%	0%
mai/11	0	42%	35%	11%	12%	0%
jun/11	0	74%	11%	14%	2%	0%
jul/11	1	73%	6%	11%	9%	2%
ago/11	1	55%	18%	17%	11%	0%
set/11	-1	42%	29%	21%	8%	0%
out/11	0	52%	12%	21%	3%	12%
nov/11	0	32%	21%	21%	20%	6%
dez/11	-1	11%	41%	18%	27%	3%
jan/12	-1	20%	36%	14%	14%	17%
fev/12	-2	27%	15%	26%	23%	9%
mar/12	-1	32%	21%	26%	20%	2%
abr/12	-2	26%	15%	33%	26%	0%
mai/12	-2	20%	23%	35%	21%	2%
jun/12	-2	26%	18%	29%	27%	0%
jul/12	-1	35%	21%	20%	21%	3%
ago/12	0	27%	27%	24%	15%	6%
set/12	0	27%	23%	29%	17%	5%
out/12	1	47%	9%	24%	5%	15%
nov/12	0	21%	26%	20%	23%	11%
dez/12	2	14%	27%	32%	24%	3%
jan/13	1	14%	36%	23%	20%	8%
fev/13	-1	23%	14%	21%	23%	20%
mar/13	1	23%	27%	30%	15%	5%
abr/13	1	35%	24%	21%	20%	0%
mai/13	0	20%	26%	32%	23%	0%
jun/13	-1	44%	3%	29%	24%	0%
jul/13	0	47%	23%	14%	14%	3%
ago/13	1	27%	30%	18%	23%	2%
set/13	0	26%	17%	32%	24%	2%
out/13	-1	36%	24%	14%	6%	20%
nov/13	0	26%	29%	20%	23%	3%
dez/13	0	24%	35%	27%	12%	2%

Tabela F.17. Classe de saturação pseudo-observada e probabilidade associada a cada classe de saturação conforme o *superensemble* (tipo C) para o horizonte de 3 meses.

Mês	Classe pseudo-observada	Previsão tipo C: Superensemble - Horizonte 3 meses				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
jun/05	0	58%	14%	26%	3%	0%
jul/05	-1	56%	17%	9%	15%	3%
ago/05	0	33%	21%	18%	24%	3%
set/05	1	32%	29%	18%	21%	0%
out/05	1	35%	23%	14%	15%	14%
nov/05	0	15%	29%	21%	29%	6%
dez/05	0	14%	45%	21%	14%	6%
jan/06	0	29%	30%	26%	11%	5%
fev/06	-2	35%	15%	23%	20%	8%
mar/06	0	18%	24%	35%	18%	5%
abr/06	0	18%	21%	35%	26%	0%
mai/06	-2	33%	30%	23%	12%	2%
jun/06	-1	58%	9%	18%	15%	0%
jul/06	0	52%	20%	14%	15%	0%
ago/06	0	35%	24%	20%	18%	3%
set/06	1	30%	26%	21%	21%	2%
out/06	0	44%	17%	17%	11%	12%
nov/06	1	27%	23%	17%	32%	2%
dez/06	1	9%	29%	27%	30%	5%
jan/07	1	15%	33%	21%	26%	5%
fev/07	0	20%	20%	15%	38%	8%
mar/07	1	20%	12%	30%	30%	8%
abr/07	1	15%	21%	27%	36%	0%
mai/07	1	21%	42%	20%	14%	3%
jun/07	-2	52%	12%	18%	18%	0%
jul/07	0	36%	21%	26%	17%	0%
ago/07	0	29%	21%	14%	29%	8%
set/07	-1	35%	23%	17%	23%	3%
out/07	0	38%	15%	21%	12%	14%
nov/07	1	17%	33%	15%	27%	8%
dez/07	0	20%	33%	27%	17%	3%
jan/08	-1	26%	24%	20%	27%	3%
fev/08	-1	26%	17%	21%	23%	14%
mar/08	-1	24%	29%	29%	15%	3%
abr/08	-1	39%	14%	26%	21%	0%
mai/08	0	39%	30%	20%	11%	0%
jun/08	1	64%	15%	6%	15%	0%
jul/08	-1	62%	11%	14%	14%	0%
ago/08	1	47%	18%	20%	12%	3%
set/08	0	42%	18%	21%	14%	5%

