



UNIVERSIDADE FEDERAL DE CAMPINA GRANDE - UFCG
CENTRO DE TECNOLOGIA E RECURSOS NATURAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL E AMBIENTAL - PPGECA
ÁREA: RECURSOS HÍDRICOS E SANEAMENTO AMBIENTAL

EPITÁCIO PEDRO DA SILVA NETO

MODELAGEM DA EVAPOTRANSPIRAÇÃO POR SENSORIAMENTO REMOTO:
AVALIAÇÃO EM DIFERENTES BIOMAS NO MUNDO

CAMPINA GRANDE, PB

2025

EPITÁCIO PEDRO DA SILVA NETO

MODELAGEM DA EVAPOTRANSPIRAÇÃO POR SENSORIAMENTO REMOTO:
AVALIAÇÃO EM DIFERENTES BIOMAS NO MUNDO

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Civil e Ambiental da Universidade Federal de Campina Grande para obtenção do título de Mestre em Engenharia Civil e Ambiental. Área de concentração: Recursos Hídricos e Saneamento Ambiental.

Linha de pesquisa: Recursos Hídricos.

Orientadores: Prof. Dr. John Elton de Brito Leite Cunha e Dr. Ulisses Alencar Bezerra

CAMPINA GRANDE - PB

2025

S586m Silva Neto, Eptácio Pedro da.
Modelagem da evapotranspiração por sensoriamento remoto:
avaliação em diferentes biomas no mundo / Eptácio Pedro da Silva
Neto. – Campina Grande, 2025.
113 f. : il. color.

Dissertação (Mestrado em Engenharia Civil e Ambiental) –
Universidade Federal de Campina Grande, Centro de Tecnologia e
Recursos Naturais, 2025.

“Orientação: Prof. Dr. John Elton de Brito Leite Cunha, Prof. Dr.
Ulisses Alencar Bezerra”.

Referências.

1. Recursos Hídricos. 2. Saneamento Ambiental. 3. Balanço de
Energia à Superfície. 4. Google *Earth Engine*. 5. Ciclo Hidrológico.
I. Cunha, John Elton de Brito Leite. II. Bezerra, Ulisses Alencar.
III. Título.

CDU 556.18(043)

EPITÁCIO PEDRO DA SILVA NETO

MODELAGEM DA EVAPOTRANSPIRAÇÃO POR SENSORIAMENTO REMOTO:
AVALIAÇÃO EM DIFERENTES BIOMAS NO MUNDO

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Civil e Ambiental da Universidade Federal de Campina Grande para obtenção do título de Mestre em Engenharia Civil e Ambiental

Aprovado em: 03 de fevereiro de 2025

PROF. DR. JOHN ELTON DE BRITO DE LEITE CUNHA
UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
ORIENTADOR

DR. ULISSES ALENCAR BEZERRA
UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
ORIENTADOR

DR. LUCIANNA MARQUES ROCHA FERREIRA
UNIVERSIDADE FEDERAL DO AMAZONAS
EXAMINADORA EXTERNA

DR. BRUCE KELLY NÓBREGA DA SILVA
INSTITUTO NACIONAL DO SEMINÁRIO
EXAMINADOR EXTERNO



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
POS-GRADUACAO ENGENHARIA CIVIL AMBIENTAL
Rua Aprigio Veloso, 882, - Bairro Universitario, Campina Grande/PB, CEP 58429-900

REGISTRO DE PRESENÇA E ASSINATURAS

1. **ATA DA DEFESA PARA CONCESSÃO DO GRAU DE MESTRE EM ENGENHARIA CIVIL E AMBIENTAL**
2. **ALUNO(A): EPITÁCIO PEDRO DA SILVA NETO / COMISSÃO EXAMINADORA: DR. JOHN ELTON DE BRITO LEITE CUNHA - PPGECA/UFCG (PRESIDENTE) - ORIENTADOR, DR. ULISSES ALENCAR BEZERRA – PPGECA/UFCG – COORIENTADOR, DR.ª LUCIANNA MARQUES ROCHA FERREIRA - UNIVERSIDADE FEDERAL DO AMAZONAS – EXAMINADORA EXTERNA, DR. BRUCE KELLY NÓBREGA DA SILVA – INSTITUTO NACIONAL DO SEMIÁRIDO - EXAMINADOR EXTERNO (PORTARIA 02/2025). / TITULO DA DISSERTAÇÃO: MODELAGEM DA EVAPOTRANSPIRACAO POR SENSORIAMENTO REMOTO: AVALICAO EM DIFERENTES BIOMAS NO MUNDO. / ÁREA DE CONCENTRAÇÃO: RECURSOS HÍDRICOS E SANEAMENTO AMBIENTAL / HORA DE INICIO: 14:30 HORAS / NA SALA DO OBSERVATÓRIO DA CAATINGA E DESERTIFICAÇÃO, LABORATÓRIO DE HIDRÁULICA 2, BLOCO BU, CAMPUS SEDE DA UFCG, DE FORMA HÍBRIDA.**
3. **EM SESSÃO REALIZADA DE FORMA HÍBRIDA, APÓS EXPOSIÇÃO DE CERCA DE 40 MINUTOS, O(A) CANDIDATO(A) FOI ARGUIDO(A) ORALMENTE PELOS MEMBROS DA COMISSÃO EXAMINADORA, TENDO DEMONSTRADO SUFICIÊNCIA DE CONHECIMENTO E CAPACIDADE DE SISTEMATIZAÇÃO NO TEMA DE SUA DISSERTAÇÃO, SENDO-LHE ATRIBUÍDA O CONCEITO “EM EXIGÊNCIA”, SENDO QUE A POSSIBILIDADE DE APROVAÇÃO ESTÁ CONDICIONADA À AVALIAÇÃO DA NOVA VERSÃO DO TRABALHO FINAL, SEGUINDO PROCEDIMENTOS PREVISTOS NA RESOLUÇÃO DO PROGRAMA. O PRESIDENTE DA COMISSÃO EXAMINADORA, OUVIDOS OS DEMAIS MEMBROS, DEVERÁ FICAR RESPONSÁVEL POR ATESTAR QUE AS CORREÇÕES SOLICITADAS NA LISTA DE EXIGÊNCIAS FORAM ATENDIDAS NA VERSÃO FINAL DO TRABALHO. A COMISSÃO EXAMINADORA CUMPRINDO OS PRAZOS REGIMENTAIS, ESTABELECE UM PRAZO MÁXIMO DE 30 DIAS PARA QUE SEJAM FEITAS AS ALTERAÇÕES EXIGIDAS. APÓS O DEPÓSITO FINAL DO DOCUMENTO DE DISSERTAÇÃO, DEVIDAMENTE REVISADO E MEDIANTE ATESTADO DO ORIENTADOR, O CONCEITO “EM EXIGÊNCIA” PASSARÁ IMEDIATAMENTE PARA O DE “APROVADO”. NA FORMA REGULAMENTAR, FOI LAVRADA A PRESENTE ATA, QUE É ASSINADA POR MIM, ISABELLY CRISTINNY GOMES GAUDENCIO, SECRETÁRIO(A), ALUNO(A) E OS MEMBROS DA COMISSÃO EXAMINADORA PRESENTES.**
4. **CAMPINA GRANDE, 03 DE FEVEREIRO DE 2025.**



Documento assinado eletronicamente por **JOHN ELTON DE BRITO LEITE CUNHA, PROFESSOR(A) DO MAGISTERIO SUPERIOR**, em 06/02/2025, às 15:39, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **ISABELLY CRISTINNY GOMES GAUDENCIO, ASSISTENTE EM ADMINISTRACAO**, em 06/02/2025, às 15:49, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **Ulisses Alencar Bezerra, Usuário Externo**, em 06/02/2025, às 17:01, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **Epitácio Pedro Da Silva Neto, Usuário Externo**, em 06/02/2025, às 19:58, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **LUCIANNA MARQUES ROCHA FERREIRA, Usuário Externo**, em 07/02/2025, às 08:15, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **Bruce Kelly da Nobrega Silva, Usuário Externo**, em 07/02/2025, às 08:31, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



A autenticidade deste documento pode ser conferida no site <https://sei.ufcg.edu.br/autenticidade>, informando o código verificador **5209962** e o código CRC **B657CAD0**.

À minha mãe Rosimeire e ao meu Pai Epitácio que sempre me ensinaram o valor da educação, me apoiaram, e incentivaram ao longo deste caminho. À minha família pelo amparo, e à minha companheira por todo o amor e apoio.

AGRADECIMENTOS

A Deus em primeiro lugar, por sempre ter guiado meus passos durante toda a minha vida e jornada acadêmica, me dando força, saúde e discernimento.

Aos meus pais Rosimeire Oenning e Eptácio Júnior, que representaram minha base e uma fonte de orgulho. Este casal me ensinou desde cedo a importância da educação e do processo de formação de um cidadão. Eles são um exemplo a ser alcançado e seu apoio foi essencial para que eu chegasse onde estou hoje.

À toda minha família por me apoiar, à minha irmã Maria Clara de quem me afastei muito cedo devido aos estudos, mas que sempre foi muito compreensível com minha ausência. E em especial ao apoio de minha tia Cristina e tio Rudiard que me acolheram em sua casa em Campina Grande como se fosse seu filho e permitiram com que a realização do meu Mestrado fosse possível.

À minha amada companheira, Eduarda Arruda, pelo amor, paciência, dedicação, e companheirismo durante todos os dias dessa minha jornada, me inspirando a buscar ser uma pessoa melhor, e a batalhar com mais determinação por nossos objetivos. Agradeço em especial sua paciência por toda minha ausência durante esse período e pelo incentivo para seguir com essa conquista.

Aos colegas de turma de 2023.1, em destaque: Angelo Costa, Sahara Guimarães, Roseana Vasconcelos e Pedro Augusto. Bem como à bolsista de iniciação científica Bruna de França, pelo apoio concedido durante a etapa de coleta de dados desta pesquisa.

Aos integrantes do Observatório da Caatinga e Desertificação. À Rejane, pela solicitude e gentileza com que sempre trata a todos no Laboratório de Hidráulica II da UFCG. E a todos que fazem parte da equipe do Laboratório de Hidráulica II, este local se tornou uma segunda casa durante este período de pós-graduação. Em especial a Carlinda Medeiros, Vinicius Pamplona, Sabrina Vivian e Carlos Galvão pela boa convivência.

Um agradecimento especial à aqueles que além de colegas, se tornaram verdadeiros amigos que pretendo levar para a vida, são eles: Anderson Matheus, Aurea Borges, Diego Souza, Maria Eduarda e Maycon Breno. Vocês tornaram os momentos no bloco BU, e fora dele, mais leves, descontraídos, e de muita aprendizagem, fazendo dessa jornada uma etapa ainda mais preciosa na minha vida.

A todos que compõem a secretaria do Programa de Pós-Graduação em Engenharia Civil e Ambiental (PPGECA) e aos docentes que tanto contribuem para o avanço científico. De forma ainda maior, presto reconhecimento aos meus orientadores Prof. Dr. John Elton e Dr. Ulisses Alencar, que com paciência e sabedoria guiaram os meus passos durante esta desafiadora pesquisa.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), com a concessão da bolsa de pesquisa, sem a qual, se tornaria impossível a dedicação exclusiva aos estudos.

A todos, que de maneira direta ou indireta contribuíram e apoiaram para a realização dessa grande conquista. Me sinto abençoado por ter essa oportunidade, e estar rodeado de pessoas maravilhosas que zelam pelo meu bem, me apoiam e estão presentes fisicamente ou virtualmente nos momentos de dificuldade e comemoração. Muito obrigado a todos !!

RESUMO

A evapotranspiração (ET) desempenha um papel crucial no ciclo da água, influenciando o clima local e os processos vitais no ambiente terrestre, sendo essencial para o balanço hídrico dos ecossistemas, além de representar uma parcela significativa do balanço energético global. É possível estimar a ET em nível regional utilizando modelos de balanço de energia à superfície (SEB) com dados de Sensoriamento Remoto (SR). Porém há muitas incertezas nas estimativas de modelos SEB e diversos produtos globais, que apresentam baixo desempenho quando aplicados em ambientes não agrícolas. A modelagem pode gerar resultados diversos, com variações significativas de acordo com as particularidades climáticas, da vegetação e da disponibilidade de recursos hídricos de cada local. Este estudo visa avaliar o desempenho de parâmetros de modelos SEB para estimativa de ET em diferentes biomas. Para isso, o desempenho dos modelos STEEP, SEBAL e S-SEBI foram avaliados em diferentes usos e cobertura do solo em uma sub bacia do Alto Paraíba sob a variação de umidade, com a inclusão do produto MOD16, em 9 diferentes biomas vegetados do mundo sob a variação de vegetação, umidade, solo e clima. Os modelos foram comparados entre si e com dados locais de ET observados, permitindo a identificação da relevância da complexidade e parâmetros abordados por cada modelo. Os modelos SEB demonstraram semelhança em locais de vegetação homogênea, perenifólia e com disponibilidade hídrica, como pastagens, os modelos SEBAL e S-SEBI assemelham-se ou superaram as estimativas do STEEP, esses modelos devido a sua baixa complexidade de algoritmo carregam menos incertezas. Por outro lado, a aplicação dos modelos SEB em locais de vegetação heterogênea, com variação fenológica e escassez hídrica, revelou que o modelo STEEP apresenta desempenho superior aos demais modelos, conseguindo representar a influência da dinâmica sazonal e não superestimando a ET em períodos de seca devido a incorporação da sazonalidade das variáveis aerodinâmicas e de superfície em seu algoritmo. Além disso, o STEEP obteve bons resultados em 6 dos 9 biomas estudados devido a calibração dos pixels âncora que se mostrou eficiente em diversos cenários com um RMSE 4,98 - 9,65 mm/8d. A aplicação do STEEP foi bem sucedida ao apresentar um avanço nas estimativas da ET em biomas complexos que possuem uma lacuna na precisão por diversos produtos globais. Esses resultados ressaltam a importância de considerar as particularidades das vegetações ao modelar processos hidrológicos, especialmente em regiões com condições climáticas contrastantes. A compreensão dessas diferenças entre os modelos SEB é crucial para aprimorar as estimativas de ET, fornecendo informações mais precisas para a gestão sustentável dos recursos hídricos nessas regiões.

Palavras-chave: Balanço de energia à superfície, Google earth engine, Ciclo hidrológico.

ABSTRACT

Evapotranspiration (ET) plays a crucial role in the water cycle, influencing local climate and detrimental processes in the terrestrial environment, being essential for the water balance of ecosystems, in addition to representing a significant portion of the global energy balance. It is possible to estimate ET at a regional level using surface energy balance (SEB) models with Remote Sensing (RS) data. However, there are many uncertainties in the estimates of SEB models and several global products, which present poor performance when applied to non-agricultural environments. Modeling can generate diverse results, with significant variations according to the particularities of climate, vegetation and availability of water resources of each location. This study aims to evaluate the performance of SEB model parameters for estimating ET in different biomes. For this purpose, the performance of the STEEP, SEBAL and S-SEBI models were evaluated in different land uses and land cover in a sub-basin of the Upper Paraíba under varying humidity, with the inclusion of the MOD16 product, in 9 different vegetated biomes of the world under varying vegetation, humidity, soil and climate. The models were compared with each other and with local TE data collected, allowing the identification of the relevance of the complexity and interactions involved in each model. The SEB models were similar in locations of interesting ecosystems, evergreen and with water availability, such as pastures, the SEBAL and S-SEBI models resembled or surpassed the STEEP estimates, these models, due to their low algorithm complexity, carry less uncertainty. On the other hand, the application of SEB models in locations with heterogeneous vegetation, with phenological variation and water deficiencies, revealed that the STEEP model outperforms the other models, being able to represent the influence of seasonal dynamics and not overestimating ET in dry periods due to the incorporation of the seasonality of aerodynamic and surface variations in its environment. In addition, STEEP obtained good results in 6 of the 9 trained biomes due to the concentration of anchor pixels that proved to be efficient in several scenarios with an RMSE of 4.98 - 9.65 mm/8d. The application of STEEP was successful in presenting an advance in ET estimates in complex biomes that have a gap in accuracy for several global products. These results highlight the importance of considering the particularities of vegetation when modeling hydrological processes, especially in regions with contrasting climatic conditions. Understanding the differences between SEB models is crucial to improve ET estimates, providing more accurate information for the sustainable management of water resources in these regions.

Keywords: Surface energy balance, Google Earth Engine, Hydrological cycle.

LISTA DE FIGURAS

Figura 1. Localização da bacia do Rio Sucuru. a) Situação geográfica da bacia frente ao estado da Paraíba; b) Composição colorida (Bandas: NIR, SWIR 1 e RED) do Satélite Sentinel-2 MSI Harmonizado adquirido via Google Earth Engine e c) Mapa de elevação via dados FABDEM com rede de drenagem principal.....	38
Figura 2. Classificação do uso do solo via Mapbiomas (Coleção 7) para os anos de 2012 (seco) à esquerda e 2020 (chuvoso) à direita.....	40
Figura 3. Localização das torres de fluxo de acordo com a classificação de biomas de Dinerstein et. al. (2017).....	45
Figura 4. Série temporal semanal de precipitação e evapotranspiração dos modelos STEEP, SEBAL e S-SEBI para as coberturas Caatinga e pastagem nos anos seco e chuvoso dos 5 pontos selecionados em pastagem e caatinga.....	49
Figura 5. Perfil de comportamento espacial da evapotranspiração no STEEP, SEBAL e S-SEBI e de NDVI em relação a diferentes usos do solo.....	51
Figura 6. Padrões espaciais da evapotranspiração média anual pelos modelos STEEP, SEBAL e S-SEBI na Bacia do Rio Sucuru nos anos seco e chuvoso.....	53
Figura 7. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações de torres de fluxo localizadas em FUTS na escala temporal de ET acumulada de 8 dias.....	56
Figura 8. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações de torres de fluxo localizadas em PSI na escala temporal de ET acumulada de 8 dias.....	57
Figura 9. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações de torres de fluxo localizadas em FBMM na escala temporal de ET acumulada de 8 dias.....	59
Figura 10. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo localizada em PMM na escala temporal de ET acumulada de 8 dias.....	61
Figura 11. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo localizada em PTS na escala temporal de ET acumulada de 8 dias.....	63

Figura 12. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações das torres de fluxo localizadas em FTC na escala temporal de ET acumulada de 8 dias.....	64
Figura 13. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações das torres de fluxo localizadas em FTLM na escala temporal de ET acumulada de 8 dias.....	66
Figura 14. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações das torres de fluxo localizadas nas PTSM na escala temporal de ET acumulada de 8 dias.....	68
Figura 15. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações das torres de fluxo localizadas nas FSTS na escala temporal de ET acumulada de 8 dias.....	69
Figura 16. Frequência de destaque de cada modelo por bioma.....	71
Figura A1. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo BR-SA1 localizada em FUTS na escala temporal de ET acumulada de 8 dias.....	97
Figura A2. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo CN-Qia localizada em FUTS na escala temporal de ET acumulada de 8 dias.....	98
Figura A3. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo BR-Npw localizada em PSI na escala temporal de ET acumulada de 8 dias.....	99
Figura A4. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo AR-Vir localizada em PSI na escala temporal de ET acumulada de 8 dias.....	100
Figura A5. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo AU-Gin localizada em FBMM na escala temporal de ET acumulada de 8 dias.....	101
Figura A6. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo IT-SRo localizada em FBMM na escala temporal de ET acumulada de 8 dias.....	102

Figura A7. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo BR-IAB localizada em PTS na escala temporal de ET acumulada de 8 dias.....	103
Figura A8. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo ZM-Mon localizada em PTS na escala temporal de ET acumulada de 8 dias.....	104
Figura A9. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo AU-Stp localizada em PTS na escala temporal de ET acumulada de 8 dias.....	105
Figura A10. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo CH-Dav localizada em FTC na escala temporal de ET acumulada de 8 dias.....	106
Figura A11. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo CZ-BK1 localizada em FTC na escala temporal de ET acumulada de 8 dias.....	107
Figura A12. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo BE-Vie localizada em FTLM na escala temporal de ET acumulada de 8 dias.....	108
Figura A13. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo CA-Gro localizada em FTLM na escala temporal de ET acumulada de 8 dias.....	109
Figura A14. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo AU-Whr localizada em PTSM na escala temporal de ET acumulada de 8 dias.....	110
Figura A15. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo AU-Ync localizada em PTSM na escala temporal de ET acumulada de 8 dias.....	111
Figura A16. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo BR-CST localizada em FSTS na escala temporal de ET acumulada de 8 dias.....	112
Figura A17. Diagramas de densidade de dispersão e regressão linear de 4 modelos de	

estimativa de ET em relação às observações da torre de fluxo BR-SNn localizada em
FSTS na escala temporal de ET acumulada de 8 dias..... 113

LISTA DE TABELAS

Tabela 1. Redes de Fluxo.....	27
Tabela 2. Obtenção da Fração Evapotranspirativa nos modelos estudados.....	34
Tabela 3. Metodologia utilizada para a seleção dos candidatos a membros finais.....	34
Tabela 4. Grau de complexidade dos Algoritmos.....	36
Tabela 5. Torres Selecionadas.....	44
Tabela 6. Estatísticas descritivas de evapotranspiração dos modelos STEEP, SEBAL e S-SEBI para as coberturas Caatinga e pastagem nos anos seco e chuvoso.....	49
Tabela 7. Métricas Estatísticas FUTS.....	55
Tabela 8. Métricas Estatísticas PSI.....	56
Tabela 9. Métricas Estatísticas FBMM.....	58
Tabela 10. Métricas Estatísticas PMM.....	60
Tabela 11. Métricas Estatísticas PTS.....	62
Tabela 12. Métricas Estatísticas FTC.....	63
Tabela 13. Métricas Estatísticas FTLM.....	65
Tabela 14. Métricas Estatísticas PTSM.....	67
Tabela 15. Métricas Estatísticas FSTS.....	68
Tabela 16. Melhores modelos por Bioma.....	69
Tabela A1. Métricas Estatísticas BR-SA1.....	96
Tabela A2. Métricas Estatísticas CN-Qia.....	97
Tabela A3. Métricas Estatísticas BR-Npw.....	98
Tabela A4. Métricas Estatísticas AR-Vir.....	99
Tabela A5. Métricas Estatísticas AU-Gin.....	100
Tabela A6. Métricas Estatísticas IT-SRo.....	101
Tabela A7. Métricas Estatísticas BR-IAB.....	102
Tabela A8. Métricas Estatísticas ZM-Mon.....	103

Tabela A9. Métricas Estatísticas AU-Stp.....	104
Tabela A10. Métricas Estatísticas CH-Dav.....	105
Tabela A11. Métricas Estatísticas CZ-BK1.....	106
Tabela A12. Métricas Estatísticas BE-Vie.....	107
Tabela A13. Métricas Estatísticas CA-Gro.....	108
Tabela A14. Métricas Estatísticas AU-Whr.....	109
Tabela A15. Métricas Estatísticas AU-Ync.....	110
Tabela A16. Métricas Estatísticas BR-CST.....	111
Tabela A17. Métricas Estatísticas BR-SNn.....	112

LISTA DE SÍMBOLOS

AOI	<i>Area of interest</i>
BRS	Bacia do Rio Sucuru
CIMEC	<i>Calibration Using Inverse Modeling at Extreme Conditions</i>
d0	Deslocamento plano zero
dT	Gradiente de temperatura
EC	<i>Eddy Covariance</i>
ET	Evapotranspiração
FBMM	Florestas, Bosques e Matagais Mediterrâneos
FE	Fração Evaporativa
FSTS	Florestas secas tropicais e subtropicais de folhas largas
FTC	Florestas Temperadas de Coníferas
FTLM	Florestas Temperadas de Folhas Largas e Mistas
FTSS	Floresta Tropical Sazonalmente Seca
FUTS	Florestas Úmidas Tropicais e Subtropicais de Folhas Largas
G	Fluxos de calor do solo
GEDI	<i>Global Ecosystem Dynamics Investigation</i>
GEE	<i>Google Earth Engine</i>

GLDAS	Global Land Data Assimilation System
H	Fluxo de calor sensível
LAI	<i>Leaf Area Index</i>
MOD16	<i>MODIS Global Terrestrial Evapotranspiration Product</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NSE	<i>Nash–Sutcliffe model efficiency coefficient</i>
PAI	<i>Plant Area Index</i>
PBIAS	<i>Percent Bias</i>
PC	Coeficiente de correlação de Pearson
PMM	Pastagens e Matagais Montanhosos
PSI	Pastagens e Savanas Inundadas
PTS	Pastagens, savanas e matagais Tropicais e Subtropicais
PTSM	Pradarias Temperadas, Savanas e Matagais
rah	Resistência aerodinâmica para transferência de calor
RMSE	Erro quadrático médio
Rn	Radiação disponível na superfície
Rn _{24h}	Saldo de radiação diário
R ²	Coeficiente de determinação

S-SEBI	<i>Simplified Surface Energy Balance Index</i>
SEB	<i>Surface energy balance</i>
SEBAL	<i>Surface Energy Balance Algorithm for Land</i>
SR	Sensoriamento Remoto
SRTM	<i>Shuttle Radar Topography Mission</i>
STEEP	<i>Seasonal tropical ecosystem energy partitioning</i>
Ta	Temperatura média diária do ar
Ts	Temperatura de superfície
z0m	Comprimento de rugosidade do momentum
λ ET	Fluxo de calor latente

SUMÁRIO

1 Introdução.....	18
2. Objetivos.....	21
2.1 Objetivo Geral.....	21
2.2 Objetivos Específicos.....	21
3. Referencial teórico.....	21
3.1 Evapotranspiração por SR.....	21
3.2 Modelos SEB.....	24
3.3 Sistema de Eddy Covariance.....	26
3.4 Base de dados Globais.....	26
3.5 Biomas e Ecorregião da Caatinga.....	28
4. Metodologia.....	32
4.1 Compreensão do comportamento espacial e temporal na ecorregião da Caatinga... 37	
4.1.1 Ecorregião da Caatinga.....	37
4.1.2 Critério para seleção temporal e espacial.....	39
4.1.3 Extração dos dados.....	40
4.2 Verificação do STEEP com EC em diferentes biomas.....	41
4.2.1 Biomas.....	42
4.2.2 Torres de Fluxo baseadas em eddy covariance.....	45
4.2.3 Verificação dos Modelos.....	46
5. Resultados e Discussão.....	47
5.1 Compreensão do comportamento espacial e temporal na ecorregião da Caatinga... 48	
5.2 Verificação do STEEP com eddy covariance em diferentes Biomas.....	54

Florestas úmidas Tropicais e Subtropicais (FUTS).....	54
Pastagens e Savanas Inundadas (PSI).....	56
Florestas, Bosques e Matagais Mediterrâneos (FBMM).....	57
Pastagens e Matagais Montanhosos (PMM).....	59
Pastagens, savanas e matagais Tropicais e Subtropicais (PTS).....	61
Florestas Temperadas de Coníferas (FTC).....	63
Florestas Temperadas de Folhas Largas e Mistas (FTLM).....	64
Pradarias Temperadas, Savanas e Matagais (PTSM).....	66
Florestas secas tropicais e subtropicais de folhas largas (FSTS).....	68
Análise Global.....	69
6. Conclusões.....	73
7. Perspectivas Futuras.....	74
Referências.....	76
APÊNDICE A	96

1 Introdução

A evapotranspiração (ET) é uma das componentes mais importantes no balanço hídrico e de energia, sendo um processo chave nos ciclos de água, carbono e energia. Quantificar a ET é uma das tarefas mais desafiadoras no fechamento desses balanços, pois sofre influência espaço-temporal de diversos fatores ambientais complexos, das propriedades do solo, condições atmosféricas, vegetação e topografia, (Wang et al., 2016; Bhattarai et al., 2017; Santos et al., 2022). Uma das maneiras eficientes de quantificar a ET em meio terrestre com maior grau de confiabilidade é o método de covariância de vórtices turbulentos ou *Eddy Covariance* (EC) que mede diretamente os fluxos de vento e umidade através de dados coletados por torres micrometeorológicas. Porém esse método está limitado a uma área inferior a 10 km² próximo ao local de coleta (Chu et al., 2021).