Mês	Classe pseudo-observada	Previsão tipo C: Superensemble - Horizonte 3 meses				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
out/08	0	32%	24%	24%	11%	9%
nov/08	0	27%	18%	18%	32%	5%
dez/08	-1	21%	27%	27%	21%	3%
jan/09	0	20%	21%	29%	21%	9%
fev/09	-1	18%	23%	23%	27%	9%
mar/09	-1	17%	26%	35%	21%	2%
abr/09	-2	18%	18%	33%	30%	0%
mai/09	-2	26%	35%	15%	21%	3%
jun/09	0	41%	15%	27%	17%	0%
jul/09	0	32%	23%	23%	20%	3%
ago/09	1	26%	24%	29%	20%	2%
set/09	1	29%	15%	30%	24%	2%
out/09	0	27%	26%	20%	8%	20%
nov/09	1	23%	20%	14%	38%	6%
dez/09	1	17%	29%	30%	23%	2%
jan/10	1	20%	26%	24%	21%	9%
fev/10	0	20%	24%	18%	32%	6%
mar/10	0	17%	21%	29%	26%	8%
abr/10	-1	14%	12%	30%	44%	0%
mai/10	1	21%	32%	23%	23%	2%
jun/10	0	48%	11%	24%	17%	0%
jul/10	0	44%	21%	21%	14%	0%
ago/10	-1	41%	26%	24%	9%	0%
set/10	1	50%	23%	15%	12%	0%
out/10	-1	47%	14%	18%	9%	12%
nov/10	-1	27%	27%	18%	23%	5%
dez/10	1	27%	30%	26%	17%	0%
jan/11	0	23%	26%	17%	24%	11%
fev/11	1	17%	12%	21%	38%	12%
mar/11	0	14%	24%	26%	30%	6%
abr/11	1	27%	18%	32%	23%	0%
mai/11	0	41%	30%	21%	8%	0%
jun/11	0	70%	6%	20%	5%	0%
jul/11	1	62%	21%	6%	11%	0%
ago/11	1	42%	26%	12%	18%	2%
set/11	-1	47%	15%	15%	20%	3%
out/11	0	45%	12%	23%	3%	17%
nov/11	0	18%	24%	17%	30%	11%
dez/11	-1	15%	27%	23%	33%	2%
jan/12	-1	14%	29%	21%	27%	9%
fev/12	-2	12%	20%	15%	38%	15%
mar/12	-1	17%	21%	39%	21%	2%

Mês	Classe pseudo-observada	Previsão tipo C: Superensemble - Horizonte 3 meses				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
abr/12	-2	42%	14%	24%	20%	0%
mai/12	-2	42%	27%	14%	17%	0%
jun/12	-2	38%	18%	17%	27%	0%
jul/12	-1	29%	24%	26%	20%	2%
ago/12	0	32%	15%	26%	24%	3%
set/12	0	26%	23%	30%	20%	2%
out/12	1	38%	11%	18%	11%	23%
nov/12	0	18%	21%	17%	41%	3%
dez/12	2	9%	23%	33%	29%	6%
jan/13	1	17%	26%	26%	18%	14%
fev/13	-1	14%	26%	27%	26%	8%
mar/13	1	15%	12%	42%	26%	5%
abr/13	1	12%	17%	39%	32%	0%
mai/13	0	27%	17%	30%	26%	0%
jun/13	-1	32%	12%	26%	30%	0%
jul/13	0	35%	24%	23%	17%	2%
ago/13	1	29%	26%	24%	21%	0%
set/13	0	27%	23%	23%	27%	0%
out/13	-1	36%	9%	21%	11%	23%
nov/13	0	17%	38%	21%	23%	2%
dez/13	0	21%	29%	30%	18%	2%

Tabela F.18. Classe de saturação pseudo-observada e probabilidade associada a cada classe de saturação conforme o *superensemble* (tipo C) para o horizonte de 6 meses.

Mês	Classe pseudo-observada	Previsão tipo C: Superensemble - Horizonte 6 meses				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
jun/05	0	20%	18%	27%	23%	12%
jul/05	-1	29%	9%	29%	20%	14%
ago/05	0	15%	26%	26%	27%	6%
set/05	1	11%	18%	30%	36%	5%
out/05	1	27%	12%	20%	21%	20%
nov/05	0	15%	21%	17%	27%	20%
dez/05	0	11%	36%	30%	17%	6%
jan/06	0	17%	33%	18%	24%	8%
fev/06	-2	17%	18%	21%	24%	20%
mar/06	0	21%	18%	24%	27%	9%
abr/06	0	23%	3%	26%	29%	20%
mai/06	-2	14%	24%	23%	20%	20%
jun/06	-1	21%	15%	27%	17%	20%
jul/06	0	18%	26%	20%	21%	15%
ago/06	0	18%	30%	20%	24%	8%
set/06	1	21%	26%	27%	21%	5%
out/06	0	24%	21%	21%	18%	15%
nov/06	1	20%	18%	15%	32%	15%
dez/06	1	15%	29%	21%	30%	5%
jan/07	1	20%	29%	15%	32%	5%
fev/07	0	15%	15%	18%	26%	26%
mar/07	1	9%	15%	38%	29%	9%
abr/07	1	14%	9%	23%	35%	20%
mai/07	1	11%	12%	35%	24%	18%
jun/07	-2	17%	17%	30%	23%	14%
jul/07	0	23%	17%	21%	27%	12%
ago/07	0	29%	27%	23%	15%	6%
set/07	-1	15%	23%	35%	24%	3%
out/07	0	24%	15%	20%	18%	23%
nov/07	1	9%	23%	33%	17%	18%
dez/07	0	11%	33%	33%	23%	0%
jan/08	-1	20%	27%	21%	14%	18%
fev/08	-1	11%	23%	24%	24%	18%
mar/08	-1	12%	27%	23%	33%	5%
abr/08	-1	20%	21%	15%	32%	12%
mai/08	0	23%	26%	27%	21%	3%
jun/08	1	42%	6%	32%	14%	6%
jul/08	-1	38%	26%	15%	17%	5%
ago/08	1	26%	30%	17%	21%	6%
set/08	0	17%	23%	26%	29%	6%