Essas medições *in situ* são limitadas espacialmente em gerar estimativas, tanto em termos de custo como de precisão (Allen et al., 2011; Anapalli et al., 2016). Isso ocorre devido a dispersão dos locais de coleta de dados, juntamente com a representatividade espacial limitada, a descontinuidade e baixa amplitude temporal dos registros observados (Sullivan et al., 2019; Chu et al., 2021), tornam a análise disponível apenas nos locais de coleta de dados e impede a possibilidade de capturar e atribuir as variações espaciais e temporais da ET (Tang et al., 2024). O Sensoriamento remoto (SR) por satélite é capaz de fornecer informações que possibilitam estimar a ET em resoluções temporais e espaciais adequadas para análise (Bastiaanssen et al., 1998; Zhang, 2016). Por apresentarem essa capacidade, os modelos de SR vem aumentando sua relevância com o maior desenvolvimento e aplicação na ET nos últimos anos (Chen e Liu, 2020).

As séries temporais de ET são uma importante contribuição para estudos regionais e de larga escala sobre balanços hídricos e energéticos, em especial em áreas com escassez de dados (Cunha et al., 2020a; Jaafar e Ahmad, 2020; Laipelt et al., 2021; Saboori et al., 2022). Para isso, a validação da ET através de dados terrestres é essencial para garantir a precisão e ampliar a aplicação do SR (Jia et al. 2012). Diversos estudos atuais verificam, em diversos biomas, como diferentes produtos que estimam a ET validados com dados observados por EC (Hu et al., 2021; Salazar-Martínez et al., 2022; Zhu et al., 2022; Tang et al., 2024). Há base de dados em todo o mundo com informações climáticas, por exemplo, a Fluxnet é uma rede de armazenamento global de dados e medições de fluxo meteorológicos como a troca de CO₂, energia entre a biosfera e atmosfera e ET (Baldocchi et al., 2001; Boden et al., 2013). Os dados de ET medidos por

estas torres instaladas estão disponíveis em diversos ambientes para possíveis validações de modelos de SR (Velpuri, 2013).

Há diversas abordagens para a estimativa de ET por SR, dentre elas a abordagem de modelos de balanço de energia à superfície (SEB) se destacam em capturar a variabilidade espacial e temporal da ET, em áreas extensas e heterogêneas (Tang e Li, 2014; Fisher et al., 2017; Trebs et al., 2021). Os modelos SEB obtêm a ET subtraindo os fluxos de calor do solo (G) e de calor sensível (H) da radiação disponível na superfície (R_n) e podem ser estimadas através de SR (Shuttleworth, 2012). Tanto as técnicas de medição direta quanto às técnicas de modelagem têm sido amplamente utilizadas para obter informações sobre a ET (Allen et al., 2011; Peroni Venancio et al., 2019; Tang et al., 2024). Há um alto número de estudos que aplicaram os modelos SEB em diferentes regiões do mundo (Mohan et al., 2020), aqueles com maior frequência de avaliação são: o *Surface Energy Balance Algorithms for Land* (SEBAL) (Bastiaanssen et al., 1998), *Simplified Surface Energy Balance Index* (S-SEBI) (Roerink et al., 2000); *Surface Energy Balance System* (SEBS) (Su, 2002), *Mapping EvapoTranspiration at high Resolution with Internal Calibration* (METRIC; Allen et al., 2007), *Operational Simplified Surface Energy Balance* (SSEBop) (Senay et al., 2013).

Por outro lado muitos desses modelos, em geral, podem não responder adequadamente quando aplicados a ambientes não agrícolas, como florestas, desertos e sistemas ripários, em virtude de que grande parte dos mesmos foram avaliados e/ou parametrizados em ecossistemas e climas da América do Norte, Europa, Austrália e Leste Asiático desconsiderando em seu algoritmo a natureza heterogênea da vegetação, terreno, solos e disponibilidade de água que tornam a energia à superfície e os processos aerodinâmicos altamente variáveis e mal definidos (Allen et al., 2011; Gokmen et al., 2012; Barraza et al., 2017; Chen e Liu, 2020; Costa-Filho et al., 2021).

A Caatinga, que é a maior Floresta Tropical Sazonalmente Seca (FTSS) das Américas é uma ecorregião que apresenta essas dificuldades (Moro et al., 2015; Paloschi et al., 2020; Bezerra et al., 2023) por apresentar uma grande variação espacial e temporal na densidade, forma e ramificação da vegetação e disponibilidade hídrica presente no solo. Isso não se aplica somente à Caatinga, mas em diversas ecorregiões do mundo, pois o tipo de vegetação e umidade do local são fatores limitantes da precisão de estimativa de ET. Observa-se que áreas de pastagem, agrícolas e regiões de clima úmido e subúmido têm estimativas mais precisas da ET por diferentes produtos globais. Enquanto em áreas de florestas, matagais e savanas, e de clima árido e semiárido,

demonstram ter uma maior lacuna na precisão da estimativa da ET (Tang et al., 2024), com uma tendência de superestimação em locais com limitação de água (Gokmen et al., 2012; Paul et al., 2014; Trebs et al., 2021).

Bezerra et al. (2023) desenvolveram o *Seasonal Tropical Ecosystem Energy Partitioning* (STEEP), um modelo SEB que utiliza dados de SR voltado para estimar a ET em FTSS. O STEEP foi avaliado através de testes robustos e da observação pontual em 4 torres de fluxo na Caatinga, com mais de 1000 observações. Os resultados apresentaram boa concordância com os dados observados quando comparados a outros produtos como o SEBAL, MOD16 e PMLv2 (Bezerra et al., 2023). Contudo, sua avaliação não contemplou o comportamento espacial e temporal do modelo em diferentes coberturas de solo e condições climáticas.

O STEEP foi proposto para incorporar características específicas dessas florestas, como fases fenológicas contrastantes e disponibilidade de água no solo, através do *Plant Area Index* (PAI) e da umidade do solo por SR, respectivamente. O algoritmo STEEP calcula da resistência aerodinâmica para transferência de calor (r_{ah}) e o gradiente de temperatura (dT) mais assertiva para a representação das FTSS, acredita-se que este modelo pode representar melhor os padrões espaciais e temporais da ET na Caatinga e ecossistemas sazonais secos, frente a outros modelos SEB. Além disso, outras ecorregiões e biomas no mundo podem se beneficiar dos fatores e abordagens implementados pelo STEEP, podendo apresentar um melhor desempenho em áreas de vegetação heterogênea e de limitação hídrica que outros modelos SEB.

O STEEP tem uma alta complexidade em seu algoritmo, incorporando fatores que consideram características sazonais de vegetação e disponibilidade de água, que normalmente não são considerados em outros modelos SEB. Portanto a compreensão do comportamento da estimativa de ET gerada por esse modelo em diferentes cenários, desde diferentes uso e cobertura do solo a até diferentes biomas do mundo, pode ser um avanço para uma melhor quantificação e compreensão da ET. Isso é valioso não apenas para pesquisas e estudos de avaliação dos recursos hídricos, mudanças climáticas, como também tem uma aplicação valiosa na previsão e monitoramento das secas, gerenciamento de demanda hídrica de plantações e melhor gestão dos recursos hídricos (Silans e Silva, 2007; Silans et al., 2008; Zhao et al., 2013; Silva, 2020; e Costa et al., 2021).

2. Objetivos

2.1 Objetivo Geral

Avaliar o desempenho dos modelos STEEP, SEBAL e S-SEBI para estimativa da evapotranspiração na ecorregião da Caatinga e em nove biomas globais.

2.2 Objetivos Específicos

- Analisar o comportamento espacial e temporal dos modelos SEB em diferentes coberturas do solo na ecorregião da Caatinga.¹
- Avaliar o desempenho dos modelos SEB em diversos biomas no mundo.

3. Referencial teórico

3.1 Evapotranspiração por SR

O termo evapotranspiração diz respeito a todos os processos nos quais a água líquida é transformada em vapor de água na superfície terrestre, combinando a perda de água por evaporação com a transpiração das plantas durante a fotossíntese (Scherer-Warren, 2012; Zhang, 2016). Destaca-se a importância da ET por abastecer hidricamente a atmosfera de água, que posteriormente contribui para chuvas em nível continental (Silveira e Stone, 1994; Ongaratto e Bortolin, 2021). A ET tem três componentes que estão diretamente relacionados com o ambiente em que está inserido. A Transpiração é um processo biológico diretamente ligado com a produtividade ecossistêmica do bioma, enquanto a Interceptação e Evaporação do solo são processos físicos (Gu et al., 2018), todos influenciados pelas características vegetativas, geológicas e climáticas que variam em cada ecossistema.

A ET é influenciada por diversos fatores que podem ser medidos por SR com sensores a bordo de satélites ou aerotransportados. O SR permitiu o desenvolvimento de diversos modelos de ET, sendo hoje considerado, financeiramente e operacionalmente, o meio mais viável para se estimar a ET em escala local e regional (Gowda et al., 2008; Mu

¹ Objetivo cumprido através do seguinte artigo escrito para compor essa dissertação: Neto, E. P. S., Bezerra, U. A., Oliveira, S. H., Cunha, J. (2024). Análise de Modelos de Evapotranspiração por Sensoriamento Remoto na Caatinga: Uma Compreensão de Variações Temporais e Espaciais. *Revista Brasileira De Geografia Física*, 17(5), 3663–3681. <https://doi.org/10.26848/rbgf.v17.5.p3663-3681>

et al., 2011; Chen e Liu, 2020; Zhu et al., 2022). Com isso diversos modelos, com diferentes abordagens, metodologias e necessidade de dados, foram desenvolvidos para a estimativa de ET, e eventualmente aplicados e validados em diferentes locais com variações de coberturas do solo, vegetação e condições climáticas. A estimativa da ET por SR começou a ser desenvolvida aproximadamente na década de 1980 e evoluiu para uma variedade de abordagens (Zhang et al., 2016). Quando as imagens de média resolução espacial são utilizadas, três abordagens são mais comuns: métodos de balanço de energia de superfície – *Surface Energy Balance* - SEB (Allen et al., 2007; Su, 2002; Roerink et al., 2000; Bastiaanssen et al., 1998; Norman et al., 1995; Kustas, 1990), métodos empíricos (Hunsaker et al., 2005; Er-Raki et al., 2010) e método da temperatura da superfície - índice de vegetação (*Land Surface Temperature – LST/ Vegetation Index - VI*) (Yang et al., 1997; 1996).

Um algoritmo muito usado para estimar a ET em escalas continentais e globais é o MOD16 (MODIS Global Terrestrial Evapotranspiration Product). O modelo foi desenvolvido por Mu et al. (2007 e 2011) com base na equação de *Penman-Monteith* para monitorar a variabilidade espacial e temporal da ET em áreas de superfície terrestre. O algoritmo combina entradas de dados de reanálise meteorológica diária *Modern-Era Retrospective Analysis for Research and Applications* (MERRA) com dados de sensoriamento remoto MODIS de 8 e 16 dias para representação de vegetação. A maioria dos dados observados *in-situ* usados para a validação e calibração do modelo foram obtidos da América do Norte (AmeriFlux e FluxNet) entre o ano 2000 e 2010 (Mu et al., 2011).

A validação de estimativa de ET do MOD16, foi frequentemente realizada utilizando dados observados de torres de fluxo obtidas por EC (Fang et al., 2016), em diversos uso e cobertura do solo e condições climáticas ao redor do mundo. Boas correlações foram obtidas para florestas em regiões áridas e polares na Ásia (Kim et al., 2012), para pastagens no Reino Unido (Srivastava et al., 2016) e para terras agrícolas e pastagens da Europa (Hu et al., 2015), tendo uma boa indicação geral para áreas onde a cobertura vegetal é alta (Biggs et al., 2015). Porém foi observado uma correlação baixa para áreas de florestas (Hu et al., 2015; Jang et al., 2013; Tang et al., 2015), savanas florestais (Ramoelo et al., 2014; Hu et al., 2015) e regiões áridas e semi áridas dos Estados Unidos (Velpuri et al., 2013). O modelo também mostrou uma irregularidade nos resultados de áreas agrícolas irrigadas podendo ter correlação razoável (Hu et al., 2015), ou variações

entre subestimação e superestimação em diferentes áreas (Kim et. al., 2012; Tang et al., 2015; Aguilar et. al., 2018).

O MOD16 apresenta bons resultados em áreas de clima temperado sem estação seca, porém apresenta baixa concordância com dados observados em áreas áridas e semi-áridas (Hu et al., 2015). Em florestas com copas densas e com o *Leaf area index* (LAI) elevado, o modelo tende a superestimar as estimativas de ET (Hu et al., 2015).

O desafio para a melhor estimativa de ET engloba o entendimento dos padrões de comportamento espacial e temporal dessa variável e como diferentes métodos respondem a ele. Diversos estudos verificaram diferentes produtos de ET sob a validação de dados *in situ*. Como o estudo de Salazar-Martínez et al. (2022) que verificou produtos de SR em ambientes florestados e não florestados de diferentes faixas latitudinais. O resultado entre os produtos variou consideravelmente de acordo com as áreas estudadas e as categorias de vegetação. Em regiões não florestadas, não foi observado diferença na validação entre os modelos em distintas áreas de análise. Porém essa diferença foi notada para regiões florestadas, apresentando uma menor concordância principalmente em florestas sazonalmente secas do que em florestas de regiões úmidas.

Hu et al. (2021) comparou modelos de diferentes abordagens como os de base física, de *data-driven* e modelos híbridos a fim de explorar ao máximo a precisão dos modelos e quais fatores mais influenciam a precisão desses modelos. Notou-se modelos *data-driven* dependem, principalmente, das variações do algoritmo de machine-learning e de técnicas de otimização, enquanto modelos de base física dependem principalmente do método de balanço de energia e do comprimento da rugosidade da superfície. Zhu et al. (2022) fez a validação de acurácia e incerteza de cinco produtos de ET por SR, e com base nos modelos de melhor validação local, concluiu que restrições físicas importantes, como precipitação, umidade do solo e estrutura da vegetação devem ser incorporadas em modelos de SR para seu máximo desempenho. Tang et al. (2024) analisou 25 produtos globais de ET com diversas fontes de dados, sendo eles produtos de reanálise, de SR, produtos híbridos, produtos de balanço hídrico e de machine learning. De acordo com essa análise os modelos de SR se destacaram por obter uma alta concordância com os dados medidos *in-loco* por torres de fluxo.

3.2 Modelos SEB

A aplicação do sensoriamento remoto está diretamente relacionada com a radiação solar disponível na superfície terrestre (R_n), radiação a qual é particionada em fluxo de calor sensível (H), fluxo de calor latente (λET) e fluxo de calor no solo (G). Elementos da superfície como plantas, solo e corpos hídricos podem absorver a radiação solar e reemitir como λET , que está associado com a perda de água para atmosfera através da ET (Zhang, 2016).

Os métodos de balanço de energia à superfície (SEB) para estimativa da ET envolvem as relações entre os fluxos de energia G , H e λET (Shuttleworth, 2012), onde a ET é obtida através do λET , encontrado como um resíduo do balanço de energia, dependendo diretamente das estimativas de G , H e R_n (Allen et al., 2011; Ferreira et al., 2020). Entre as variáveis do balanço de energia, o H pode carregar muitas incertezas, pois depende de variáveis como r_{ah} e dT , que podem reduzir o desempenho dos modelos SEB se mal estimadas (Gokmen et al., 2012; Costa-Filho et al., 2021; Liu et al., 2021). Consequentemente as incertezas de H podem prejudicar a estimativa de λET e ET (Gokmen et al., 2012; Paul et al., 2014; Costa-Filho et al., 2021; Bezerra et al., 2023).

O desafio para a implementação operacional utilizando os métodos de SEB para estimativas da evapotranspiração em escala regional é a necessidade de extensos registros de dados meteorológicos (Kite e Droogers, 2000). Para contornar esses problemas, os métodos SEB de uma camada (*one-source layer*) e LST-VI foram propostos, exigindo apenas uma pequena quantidade de dados oriundos de estações meteorológicas. O Surface Energy Balance Algorithm for Land - SEBAL (Bastiaanssen et al, 1998) e o Mapping EvapoTranspiration at high Resolution with Internalized Calibration - METRIC (Allen et al, 2011; 2007) são dois exemplos de modelos SEB de uma camada amplamente utilizados. Eles foram aplicados com sucesso em áreas agrícolas (Jiménez-Bello et al., 2015; Paço et al., 2014; Allen et al., 2007) e em florestas (Teixeira et al., 2009).

Algumas limitações apresentadas pelos modelos SEB são especialmente desafiadoras quando aplicadas em certos ambientes, sob certas condições climáticas e de vegetação. Há desafios significativos na aplicação dos modelos SEB em locais de limitação hídrica, onde o H tende a ser subestimado e o λET superestimado devido às discrepâncias nos índices de r_{ah} sob essas condições (Trebs et al., 2021). A disponibilidade hídrica é o principal fator de regulação sobre as transições fenológicas da

vegetação (Campos et al., 2019; Paloschi et al., 2020) as quais podem apresentar mecanismos adaptativos para lidar com a seca, implicando em possíveis variações em padrões de cobertura do solo e respostas espectrais ao longo do tempo e do espaço (Paloschi et al., 2020; Andrade et al., 2021). Portanto a variação fenológica dificulta a aplicação dos modelos SEB nesses ambientes (Silva et al., 2019).

Durante muitos anos, a dependência de uma análise visual interativa tem sido um obstáculo severo para o uso dos modelos SEBAL ou METRIC para a construção de longas séries temporais, em grandes áreas (Biggs et al., 2016; Allen et al., 2013). Esses algoritmos requerem um procedimento de calibração/identificação, conhecido como calibração usando modelagem inversa em condições extremas (Calibration Using Inverse Modeling at Extreme Conditions - CIMEC). De acordo com essa metodologia, superfícies de solo seco e irrigado representam os extremos seco (pixel quente), onde o fluxo de calor latente (λET) é assumido como zero, e o extremo úmido (pixel frio), onde H é assumido como zero pelo que λET é igual à diferença entre a radiação líquida (R_n) e fluxo de calor no solo (G), ou seja, $\lambda ET = R_n - G$. Também chamados de pixels de membros finais ou pixels âncoras. A escolha dos pixels de membros finais foi originalmente conduzida de forma manual, ou seja, procuravam-se os pixels quente e frio observando em cada imagem regiões com as características recomendadas. Por ser um processo minucioso deve ser feito por operadores/usuários treinados, pois o resultado é sensível aos pixels selecionados. De acordo com Long et al. (2011), a seleção dos pixels âncoras é um dos critérios que mostra a maior influência sobre a estimativa de ET.

Destacam-se avanços na construção de procedimentos para seleção automática dos pixels âncoras (Allen et al., 2013, Biggs et al., 2016; Feng, 2015; Long et al., 2011), com desempenho semelhante ao alcançado pela calibração/identificação manual (Morton et al., 2013). Esses procedimentos usam, em geral, valores limiares ou quantis de LST e VI para determinar os pixels quentes e frios. Ressalta-se que as avaliações dos procedimentos automáticos para obtenção da evapotranspiração têm sido realizadas a partir de procedimentos tradicionais (visuais) ou a informações provenientes de outros sensores orbitais. Além da automação do processo de estimar ET por métodos de sensoriamento remoto, também foi feito progresso na identificação de fontes de incerteza nestes métodos (Liou & Kar, 2014), na fusão de diferentes métodos de sensoriamento remoto (Zhang et al. 2016) e no uso de multifonte de dados de sensoriamento remoto (Laing et al., 2017; Cammaleri et al., 2012).

3.3 Sistema de Eddy Covariance

Na busca por um método com boa precisão e aceitabilidade para quantificar a ET, tanto em sistemas de cultivo quanto em florestas, diversos métodos de diferentes complexidades são abordados na literatura. Entre eles o balanço hídrico superficial, balanço de energia residual, lisímetros de campo, medições do fluxo de seiva, razão de Bowen e o sistema de EC (Wilson et al., 2001; Anapalli et al., 2018). Entre esses métodos, o sistema de EC se destaca como um modelo de fácil instalação e operacionalização para uma coleta precisa de dados de ET *in situ* (Baldocchi, 2003; Shurpali et al., 2013; Tallec et al., 2013; Uddin et al., 2013; Anapalli et al., 2018). A técnica de EC possibilita a medição direta, em alta frequência, de diversos gases, do fluxo de vapor de água e da troca de energia entre a superfície e a atmosfera, fornecendo dados em escala de ecossistema com resolução temporal geralmente a cada 30 minutos (Aubinet et al., 2012; Anapalli et al., 2018; Papale, 2020).

Desde as primeiras medições de EC (Black et al., 1996; Valentini et al., 1996) o uso deste método vem se tornando mais comum para diferentes fins, devido a variedade e relevância dos dados de sua medição. Os estudos de Reichstein et al. (2007), Mahecha et al. (2010) e Besnard et al. (2018) exibem o uso da técnica para o estudo de ecossistemas individuais com um ponto de vista fisiológico e ecológico.

E não somente isso, mas o uso de EC vem sendo usado principalmente como dados observados para validação e desenvolvimento de modelos de SR aplicados à superfície terrestre (Friend et al., 2007; Williams et al., 2009; Bonan et al., 2011; Balzarolo et al., 2014; Jung et al., 2020). Como o estudo de Campos et al. (2019) que analisou o comportamento anual e sazonal da partição e fechamento do balanço energético na ecorregião da Caatinga, e o estudo de Bezerra et al. (2023) que validou o STEEP e o SEBAL nesta ecorregião.

3.4 Base de dados Globais

A ampla gama de aplicações para os dados de EC e o crescimento no interesse por essas medições resultaram em um grande número de torres de fluxos implantadas em todo o mundo nas últimas décadas, abrangendo vários tipos de cobertura de solo e ecorregiões, para obter observações contínuas e regulares com variação entre 30 min ou 1h entre as medições (Oliveira e Santos, 2023). Assim, cria-se redes regionais, que

eventualmente foram estabelecidas em diversos continentes (e.g., Dolman et al., 2006; Yu et al., 2006; Beringer et al., 2016; Novick et al., 2018).

Essas iniciativas culminaram na organização Fluxnet, uma base de dados global, que integra dados provenientes de diversas redes regionais, que contribuem com uma extensa disponibilidade de dados tanto em termos de cobertura geográfica quanto de séries temporais (Papale, 2020). As redes mais abrangentes da literatura incluem as citadas na Tabela 1, mas não estão limitadas às mesmas. As observações das redes de fluxo permitem avaliar vários modelos e produtos de ET por fornecerem recursos únicos para esse propósito (Yee et al., 2015; Jiang e Ryu, 2016; Bodesheim et al., 2018; Jung et al., 2019; Zhang et al., 2019).

Tabela 1. Redes de Fluxo.

Redes de torres	Locais Ativos	Continuidade dos dados	Acesso dos Dados	Referência
Fluxnet	1000 +	1 a 22 anos desde 1991	https://fluxnet.org/	Pastorello et al., 2020
AmeriFlux	444	1 a 32 anos desde 1991	https://ameriflux.lbl.gov/	Novick et al., 2018
European Fluxes Database Cluster	95	1 a 26 anos desde 1996	http://www.europe-fluxdata.eu/	Tang et al., 2024
OzFlux	34	3 a 22 anos desde 2001	https://data.ozflux.org.au/portal/	Beringer et al., 2016
Heihe Watershed Allied Telemetry Experimental Research (HiWATER)	23	desde 2012	https://data.tpdc.ac.cn/	Li et al., 2017
Cold and Arid Research Network da Universidade de Lanzhou (CARN)	9	desde 2018	https://data.tpdc.ac.cn/	Liu et al., 2018

Há diversos relatos na literatura de conjuntos de modelos de ET que foram validados e comparados com as estimativas por EC de diversas torres de fluxo disponíveis mundialmente, pois elas oferecem boas oportunidades para quantificar a ET e

explorar os padrões de variabilidade espacial e temporal. Essas comparações foram feitas sobre a métrica do erro quadrático médio (ou *root mean-square error* RMSE) (Tang et al., 2024), que é utilizado para medir as diferenças entre valores estimados e valores reais (Wang e Lu, 2018). Como no estudo de Salazar-Martínez et al. (2022) validou os modelos GLEAM (Miralles et al., 2011; Martens et al., 2017) e MOD16 (Mu et al., 2011) com 40 torres de fluxo usando MexFlux, Fluxnet, AsiaFlux e OzFlux durante o período de 2002–2019 em escalas temporais de ET a cada 8 dias obtendo um RMSE de 6,4–11,2 mm/8d para o GLEAM, e de 7,2–13,6 mm/8d para o MOD16.

3.5 Biomas e Ecorregião da Caatinga

A classificação de Biomas utilizada é referente ao estudo de Dinerstein et al. (2017) sendo uma revisão da classificação de ecorregiões e biomas terrestres mundiais de Olson et al. (2001), que modela os impactos ecológicos das mudanças climáticas. A classificação de Biomas permite a identificação de áreas com características em comum, como a fitofisionomia, clima, e muitas vezes o solo (Coutinho, 2006), características essas que são relevantes para a ET local, e para o desempenho de alguns modelos.

Floresta úmidas tropicais e subtropicais de folhas largas

As Florestas Úmidas Tropicais e Subtropicais de Folhas Largas (FUTS) são encontradas próximas do equador, espalhadas em mais de 30 países diferentes, na América Central e do Sul, África e sudoeste Asiático (Dinerstein et al., 2017). Elas se concentram na faixa de alta pressão entre os trópicos de Câncer e Capricórnio (Holdridge e Tosi, 1967; Whitmore, 1998; Sala, 2001; Dinerstein et al., 2017). As FUTS são caracterizadas por serem florestas densas com copas fechadas formadas por árvores perenifólias altas que frequentemente atingem 30 a 50 metros de altura (Whitmore, 1998). Essas áreas possuem alta precipitação (1700-3000 mm/ano) e umidade durante o ano todo, e com altas temperaturas médias anuais em torno de 20 a 28° C, podendo variar consideravelmente devido às variações da altura do dossel (Walsh, 1966; Whitmore, 1998; Peel et al., 2007). As chuvas intensas são frequentes contribuindo em grande parte para a precipitação anual total, com mais de 40% das tempestades tendo intensidade superior a 25 mm/h (Whitmore, 1998).

Pastagens e Savanas Inundadas

As Pastagens e Savanas Inundadas (PSI) são caracterizadas pelo seu fenômeno de alagamento tipicamente encontrada em regiões tropicais e subtropicais, como o

pantanal na América do Sul, Delta do Okavango na África e Everglades na América do Norte (Dinerstein et. al., 2017). A sazonalidade das inundações é a maior força controladora da biota dos rios da PSI, que consiste em picos de inundações e secas com amplitudes e períodos diferentes (Resende, 2008). O clima varia, mas essas regiões costumam apresentar temperaturas quentes com a precipitação anual concentrada em um período específico. A adaptação da flora está diretamente atrelada em lidar com os extremos de disponibilidade de água. As plantas das PSI se mostram resilientes e adaptadas às enchentes e as secas (Braddock e Hennessey, 2018)

Florestas, Bosques e Matagais Mediterrâneos

As Florestas, Bosques e Matagais Mediterrâneos (FBMM) são encontradas em regiões específicas ao redor do mundo, como na Bacia do Mediterrâneo em partes do Chile e no sudoeste da Austrália (Bolle, 2003; Dinerstein et. al., 2017). São áreas que compartilham de ecossistemas paralelos e um clima similar definido por verões quentes e secos e invernos úmidos e chuvosos (Henderson-Sellers e Robinson, 1991; Osborne et al., 2000; Bolle, 2003). Os incêndios característicos das FBMM ocorrem durante os meses de verão, de alta temperatura e taxas de ET, que leva a mudanças na estrutura e composição vegetal, redução de infiltração, aumento no escoamento e consequentemente lixiviação do solo (Pérez-Cabello et al., 2009). A variedade da vegetação que compõe as FBMM varia em fenologia, fisiologia e função, contribuindo de formas diferentes para as trocas turbulentas e o balanço de transferência radiativa, impactando o microclima e a hidrologia local (Baldochi et al., 2004; Carpintero et al., 2021).

A vegetação das FBMM é bem adaptada para sobreviver à seca do verão, quando a maioria das espécies das árvores toleram alta radiação e são perenifólias pois a estrutura e fisiologia das folhas grossas e cerosas minimizam a perda de água e ajudam a resistir ao fogo (Baldochi e Xu, 2007; Jofree et al., 2007; Carpintero et al., 2021). Porém mudanças na estrutura e composição vegetal podem ocorrer devido a possíveis incêndios (Pérez-Cabello et al., 2009). O sistema de raízes profundas, capazes de alcançar leitos rochosos intemperizados, fazem com que as reservas de armazenamento de água disponível para as plantas no regolito profundo exceda as reservas de umidade no solo superficial (Specht, 1988; Graham et al., 2010; Schwinning, 2010; Archibold, 2012)

Pastagens e Matagais Montanhosos

As Pastagens e Matagais Montanhosos (PMM) estão localizados em áreas da grande altitude, tipicamente superior a 1000 metros acima do nível do mar, em regiões

como os Andes, os Himalaias, e os alpes australianos, marcados pelas baixas temperaturas e um alto grau de radiação solar devido à altitude (Korner, 2003; Dinerstein et. al., 2017). Em PMM a água é um fator limitante pois a declividade do terreno causa um escoamento rápido da água e os solos são finos e rochosos, que dificulta o armazenamento e contribui para uma vegetação esparsa (Korner, 2003). A vegetação das PMM consiste em gramíneas, arbustos e pequenas plantas herbáceas que são adaptadas e resistentes às condições extremas em grande altitude, com folhas pequenas e cerosas e sistemas de raízes profundas para minimizar a perda de água e suportar ventos fortes (Miehe e Miehe, 2000; Korner, 2003)

Pastagens, savanas e matagais tropicais e subtropicais

As Pastagens, savanas e matagais Tropicais e Subtropicais (PTS) encontradas na América do Sul, África e Austrália, tem seus limites determinados por padrões de precipitação, altitude e latitude, com temperaturas medianas a elevadas o ano todo, e períodos secos e chuvosos bem definidos (Dinerstein et. al., 2017; Beck et. al., 2023). As vegetações dessas regiões são caracterizadas pela pouca quantidade ou falta de árvores, dominadas principalmente por matagais, e pastagens moldadas por processos ecológicos como as gramíneas (Dixon et al., 2014). A classificação de espécies de pastagens é baseada em vias fotossintéticas que divide as plantas em C3 e C4 de acordo com sua anatomia foliar (Sala, 2001). As gramíneas C4 tendem a ser distribuídas em baixas elevações e latitudes, crescendo exclusivamente em áreas abertas (Paruelo et al., 1998 ;Sala, 2001 ;Dixon et al., 2014). Essas gramíneas tem alta capacidade de fotossíntese e assimilação de carbono sob altas temperaturas e baixa umidade, sendo favorecidas nas PTS em áreas de verão úmido (Stromberg, 2011).

Florestas temperadas de coníferas

As Florestas Temperadas de Coníferas (FTC) apresentam invernos com temperaturas baixas e verões amenos, em locais com precipitações moderadas a intensas, muitas vezes na forma de neve em latitudes maiores (Richardson, 2000; Beck et. al., 2023). Devido a lenta decomposição da serrapilheira e ação de lixiviação da chuva, os solos são tipicamente ácidos e pobres em nutrientes (Richardson, 2000). O conjunto de vegetação de baixa estatura localizado abaixo do dossel florestal varia de forma significativa de acordo com o clima e umidade, variando desde arbustos densos e musgos em áreas úmidas a plantas herbáceas e gramíneas em áreas secas (Richardson, 2000). As FTC são resilientes a uma série de perturbações como cargas de neve, seca e

incêndios, isso possibilita que as árvores coníferas estejam presentes tanto em ambientes de alto estresse, como regiões montanhosas frias como em áreas propensas a incêndios (Agee, 1993).

Florestas Temperadas de Folha Larga e Mistas

As Florestas Temperadas de Folhas Largas e Mistas (FTLM) são encontradas em regiões temperadas da América do Norte, Europa e partes da Ásia, onde a temperatura nos meses mais frios são abaixo de 0 °C e em torno de 10 °C nos meses quentes (Dansereau, 1957; Ciesla, 2011). A maioria das espécies vegetais das FTLM são decíduas, caracterizadas pela queda das folhas no outono e inverno que é uma adaptação à limitação de água líquida que é restrita ou inacessível às plantas devido ao congelamento (Ciesla, 2011). Nas FTLM a precipitação costuma ocorrer de forma uniforme durante o ano, podendo variar de 550 a 1500 mm/ano (Andorfer et al., 2010; Ciesla, 2011; Knudsen et al., 2017).

Pradarias temperadas, savanas e matagais

As Pradarias Temperadas, Savanas e Matagais (PTSM) são encontradas nas pradarias Norte-Americanas, estepes da Eurásia e pampas na América do Sul (Dinerstein et. al., 2017; Beck et. al., 2023). Ocorrem em áreas onde há precipitação durante a estação fria, porque esse padrão sazonal favorece a penetração de água em camadas profundas do solo com os arbustos e gramíneas característicos do bioma (Sala, 2001). A precipitação anual varia entre 150 a 1200 mm/ano e temperaturas médias anuais variando entre 0 e 25°C (Sala, 2001; Lieth e Whittaker, 2012). As PTSM são caracterizadas pela sua limitação hídrica, que ocorre pelo menos uma vez durante o ano (Sala, 2001). As gramíneas que apresentam via fotossintética C3 tendem a ser distribuídas em áreas de elevadas altitudes e latitudes, em climas mais amenos e são mais resistentes às secas da PTSM (Paruelo et al., 1998 ;Sala, 2001; Stromberg, 2011).

Florestas secas tropicais e subtropicais de folhas largas

As Florestas secas tropicais e subtropicais de folhas largas (FSTS) são um tipo de floresta caracterizada por uma estação seca duradoura, com vegetação decídua, e uma variedade de vida selvagem (Hasnat e Hossain, 2020). Geralmente encontrada em locais com estações úmidas e secas bem definidas, na Ásia, África e América do Sul, na faixa latitudinal entre 10° e 20° em ambos hemisférios (Gentry, 1995; Dinerstein et. al., 2017). Nas FSTS as temperaturas são elevadas o ano todo, durante a estação úmida as chuvas

intensas causam a lixiviação no solo, isso em conjunto com a escassez hídrica durante a estação seca cria um ambiente hostil para a flora local (Murphy e Lugo, 1986).

Ecorregião da Caatinga

A Caatinga é classificada como uma das ecorregiões pertencentes às FSTS em uma perspectiva global com a classificação de Dinerstein et. al. (2017). A vegetação da caatinga possui características condizentes às das FSTS, com destaque para sua alta resiliência à escassez hídrica, com mecanismos de conservação, tanto físicos quanto bioquímicos, que preservam a vegetação por longos períodos de estiagem (Ribeiro, 2014; Sousa, 2023). A importância dessa ecorregião em específico para este estudo se deve ao fato de que, originalmente, o algoritmo de maior complexidade entre os selecionados, o STEEP, foi desenvolvido para atender as especificações da caatinga.

4. Metodologia²

A aplicação de modelos SEB em diferentes usos e coberturas do solo na ecorregião da Caatinga e em diversos biomas ao redor do mundo, utilizando modelos com variados níveis de complexidade física e componentes, desde os mais simples até os mais robustos, é essencial para compreender as potencialidades e limitações de cada abordagem. Essa análise permite avaliar a eficiência dos métodos em distintas condições ambientais e aprimorar o entendimento da relevância dos fatores, abordagens e complexidade do algoritmo em cada Bioma. Os modelos selecionados para este estudo, do menos complexo ao mais complexo, foram: S-SEBI (Roerink et al., 2000); SEBAL (Bastiaanssen et al., 1998) e STEEP (Bezerra et al., 2023).

A inclusão do SEBAL e do S-SEBI se fez em virtude de diversas aplicações dos modelos realizados na Caatinga, como os estudos de Santos e Silva (2010), Santos et al. (2014), Borges et al. (2021) que aplicaram o S-SEBI; e Teixeira et al. (2009), Santos et al. (2020a), Costa et al. (2021), e Lima et al. (2021), que utilizaram o SEBAL.

Os modelos foram implementados no ambiente de computação em nuvem, sendo utilizado a plataforma do *Google Earth Engine* (GEE), que além de proporcionar alto poder computacional, os dados necessários para aplicação dos modelos estão disponíveis gratuitamente. No presente estudo, os modelos fizeram uso de dados de SR

² A metodologia contém partes do seguinte artigo escrito para compor essa dissertação: Neto, E. P. S., Bezerra, U. A., Oliveira, S. H., Cunha, J. (2024). Análise de Modelos de Evapotranspiração por Sensoriamento Remoto na Caatinga: Uma Compreensão de Variações Temporais e Espaciais. *Revista Brasileira De Geografia Física*, 17(5), 3663–3681. <https://doi.org/10.26848/rbgf.v17.5.p3663-3681>

provenientes de produtos dos sensores MODIS e de diversos produtos para obtenção de dados usados na implementação dos modelos. Para obter o albedo de superfície e os índices de vegetação por diferença normalizada (NDVI) e ajustado ao solo (SAVI), foi utilizado o produto de reflectância de superfície MCD43A4. Este produto combina dados de reflectância dos sensores MODIS a bordo dos satélites AQUA e TERRA, minimizando perdas pela presença de nuvens ou o mau funcionamento instrumental (Schaaf & Wang, 2015). A obtenção dos dados de temperatura de superfície (Ts) foi realizada com o produto MOD11A1 e, para preencher dados faltantes, aplicou-se um filtro com o valor médio para uma janela mensal, utilizando uma metodologia semelhante à do MOD16 e ao método proposto por Zhao et al. (2005).

Dados de elevação foram obtidos do Shuttle Radar Topography Mission (SRTM), enquanto a altura da vegetação foi extraída do produto *Global Ecosystem Dynamics Investigation* (GED1) e *Global Forest Canopy Height* (Potapov et al., 2021). Os dados climáticos necessários para executar os modelos, como velocidade do vento, temperatura do ar, umidade relativa, radiação de ondas curtas e radiação térmica líquida na superfície, foram obtidos do produto de reanálise ERA5-Land (Sabater, 2019). O STEEP usa dados de umidade do solo e, para isso, utilizou-se o produto *Global Land Data Assimilation System* (GLDAS) (Rodell et al., 2004).

O STEEP e SEBAL realizam o balanço de energia no momento da passagem do satélite (instantâneo) para obter o fluxo de calor latente (λET) como resíduo do balanço de energia à superfície. A partir do λET é possível obter a Fração Evapotranspirativa (FE) instantânea (Ver Tabela 3). O S-SEBI, por sua vez, obtém diretamente a FE instantânea através dos valores de temperatura de superfície identificados nos pixels de membros finais. A estimativa da ET diária (mm/dia) nos modelos foi obtida seguindo a proposta de Bastiaanssen (2000) que considera que a FE instantânea é igual a FE diária, conforme Equação 1.

$$ET_{24h} = \frac{86400}{(2,501 - 0,00236 \times T_a) \times 10^6} \times FE_{24h} \quad (1)$$

Em que T_a é a temperatura média diária do ar ($^{\circ}C$), e Rn_{24h} corresponde ao saldo de radiação diário (W/m^2); neste estudo essas variáveis foram obtidas com dados do produto ERA5-Land. A FE_{24h} (adimensional) é a Fração Evapotranspirativa obtida conforme descrito na Tabela 2.

Tabela 2. Obtenção da Fração Evapotranspirativa nos modelos estudados.

Acrônimo do modelo	Nome do modelo	Referências principais	Equação para obter FE_{24h}
STEEP	<i>Seasonal Tropical Ecosystem Energy Partitioning</i>	Bezerra et al. (2023)	$FE_{inst} = \frac{\lambda ET}{Rn-G} = FE_{24h}$
SEBAL	<i>Surface Energy Balance Algorithm for Land</i>	Bastiaanssen et al. (2002); Laipelt et al. (2021)	
S-SEBI	<i>Simplified Surface Energy Balance Index</i>	Roerink et al. (2000); Borges et al. (2021)	$FE_{inst} = \frac{T_H - T_s}{T_H - T_C} = FE_{24h}$

onde λET é o fluxo de calor latente obtido subtraindo os fluxos de calor do solo (G) e calor sensível (H) do saldo de radiação (Rn). Todas as variáveis são expressas em unidades de energia (W/m^2). T_H (K) é a temperatura do *pixel* quente; T_C (K) é a temperatura do *pixel* frio; T_s (K) é a temperatura de superfície em cada *pixel*.

Todos os três modelos utilizados neste estudo seguem a abordagem CIMEC da identificação de áreas com condições extremas contrastantes em termos de cobertura e umidade proposta por Bastiaanssen et al. (1998), seja para obter a FE no caso do S-SEBI, ou para se obter o fluxo de calor sensível no SEBAL e STEEP. Contudo devido ao fato de a seleção dos pixels serem feitas originalmente de forma manual e sendo suscetível a erros, estudos como Bhattarai et al. (2017), Silva et al. (2019), Laipelt et al. (2021), vêm sendo desenvolvidos utilizando a seleção automática de candidatos a pixels âncora com base nas propriedades biofísicas, como índices de vegetação, albedo de superfície e cobertura do solo. Assim, a seleção não fica sujeita à intervenção do usuário.

A abordagem para seleção automática de candidatos a membros finais segue a descrita em Bezerra et al. (2023), utilizando as variáveis biofísicas NDVI, albedo de superfície e TS para a seleção (Tabela 3). Vale salientar que o procedimento para encontrar os pixels de membros finais foi realizado na escala diária, desde que os dados MODIS estivessem disponíveis. Para encontrar os pixels de membros finais utilizou-se áreas de interesse (AOI) de 1000 x 1000 km conforme indicado em Cheng et al. (2021) e Bezerra et al. (2023), centradas em cada um dos pontos selecionados para análise.

Tabela 3. Metodologia utilizada para a seleção dos candidatos a membros finais.

Membros finais	
Etapa 1	<div style="display: flex; justify-content: space-between;"> <div style="width: 45%;"> <p><i>Pixel</i> quente/seco</p> <p>Q50% < albedo de superfície < Q75% e 0,10 < NDVI < Q15%</p> </div> <div style="width: 45%;"> <p><i>Pixel</i> frio/úmido</p> <p>Q25% < albedo de superfície < Q50% e NDVI > Q97%</p> </div> </div>

Etapa 2	dos <i>pixels</i> da Etapa 1, selecionar os <i>pixels</i> com $Q85\% < T_s < Q97\%$	dos <i>pixels</i> da Etapa 1, selecionar os <i>pixels</i> com $T_s < Q20\%$
Etapa 3	Do conjunto de <i>pixels</i> que atenderam as etapas anteriores, foram calculados os valores medianos de R_n , G e T_s para estabelecer um valor único para cada variável e descrever as características dos membros finais	

Q = quantil.

Embora o núcleo dos algoritmos STEEP e SEBAL sejam baseados em encontrar o λET como o resíduo do balanço de energia, eles diferem quanto à abordagem utilizada para calcular o H . Bezerra et al. (2023), ao formularem o STEEP, calcularam H usando a rah e dT , ambos tradicionalmente aplicados em modelos SEB, mas também dando ênfase em características de florestas secas. A rah foi descrita de acordo com Verhoef et al. (1997a) e Paul et al. (2013), que requer, entre outros parâmetros/variáveis, o comprimento de rugosidade do momentum ($z0m$), a altura de deslocamento plano zero ($d0$) o parâmetro adimensional $kB-1$ e as correções de estabilidade atmosférica de Monin-Obukhov (Paulson, 1970). $z0m$ é influenciado por uma série de propriedades estruturais da planta, por exemplo, altura da vegetação, largura e coeficientes de arrasto da vegetação e espaçamento (ou densidade).

Comprimento de rugosidade de momentum ($z0m$) é comumente calculado em função do Leaf Area Index (LAI) (Verhoef et al., 1997b; Liu et al., 2021). No entanto, a maioria das plantas de diversos biomas do mundo passam uma parte substancial do ano sem folhas; sob essas condições, $z0m$ é derivado de troncos, caules e galhos. Como o LAI está relacionado apenas à quantidade e variabilidade de folhas, ele não pode representar a estrutura lenhosa sem folhas (Miranda et al., 2020). Foi por esta razão que o PAI, que é a área total da planta acima do solo, ou seja, folhas e estruturas lenhosas que interceptam ativamente a luz, foi usado para representar as estruturas das plantas no cálculo de $z0m$ e $d0$ no STEEP.

O modelo também incorpora as condições de variabilidade hídrica no sistema florestal no cálculo do fluxo de calor sensível, foi aplicado o procedimento descrito em Gokmen et al. (2012) que corrige a equação $kB-1$ apresentada em Su et al. (2001), incorporando a umidade do solo obtida por sensoriamento remoto. Os perfis de condutância do dossel são a ligação entre a umidade do solo e o fluxo de calor sensível/latente. A fonte de calor sensível/latente se move verticalmente ao longo do dossel em função do estresse hídrico da planta (Gokmen et al., 2012; Bonan et al., 2021), o que afeta o comprimento da rugosidade de calor e, portanto, $kB-1$ e rah . Assim, quando

há redução da umidade do solo, ocorre também redução do valor de λET e, conseqüentemente, aumento de H e diminuição de λET .

Além disso, para o cálculo do dT , o STEEP utiliza a regressão linear da T_s , com a suposição de extremo contraste em termos de cobertura e umidade (extremos quentes/secos e frios/úmidos) para determinar os coeficientes de regressão linear. No entanto, nos pixels dos membros finais quentes/secos e frios/úmidos, H foi calculado pelo balanço de energia à superfície (Allen et al., 2007), e o λET remanescente foi incorporado através da equação de Priestley-Taylor (1972) com restrições fisiológicas da planta conforme a abordagem dos estudos de Singh e Irmak (2011) e French et al. (2015). Para mais detalhes sobre a formulação do STEEP, consultar Bezerra et al. (2023), que descrevem todas as equações utilizadas para o cálculo de H . A tabela 4 evidencia os fatores e as abordagens que diferem de modelo a modelo

Tabela 4. Grau de complexidade dos Algoritmos.

	S-SEBI	SEBAL	STEEP
Metodologia pixel âncora	CIMEC (pixels âncora)	CIMEC (pixels âncora)	CIMEC (pixels âncora)
Cálculo da Fração evaporativa	Diretamente da temperatura de superfície	Encontra λET como resíduo do balanço de energia	Encontra λET como resíduo do balanço de energia
Cálculo de H	Não	Sim	Sim
Calibração dos pixels âncora	-	-	Considera o teor de umidade residual na calibração dos pixels âncora através da equação de Priestley-Taylor (Priestley & Taylor, 1972)
Parâmetros de rugosidade	-	Valor constante para comprimento de rugosidade e outras variáveis	Incorpora o PAI. Que é capaz de representar a variabilidade fenológica da planta.
Umidade no solo	-	-	Incorpora a umidade do solo

4.1 Compreensão do comportamento espacial e temporal na ecorregião da Caatinga

O item 4.1 trata-se da metodologia abordada para atingir o objetivo específico 1 deste trabalho. Tendo em mente que o algoritmo STEEP foi desenvolvido para a Caatinga, é importante entender o funcionamento do modelo em diferentes condições hídricas e diferentes classificações de uso do solo, para ter o entendimento de seu comportamento temporal e espacial na região para a qual ele foi projetado.