Mês	Classe pseudo-observada	Previsão tipo C: Superensemble - Horizonte 6 meses				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
out/08	0	18%	27%	23%	15%	17%
nov/08	0	17%	30%	21%	18%	14%
dez/08	-1	14%	38%	30%	17%	2%
jan/09	0	17%	20%	24%	32%	8%
fev/09	-1	11%	12%	24%	27%	26%
mar/09	-1	5%	20%	41%	29%	6%
abr/09	-2	12%	18%	27%	26%	17%
mai/09	-2	20%	27%	21%	17%	15%
jun/09	0	35%	12%	23%	18%	12%
jul/09	0	26%	12%	20%	30%	12%
ago/09	1	17%	30%	26%	14%	14%
set/09	1	20%	14%	33%	23%	11%
out/09	0	18%	14%	24%	17%	27%
nov/09	1	17%	24%	18%	17%	24%
dez/09	1	17%	38%	20%	21%	5%
jan/10	1	12%	30%	29%	18%	11%
fev/10	0	14%	12%	15%	38%	21%
mar/10	0	12%	14%	29%	36%	9%
abr/10	-1	11%	12%	23%	38%	17%
mai/10	1	9%	23%	17%	29%	23%
jun/10	0	21%	11%	23%	27%	18%
jul/10	0	14%	18%	26%	27%	15%
ago/10	-1	18%	33%	29%	18%	2%
set/10	1	18%	18%	32%	24%	8%
out/10	-1	24%	14%	30%	15%	17%
nov/10	-1	21%	21%	21%	29%	8%
dez/10	1	21%	26%	33%	18%	2%
jan/11	0	17%	32%	20%	27%	5%
fev/11	1	12%	30%	14%	32%	12%
mar/11	0	20%	29%	29%	18%	5%
abr/11	1	21%	24%	18%	32%	5%
mai/11	0	29%	27%	23%	6%	15%
jun/11	0	45%	9%	24%	14%	8%
jul/11	1	33%	30%	14%	17%	6%
ago/11	1	39%	26%	12%	14%	9%
set/11	-1	24%	12%	29%	27%	8%
out/11	0	24%	18%	26%	15%	17%
nov/11	0	14%	30%	21%	17%	18%
dez/11	-1	18%	29%	24%	24%	5%
jan/12	-1	8%	24%	26%	30%	12%
fev/12	-2	3%	9%	23%	42%	23%
mar/12	-1	9%	18%	39%	29%	5%

Mês	Classe pseudo-observada	Previsão tipo C: Superensemble - Horizonte 6 meses				
		Probabilidade de ocorrência da classe -2: Muito seco	Probabilidade de ocorrência da classe -1: Seco	Probabilidade de ocorrência da classe 0: Normal	Probabilidade de ocorrência da classe +1: Úmido	Probabilidade de ocorrência da classe +2: Muito úmido
abr/12	-2	15%	26%	29%	21%	9%
mai/12	-2	20%	18%	33%	18%	11%
jun/12	-2	36%	12%	20%	20%	12%
jul/12	-1	20%	18%	23%	30%	9%
ago/12	0	26%	18%	27%	14%	15%
set/12	0	17%	21%	20%	36%	6%
out/12	1	27%	23%	26%	15%	9%
nov/12	0	23%	20%	18%	27%	12%
dez/12	2	12%	27%	35%	26%	0%
jan/13	1	12%	36%	24%	21%	6%
fev/13	-1	18%	15%	29%	23%	15%
mar/13	1	14%	20%	27%	29%	11%
abr/13	1	12%	11%	27%	35%	15%
mai/13	0	5%	27%	17%	26%	26%
jun/13	-1	17%	5%	21%	30%	27%
jul/13	0	24%	5%	27%	27%	17%
ago/13	1	20%	27%	21%	26%	6%
set/13	0	15%	24%	30%	29%	2%
out/13	-1	29%	24%	18%	12%	17%
nov/13	0	23%	24%	20%	17%	17%
dez/13	0	20%	36%	27%	14%	3%

F.5 Previsões tipos B e D: Média do ensemble (previsões tipo B) e ensemble das médias (multimodelos, previsões tipo D)

Apresentam-se nas tabelas F.19 a F.21 os resultados da previsão realizada com a média do *ensemble* da previsão de precipitação, e a previsão resultante do *ensemble* destas médias, configurando uma abordagem multimodelos. O resultado do *ensemble* das médias (de saturação) foi calculado como a média (arredondada para o número inteiro mais próximo) das classes encontradas pela previsão realizada com a média (de precipitação) de cada modelo. A probabilidade associada, nestes casos, foi definida pela contagem de modelos com classe prevista igual à classe média. Este valor varia entre 0%, quando nenhum dos modelos previu aquela classe, e 100%, quando os três modelos previram a mesma classe de saturação. A probabilidade 0% é atingida, por exemplo, no caso de outubro/2005 para horizonte 1 mês, quando dois modelos previram classe +2 e um, classe 0. A previsão do *ensemble* das médias é classe +1 ($((2+0+2) / 3 = 1,333 \gg$ classe +1); porém nenhum dos modelos havia previsto, para aquele mês, esta classe.