4.1.1 Ecorregião da Caatinga

Para a análise espacial e temporal dos modelos SEB foi escolhida a bacia do Rio Sucuru (BRS), situada no estado da Paraíba (Figura 1). A mesma foi escolhida por estar inserida em uma ecorregião com características de limitação hídrica e apresentar variações na fenologia de vegetação intra/inter-anual, as quais são fatores limitantes para modelos SEB (Silva et al., 2019; Paloschi et al., 2020). Está localizada em uma área conhecida como Cariris Velhos, região de grande representatividade para o semiárido/Caatinga brasileiro em questão de clima, solo, geologia, vegetação e topografia (Cadier, 1996; Nouvelot, 1974; Padilha et al., 2016, Cunha et al., 2020a). A bacia está localizada na Mesorregião da Borborema e na Microrregião Homogênea do Cariri Ocidental. Sua área territorial é de 1.652,5 km², representando uma parcela significativa da bacia do Alto Rio Paraíba (Santos et al., 2020b). O clima predominante na região é classificado como Bsh (semiárido quente) de acordo com a classificação climática de Köppen (Alvares et al., 2013).

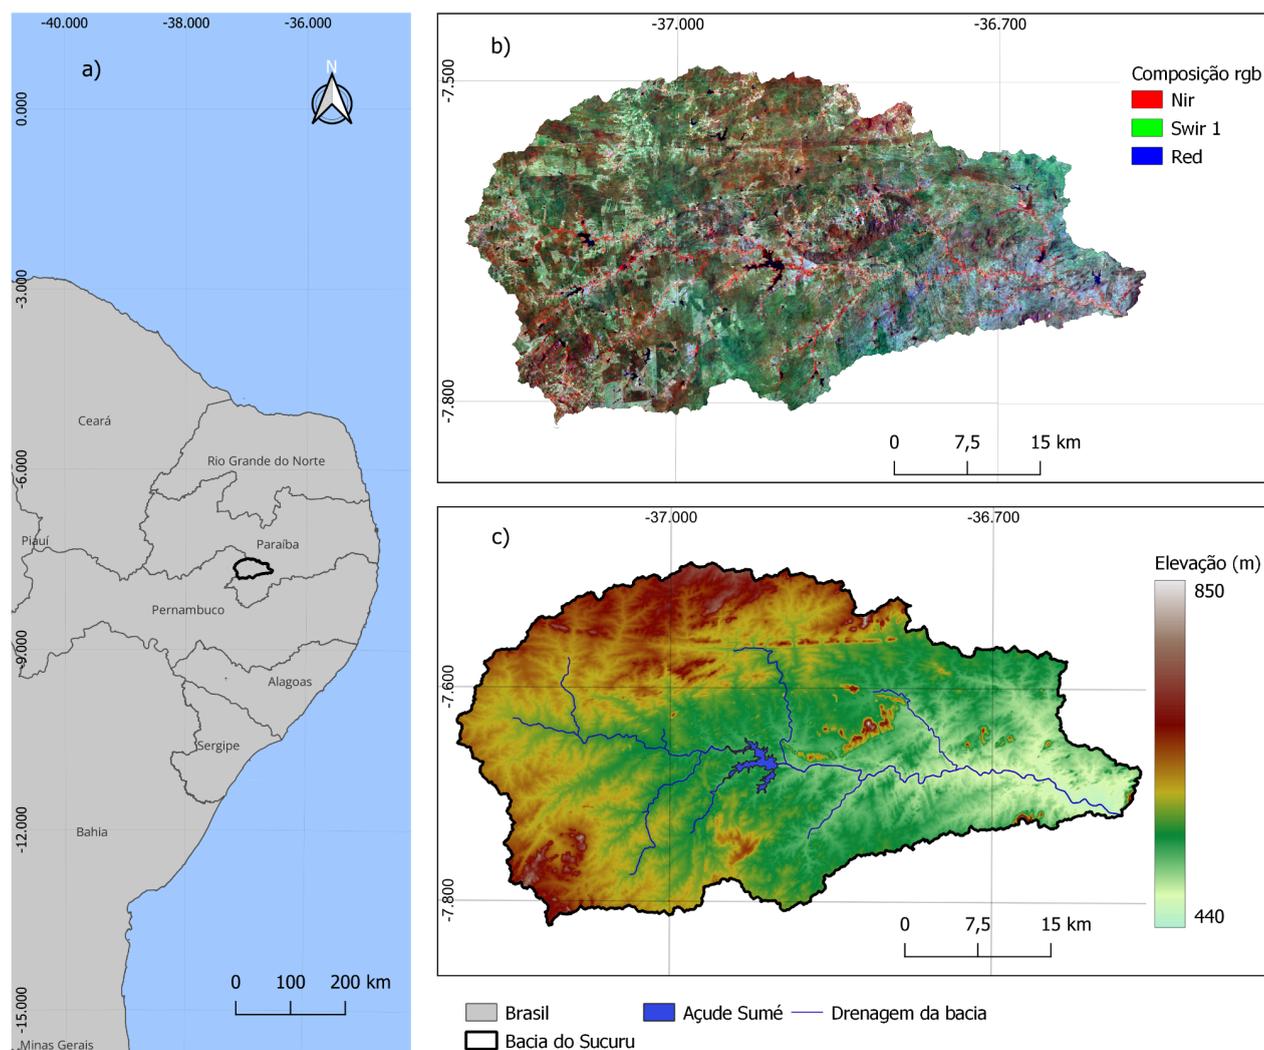


Figura 1. Localização da bacia do Rio Sucuru. a) Situação geográfica da bacia frente ao estado da Paraíba; b) Composição colorida (Bandas: NIR, SWIR 1 e RED) do Satélite Sentinel-2 MSI Harmonizado adquirido via Google Earth Engine e c) Mapa de elevação via dados FABDEM com rede de drenagem principal.

Além disso, o índice de aridez de Thornthwaite para a região é de 0,22, o que caracteriza a região como semiárido. Apresenta duas estações distintas: quente e seca (de junho a janeiro) e chuvosa muito quente (de fevereiro a maio), com precipitação média anual de aproximadamente 596 mm e temperatura média anual de 24°C (Cunha et al., 2020a). A Caatinga hiperxerófila é predominante na BRS, caracterizada pelo porte arbóreo baixo ou arbustivo (Sousa, 2023). Esta vegetação apresenta um mecanismo de resiliência para lidar com a seca característica do solo e da região, marcado principalmente pela queda das folhas e conseqüentemente alteração fenológica durante o ano (Dombroski et al., 2011; Paloschi et al., 2020).

4.1.2 Critério para seleção temporal e espacial

A avaliação da ET na BRS foi conduzida em anos com condições pluviométricas contrastantes. Essa escolha permite analisar a resposta da ET após longo período de escassez hídrica, proporcionando *insights* sobre a resiliência e adaptação da bacia frente a variações extremas no regime de precipitações. A escolha dos anos foi respaldada por Farias e Xavier (2023), os quais observaram a ocorrência de um evento de seca extrema entre os anos de 2012–2019, com 2012 sendo o ano mais grave e significativo em termos de escassez hídrica.

Neste ano, os índices pluviométricos foram notoriamente inferiores às médias históricas, com muitas áreas recebendo menos de 50% da precipitação média durante a estação chuvosa. Em contraste com essa sequência de anos secos, em 2020 houve precipitações acima da média, encerrando a seca na região. Assim, os anos selecionados para esta investigação foram 2012 e 2020.

Dentro dos limites da BRS, foram selecionados dez pontos, sendo cinco para cada tipo de cobertura, a fim de analisar as séries temporais de ET nos anos escolhidos. A escolha dos pontos foi baseada no tipo de cobertura do solo, para tanto foi utilizado uma reclassificação do MapBiomas (Coleção 7), considerando variações da caatinga, conforme apresentado na Figura 2. A escolha dos pontos foi fundamentada nas coberturas do solo que apresentaram maior percentual de área na bacia, sendo Caatinga floresta com ~68% e pastagem com ~30%.

Além disso, para selecionar os pontos, foram estabelecidos os critérios de não haver alteração de cobertura do solo entre os anos de 2012-2020, e que eles estivessem dentro de uma área homogênea de aproximadamente 500 metros, em virtude da resolução espacial dos modelos de ET abordados no estudo.

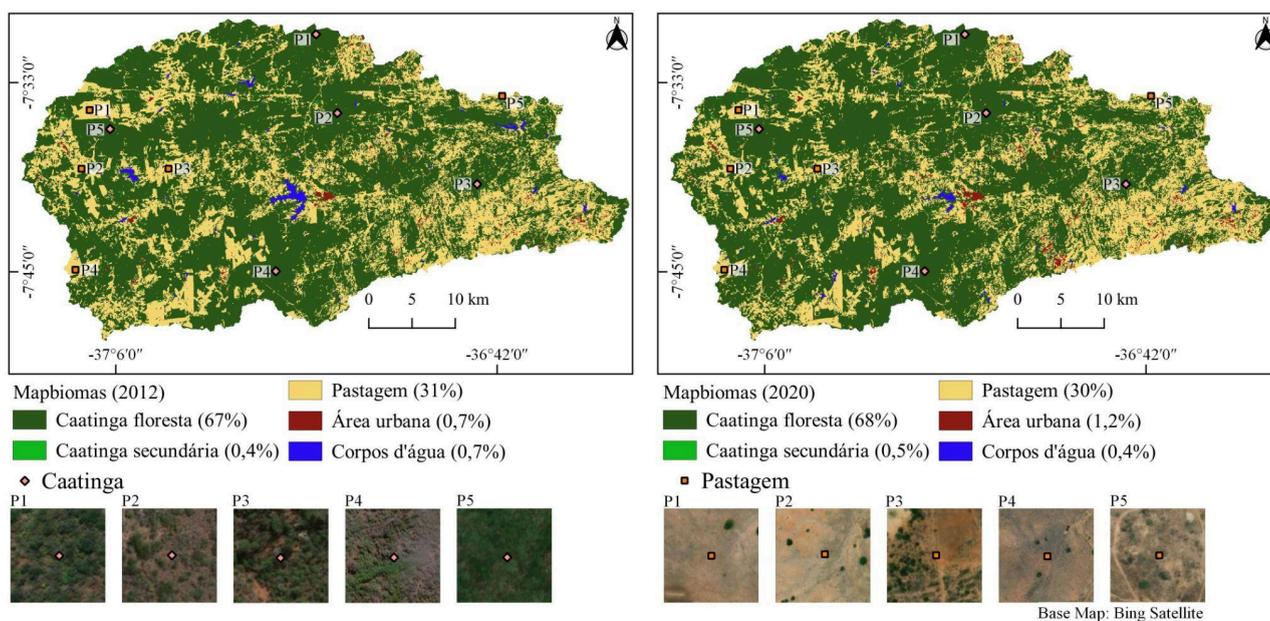


Figura 2. Classificação do uso do solo via Mapbiomas (Coleção 7) para os anos de 2012 (seco) à esquerda e 2020 (chuvoso) à direita.

4.1.3 Extração dos dados

A plataforma do GEE possibilita o processamento em larga escala de informações geoespaciais, a partir da computação de alto desempenho em nuvem (Gorelick et al., 2017; Miettinen et al., 2019). O aplicativo ET Caatinga – *Time Series Inspector* desenvolvido por Bezerra e Cunha (2023) foi utilizado neste estudo para facilitar as estimativas de ET dentro dos limites da Caatinga. Com ele é possível obter séries temporais de ET em um ano e local selecionado através da coordenada. O aplicativo permite que o usuário faça o download da série temporal do pixel de ET escolhido em formato de tabela de extensão csv, além do raster da ET acumulada anual. O aplicativo pode ser executado no período no qual os dados MODIS estão disponíveis (~2004–2022), e é possível escolher um dos modelos implementados no aplicativo para a estimativa de ET, que na atual versão é constituído pelo SEBAL, S-SEBI e STEEP (Bezerra e Cunha, 2023). O ET Caatinga – *Time Series Inspector* pode ser encontrado através da URL: <https://ulissesalencar17.users.earthengine.app/view/appetmodels>

Com o uso da ferramenta ET Caatinga – *Time Series Inspector* foram extraídas as séries temporais de ET diária modelada por STEEP, SEBAL e S-SEBI nas coordenadas dos pontos de Caatinga e pastagem escolhidos nos anos de 2012 e 2020. Para se observar o comportamento da precipitação nos pontos selecionados durante os anos de

análise, utilizou-se o produto CHIRPS (Funk et al., 2015) adquirido via a plataforma do GEE. A avaliação das estimativas de ET entre os modelos STEEP, SEBAL e S-SEBI foi realizada com base nos índices estatísticos, média, mínimo, máximo e desvio padrão. Estas análises foram realizadas em *Python* no ambiente de programação *Jupyter* com auxílio da biblioteca *Pandas* para processar as tabelas de dados e os dados estatísticos, e a biblioteca *matplotlib* para gerar os gráficos.

Para verificar o comportamento dos modelos ao longo do tempo, utilizou-se os dados de ET em médias semanais, pois mesmo com a utilização do produto MODIS, que possui grande abrangência temporal, o mesmo ainda apresenta falhas em sua completude de dados diários. Dessa forma, os dados de precipitação também foram acumulados para a escala de 7 dias. Para elaboração dos mapas de ET acumulada anual na BRS foi utilizado o *software* QGIS versão 3.28.6.

Para demonstrar a sensibilidade dos modelos de ET avaliados neste estudo, aos diversos usos e cobertura do solo, foram traçados perfis dos valores de ET e de NDVI para os anos de 2012 e 2020. Para a elaboração dos perfis utilizou-se o *plug-in Profile Tool* versão 4.2.6, disponível no QGIS. A linha de perfil traçada sobre a BRS, teve como critério perpassar alguns pontos de interesse para análise, como regiões de Caatinga, pastagem, área urbana e o açude de Sumé. Estes pontos foram definidos pois possuem características que induzem um comportamento específico da ET, o qual espera-se que os modelos consigam representar.

4.2 Verificação do STEEP com EC em diferentes biomas

O item 4.2 trata-se da metodologia abordada para alcançar o objetivo específico 2 deste trabalho. Para avaliar a relevância dos diferentes aspectos abordados pelos modelos do estudo em cada bioma, além dos modelos SEB, foi incluído na análise o modelo MOD16, que utiliza uma abordagem distinta da identificação de áreas de cobertura e umidade contrastantes. O MOD16 possui ampla aplicabilidade global, possuindo estudos em diversos Biomas e ecorregiões, como no oeste da Amazônia (Andrade et al., 2023), nos alpes Europeus (Castelli, 2021), em áreas florestadas da Europa (Hu et al., 2015), no pantanal Brasileiro (Oliveira e Morais Danelichen, 2022) e em florestas temperadas (Wang et al., 2015), sendo uma adição relevante no comparativo entre modelos. Além disso, o modelo STEEP foi adaptado em uma versão simplificada, com o acrônimo de STEEP_spf, que exclui a etapa de correção do pixel frio/úmido pelo método Priestley-Taylor. Tanto a adição do MOD16 quanto do STEEP_spf possibilita

identificar a limitação de cada método nas áreas de análise, como a abordagem de seleção dos *pixels* âncora e sua calibração respectivamente.

A evapotranspiração é influenciada por diversos fatores ambientais, físicos, geográficos e climáticos. O bioma é a classificação de uma área do espaço geográfico representada por um tipo uniforme de ambiente, identificado e classificado de acordo com o macroclima, a fitofisionomia, o solo e a altitude (Walter, 1986; Coutinho, 2006). Segmentar o estudo em diferentes biomas do globo, permite uma ampla abordagem, abrangendo diversas combinações de fatores ambientais, físicos, geográficos e climáticos, e permite uma cobertura mais diversa entre os ambientes em termos de uso e ocupação do solo, vegetação e tipos de ecossistemas. Permitindo ter insights sobre a eficiência da complexidade dos modelos, e quais aspectos e abordagens são mais relevantes na aplicação de um modelo SEB em cada bioma.

4.2.1 *Biomas*

A análise nas Florestas Úmidas Tropicais e Subtropicais de Folhas Largas (FUTS) ocorreu através das observações de duas torres de fluxo, uma sendo a BR-SA1 (Tabela e Figura A1) localizada na Amazônia (Brasil) (Dinerstein et. al., 2017), o clima predominante na região é classificado como Am (Monção Tropical) de acordo com a classificação climática de Koppen (Beck et. al., 2023). A segunda torre CN-Qia (Tabela e Figura A2), localizada na ecorregião de florestas perenes subtropicais de Jiang Nan na China (Dinerstein et. al., 2017), com o clima predominante Cfa (Subtropical úmido) (Beck et. al., 2023). O número de observações total da análise FUTS foi de 49 observações de ET/8dias onde 19 são pertencentes a BR-SA1 e 30 em CN-Qia.

Duas torres de fluxo foram utilizadas como dados observados para a análise em PSI, uma sendo a BR-Npw (Tabela e Figura A3) localizada no Pantanal Brasileiro (Dinerstein et. al., 2017), o clima predominante na região é classificado como Aw (Clima Tropical com estação seca no inverno). A segunda torre AR-Vir (Tabela e Figura A4), localizada na savana mesopotâmica do Cone Sul na Argentina (Dinerstein et. al., 2017), com o clima predominante Cfa (Subtropical úmido) (Beck et. al., 2023). O número de observações total da análise PSI foi de 152 observações de ET/8dias onde 65 são pertencentes a BR-Npw e 87 em AR-Vir.

Quanto às Florestas, Bosques e Matagais Mediterrâneos (FBMM) tiveram sua análise a partir das observações de duas torres de fluxo, a AU-Gin (Tabela e Figura A5) localizada na ecorregião conhecida como *Jarrah Forest* ou como florestas do sudoeste da

Austrália (Dinerstein et. al., 2017). A segunda torre IT-SRo (Tabela e Figura A6), está localizada na ecorregião de florestas esclerófilas e caducifólias italianas (Dinerstein et. al., 2017). Ambas as torres estão localizadas em áreas com o clima predominante Csa (Clima mediterrânico de verão quente). O número de observações total da análise PSI foi de 161 observações de ET/8dias onde 12 são pertencentes a AU-Gin e 149 em IT-SRo.

A análise das Pastagens e Matagais Montanhosos (PMM) foi feita mediante a observação da torre AU-Tum localizada nas pastagens montanhosas dos Alpes Australianos, com clima predominante Cfb (Clima temperado, com verão ameno). O número de observações total da análise PMM foi de 137 observações de ET/8dias.

A análise em Pastagens, savanas e matagais Tropicais e Subtropicais (PTS) foi feita com o auxílio das observações da torre de fluxo BR-IAB (Tabela e Figura A7) localizada no Cerrado Brasileiro, da torre ZM-Mon (Tabela e Figura A8) inserida na ecorregião das florestas Zambezianas de Baikiaea na África, onde ambos os climas classificados como Cwa (Clima subtropical úmido). E da torre AU-Stp (Tabela e Figura A9) na ecorregião *Mitchell Grass Downs* na Austrália, com clima predominante BSh (Semiárido Quente) da classificação de Koppen. O número total de observações de ET/8dias na PTS foi de 112. Dentre essas, 73 pertencem à BR-IAB, 21 são observações de ZM-Mon e 18 são observações de AU-Stp.

A análise em Florestas Temperadas de Coníferas (FTC) foi feita através das observações de duas torres de fluxo, a CH-Dav (Tabela e Figura A10) localizada nas florestas de coníferas dos Alpes Suíços, onde o clima predominante é classificado como Dfc (Clima subártico extremamente frio sem estação seca) de acordo com a classificação climática de Koppen. E a torre CZ-BK1 (Tabela e Figura A11) localizada nas florestas montanhosas de Carpathian na Tchécua, com classificação climática Dfb (Clima continental úmido de verão fresco). O número de observações total da análise FTC foi de 289 observações de ET/8dias onde 148 são pertencentes a CH-Dav e 141 em CZ-BK1.

A análise em Florestas Temperadas de Folhas Largas e Mistas (FTLM) foi feita mediante aos dados observados em duas torres de fluxo, uma sendo a BE-Vie (Tabela e Figura A12) localizada na ecorregião das florestas de folhas largas da Europa Ocidental na Bélgica, com um clima predominante Cfb (Clima Oceânico Temperado). A torre CA-Gro (Tabela e Figura A13) fica na ecorregião de transição Florestal-Boreal do Leste Canadense, onde o clima predominante é Dfb (Clima continental úmido de verão fresco).

O número de observações total da análise FTLM foi de 160 observações de ET/8dias onde 60 são pertencentes a BE-Vie e 100 em CA-Gro.

Nas Pradarias Temperadas, Savanas e Matagais (PTSM) os dados observados foram de duas torres de fluxo na Austrália, a AU-Whr (Tabela e Figura A14) se encontra na ecorregião de florestas temperadas do sudeste da Austrália, e a AU-Ync (Tabela e Figura A15) se encontra na ecorregião de savana temperada do sudeste da Austrália, ambas com um clima predominante de BSk (Clima semiárido frio). Das 82 observações coletadas nas PTSM, são 36 observações referentes a AU-Whr e 46 referentes a AU-Ync.

Nas Florestas secas tropicais e subtropicais de folhas largas (FSTS) a análise ocorreu com duas torres de fluxo, a BR-CST (Tabela e Figura A16) e a BR-SNn (Tabela e Figura A17), ambas localizadas na Caatinga Brasileira, com o clima predominante BSh (Clima Semiárido Quente). A análise na FSTS contou com 74 observações, onde 40 observações são referentes à torre BR-CST, e 34 a BR-SNn.

A Tabela 5 apresenta as 18 torres de fluxo que foram selecionadas no globo abrangendo 9 biomas vegetados e 8 classificações climáticas distintas. Também contém os anos de análise feitos na respectiva torre, é importante salientar que em nenhum dos casos foi incluído o ano de 2008 e 2016 por falta de dados MODIS. Estas torres atenderam os critérios de seleção, apresentando completude de dados, uso de cobertura do solo consistente, e dados de altura de vegetação pelo modelo GEDI presentes. A figura 3 mostra a distribuição espacial das torres de acordo com a classificação de biomas. O Anexo A contém os dados e análise das torres individualmente.

Tabela 5. Torres Selecionadas.

Bioma	ID da torre de fluxo	Coordenada	Class. Climática	Anos de análise
FUTS	BR-Sa	-2.8567, -54.9589	Am	2004 a 2005; 2009 a 2010
FUTS	CN-Qia	26.7414, 115.0581	Cfa	2004 a 2005
PSI	BR-Npw	-16.4980, -56.4120	Aw	2014 a 2017
PSI	AR-Vir	-28.2395, -56.1886	Cfa	2010 a 2012
FBMM	AU-Gin	-31.3764, 115.7138	Csa	2011 e 2012
FBMM	IT-SRo	43.7279, 10.2844	Csa	2005 a 2010

PMM	AU-Tum	-35.6566, 148.1517	Cfb	2004 a 2014
PTS	ZM-Mon	-15.4391, 23.2525	Cwa	2007 e 2009
PTS	BR-IAB	-22.1710, -47.8710	Cwa	2018 a 2021
PTS	AU-Stp	-15.4391, 23.2525	BSh	2012 e 2014
FTC	CH-Dav	46.8153, 9.8559	Dfc	2009 a 2014
FTC	CZ-BK1	49.5021, 18.5369	Dfb	2004 a 2014
FTLM	BE-Vie	50.3049, 5.9981	Cfb	2009 a 2012
FTLM	CA-Gro	48.2167, -82.1556	Dfb	2006 a 2013
PTSM	AU-Whr	-36.6732, 145.0294	BSk	2012 a 2014
PTSM	AU-Ync	-34.9893, 146.2907	BSk	2012 a 2014
FSTS	BR-CST	-7.9682, -38.3842	BSh	2014 e 2015
FSTS	BR-SNn	-6.5783, -37.2514	BSh	2014

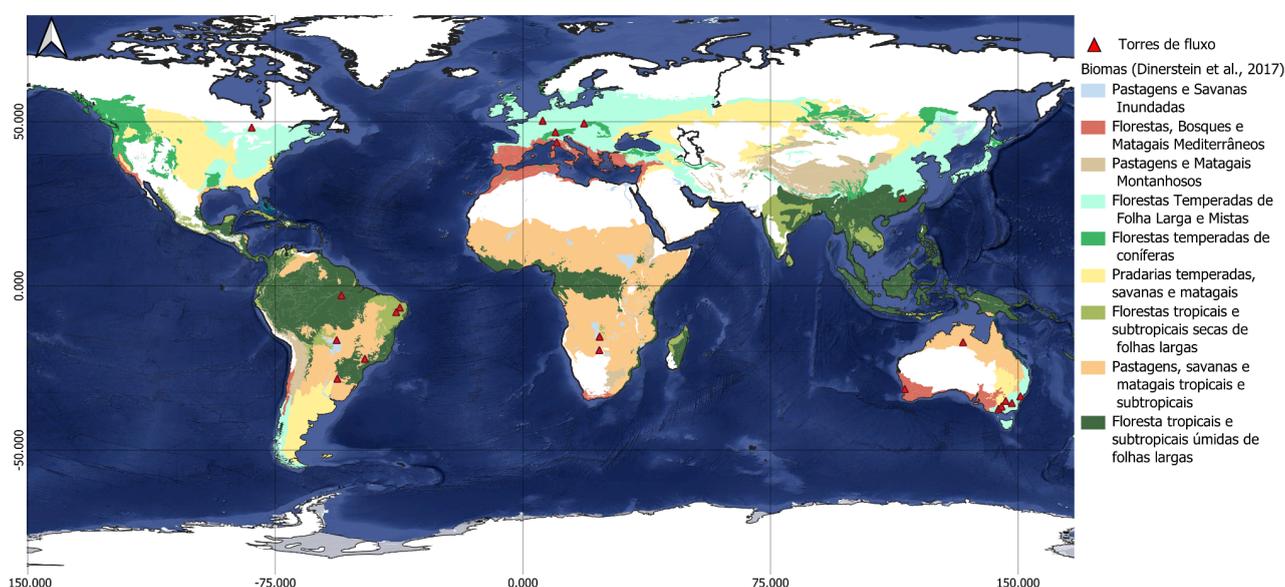


Figura 3. Localização das torres de fluxo de acordo com a classificação de biomas de Dinerstein et. al. (2017).