Tabela F.19. Classe de saturação pseudo-observada, prevista pela média do *ensemble* (de precipitação) de cada modelo (tipo B) e média do *ensemble* de modelos (tipo D) para o horizonte de 1 mês.

Mês	Classe pseudo-observada	Classe prevista Previsões tipo B			Ensemble das médias (multimodelos) Previsão tipo D		Erro			
		CCM3v6	ECPC	GFDL	Classe	Probabilidade	CCM3v6	ECPC	GFDL	Ensemble das médias Previsão tipo D)
jun/05	0	-1	1	-2	-1	33%	-1	1	-2	-1
jul/05	-1	0	1	-1	0	33%	1	2	0	1
ago/05	0	1	2	-1	1	33%	1	2	-1	1
set/05	1	1	1	-2	0	0%	0	0	-3	-1
out/05	1	2	0	2	1	0%	1	-1	1	0
nov/05	0	1	1	1	1	100%	1	1	1	1
dez/05	0	0	0	0	0	100%	0	0	0	0
jan/06	0	0	0	0	0	100%	0	0	0	0
fev/06	-2	1	1	0	1	67%	3	3	2	3
mar/06	0	1	1	0	1	67%	1	1	0	1
abr/06	0	0	1	0	0	67%	0	1	0	0
mai/06	-2	1	1	0	1	67%	3	3	2	3
jun/06	-1	0	1	0	0	67%	1	2	1	1
jul/06	0	0	1	-1	0	33%	0	1	-1	0
ago/06	0	0	1	0	0	67%	0	1	0	0
set/06	1	0	1	0	0	67%	-1	0	-1	-1
out/06	0	1	1	1	1	100%	1	1	1	1

Mês	Classe pseudo-observada	Classe prevista Previsões tipo B			Ensemble das médias (multimodelos) Previsão tipo D		Erro			
		CCM3v6	ECPC	GFDL	Classe	Probabilidade	CCM3v6	ECPC	GFDL	Ensemble das médias Previsão tipo D)
nov/06	1	1	0	1	1	67%	0	-1	0	0
dez/06	1	1	0	1	1	67%	0	-1	0	0
jan/07	1	1	0	0	0	67%	0	-1	-1	-1
fev/07	0	1	0	0	0	67%	1	0	0	0
mar/07	1	1	-1	0	0	33%	0	-2	-1	-1
abr/07	1	1	-1	1	0	0%	0	-2	0	-1
mai/07	1	1	-1	1	0	0%	0	-2	0	-1
jun/07	-2	0	0	1	0	67%	2	2	3	2
jul/07	0	1	1	0	1	67%	1	1	0	1
ago/07	0	1	1	0	1	67%	1	1	0	1
set/07	-1	1	2	0	1	33%	2	3	1	2
out/07	0	1	1	1	1	100%	1	1	1	1
nov/07	1	0	1	1	1	67%	-1	0	0	0
dez/07	0	0	0	0	0	100%	0	0	0	0
jan/08	-1	0	0	1	0	67%	1	1	2	1
fev/08	-1	1	1	1	1	100%	2	2	2	2
mar/08	-1	0	0	0	0	100%	1	1	1	1
abr/08	-1	-1	0	0	0	67%	0	1	1	1
mai/08	0	-2	1	0	0	33%	-2	1	0	0
jun/08	1	-2	1	-1	-1	33%	-3	0	-2	-2
jul/08	-1	0	1	-1	0	33%	1	2	0	1
ago/08	1	1	1	-1	0	0%	0	0	-2	-1
set/08	0	1	1	-2	0	0%	1	1	-2	0
out/08	0	2	1	1	1	67%	2	1	1	1
nov/08	0	0	1	1	1	67%	0	1	1	1
dez/08	-1	-1	0	0	0	67%	0	1	1	1
jan/09	0	-1	-1	0	-1	67%	-1	-1	0	-1
fev/09	-1	1	1	1	1	100%	2	2	2	2
mar/09	-1	1	1	1	1	100%	2	2	2	2
abr/09	-2	0	0	1	0	67%	2	2	3	2
mai/09	-2	1	1	1	1	100%	3	3	3	3
jun/09	0	0	1	1	1	67%	0	1	1	1
jul/09	0	1	1	0	1	67%	1	1	0	1
ago/09	1	0	0	1	0	67%	-1	-1	0	-1
set/09	1	1	1	0	1	67%	0	0	-1	0
out/09	0	2	0	1	1	33%	2	0	1	1
nov/09	1	1	1	1	1	100%	0	0	0	0
dez/09	1	1	1	1	1	100%	0	0	0	0
jan/10	1	0	0	0	0	100%	-1	-1	-1	-1
fev/10	0	1	2	0	1	33%	1	2	0	1
mar/10	0	1	2	0	1	33%	1	2	0	1
abr/10	-1	1	1	1	1	100%	2	2	2	2
mai/10	1	1	1	1	1	100%	0	0	0	0
jun/10	0	1	1	0	1	67%	1	1	0	1

Mês	Classe pseudo-observada	Classe prevista Previsões tipo B			Ensemble das médias (multimodelos) Previsão tipo D		Erro			
		CCM3v6	ECPC	GFDL	Classe	Probabilidade	CCM3v6	ECPC	GFDL	Ensemble das médias Previsão tipo D)
jul/10	0	0	0	-1	0	67%	0	0	-1	0
ago/10	-1	0	0	-1	0	67%	1	1	0	1
set/10	1	1	1	-2	0	0%	0	0	-3	-1
out/10	-1	-1	1	1	0	0%	0	2	2	1
nov/10	-1	-1	1	1	0	0%	0	2	2	1
dez/10	1	-1	0	-1	-1	67%	-2	-1	-2	-2
jan/11	0	-1	1	-1	0	0%	-1	1	-1	0
fev/11	1	1	0	0	0	67%	0	-1	-1	-1
mar/11	0	0	-1	0	0	67%	0	-1	0	0
abr/11	1	0	-1	0	0	67%	-1	-2	-1	-1
mai/11	0	0	1	0	0	67%	0	1	0	0
jun/11	0	-1	-1	-2	-1	67%	-1	-1	-2	-1
jul/11	1	0	0	-2	-1	0%	-1	-1	-3	-2
ago/11	1	1	0	-2	0	33%	0	-1	-3	-1
set/11	-1	0	0	-2	-1	0%	1	1	-1	0
out/11	0	1	2	1	1	67%	1	2	1	1
nov/11	0	0	1	1	1	67%	0	1	1	1
dez/11	-1	0	1	0	0	67%	1	2	1	1
jan/12	-1	0	1	0	0	67%	1	2	1	1
fev/12	-2	1	1	0	1	67%	3	3	2	3
mar/12	-1	0	0	1	0	67%	1	1	2	1
abr/12	-2	-1	1	1	0	0%	1	3	3	2
mai/12	-2	0	2	1	1	33%	2	4	3	3
jun/12	-2	1	2	1	1	67%	3	4	3	3
jul/12	-1	1	1	0	1	67%	2	2	1	2
ago/12	0	1	1	0	1	67%	1	1	0	1
set/12	0	1	1	0	1	67%	1	1	0	1
out/12	1	2	2	-1	1	0%	1	1	-2	0
nov/12	0	2	1	1	1	67%	2	1	1	1
dez/12	2	1	1	0	1	67%	-1	-1	-2	-1
jan/13	1	0	1	0	0	67%	-1	0	-1	-1
fev/13	-1	1	2	1	1	67%	2	3	2	2
mar/13	1	0	1	1	1	67%	-1	0	0	0
abr/13	1	0	-1	1	0	33%	-1	-2	0	-1
mai/13	0	1	0	1	1	67%	1	0	1	1
jun/13	-1	1	1	1	1	100%	2	2	2	2
jul/13	0	0	1	0	0	67%	0	1	0	0
ago/13	1	1	1	0	1	67%	0	0	-1	0
set/13	0	1	1	0	1	67%	1	1	0	1
out/13	-1	2	1	1	1	67%	3	2	2	2
nov/13	0	1	1	1	1	100%	1	1	1	1
dez/13	0	0	-1	0	0	67%	0	-1	0	0

Tabela F.20. Classe de saturação pseudo-observada, prevista pela média do *ensemble* (de precipitação) de cada modelo (tipo B) e média do *ensemble* de modelos (tipo D) para o horizonte de 3 meses.