4.2.2 Torres de Fluxo baseadas em eddy covariance.

Com o intuito de observar o comportamento do STEEP em diferentes biomas fora da FSTS, foram selecionadas torres de fluxo que obtêm a evapotranspiração por EC, dentre as redes da Fluxnet (<https://Fluxnet.org/Data/download-Data/>), Ameriflux

(<https://AmeriFlux.lbl.gov/Data/>), Euroflux (<http://www.europe-fluxdata.eu/>) e de outras fontes em diferentes áreas do mundo. O critério de seleção das Torres de Fluxo se deu com base na classificação de biomas na qual a mesma está inserida.

As torres de fluxo fornecem os valores de fluxo de calor latente (λET) da região, que podem ser convertidos para ET. É importante garantir que medidas de ET filtradas para validação sejam de boa completude e qualidade, e que não alterem o fechamento do balanço energético (Tang et al., 2024), para isso, seguindo essa linha metodológica o processamento para seleção dos dados e controle de qualidade sobre o λET local da torre vem das seguintes observações:

- Cada torre selecionada deve estar inserida em um dos 9 biomas com vegetação característica para sua representação na validação.
- Converter o λET dado pela torre a cada 30 minutos em dados de ET na escala diária, onde somente são considerado os dias com mais de 40 dados diários.
- Considerar somente os meses com mais de 25 dados de ET diária.
- Considerar somente dados com disposição temporal compatível com a disponibilidade do sensor MODIS, pois os modelos SEB selecionados dependem dessa disposição para sua execução. (2004 - 2007 ; 2009-2015 e 2017 - atual).
- Considerar todos os anos com dados disponíveis da torre de fluxo que atendem aos critérios.
- Excluir os locais das torres onde o tipo e uso de cobertura são inconsistentes, em que a cobertura do solo dominante ocupa menos que 70% de uma área de 10km², que é a área de influência da torre (Chu et al., 2021)
- Excluir locais onde não há dados de altura de vegetação via satélite pelo produto *GEDI's Level 2A Geolocated Elevation and Height Metrics* (GEDI). Pois o STEEP depende de dados de altura de vegetação para sua execução.

4.2.3 Verificação dos Modelos

Com a seleção devida de cada torre representativa dos biomas de estudo, os modelos são aplicados nas áreas de análise de cada torre para a devida validação. Cada torre de fluxo selecionada tem suas mensurações geradas para uma área de contribuição (*footprint*), para que as comparações sejam feitas de forma válida e com mais precisão, ao realizar as estimativas de ET com os modelos SEB e MOD16, a seleção de pixels deve

se dar de acordo com a área de influência de captação de cada torre dos sites selecionados. Além disso, devido a inclusão do MOD16, os dados de ET dos modelos SEB e das torres de fluxo foram convertidos para dados de ET acumulada a cada 8 dias para que houvesse uma análise com uma resolução temporal compatível com o MOD16.

É significativo que incertezas podem estar envolvidas não somente na aplicação do modelo, mas em todo o processo de validação, justificando a análise como uma etapa essencial (Jia et al. 2012). A análise considera as limitações e características do sistema. A verificação da proximidade das estimativas gerada pelo modelo de SR com os dados de EC, foi feito através do método de regressão linear. Com a relação de dado observado (ET por EC) e dados estimados (dos modelos STEEP, SEBAL, S-SEBI, MOD16 e STEEP_spf) compilados em cada ano e cada torre presente no bioma de análise e unidos em um único gráfico de regressão linear correspondente ao bioma.

A partir da correlação dos dados estimados dos modelos e os dados observados levantou-se alguns parâmetros estatísticos de análise, sendo calculado o erro quadrático médio (RMSE) que representa o quanto os modelos se afastam da média observada é o parâmetro mais comumente considerado para validação de modelos de SR e o parâmetro primário para a análise. Além disso, foram considerados o Coeficiente de determinação (R^2) que representa o quanto a linha de regressão se ajusta aos dados, *Percent Bias* (PBIAS) que indica se os modelos subestimam ou superestimam em relação aos valores observados, *Nash–Sutcliffe model efficiency coefficient* (NSE) que é utilizado para avaliar a eficiência de modelos de previsão e o Coeficiente de correlação de Pearson (PC) que mede a intensidade e a direção de relações lineares. Estas análises foram feitas em *Python* no ambiente *Jupyter* com auxílio da biblioteca *Pandas* para processar as tabelas de dados e os dados estatísticos, e a biblioteca *matplotlib* para gerar os gráficos.

5. Resultados e Discussão³

O Item 5.1 aborda os resultados obtidos referentes ao objetivo específico 1, enquanto o item 5.2 aborda os resultados obtidos referentes ao objetivo específico 2.

³ Os Resultados contém partes do seguinte artigo escrito para compor essa dissertação: Neto, E. P. S., Bezerra, U. A., Oliveira, S. H., Cunha, J. (2024). Análise de Modelos de Evapotranspiração por Sensoriamento Remoto na Caatinga: Uma Compreensão de Variações Temporais e Espaciais. *Revista Brasileira De Geografia Física*, 17(5), 3663–3681. <https://doi.org/10.26848/rbgf.v17.5.p3663-3681>

5.1 Compreensão do comportamento espacial e temporal na ecorregião da Caatinga

Na Figura 4 é apresentada a série temporal da ET nos modelos STEEP, SEBAL e S-SEBI em cada um dos pontos selecionados de pastagem e caatinga nos anos seco e chuvoso. Ao observar os pontos de pastagem durante o ano seco, constata-se que nos três modelos, a ET apresentou baixa variabilidade, com valores médios não superiores a 2 mm/dia. Conforme evidenciado na Tabela 6, a ET na cobertura de pastagem no ano de 2012 variou de 0,11 a 1,20 mm/dia, com média de 0,63 mm/dia no STEEP, 0,08 a 1,67 mm/dia, com média de 0,87 mm/dia no SEBAL, e 0,39 a 1,92 mm/dia, com média de 0,91 mm/dia no S-SEBI. O STEEP foi o modelo em que a ET se manteve mais constante durante o ano, como evidenciado por seu desvio padrão 0,27 mm/dia (Tabela 6). O SEBAL, por sua vez, foi o modelo que apresentou maior desvio padrão com 0,34 mm/dia (Tabela 6)

Em relação ao ano chuvoso, nos pontos de pastagem, o comportamento da ET entre os modelos seguiu padrão semelhante, obtendo maiores valores de ET após os picos de chuva, e decaindo nos demais meses. A ET nesse ano variou de 0,22 a 3,98 mm/dia, com média de 1,59 mm/dia no STEEP, 0,70 a 4,18 mm/dia, com média de 2,13 mm/dia no SEBAL, e 0,69 a 3,46 mm/dia, com média de 1,85 mm/dia no S-SEBI (Tabela 6). Ao observar os modelos, na área de pastagem ao longo dos dois anos analisados, o STEEP é o que apresenta a maior dinâmica sazonal, com destaque para o período de estiagem, compreendido entre os meses de agosto a dezembro, que apresenta valores baixos de ET e aproximadamente constantes nesse período. Apesar disso, as diferenças entre os modelos para a representação da pastagem foram suaves, não apresentando grandes contrastes entre seus comportamentos.

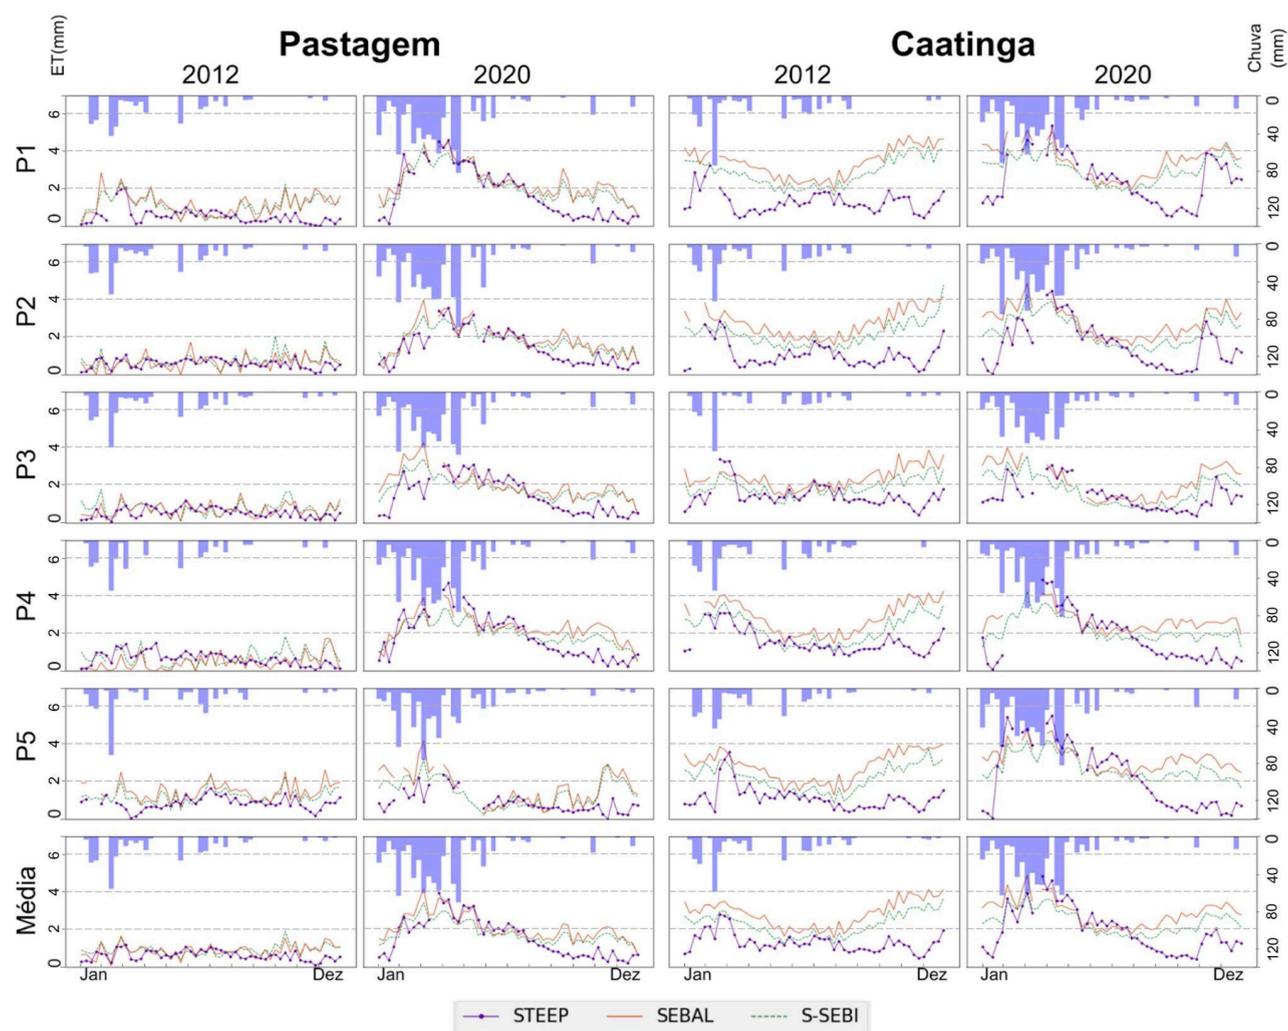


Figura 4. Série temporal semanal de precipitação e evapotranspiração dos modelos STEEP, SEBAL e S-SEBI para as coberturas Caatinga e pastagem nos anos seco e chuvoso dos 5 pontos selecionados em pastagem e caatinga.

Ao observar os pontos de Caatinga (Figura 4), foi possível constatar as maiores diferenças da ET entre os modelos STEEP, SEBAL e S-SEBI, nos anos seco e chuvoso. A ET no ano seco variou de 0,48 a 2,83 mm/dia, com média de 1,32 mm/dia no STEEP, 1,58 a 4,16 mm/dia, com média de 2,86 mm/dia no SEBAL, e 1,22 a 3,71 mm/dia, com média de 2,28 mm/dia no S-SEBI (Tabela 6). No ano chuvoso a ET nos modelos variou de 0,42 a 4,88 mm/dia, com média de 2,00 mm/dia no STEEP, 1,78 a 4,93 mm/dia, com média de 2,93 mm/dia no SEBAL, e 1,47 a 4,15 mm/dia, com média de 2,44 mm/dia no S-SEBI (Tabela 6).

Tabela 6. Estatísticas descritivas de evapotranspiração dos modelos STEEP, SEBAL e S-SEBI para as coberturas Caatinga e pastagem nos anos seco e chuvoso

Uso do solo	Modelo	Ano: Seco (2012) Chuvoso (2020)
-------------	--------	-----------------------------------

		Mínimo	Média	Máximo	Desvio Padrão
<i>Caatinga</i>	STEEP	0,48 0,42	1,32 2,00	2,83 4,88	0,51 1,19
	SEBAL	1,58 1,78	2,86 2,93	4,16 4,93	0,72 0,74
	S-SEBI	1,22 1,47	2,28 2,44	3,71 4,15	0,63 0,65
<i>Pastagem</i>	STEEP	0,11 0,22	0,63 1,59	1,20 3,98	0,27 1,02
	SEBAL	0,08 0,70	0,87 2,13	1,67 4,18	0,34 0,74
	S-SEBI	0,39 0,69	0,91 1,85	1,92 3,46	0,28 0,60

As diferenças encontradas entre os modelos podem ser explicadas em virtude da vegetação da Caatinga possuir espécies xerófitas e/ou caducifólias, que têm um mecanismo de resiliência típico. Esse mecanismo atua especialmente na transição da estação chuvosa para a seca (intra-anual). Nesse período, quando a umidade do solo atinge seus níveis mais baixos, a vegetação da Caatinga entra em estado de dormência.

Esse estado é marcado pela queda das folhas e uma redução drástica da atividade fotossintética (e, portanto, da transpiração) como estratégia para lidar com a falta da umidade disponível do solo (Dombroski et al., 2011; Paloschi et al., 2020; Bezerra et al., 2023). Isso explica o motivo pelo qual a ET, tanto no ano seco (2012) quanto na estação seca (agosto a dezembro), deve apresentar baixas taxas evapotranspirativas. Esse comportamento é evidenciado nas séries temporais de ET no STEEP, com um melhor desempenho que pode ser explicado porque a umidade do solo está incorporada no seu algoritmo e ele tem uma melhor representação da variabilidade fenológica da planta com a incorporação do PAI e um *rah* mais robusto (Bezerra et al., 2023). Por outro lado, modelos SEB como o SEBAL e S-SEBI, formulados para depender principalmente da disponibilidade de energia e sem considerar a disponibilidade de água do solo e das plantas, podem não representar satisfatoriamente a ET na vegetação da Caatinga (Gokmen et al., 2012; Paul et al., 2014; Zhu et al., 2022; Bezerra et al., 2023).

Os resultados da linha traçada do perfil de ET e do NDVI ao longo de diferentes usos do solo nos anos de 2012 e 2020 na BRS são apresentados na Figura 5. Os três modelos aplicados neste estudo demonstram ser eficazes para capturar as variações de ET entre os distintos usos e ocupação do solo na bacia. Destacam-se valores elevados de ET na região do açude, em contraste com valores mais baixos observados na cidade de

Sumé. É notável as diferenças acentuadas quando se observa a transição entre Caatinga e pastagem. Predominantemente, a Caatinga se manteve com taxas de ET superiores às observadas na pastagem. Esse comportamento também foi observado em Silva et al. (2019) e Khoshnood et al. (2023).

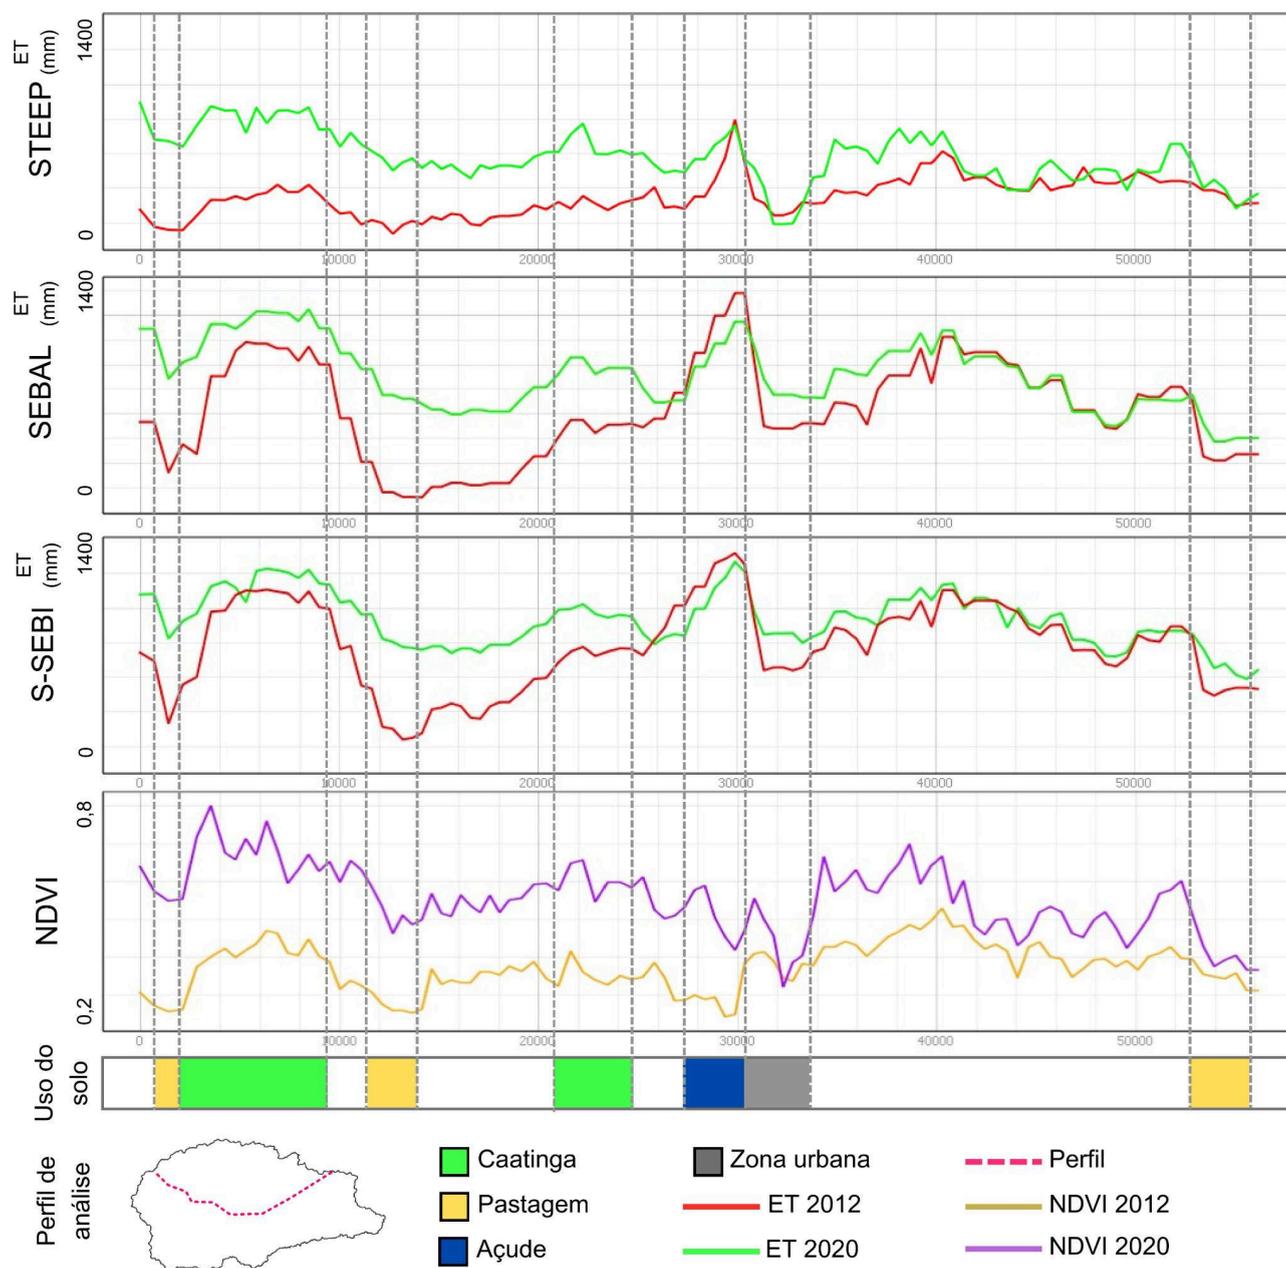


Figura 5. Perfil de comportamento espacial da evapotranspiração no STEEP, SEBAL e S-SEBI e de NDVI em relação a diferentes usos do solo.

Apesar da concordância geral nos padrões de ET ao longo das distintas coberturas, a classe de Caatinga nos modelos SEBAL e S-SEBI, durante o ano de 2012, exibiu taxas de ET próximas às registradas no ano de 2020. Isso contraria a esperada sazonalidade interanual acentuada desse bioma (Campos et al., 2019). No entanto, esse

comportamento é observado ao se analisar os perfis de ET no STEEP com o NDVI, indicando que as respostas da vegetação e de ET entre os anos seco e chuvoso são mais pronunciadas.

A Figura 5 ilustra o padrão espacial da ET anual nos anos de 2012 e 2020, obtido pelos modelos STEEP, SEBAL e S-SEBI em toda a BRS. A média anual de ET na BRS em 2012 e 2020 pelo STEEP foi de 332 e 582 mm/ano, no SEBAL foi de 669 e 875 mm/ano, e no S-SEBI foi de 546 e 717 mm/ano. Destaca-se que o STEEP apresentou o maior ganho percentual (75%) em termos de ET média anual ao considerar os períodos seco (2012) e chuvoso (2020). Em contraste às estimativas obtidas pela aplicação do modelo SEBAL e S-SEBI, esse ganho foi de 30% e 32% respectivamente. O baixo ganho percentual do SEBAL e S-SEBI entre os anos ocorre pois normalmente os modelos baseados em SR tem dificuldade em considerar a influência de processos como fenologia da vegetação e eventos extremos (Keenan et al., 2012; Jiang e Ryu, 2016), como a seca que ocorreu na BRS em 2012 (Farias e Xavier, 2023). Isso provocou uma superestimacão da ET na bacia como um todo durante o ano de 2012 e o período de estiagem de 2020, aproximando as estimativas de ET de ambos os anos. Essa superestimacão em ambientes secos é uma tendência já constatada por outros estudos (Gokmen et al., 2012; Paul et al., 2014; Trebs et al., 2021). O SEBAL foi o modelo que apresentou as maiores superestimativas, especialmente em áreas da Caatinga. Bezerra et al. (2023) também constataram superestimativas similares em sua análise pontual, com o SEBAL registrando superestimativas superiores a 140%, enquanto a maior superestimativa do STEEP foi de 60% em relação aos dados observados. Apesar disso, em todos os três modelos é possível observar, espacialmente, que a pastagem foi claramente distinguível da Caatinga. Esse resultado pode ser atribuído à observação de que áreas de pastagem ou agrícolas tendem a apresentar um comportamento de ET mais previsível para diversos modelos (Tang et al., 2024).

O contraste observado na capacidade de representação dos modelos SEB nos ambientes de Caatinga e pastagem pode ser atribuído às formulações físicas distintas de cada modelo. O SEBAL, na seleção de membros finais, assume que H e dT no membro final frio/úmido e λET no membro final quente/seco são irrelevantes (Bastiaanssen et al., 1998). O membro final frio/úmido refere-se a uma área com uma superfície úmida ou totalmente coberta por vegetação. Assim, em pontos da caatinga durante períodos secos, quando a vegetação reduz sua atividade fotossintética e ET, uma parcela significativa de H é negligenciada. Da mesma forma, para o membro final quente/seco, em uma área

dominada por solo descoberto pode haver um λ ET remanescente resultante de eventos de chuva antecedentes.