Mês	Classe pseudo-observada	Classe prevista Previsões tipo B			Ensemble das médias (multimodelos) Previsão tipo D		Erro			
		CCM3v6	ECPC	GFDL	Classe	Probabilidade	CCM3v6	ECPC	GFDL	Ensemble das médias Previsão tipo D)
jun/05	0	-1	1	-2	-1	33%	-1	1	-2	-1
jul/05	-1	0	1	-2	0	33%	1	2	-1	1
ago/05	0	1	1	-1	0	0%	1	1	-1	0
set/05	1	1	2	-1	1	33%	0	1	-2	0
out/05	1	1	0	1	1	67%	0	-1	0	0
nov/05	0	1	0	1	1	67%	1	0	1	1
dez/05	0	1	-1	0	0	33%	1	-1	0	0
jan/06	0	1	-1	-1	0	0%	1	-1	-1	0
fev/06	-2	1	0	-1	0	33%	3	2	1	2
mar/06	0	1	2	0	1	33%	1	2	0	1
abr/06	0	0	1	1	1	67%	0	1	1	1
mai/06	-2	0	1	1	1	67%	2	3	3	3
jun/06	-1	-1	1	0	0	33%	0	2	1	1
jul/06	0	0	1	-1	0	33%	0	1	-1	0
ago/06	0	1	1	0	1	67%	1	1	0	1
set/06	1	1	1	0	1	67%	0	0	-1	0
out/06	0	0	1	1	1	67%	0	1	1	1
nov/06	1	1	1	1	1	100%	0	0	0	0
dez/06	1	1	1	1	1	100%	0	0	0	0
jan/07	1	0	0	0	0	100%	-1	-1	-1	-1
fev/07	0	1	1	1	1	100%	1	1	1	1
mar/07	1	1	1	1	1	100%	0	0	0	0
abr/07	1	1	1	1	1	100%	0	0	0	0
mai/07	1	1	1	1	1	100%	0	0	0	0
jun/07	-2	0	1	0	0	67%	2	3	2	2
jul/07	0	1	1	-1	0	0%	1	1	-1	0
ago/07	0	1	1	0	1	67%	1	1	0	1
set/07	-1	1	1	0	1	67%	2	2	1	2
out/07	0	2	1	0	1	33%	2	1	0	1
nov/07	1	2	1	1	1	67%	1	0	0	0
dez/07	0	0	1	0	0	67%	0	1	0	0
jan/08	-1	-1	1	0	0	33%	0	2	1	1
fev/08	-1	1	1	1	1	100%	2	2	2	2
mar/08	-1	1	1	0	1	67%	2	2	1	2
abr/08	-1	0	1	0	0	67%	1	2	1	1
mai/08	0	0	1	0	0	67%	0	1	0	0
jun/08	1	-1	1	0	0	33%	-2	0	-1	-1
jul/08	-1	0	1	-1	0	33%	1	2	0	1
ago/08	1	0	1	-1	0	33%	-1	0	-2	-1
set/08	0	1	2	-1	1	33%	1	2	-1	1
out/08	0	1	0	2	1	33%	1	0	2	1

Mês	Classe pseudo-observada	Classe prevista Previsões tipo B			Ensemble das médias (multimodelos) Previsão tipo D		Erro			
		CCM3v6	ECPC	GFDL	Classe	Probabilidade	CCM3v6	ECPC	GFDL	Ensemble das médias Previsão tipo D)
nov/08	0	1	1	1	1	100%	1	1	1	1
dez/08	-1	0	0	0	0	100%	1	1	1	1
jan/09	0	0	0	0	0	100%	0	0	0	0
fev/09	-1	1	1	1	1	100%	2	2	2	2
mar/09	-1	1	0	0	0	67%	2	1	1	1
abr/09	-2	0	1	1	1	67%	2	3	3	3
mai/09	-2	0	1	1	1	67%	2	3	3	3
jun/09	0	1	2	0	1	33%	1	2	0	1
jul/09	0	0	1	1	1	67%	0	1	1	1
ago/09	1	0	1	0	0	67%	-1	0	-1	-1
set/09	1	1	2	0	1	33%	0	1	-1	0
out/09	0	2	1	2	2	67%	2	1	2	2
nov/09	1	1	1	1	1	100%	0	0	0	0
dez/09	1	0	0	0	0	100%	-1	-1	-1	-1
jan/10	1	0	1	0	0	67%	-1	0	-1	-1
fev/10	0	1	1	0	1	67%	1	1	0	1
mar/10	0	1	1	1	1	100%	1	1	1	1
abr/10	-1	1	1	1	1	100%	2	2	2	2
mai/10	1	0	1	1	1	67%	-1	0	0	0
jun/10	0	0	2	0	1	0%	0	2	0	1
jul/10	0	0	1	-1	0	33%	0	1	-1	0
ago/10	-1	0	0	-1	0	67%	1	1	0	1
set/10	1	0	0	-1	0	67%	-1	-1	-2	-1
out/10	-1	0	1	1	1	67%	1	2	2	2
nov/10	-1	1	1	1	1	100%	2	2	2	2
dez/10	1	0	1	-1	0	33%	-1	0	-2	-1
jan/11	0	0	1	0	0	67%	0	1	0	0
fev/11	1	1	1	1	1	100%	0	0	0	0
mar/11	0	1	1	1	1	100%	1	1	1	1
abr/11	1	0	1	1	1	67%	-1	0	0	0
mai/11	0	-1	1	0	0	33%	-1	1	0	0
jun/11	0	-1	1	-1	0	0%	-1	1	-1	0
jul/11	1	0	0	-2	-1	0%	-1	-1	-3	-2
ago/11	1	1	0	-1	0	33%	0	-1	-2	-1
set/11	-1	1	0	-1	0	33%	2	1	0	1
out/11	0	1	1	1	1	100%	1	1	1	1
nov/11	0	1	0	1	1	67%	1	0	1	1
dez/11	-1	1	0	0	0	67%	2	1	1	1
jan/12	-1	1	1	0	1	67%	2	2	1	2
fev/12	-2	1	1	1	1	100%	3	3	3	3
mar/12	-1	1	1	1	1	100%	2	2	2	2
abr/12	-2	-1	1	0	0	33%	1	3	2	2
mai/12	-2	-1	1	0	0	33%	1	3	2	2
jun/12	-2	0	2	1	1	33%	2	4	3	3

Mês	Classe pseudo-observada	Classe prevista Previsões tipo B			Ensemble das médias (multimodelos) Previsão tipo D		Erro			
		CCM3v6	ECPC	GFDL	Classe	Probabilidade	CCM3v6	ECPC	GFDL	Ensemble das médias Previsão tipo D)
jul/12	-1	0	1	1	1	67%	1	2	2	2
ago/12	0	0	1	1	1	67%	0	1	1	1
set/12	0	1	1	1	1	100%	1	1	1	1
out/12	1	2	1	1	1	67%	1	0	0	0
nov/12	0	1	1	1	1	100%	1	1	1	1
dez/12	2	0	1	1	1	67%	-2	-1	-1	-1
jan/13	1	0	1	1	1	67%	-1	0	0	0
fev/13	-1	1	1	1	1	100%	2	2	2	2
mar/13	1	1	1	1	1	100%	0	0	0	0
abr/13	1	1	1	1	1	100%	0	0	0	0
mai/13	0	0	1	1	1	67%	0	1	1	1
jun/13	-1	1	2	1	1	67%	2	3	2	2
jul/13	0	1	1	0	1	67%	1	1	0	1
ago/13	1	0	1	0	0	67%	-1	0	-1	-1
set/13	0	1	0	1	1	67%	1	0	1	1
out/13	-1	2	1	2	2	67%	3	2	3	3
nov/13	0	1	1	1	1	100%	1	1	1	1
dez/13	0	0	-1	0	0	67%	0	-1	0	0

Tabela F.21. Classe de saturação pseudo-observada, prevista pela média do *ensemble* (de precipitação) de cada modelo (tipo B) e média do *ensemble* de modelos (tipo D) para o horizonte de 6 meses.

Mês	Classe pseudo-observada	Classe prevista Previsões tipo B			Ensemble das médias (multimodelos) Previsão tipo D		Erro			
		CCM3v6	ECPC	GFDL	Classe	Probabilidade	CCM3v6	ECPC	GFDL	Ensemble das médias Previsão tipo D
jun/05	0	0	0	1	0	67%	0	0	1	0
jul/05	-1	0	1	1	1	67%	1	2	2	2
ago/05	0	1	1	1	1	100%	1	1	1	1
set/05	1	1	2	1	1	67%	0	1	0	0
out/05	1	1	1	2	1	67%	0	0	1	0
nov/05	0	1	1	2	1	67%	1	1	2	1
dez/05	0	0	1	0	0	67%	0	1	0	0
jan/06	0	1	1	0	1	67%	1	1	0	1
fev/06	-2	1	1	2	1	67%	3	3	4	3
mar/06	0	0	2	1	1	33%	0	2	1	1
abr/06	0	0	1	2	1	33%	0	1	2	1
mai/06	-2	1	1	2	1	67%	3	3	4	3
jun/06	-1	1	1	2	1	67%	2	2	3	2
jul/06	0	0	1	2	1	33%	0	1	2	1
ago/06	0	1	1	1	1	100%	1	1	1	1
set/06	1	1	1	1	1	100%	0	0	0	0
out/06	0	2	1	2	2	67%	2	1	2	2
nov/06	1	1	2	2	2	67%	0	1	1	1
dez/06	1	0	1	1	1	67%	-1	0	0	0
jan/07	1	0	1	0	0	67%	-1	0	-1	-1
fev/07	0	1	1	2	1	67%	1	1	2	1
mar/07	1	1	1	2	1	67%	0	0	1	0
abr/07	1	1	0	2	1	33%	0	-1	1	0
mai/07	1	1	1	2	1	67%	0	0	1	0
jun/07	-2	1	1	2	1	67%	3	3	4	3
jul/07	0	0	1	1	1	67%	0	1	1	1
ago/07	0	0	0	1	0	67%	0	0	1	0
set/07	-1	1	1	1	1	100%	2	2	2	2
out/07	0	1	2	2	2	67%	1	2	2	2
nov/07	1	1	1	2	1	67%	0	0	1	0
dez/07	0	0	1	0	0	67%	0	1	0	0
jan/08	-1	0	2	0	1	0%	1	3	1	2
fev/08	-1	1	1	2	1	67%	2	2	3	2
mar/08	-1	1	1	1	1	100%	2	2	2	2
abr/08	-1	0	1	2	1	33%	1	2	3	2
mai/08	0	1	1	1	1	100%	1	1	1	1
jun/08	1	1	0	1	1	67%	0	-1	0	0
jul/08	-1	0	0	1	0	67%	1	1	2	1
ago/08	1	1	1	0	1	67%	0	0	-1	0
set/08	0	1	1	0	1	67%	1	1	0	1
out/08	0	2	0	2	1	0%	2	0	2	1