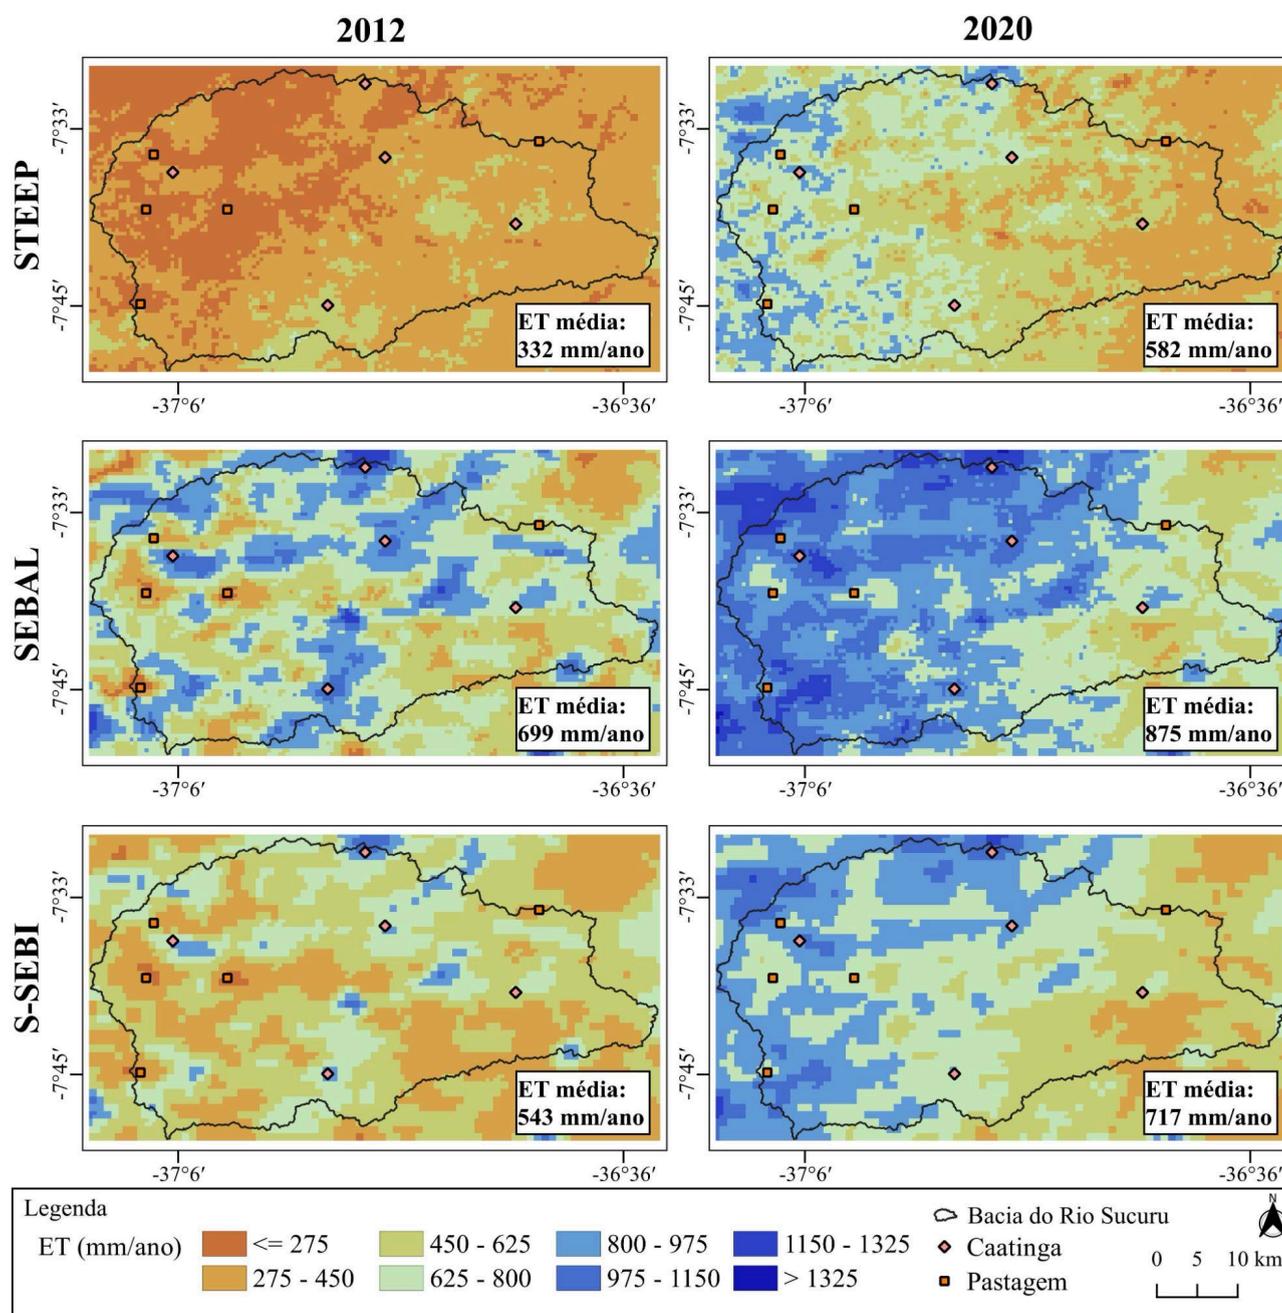


Figura 6. Padrões espaciais da evapotranspiração média anual pelos modelos STEEP, SEBAL e S-SEBI na Bacia do Rio Sucuru nos anos seco e chuvoso.

O S-SEBI apresenta ainda mais simplificações ao calcular a fração evaporativa a partir da temperatura de superfície nos membros finais sem considerar fatores complexos que interferem na estimativa de ET como λ ET. Bezerra et al. (2023) consideraram a λ ET remanescente nos pixels de membros finais por meio da equação de Priestley-Taylor, que visa calibrar os pixels âncora de acordo com o teor de umidade residual (Priestley & Taylor, 1972). Essa correção minimiza o fluxo de calor negligenciado pelo modelo.

Modelos de base física, como os modelos SEB, são altamente influenciados pela representação dos parâmetros de rugosidade (Hu et al., 2021), principalmente em ambientes florestais, que demandam uma representação mais precisa dessa variável. Na Caatinga, essa representação da rugosidade torna-se ainda mais crucial devido à sua marcada variação fenológica ao longo do ano (Verhoef et al., 1997b). O S-SEBI não apresenta uma abordagem voltada para a representação da rugosidade, e SEBAL apresenta simplificações no cálculo da resistência aerodinâmica, como valor único e constante para comprimento de rugosidade de calor e outras variáveis (Bastiaanssen et al., 1998; Bastiaanssen et al., 2005) que podem afetar negativamente nas estimativas de H e λET (Paul et al., 2014; Liu et al., 2021). O modelo STEEP ao incorporar o PAI, um índice que tem maior capacidade de representar as alterações fenológicas inter/intra-anuais na Caatinga (Miranda et al., 2020), nas equações de rugosidade, possibilita que esses processos sejam fisicamente melhor representados, em vez da introdução de parâmetros empíricos adicionais.

5.2 Verificação do STEEP com eddy covariance em diferentes Biomas

Florestas úmidas Tropicais e Subtropicais (FUTS)

De acordo com a Tabela 7 e observações da figura 7, dentre os modelos o S-SEBI se destacou por ter as melhores métricas avaliadas, apresentando o maior coeficiente de determinação ($R^2 = 0,636398$), a menor diferença entre o valor previsto e o real (RMSE = 6,359365) e o menor viés entre os modelos, não tendo altas tendências a subestimação ou superestimação (PBIAS = -1,73%) em relação ao valor observado, sendo o modelo com melhor desempenho nas FUTS. O modelo SEBAL mostra bons resultados, tendo um RMSE e NSE superior ao do STEEP, porém demonstrando um viés de superestimativa dos dados (PBIAS = -17,15%). De forma semelhante o STEEP apresenta valores próximos, porém ligeiramente inferiores aos demais modelos. Vale ressaltar que o STEEP e STEEP_spf apresenta o maior viés de superestimativa dentre os modelos (PBIAS = -17,15%). Por fim o MOD16 apresenta o pior desempenho nas FUTS, não conseguindo representar adequadamente a ET nas áreas estudadas.

A disponibilidade e água constante presente no solo das FUTS devido a umidade local, a floresta densa adaptada para abundância de água, e a vegetação perenifólia, ou seja com folhas perenes e verdes o ano todo, são características que tornam os fatores

abordados no STEEP, como a capacidade de representar as alterações fenológicas inter/intra-anuais da vegetação e a incorporação de umidade no solo, menos relevantes. Esses fatores podem introduzir incertezas que podem comprometer a estimativa de ET do STEEP nas FUTS. Isso é evidenciado pelo melhor desempenho geral do SEBAL e S-SEBI, que, mesmo sendo modelos de maior simplicidade, apresentam resultados mais confiáveis.

Tabela 7. Métricas Estatísticas FUTS.

Modelo	R ²	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,427447	8,3364	3,380738	0,042782	65,37945
STEEP_spf	0,438209	8,328289	-17,1455	0,044644	66,19735
SEBAL	0,459228	7,791708	-14,0642	0,163783	67,76639
S-SEBI	0,636398	6,359365	-1,7276	0,442967	79,77458
MOD16	0,001015	16,81086	-5,87335	-2,89254	3,186086

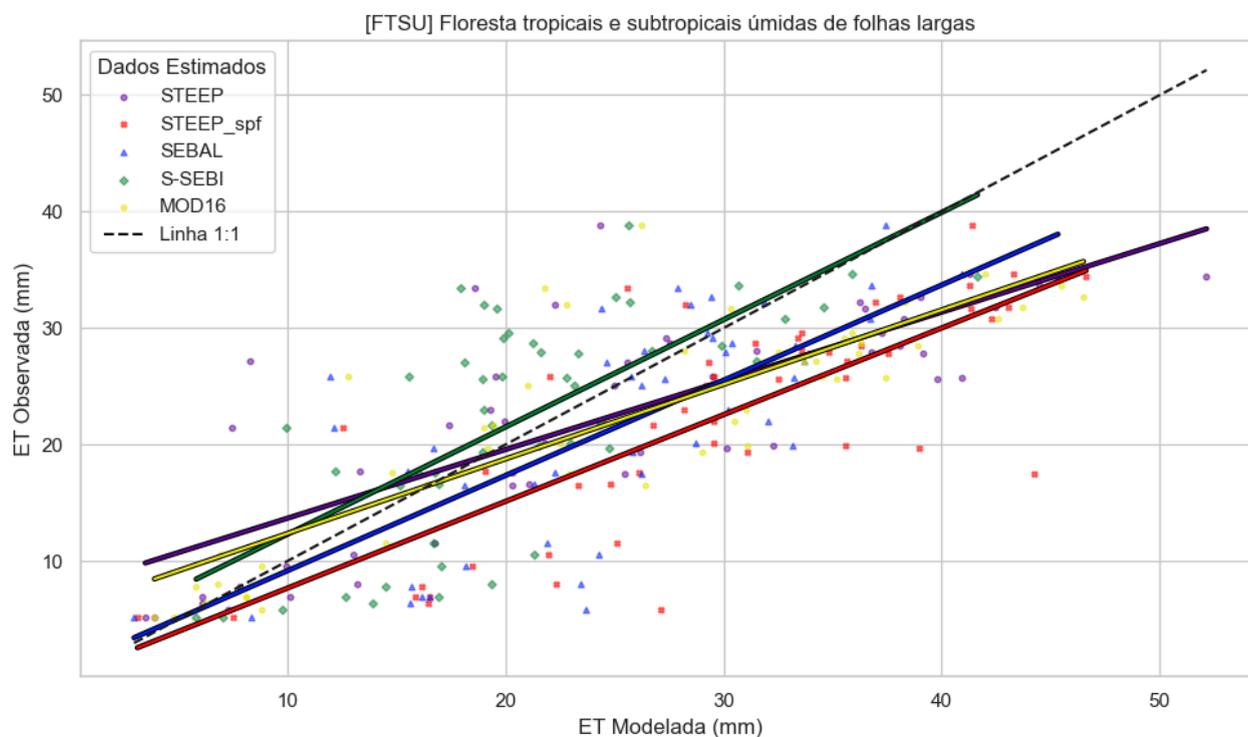


Figura 7. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações de torres de fluxo localizadas em FUTS na escala temporal de ET acumulada de 8 dias.

Pastagens e Savanas Inundadas (PSI)

Com base nas observações da Tabela 8 e Figura 8, nota-se que o modelo STEEP_spf apresenta o melhor desempenho geral, com os melhores índices de R², RMSE, NSE, e PC, além de ter um PBIAS aceitável (-5,00645) com um baixo viés, se mostrando ser o modelo com melhor desempenho em PSI. Em contrapartida o STEEP apresenta desempenho inferior se executado com a correção do pixel frio, havendo um distanciamento considerável dos dados observados.

Indicando que devido aos alagamentos em grande escala, característicos da PSI, a consideração de λ ET remanescente pelo método de priestley-taylor pode comprometer a estimativa de ET no bioma por esse algoritmo. O SEBAL e S-SEBI apresentam bom desempenho e estimativas próximas, com o SEBAL obtendo melhores resultados estatísticos gerais, e o S-SEBI apresentando uma subestimativa moderada (PBIAS = 14,88%). Por fim, o MOD16 tem o pior desempenho relativo entre os modelos, apresentando NSE (-0,840) negativo, alto RMSE (10,52) e o maior viés de superestimativa entre os modelos (PBIAS = -27,55%).

No geral os modelos SEB apresentaram maior concordância com os dados observados que o modelo baseado no método de *Penman-Monteith*. Além das PSI apresentarem uma vegetação heterogênea em seu bioma (Metelo et al., 2013), o período de seca, quando há escassez de água, e o período chuvoso, onde há alagamentos, fazem com que a umidade do solo varie de forma contrastante durante o ano (Novais et al., 2016). Esses fatores relevantes para a estimativa espacial e temporal da ET nas PSI são incorporados pelo algoritmo do STEEP_spf, que justifica seu melhor desempenho em relação ao SEBAL e ao S-SEBI.

Tabela 8. Métricas Estatísticas PSI.

Modelo	R ²	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,449976	9,283957	9,783442	-0,43394	67,08025
STEEP_spf	0,659897	6,46382	-5,00645	0,304907	81,23404

SEBAL	0,592234	6,832553	3,671749	0,223341	76,95675
S-SEBI	0,535742	7,494159	14,87714	0,065648	73,19442
MOD16	0,505335	10,5155	-27,5528	-0,8396	71,08691

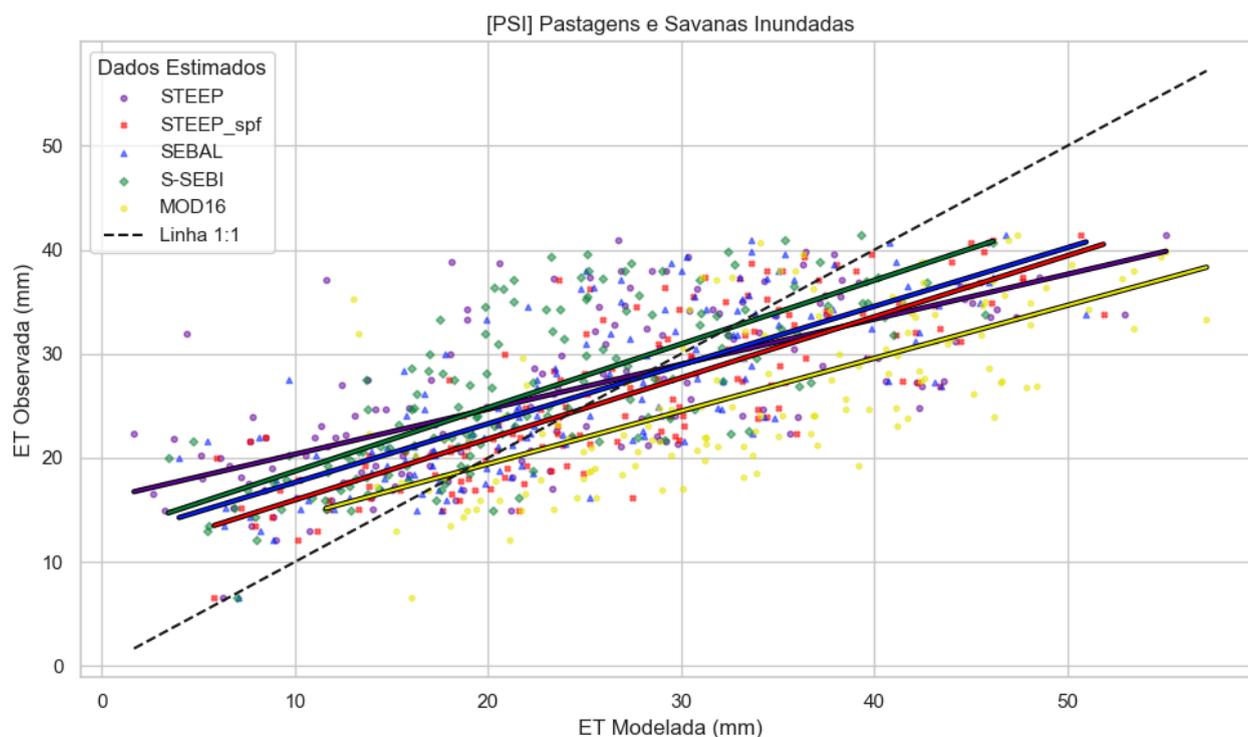


Figura 8. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações de torres de fluxo localizadas em PSI na escala temporal de ET acumulada de 8 dias.

Florestas, Bosques e Matagais Mediterrâneos (FBMM)

Verificou-se que todos os modelos apresentaram correlação mediana a ruim com os dados observados ($RMSE > 9$, tabela 9, figura 9). O modelo STEEP apresenta o melhor desempenho relativo quanto aos outros modelos, apresentando os melhores parâmetros estatísticos, com a linha de regressão que melhor se ajusta aos dados observados ($R^2 = 0,464$), o menor erro entre o valor previsto e o observado ($RMSE = 9,65$), o menor viés de tendência ($PBIAS = 0,3688$), sendo o modelo com maior capacidade de representar e se aproximar dos dados observados com mais precisão e consistência.. O MOD16 é o modelo que mais se aproxima do STEEP em termos de precisão, apesar disso, evidencia-se um viés de subestimativa considerável ($PBIAS =$

25,87%). Quanto ao STEEP_spf, SEBAL e S-SEBI, foram os modelos que apresentaram os piores desempenhos para capturar a variabilidade dos dados observados.

A superioridade do STEEP e MOD16 sobre os baixos parâmetros dos demais modelos que utilizam a metodologia CIMEC para seleção de pixels âncora tradicional, demonstra que a metodologia CIMEC não é adequada para biomas de FBMM. Sendo assim, o principal fator de destaque do STEEP sobre os demais modelos se deve principalmente à consideração do λ ET remanescente e a calibração dos pixels de membros finais pela metodologia de Priestley-Taylor.

Tabela 9. Métricas Estatísticas FBMM.

Modelo	R ²	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,464984	9,656692	0,368812	0,259083	68,18976
STEEP_spf	0,435766	12,99929	-21,4561	-0,34262	66,01258
SEBAL	0,36449	11,78633	-4,77503	-0,10375	60,37297
S-SEBI	0,377155	11,15844	9,561873	0,010719	61,41298
MOD16	0,427954	10,83442	25,86746	0,067339	65,41821

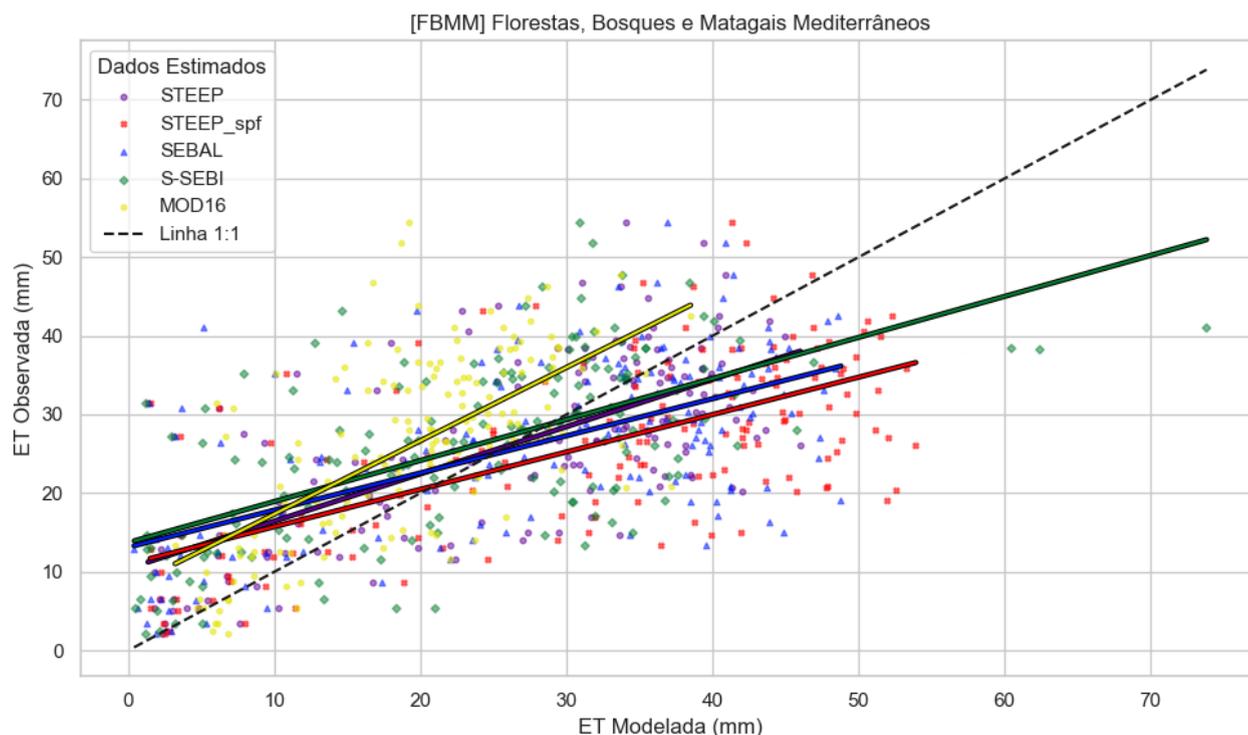


Figura 9. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações de torres de fluxo localizadas em FBMM na escala temporal de ET acumulada de 8 dias.

Pastagens e Matagais Montanhosos (PMM)

Ao observar a Tabela 10 e Figura 10 fica claro a disparidade de desempenho do MOD16 e STEEP dos demais modelos. O MOD16 apresenta o melhor desempenho geral e indicadores, destaca-se sua baixa tendência de erro (RMSE = 6,911) e baixo viés de superestimação (PBIAS = -4,153%). O STEEP embora tenha um desempenho levemente inferior ao MOD16, é o modelo SEB que melhor representa a ET em PMM com uma linha de regressão que melhor se ajusta bem aos dados observados ($R^2 = 0,464$) e baixa tendência de erro (RMSE = 8,023) ainda que tenha um leve viés de superestimativa de dados (PBIAS = -9,517). O STEEP_spf, SEBAL e S-SEBI tem parâmetros que revelam um desempenho insatisfatório com RMSE (>21), PBIAS altos (>-73%), e NSE negativos (em torno de -2,95), especialmente devido à baixa precisão e elevada tendência a superestimar os dados de ET em PMM.

As PMM possuem características que já demonstraram favorecer o desempenho do MOD16 no estudo de Hu et al. (2015), que é uma vegetação com baixo LAI e clima temperado (Korner, 2003) que justifica seu bom desempenho nesse bioma. Os modelos

SEB por outro lado mostraram dificuldades de estimativas nessas áreas, indicando que o procedimento de calibração CIMEC por pixel âncora não é satisfatório. O STEEP foi o único modelo com desempenho positivo entre os modelos SEB, indicando que a correção de calibração dos pixels âncora por Priestley-Taylor foi essencial para seu desempenho, uma vez que STEEP_spf não obteve bons resultados.

Tabela 10. Métricas Estatísticas PMM.

Modelo	R ²	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,573883	8,023663	-9,51785	0,446663	75,75507
STEEP_spf	0,585417	21,50681	-73,241	-2,97554	76,51253
SEBAL	0,625081	21,42913	-73,7226	-2,94687	79,06203
S-SEBI	0,62501	21,43093	-75,6948	-2,94754	79,0576
MOD16	0,625285	6,911323	-4,15299	0,589449	79,07495

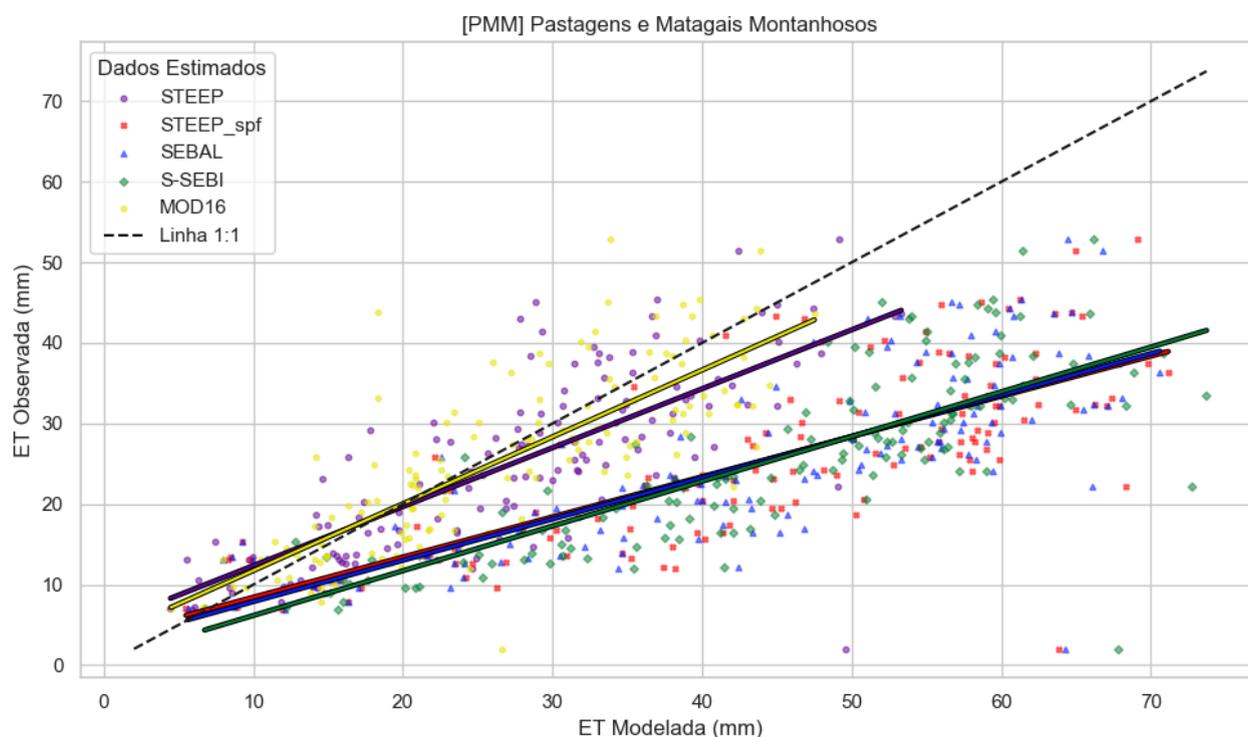


Figura 10. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo localizada em PMM na escala temporal de ET acumulada de 8 dias.

O destaque considerável do MOD16 e STEEP dos demais modelos SEB, mostra que a metodologia de seleção de pixels âncora convencional não tem boa aplicabilidade em PMM, sem a consideração do λ ET remanescente pelo método de Priestley-Taylor, evidenciando que esse fator abordado no STEEP exerce grande influência para a melhor estimativa em PMM. A proximidade de desempenho dos três modelos SEB indica que, sem a correção dos pixels de membros finais, o STEEP_spf se equipara ao SEBAL e S-SEBI, revelando que os demais parâmetros abordados pelo modelo podem ser irrelevantes se não somados com a correção de Priestley-Taylor.

Pastagens, savanas e matagais Tropicais e Subtropicais (PTS)

No bioma PTS observa-se através da Tabela 11 e Figura 11, que o S-SEBI e STEEP destacaram-se por apresentar bons parâmetros estatísticos para a estimativa de ET. O S-SEBI é o modelo que possui menor tendência de erro (RMSE = 5,887), com baixo viés (PBIAS = -2,108%) e único NSE positivo (0,196), indicando ser o modelo mais eficaz para estimar a ET em PTS. O STEEP é o segundo melhor modelo com menor tendência de erro (RMSE = 7,337), possui a melhor capacidade de capturar a variabilidade dos dados observados ($R^2 = 0,570$), tem um bom alinhamento no PBIAS (-1,742118), e o maior PC (75,55%), indicando boa correlação com os dados observados. Os modelos STEEP_spf e SEBAL apresentaram desempenhos razoáveis, com R^2 semelhantes aos demais modelos, uma tendência de erro levemente superior ao STEEP (RMSE > 7,6), porém com PBIAS altos, demonstrando um alto viés de superestimativa. O MOD16 foi o modelo que apresentou o pior desempenho em todos indicadores, mostrando grande dificuldade em estimar a ET em PTS de forma confiável.

O bom desempenho geral dos modelos SEB sobre o MOD16 demonstra a maior facilidade de seleção dos pixels pelo método CIMEC, tendo boa aplicabilidade em PTS por se tratar de regiões de vegetação de pastagem e homogêneas, atendendo mais facilmente os critérios de disponibilidade de energia (Tang et al., 2024). Por não ter a caracterização de limitação hídrica nessas regiões e as gramíneas (C4) mais comuns terem a capacidade de manter a fotossíntese em baixa umidade (Strongberg, 2011), a relevância da umidade do solo, e a representação robusta da estrutura lenhosa não são fatores decisivos para a estimativa de ET em PTS. Isso justifica o S-SEBI como o modelo

que melhor representa a ET nessas regiões, devido a simplicidade de seu algoritmo ao considerar menos fatores, e conseqüentemente, carregar menos incertezas em sua estimativa. Apesar disso, o STEEP ainda tem bons resultados devido a uma seleção de pixels âncora aprimorada.

Tabela 11. Métricas Estatísticas PTS.

Modelo	R ²	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,570819	7,337859	-1,742118	-0,247539	75,552582
STEEP_spf	0,508959	8,290248	-26,632954	-0,592394	71,341328
SEBAL	0,537238	7,621978	-20,525449	-0,346018	73,296510
S-SEBI	0,498533	5,887830	-2,108962	0,196796	70,606902
MOD16	0,480413	11,476488	-30,503492	-2,051642	69,311860

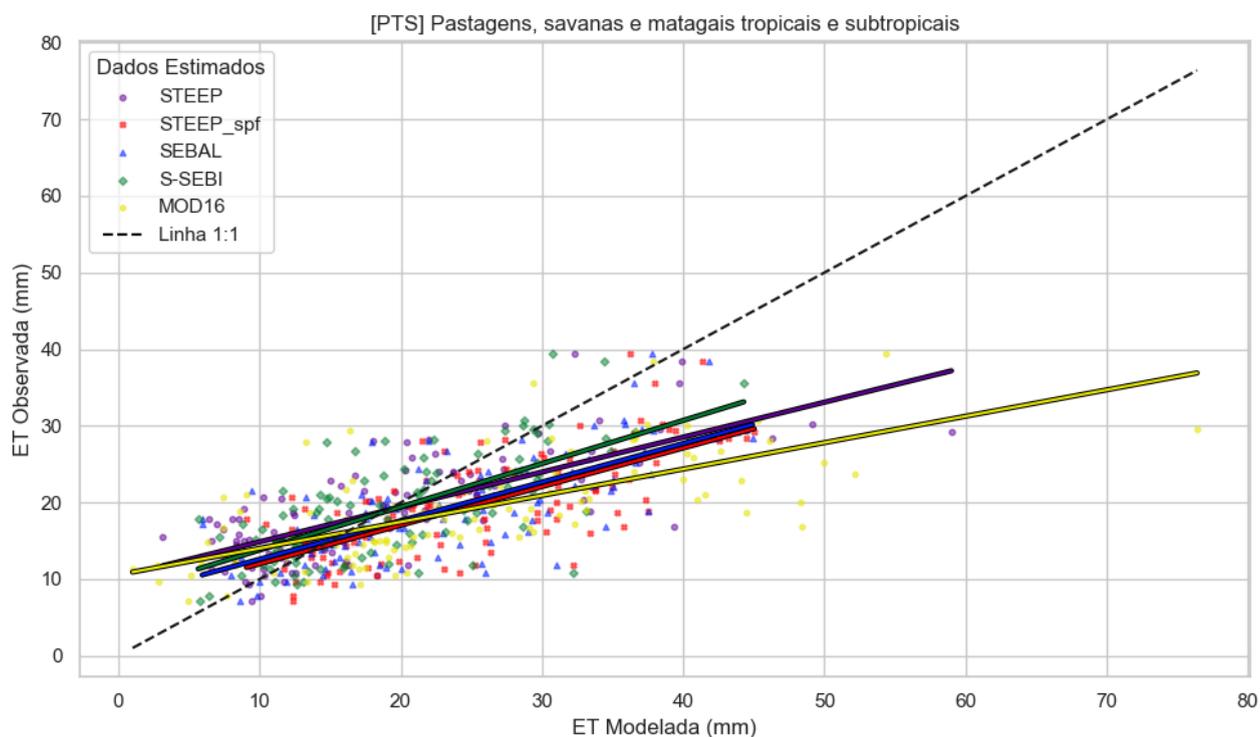


Figura 11. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo localizada em PTS na escala temporal de ET acumulada de 8 dias.

Florestas Temperadas de Coníferas (FTC)

Observando a Tabela 12 e Figura 12 nota-se que o MOD16 apresenta um distanciamento considerável aos demais modelos com um desempenho mais condizente com as FTC, apresentando menor tendência de erro (RMSE = 7,043), menor viés de subestimação (PBIAS = 1,232%), único NSE positivo (0,286) e bons parâmetros gerais de R² e PC. Fica evidente que os modelos SEB no geral não possuem respostas satisfatórias para as FTC com STEEP_spf, SEBAL e S-SEBI apresentando grandes taxas de erro entre a estimativa do modelo e o valor observado (RMSE > 12). Porém ainda assim, o STEEP consegue apresentar respostas relativamente positivas em relação aos outros modelos SEB, com a menor taxa de erro (RMSE = 9,203), menor viés (PBIAS = 11,361%) e maior NSE (NSE = -0,217) entre eles.

Apesar dos modelos SEB não responderem bem às FTC, o destaque do STEEP evidencia que a complexidade abordada por este modelo, especialmente com a correção dos pixels âncora pelo método de Priestley-Taylor, foi um fator decisivo para a melhor representação da ET nessas áreas. Mesmo o STEEP_spf apresentou uma correlação ligeiramente superior com os dados observados em relação ao SEBAL e S-SEBI, indicando que a representação da fenologia e a umidade do solo são fatores potencialmente relevantes para a estimativa de ET em FTC.

Tabela 12. Métricas Estatísticas FTC.

Modelo	R ²	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,338238	9,203262	11,36152	-0,21723	58,15824
STEEP_spf	0,496807	12,94854	-51,9989	-1,40951	70,48456
SEBAL	0,489748	13,48486	-56,3845	-1,61325	69,98198
S-SEBI	0,434293	13,38629	-55,8648	-1,57518	65,9009
MOD16	0,428603	7,043722	1,232798	0,286996	65,4678

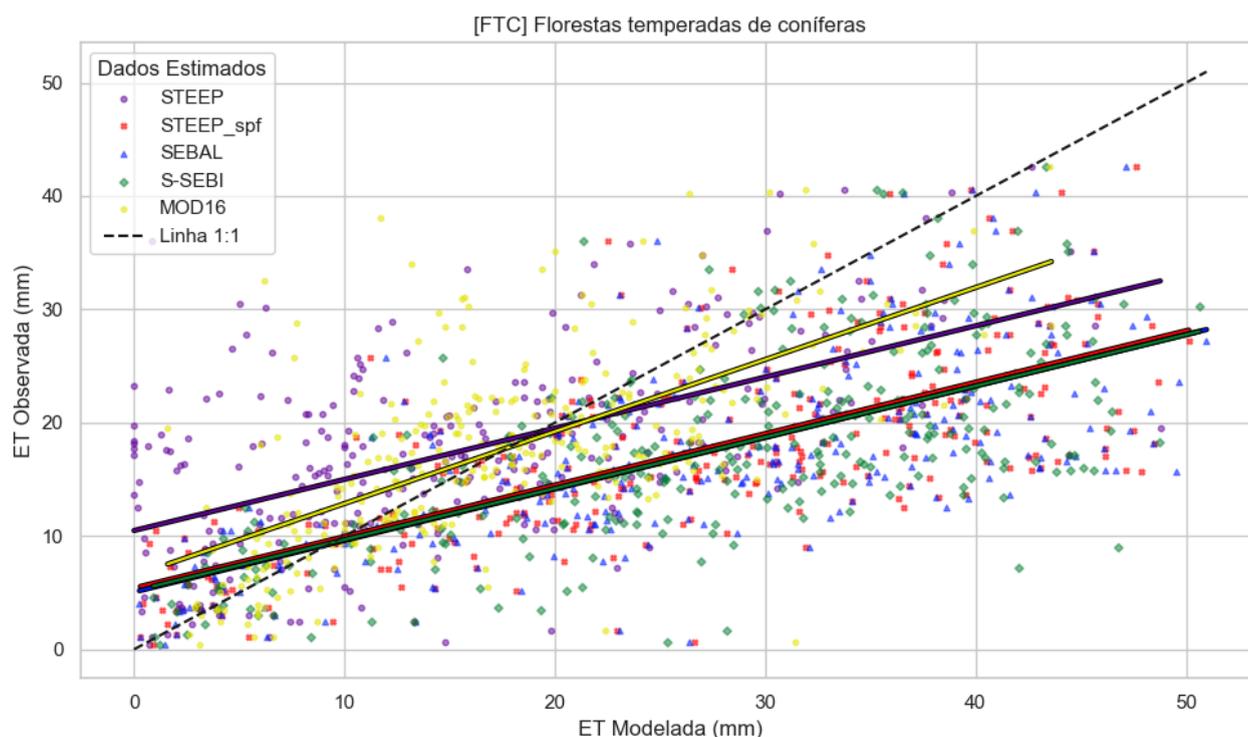


Figura 12. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações das torres de fluxo localizadas em FTC na escala temporal de ET acumulada de 8 dias.

Florestas Temperadas de Folhas Largas e Mistas (FTLM)

Percebe-se na Figura 13 que as regressões lineares dos modelos não se aproximam adequadamente dos dados observados (Linha 1:1), com todos os modelos apresentando alto viés de superestimativa (PBIAS < -21%). Observando a tabela 13, o modelo MOD16 se destaca como o melhor entre os avaliados em FTLM, apresentando o maior R^2 (0,843) e PC (91,86%), demonstrando boa capacidade de explicar a variabilidade dos dados e uma forte correlação com os valores observados. Ele também possui o menor RMSE (6,47) e único NSE positivo, indicando ser o modelo mais preciso nas estimativas. O STEEP ocupa a segunda posição, sendo o modelo SEB que melhor estima a ET em FTLM, com o segundo menor RMSE (7,455), um bom R^2 (0,608353) e PC (77,99%), além de um PBIAS relativamente baixo (-21,87%), demonstrando o viés menor de superestimativa em comparação aos outros modelos. Os demais modelos apresentam desempenho inferior com maior RMSE (>7,9) e NSE negativos, indicando baixa eficiência, com o SEBAL tendo os resultados mais razoáveis, seguido pelo S-SEBI e pelo STEEP_spf que demonstra ter o pior desempenho em FTLM.

A perda de folhas no inverno e outono, característica da vegetação decídua das FTLM, resultante da limitação hídrica causada por congelamento (Ciesla, 2011) é um fator melhor representado pelo STEEP, que através do PAI, consegue representar as alterações fenológicas da vegetação ao longo do ano, que justifica seu melhor desempenho entre os modelos SEB. Apesar disso, devido à umidade e precipitação uniforme durante todo o ano (Andorfer et al., 2010; Ciesla, 2011; Knudsen et al., 2017), a representação de umidade do solo, tem baixa relevância para a estimativa de ET nas FTLM que pode ter provocado uma aproximação do STEEP com SEBAL e S-SEBI e uma pior estimativa do STEEP_spf. A correção dos pixels de membros finais se mostrou eficiente devido a disparidade entre a eficiência do STEEP com e sem esta correção.

Tabela 13. Métricas Estatísticas FTLM.

Modelo	R ²	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,608353	7,45535	-21,8743	-0,43948	77,99699
STEEP_spf	0,516833	10,34331	-50,7324	-1,49571	71,89108
SEBAL	0,428849	7,910362	-27,2512	-0,45971	65,48655
S-SEBI	0,397952	8,702439	-31,7932	-0,76668	63,08343
MOD16	0,843839	6,471983	-46,7246	0,022875	91,86069

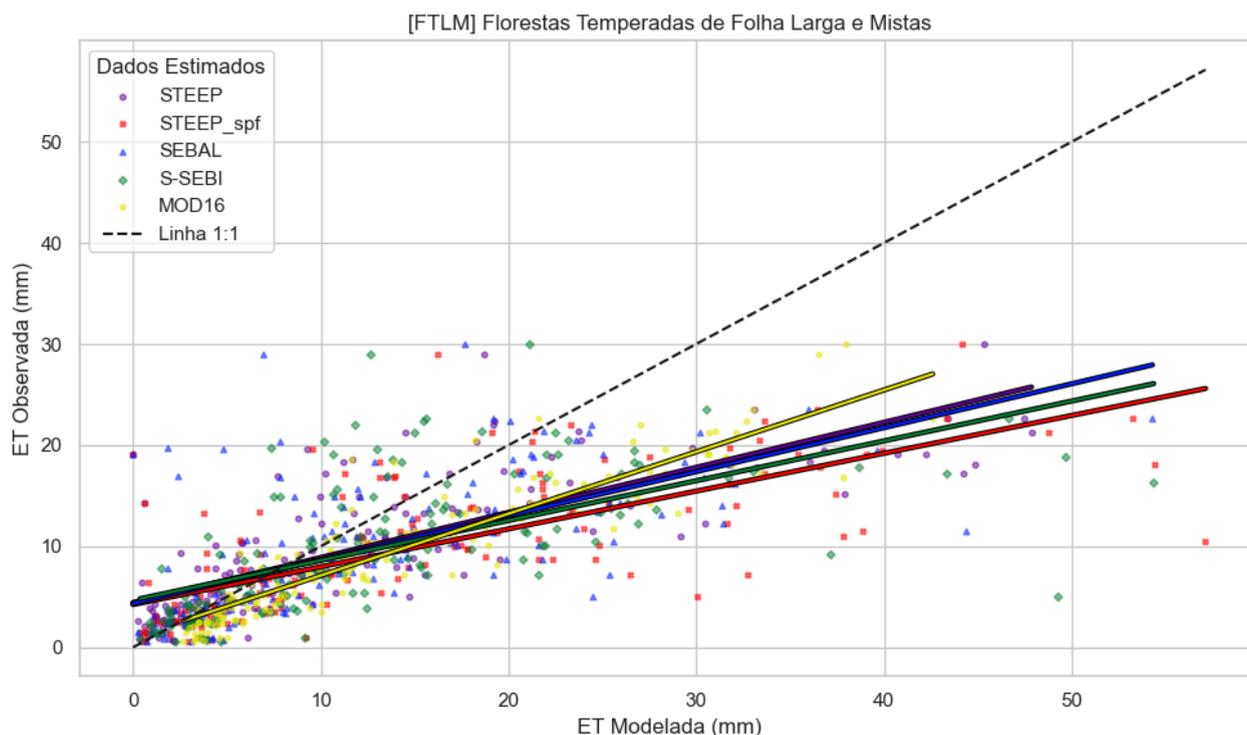


Figura 13. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações das torres de fluxo localizadas em FTLM na escala temporal de ET acumulada de 8 dias

Pradarias Temperadas, Savanas e Matagais (PTSM)

De acordo com a Tabela 14 e Figura 14 é possível notar que a regressão linear de nenhum dos modelos se adequa bem aos dados observados (linha 1:1) com todos os modelos obtendo valores de R^2 baixos ($< 0,369$) e valores de NSE negativos ($< -0,209$). Diferente das PTS as PTSM caracterizam-se por sua limitação hídrica (Sala, 2001) que tornam a disponibilidade de água no solo um fator importante para a ET do bioma, isso é evidenciado pelo o STEEP ser o modelo com melhor desempenho geral, que além de abordar esse fator, a correção dos pixels âncora se mostrou eficaz (STEEP $>$ STEEP_spf). Além disso o STEEP se destaca com o maior R^2 (0,369), menor erro absoluto (RMSE= 5,026), menor tendência de viés (PBIAS = 1,223%) e maior PC (60,77%), sendo o modelo com a melhor representação de estimativa de ET nas PTSM. O S-SEBI possui boas métricas estatísticas em relação a tendência de erro com um RMSE baixo (6,171) e um PBIAS intermediário (-16,315) que tende à superestimativa, isso se deve a simplicidade de seu algoritmo corresponder bem a um ambiente com coberturas mais homogêneas, que atende mais facilmente os critérios de disponibilidade de energia. Mesmo assim o S-SEBI apresenta baixa correlação com os dados observados (PC =

35,83), limitando sua confiabilidade em estimativas de ET. O SEBAL apresenta um RMSE (7,799) e PC (49,899) moderados, mas com baixo R^2 , NSE e com altas tendências a superestimar a ET no bioma (PBIAS = -41,954), não sendo o melhor modelo para estimativa em PTSM. O STEEP_spf e MOD16 apresentam parâmetros estatísticos insatisfatórios para a região, apresentando um alto índice de erro das estimativas (RMSE > 9) e baixa correlação com os dados observados (PC < 2%) respectivamente.

Tabela 14. Métricas Estatísticas PTSM.

Modelo	R^2	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,369403	5,026141	1,223136	-0,20937	60,77853
STEEP_spf	0,29861	9,546136	-57,5196	-3,3626	54,64518
SEBAL	0,249	7,799868	-41,954	-1,91249	49,8999
S-SEBI	0,128385	6,171627	-16,315	-0,82343	35,8308
MOD16	0,000301	6,43797	33,15419	-0,98421	1,734775

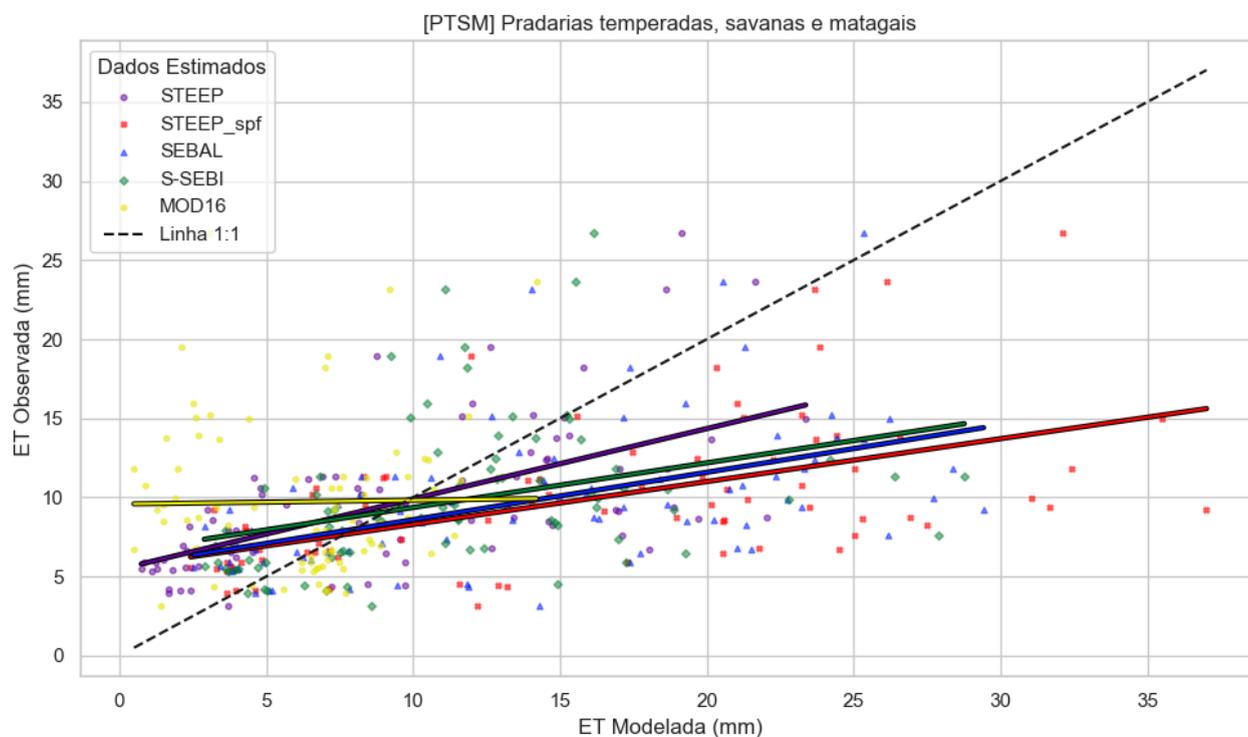


Figura 14. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações das torres de fluxo localizadas nas PTSM na escala temporal de ET acumulada de 8 dias

Florestas secas tropicais e subtropicais de folhas largas (FSTS)

Observando a Figura 15 nota-se que a regressão linear do STEEP quase se sobrepõe aos dados observados, o MOD16 também apresenta bom alinhamento com a Linha:1:1. Na Tabela 14 o modelo STEEP destaca-se como o mais equilibrado, com o maior R^2 (0,69), menor RMSE (4,98), e PBIAS mais próximo de zero (1,61), indicando alta precisão e baixa tendência de viés. Além disso, seu NSE (0,69) e PC (83.42%) reforçam sua eficiência e correlação com os dados observados, sendo o modelo mais confiável para estimativas precisas de ET na FSTS. O bom desempenho do modelo já era esperado, pois ele incorpora as características das FSTS, e os testes robustos realizados por Bezerra et al. (2023) reforçam esses resultados. O MOD16 apresenta bons parâmetros com valores próximos ao STEEP em quase todas as métricas, mesmo apresentando um leve viés de superestimativa, ainda demonstra precisão e baixa tendência de viés, tornando-o uma escolha alternativa robusta. O S-SEBI ocupa uma posição intermediária, com bom R^2 (0,69), RMSE (5,28), e NSE (0,65). No entanto, seu PBIAS (-10.75) sugere uma maior superestimativa em relação aos dois primeiros modelos, o que pode comprometer a precisão da estimativa de ET nesse cenário. Já o SEBAL e o STEEP_spf apresentam desempenhos inferiores, com RMSE mais elevados (>7,5) e PBIAS altos (< -50,65%), indicando tendência acentuada de superestimativa dos dados tornando os modelos menos confiáveis para estimativa de ET nas FSTS.