Mês	Classe pseudo-observada	Classe prevista Previsões tipo B			Ensemble das médias (multimodelos) Previsão tipo D		Erro			
		CCM3v6	ECPC	GFDL	Classe	Probabilidade	CCM3v6	ECPC	GFDL	Ensemble das médias Previsão tipo D
nov/08	0	1	0	2	1	33%	1	0	2	1
dez/08	-1	0	0	0	0	100%	1	1	1	1
jan/09	0	1	0	0	0	67%	1	0	0	0
fev/09	-1	1	1	2	1	67%	2	2	3	2
mar/09	-1	2	1	1	1	67%	3	2	2	2
abr/09	-2	1	1	2	1	67%	3	3	4	3
mai/09	-2	0	1	2	1	33%	2	3	4	3
jun/09	0	0	1	2	1	33%	0	1	2	1
jul/09	0	0	2	2	1	0%	0	2	2	1
ago/09	1	1	1	1	1	100%	0	0	0	0
set/09	1	1	1	1	1	100%	0	0	0	0
out/09	0	2	1	2	2	67%	2	1	2	2
nov/09	1	1	0	2	1	33%	0	-1	1	0
dez/09	1	0	0	0	0	100%	-1	-1	-1	-1
jan/10	1	0	0	0	0	100%	-1	-1	-1	-1
fev/10	0	1	1	2	1	67%	1	1	2	1
mar/10	0	1	1	2	1	67%	1	1	2	1
abr/10	-1	1	0	2	1	33%	2	1	3	2
mai/10	1	1	1	2	1	67%	0	0	1	0
jun/10	0	1	1	2	1	67%	1	1	2	1
jul/10	0	1	1	2	1	67%	1	1	2	1
ago/10	-1	1	1	0	1	67%	2	2	1	2
set/10	1	1	1	1	1	100%	0	0	0	0
out/10	-1	1	1	2	1	67%	2	2	3	2
nov/10	-1	1	1	1	1	100%	2	2	2	2
dez/10	1	-1	1	0	0	33%	-2	0	-1	-1
jan/11	0	-1	2	0	0	33%	-1	2	0	0
fev/11	1	1	0	1	1	67%	0	-1	0	0
mar/11	0	0	0	1	0	67%	0	0	1	0
abr/11	1	0	1	1	1	67%	-1	0	0	0
mai/11	0	-1	1	2	1	33%	-1	1	2	1
jun/11	0	0	0	1	0	67%	0	0	1	0
jul/11	1	0	0	1	0	67%	-1	-1	0	-1
ago/11	1	0	0	0	0	100%	-1	-1	-1	-1
set/11	-1	1	1	1	1	100%	2	2	2	2
out/11	0	2	1	2	2	67%	2	1	2	2
nov/11	0	1	1	2	1	67%	1	1	2	1
dez/11	-1	1	1	0	1	67%	2	2	1	2
jan/12	-1	0	2	1	1	33%	1	3	2	2
fev/12	-2	1	2	2	2	67%	3	4	4	4
mar/12	-1	1	1	1	1	100%	2	2	2	2
abr/12	-2	0	1	1	1	67%	2	3	3	3
mai/12	-2	0	1	2	1	33%	2	3	4	3
jun/12	-2	0	1	2	1	33%	2	3	4	3

Mês	Classe pseudo-observada	Classe prevista Previsões tipo B			Ensemble das médias (multimodelos) Previsão tipo D		Erro			
		CCM3v6	ECPC	GFDL	Classe	Probabilidade	CCM3v6	ECPC	GFDL	Ensemble das médias Previsão tipo D
jul/12	-1	1	1	2	1	67%	2	2	3	2
ago/12	0	1	1	1	1	100%	1	1	1	1
set/12	0	1	2	1	1	67%	1	2	1	1
out/12	1	0	1	1	1	67%	-1	0	0	0
nov/12	0	1	1	1	1	100%	1	1	1	1
dez/12	2	0	1	1	1	67%	-2	-1	-1	-1
jan/13	1	0	0	1	0	67%	-1	-1	0	-1
fev/13	-1	0	1	2	1	33%	1	2	3	2
mar/13	1	1	1	1	1	100%	0	0	0	0
abr/13	1	1	1	2	1	67%	0	0	1	0
mai/13	0	1	2	2	2	67%	1	2	2	2
jun/13	-1	1	1	2	1	67%	2	2	3	2
jul/13	0	1	1	2	1	67%	1	1	2	1
ago/13	1	1	0	1	1	67%	0	-1	0	0
set/13	0	1	0	1	1	67%	1	0	1	1
out/13	-1	2	1	2	2	67%	3	2	3	3
nov/13	0	1	1	2	1	67%	1	1	2	1
dez/13	0	1	0	0	0	67%	1	0	0	0