Tabela 15. Métricas Estatísticas FSTS.

Modelo	R^2	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,696044	4,986131	1,613534	0,693253	83,429277
STEEP_spf	0,680644	9,618152	-77,996038	-0,141394	82,501125
SEBAL	0,598818	7,704127	-50,800063	0,267683	77,383307
S-SEBI	0,692124	5,280471	-9,755065	0,655969	83,193979
MOD16	0,682588	5,337155	-6,643580	0,648543	82,618867

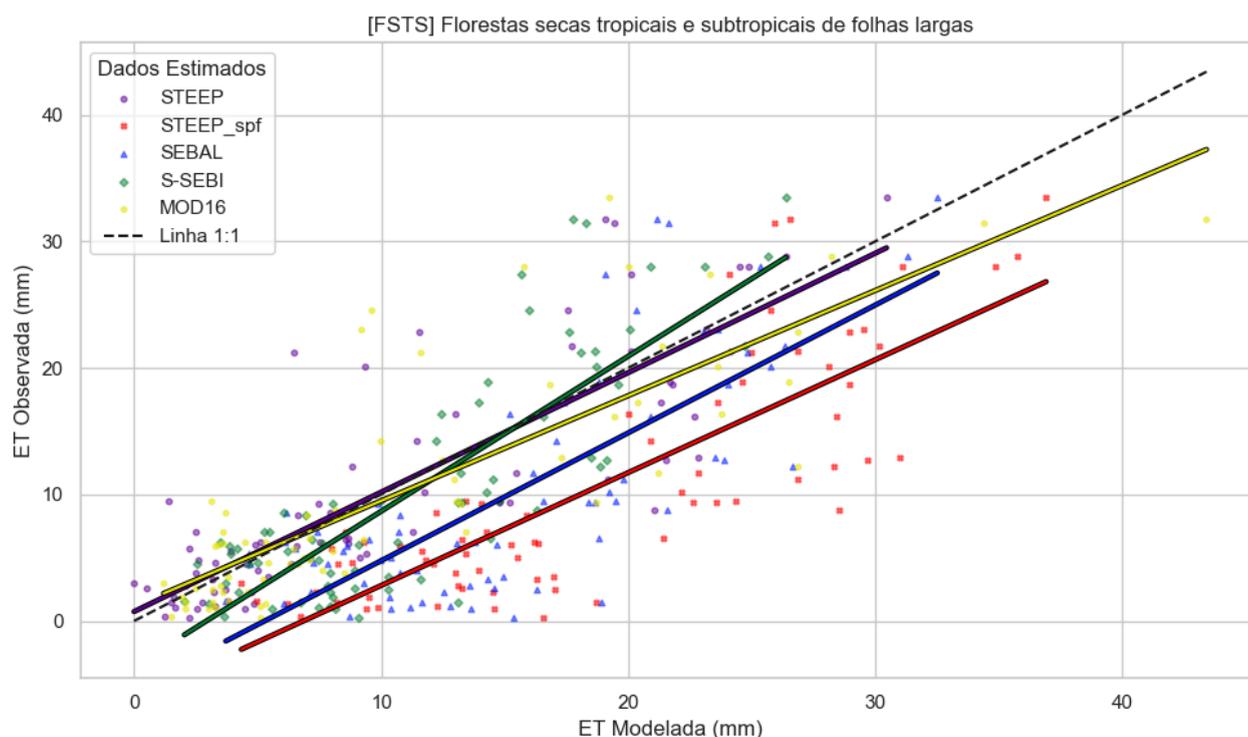


Figura 15. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações das torres de fluxo localizadas nas FSTS na escala temporal de ET acumulada de 8 dias

Análise Global

De forma resumida a Tabela 16 apresenta quais modelos obtiveram o melhor e o segundo melhor desempenho estatístico relativo em relação a cada bioma estudado. O STEEP foi o modelo com maior destaque, obtendo o melhor desempenho relativo em 3 dos 9 biomas estudados, e o segundo melhor desempenho em 4 dos 9 biomas, só não obtendo um desempenho aceitável em FUTS. Após o STEEP os modelos com o melhor desempenho para o pior desempenho respectivamente foram: MOD16, S-SEBI, SEBAL e STEEP_spf.

Tabela 16. Melhores modelos por Bioma.

Bioma	Melhor desempenho	2º melhor desempenho
FUTS	S-SEBI	SEBAL
PSI	STEEP_spf	SEBAL
FBMM	STEEP	MOD16
PMM	MOD16	STEEP

PTS	S-SEBI	STEEP
FTC	MOD16	STEEP
FTLM	MOD16	STEEP
PTSM	STEEP	S-SEBI
FSTS	STEEP	MOD16

Através da análise dos parâmetros individuais de torre a torre do anexo A, é possível notar a frequência com que cada modelo teve o melhor desempenho em cada indicador estatístico. A figura 16 resume o número de torres em que cada modelo demonstrou melhor desempenho em relação ao total de torres avaliadas. O STEEP se destacou com um desempenho geral consistente em múltiplos indicadores, com destaque para RMSE, PBIAS e NSE onde mais frequentemente foi o modelo de melhor resultado, e apresentou destaques consistentes em R^2 e PC. Isso sugere boa capacidade geral do modelo de estimar valores próximos aos observados, com baixo viés de superestimativa ou subestimativa. O MOD16 apresenta resultados similares, com um desempenho acima da média dos modelos analisados, se destacando com frequência em alguns biomas. Também vale ressaltar que o S-SEBI, apesar da simplicidade de algoritmo e não se destacar com frequência, apresentou uma performance equilibrada e consistente.

	<i>Número de Torres com melhor desempenho do modelo / Total de torres</i>				
Modelo	R^2	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	4/18	7/18	7/18	7/18	4/18
STEEP_spf	4/18	1/18	1/18	1/18	4/18
SEBAL	2/18	2/18	1/18	2/18	1/18
S-SEBI	4/18	3/18	4/18	4/18	2/18
MOD16	4/18	5/18	5/18	4/18	7/18

Menor frequência

Maior Frequência



Figura 16. *Frequência de destaque de cada modelo por bioma.*

Os algoritmos em sua gama de complexidade, demonstraram diferentes comportamentos de acordo com a variação de latitude, altitude, umidade, clima e vegetação ao longo da análise das 18 torres de fluxo entre 9 biomas distintos. O S-SEBI se destacou principalmente em ambientes caracterizados por um clima Tropical ou Subtropical como em FUTS, PTS, PTSM e FSTS com resultados estáveis de RMSE entre 5,28 - 6,35 mm/8d com um destaque para regiões de pastagem de PTS, que registrou o melhor resultado entre os modelos, e PTSM que obteve a segunda melhor métrica estatística. Por outro lado, em regiões temperadas, sub árticas ou de clima mediterrânico de baixas temperaturas como em FBMM, PMM, FTC e FTLM o modelo obteve baixa concordância de acordo com os dados observados com um RMSE de 8,70 - 21,50 mm/8d. O S-SEBI é um modelo que estima a ET considerando como seu principal componente a relação entre a temperatura de superfície terrestre (T_s) e albedo nos pixels âncora, para determinar a fração evaporativa (Sobrinho et al., 2005; Rocha et al., 2020), portanto, a estimativa adequada de T_s e a disponibilidade de energia no local de análise são aspectos importantes para o funcionamento desse modelo (Abid et al., 2019). Apesar disso, o S-SEBI demonstrou com sua simplicidade de algoritmo, que ao considerar menos variáveis, carrega poucas incertezas para a estimativa de ET e consequentemente, resultados mais estáveis para diferentes vegetações.

O SEBAL obteve menos destaque entre os modelos do estudo, apresentando bons resultados em FUTS e PSI com RMSE de 6,83 - 7,79 mm/8d, e resultados relativamente razoáveis em áreas de pastagem como PTS e PTSM com RMSE de 7,62 - 7,79 mm/8d. Com isso o SEBAL obtém resultados satisfatórios, principalmente em áreas homogêneas, com disponibilidade hídrica e de energia para uma estimativa adequada de H e consequentemente ET. Em biomas caracterizados pela limitação hídrica, ou por uma vegetação decídua com variação fenológica como em FTLM e FSTS o modelo apresenta limitações na estimativa de ET em relação aos demais.

O MOD16 tem bom desempenho em áreas temperadas e sub árticas com disponibilidade hídrica e baixa variação de umidade ao longo do ano (Hu et al., 2015), como é demonstrado sendo o melhor modelo em PMM, FTC e FTLM com RMSE de 6,47 - 7,04 mm/8d. Porém o modelo apresenta limitações em locais que apresentam uma estação seca bem definida, áreas semiáridas (Velpuri et. al., 2013), savanas florestais (Ramoelo et. al., 2014; Hu et al., 2015) e florestas (Jang et. al., 2013; Hu et al., 2015; Tang et. al., 2015) como é evidenciado com seu desempenho em FUTS, PSI e PTS com

RMSE de 11,47 - 16,81 mm/8d. Com a inclusão do MOD16 no estudo, foi possível ter um parâmetro de comparação externo aos modelos SEB, identificando possíveis limitações da metodologia, como ocorreu em PMM e FTC, uma vez que fica explícito a existência de uma lacuna entre o desempenho do MOD16 e de modelos SEB sem calibração de pixels âncora.

O STEEP foi o modelo que se destacou em locais marcados por uma estação seca bem definida e de características de limitação hídrica do solo ou das plantas como é o caso das PSI, FBMM, PTSM e FSTS sendo o modelo com melhores resultados nessas regiões com um RMSE 4,98 - 9,65 mm/8d. O modelo teve boas respostas em biomas marcados por uma vegetação decídua devido à sua maior capacidade de representar a variabilidade fenológica da planta ao longo do ano, com parâmetros de representação mais robustos para o z0m através do PAI. Esse fator foi relevante nas estimativas de ET em FTC, FTLM e FSTS onde o STEEP obteve a melhor concordância entre os modelos SEB.

A análise com a distinção entre STEEP e STEEP_spf permitiu a identificação da relevância da consideração do teor de umidade residual na calibração dos pixels âncora através da equação de Priestley-Taylor na estimativa de ET. De acordo com os dados, todos os biomas, com exceção de PSI, a calibração do pixels âncora se mostrou ser o principal fator de destaque do STEEP, principalmente em FBMM, PMM e FTC, pois o procedimento CIMEC tradicional para seleção de pixels âncora se mostrou ineficiente. Isso ocorre pois com a calibração por Priestley-Taylor a estimativa de H se torna mais confiável nos pixels de membros finais, e conseqüentemente, a estimativa de ET é melhorada, conforme também evidenciado pelo estudo de Singh e Irmak (2011).

Em contrapartida, o STEEP não se destacou em regiões úmidas de baixa variabilidade de precipitação ao longo do ano ou que não apresentam característica de limitação hídrica, como é o caso de FUTS, onde ele apresentou o pior desempenho relativo entre os modelos SEB com um RMSE de 8,33 mm/8d, em FTLM onde obteve resultados semelhantes ao SEBAL e S-SEBI com RMSE de 7,45 - 8,70 mm/8d. E em locais onde há vegetação perenifolia ou que a fenologia da planta não apresenta alterações significativas durante o ano como em FUTS, citado anteriormente, FBMM que apesar de se destacar apresentou um RMSE alto de 9,65 mm/8d e PTS que obteve desempenho inferior ao S-SEBI com um RMSE de 7,33 mm/8d.

Isso ocorre pois os parâmetros adicionais de consideração de umidade no solo, e representação da fenologia da vegetação podem carregar incertezas em ambientes onde esses parâmetros não são relevantes. Em suma o STEEP obteve resultados inferiores ou equivalentes a outros modelos SEB em áreas de vegetação homogênea e de disponibilidade hídrica, que são regiões onde se obtêm estimativas de ET mais comumente precisas e consistentes em diferentes produtos globais (Tang et al., 2024). Porém em ambientes de vegetação heterogênea, de clima árido e semi-árido e principalmente em locais com limitação de água, que demonstram ter uma maior lacuna na precisão de estimativa de ET em diversos estudos (Gokmen et al., 2012; Paul et al., 2014; Trebs et al., 2021; Tang et al., 2024), o STEEP demonstrou um avanço significativo em relação a outros modelos SEB.

6. Conclusões

Os resultados deste estudo destacam a influência significativa das especificidades das condições climáticas e da vegetação no comportamento para as estimativas de ET, particularmente em ecorregiões ou biomas complexos. Ao analisar as séries temporais e os padrões espaciais de ET estimadas por diferentes modelos SEB em coberturas do solo e em diferentes biomas, evidencia-se que a escolha do modelo desempenha um papel crucial na representação desses processos biofísicos para a representação da ET. É possível notar que o desempenho dos modelos STEEP, SEBAL e S-SEBI se destacam em diferentes biomas, ao atenderem a diferentes critérios na estimativa de ET.

- O MOD16 apresentou maior desempenho em áreas de baixas temperaturas de clima temperado ou sub-ártico, e com disponibilidade hídrica, como nos biomas PMM, FTC e FTLM. Porém apresenta limitações em biomas com estação seca bem definida, de vegetação florestal ou de savana florestal como em FUTS, PSI e PTS.
- O S-SEBI possui boas estimativas de ET em locais em que o ambiente atende mais facilmente os critérios de disponibilidade de energia, como em áreas de pastagem, e em locais de clima tropical. Como foi observado nas análises nos pontos de pastagem na BRS, e nos biomas FUTS, PTS e PTSM. Por outro lado apresentou limitações principalmente em locais de baixa temperatura, como de clima temperado, sub-ártico ou mediterrâneos observado nas análises de FBMM, PMM, FTC e FTLM.

- O SEBAL obteve melhor desempenho relativo em áreas de vegetação homogênea, com disponibilidade hídrica como em PTS e PSI. E apresentou limitações em locais que apresentam limitação hídrica, e variação fenológica da vegetação durante o ano, como em FSTS e FTLM.
- O STEEP obteve os melhores resultados gerais em relação aos demais modelos, se destacando principalmente em áreas com vegetação heterogênea, que apresentam alterações fenológicas durante o ano e em cenários de escassez de água. Como ficou evidenciado na ecorregião e vegetação da Caatinga, e nos biomas FBMM, PTSM, FTLM e FSTS. Em contrapartida apresentou limitações em locais de regiões úmidas e de vegetação perenifólia como em FUTS.
- A calibração dos pixels âncora incorporada através da equação de Priestley-Taylor foi um fator decisivo tanto para o desempenho do STEEP em si, quanto em relação aos demais modelos SEB, principalmente em FBMM, PMM e FTC. O resultado da estimativa de ET é muito sensível à escolha dos pixels âncora em modelos SEB, portanto a calibração provoca mudanças positivas significativas.

Conclui-se que em biomas homogêneos com disponibilidade hídrica como PTS, a complexidade de um modelo como o STEEP pode carregar incertezas em variáveis pouco relevantes, como a disponibilidade de água no solo em ambientes úmidos, e fenologia de planta para vegetações perenifólias, onde um modelo de maior simplicidade como o S-SEBI obteve resultados consistentes. Nenhum dos modelos estudados foi capaz de representar a ET de forma precisa em todos os nove biomas estudados, onde cada algoritmo apresentou suas particularidades. Entretanto, se tratando de biomas com uma maior sazonalidade fenológica, onde caracteriza-se uma lacuna na precisão de estimativa da ET por diversos produtos globais, um modelo SEB como o STEEP que preconiza a representação da sazonalidade fenológica indicou um avanço na melhoria da estimativa de ET, especialmente em áreas de limitação hídrica.

7. Perspectivas Futuras

Com base nos resultados obtidos, algumas direções promissoras podem ser exploradas para melhorar a estimativa de ET em diversos ecossistemas e biomas do mundo.

- Hibridização de modelos: A combinação de diferentes modelos pode potencializar

a acurácia das estimativas de ET. A abordagem híbrida pode unir as diferentes qualidades de dois modelos distintos para a melhor representação das particularidades de um bioma analisado.

- Incorporação de técnicas de *Machine Learning*: A utilização de machine learning pode trazer avanços significativos para a calibração de modelos de ET. Técnicas como redes neurais, *random forest*, e aprendizado supervisionado poderiam ser treinados com dados locais para identificar padrões fenológicos e hídricos e aplicar as devidas abordagens, melhorando a precisão das estimativas em diferentes biomas.
- Modelo adaptativo e automatizado: Desenvolver um algoritmo que integre múltiplos modelos de ET e seja capaz de testar e identificar qual deles fornece o melhor resultado para uma região específica. Esse sistema dinâmico poderia ajustar-se às condições ambientais locais, de forma a garantir maior precisão e confiabilidade nas estimativas.

Essas estratégias podem contribuir para uma estimativa mais precisa e robusta da ET, respondendo às lacunas dos modelos estudados no presente trabalho e promovendo uma melhor compreensão dos processos hídricos em diferentes biomas.

Referências

- Abid, N., Mannaerts, C. M., & Bargaoui, Z. (2019). Sensitivity of actual evapotranspiration estimation using the sebs model to variation of input parameters (LST, DSSF, aerodynamics parameters, LAI, FVC). In 4th ISPRS Geospatial Week 2019 (pp. 1193-1200). *International Society for Photogrammetry and Remote Sensing (ISPRS)*.
- Agee, J. K. (1993). *Fire ecology of Pacific Northwest forests* (Vol. 499). Washington, DC: Island press.
- Aguilar, A. L., Flores, H., Crespo, G., Marín, M. I., Campos, I., & Calera, A. (2018). Performance assessment of MOD16 in evapotranspiration evaluation in Northwestern Mexico. *Water*, 10(7), 901.
- Allen, R. G., Burnett, B., Kramber, W., Huntington, J., Kjaersgaard, J., Kilic, A., ... & Trezza, R. (2013). Automated calibration of the metric-landsat evapotranspiration process. *JAWRA Journal of the American Water Resources Association*, 49(3), 563-576.
- Allen, R. G., Pereira, L. S., Howell, T. A., & Jensen, M. E. (2011). Evapotranspiration information reporting: I. Factors governing measurement accuracy. *Agricultural Water Management*, 98(6), 899-920.
- Allen, R. G., Tasumi, M., & Trezza, R. (2007). Satellite-based energy balance for mapping evapotranspiration with internalized calibration (METRIC)—Model. *Journal of irrigation and drainage engineering*, 133(4), 380-394.
- Anapalli, S. S., Ahuja, L. R., Gowda, P. H., Ma, L., Marek, G., Evett, S. R., & Howell, T. A. (2016). Simulation of crop evapotranspiration and crop coefficients with data in weighing lysimeters. *Agricultural Water Management*, 177, 274-283.
- Anapalli, S. S., Fisher, D. K., Reddy, K. N., Wagle, P., Gowda, P. H., & Sui, R. (2018). Quantifying soybean evapotranspiration using an eddy covariance approach. *Agricultural Water Management*, 209, 228-239.
- Andrade, J., Cunha, J., Silva, J., Rufino, I., & Galvão, C. (2021). Evaluating single and multi-date Landsat classifications of land-cover in a seasonally dry tropical forest. *Remote Sensing Applications: Society and Environment*, 22, 100515.
- Andrade, N. L. R., Sandwiches, L., Zeilhofer, P., João, G., Gutieres, C. B., & Carlo, R. D. (2023). Different spatial and temporal arrangements for validating the latent heat flux

obtained using the MOD16 product in a forest in the Western Amazon. *Int. J. Hydro*, 7, 18-25.

Archibold, O. W. (2012). *Ecology of world vegetation*. Springer Science & Business Media.

Arndorfer, M., Angelova, S., Balazs, K., Bogers, M. M., Centeri, C., Choisis, J. P., ... & Zanetti, T. (2010). Delimitation of BIOBIO case study regions and the selection of case study farms.

Aubinet, M., Vesala, T., & Papale, D. (Eds.). (2012). *Eddy covariance: a practical guide to measurement and data analysis*. Springer Science & Business Media.

Baldocchi, D. D. (2003). Assessing the eddy covariance technique for evaluating carbon dioxide exchange rates of ecosystems: past, present and future. *Global change biology*, 9(4), 479-492.

Baldocchi, D. D., & Xu, L. (2007). What limits evaporation from Mediterranean oak woodlands—the supply of moisture in the soil, physiological control by plants or the demand by the atmosphere?. *Advances in Water Resources*, 30(10), 2113-2122.

Baldocchi, D. D., Hincks, B. B., & Meyers, T. P. (1988). Measuring biosphere-atmosphere exchanges of biologically related gases with micrometeorological methods. *Ecology*, 69(5), 1331-1340.

Baldocchi, D. D., Xu, L., & Kiang, N. (2004). How plant functional-type, weather, seasonal drought, and soil physical properties alter water and energy fluxes of an oak–grass savanna and an annual grassland. *Agricultural and Forest Meteorology*, 123(1-2), 13-39.

Baldocchi, D., Falge, E., Gu, L., Olson, R., Hollinger, D., Running, S., ... & Wofsy, S. (2001). FLUXNET: A new tool to study the temporal and spatial variability of ecosystem-scale carbon dioxide, water vapor, and energy flux densities. *Bulletin of the American Meteorological Society*, 82(11), 2415-2434.

Balzarolo, M., Boussetta, S., Balsamo, G., Beljaars, A., Maignan, F., Calvet, J. C., ... & Papale, D. (2014). Evaluating the potential of large-scale simulations to predict carbon fluxes of terrestrial ecosystems over a European Eddy Covariance network. *Biogeosciences*, 11(10), 2661-2678.

Barraza, V., Restrepo-Coupe, N., Huete, A., Grings, F., Beringer, J., Cleverly, J., & Eamus, D. (2017). Estimation of latent heat flux over savannah vegetation across the North

Australian Tropical Transect from multiple sensors and global meteorological data. *Agricultural and Forest Meteorology*, 232, 689-703.

Bastiaanssen, W. G. M. (2000). SEBAL-based sensible and latent heat fluxes in the irrigated Gediz Basin, Turkey. *Journal of hydrology*, 229(1-2), 87-100.

Bastiaanssen, W. G. M., Noordman, E. J. M., Pelgrum, H., Davids, G., Thoreson, B. P., & Allen, R. G. (2005). SEBAL model with remotely sensed data to improve water-resources management under actual field conditions. *Journal of irrigation and drainage engineering*, 131(1), 85-93.

Bastiaanssen, W. G., Ahmad, M. U. D., & Chemin, Y. (2002). Satellite surveillance of evaporative depletion across the Indus Basin. *Water resources research*, 38(12), 9-1.

Bastiaanssen, W. G., Menenti, M., Feddes, R. A., & Holtslag, A. A. M. (1998). A remote sensing surface energy balance algorithm for land (SEBAL). 1. Formulation. *Journal of hydrology*, 212, 198-212.

Beck, H. E., McVicar, T. R., Vergopolan, N., Berg, A., Lutsko, N. J., Dufour, A., ... & Miralles, D. G. (2023). High-resolution (1 km) Köppen-Geiger maps for 1901–2099 based on constrained CMIP6 projections. *Scientific data*, 10(1), 724.

Beringer, J., Hutley, L. B., McHugh, I., Arndt, S. K., Campbell, D., Cleugh, H. A., ... & Wardlaw, T. (2016). An introduction to the Australian and New Zealand flux tower network–OzFlux. *Biogeosciences*, 13(21), 5895-5916.

Besnard, S., Carvalhais, N., Arain, M. A., Black, A., De Bruin, S., Buchmann, N., ... & Reichstein, M. (2018). Quantifying the effect of forest age in annual net forest carbon balance. *Environmental Research Letters*, 13(12), 124018.

Bezerra, U. A., & Cunha, J. E. D. B. L. (2023). Aplicativo para estimativa de séries temporais e evapotranspiração na Caatinga. In *Simpósio Brasileiro de Recursos Hídricos*, 25.

Bezerra, U. A., Cunha, J., Valente, F., Nóbrega, R. L., Andrade, J. M., Moura, M. S., ... & Galvão, C. O. (2023). STEEP: A remotely-sensed energy balance model for evapotranspiration estimation in seasonally dry tropical forests. *Agricultural and Forest Meteorology*, 333, 109408.

- Bhattarai, N., Quackenbush, L. J., Im, J., & Shaw, S. B. (2017). A new optimized algorithm for automating endmember pixel selection in the SEBAL and METRIC models. *Remote sensing of environment*, 196, 178-192.
- Biggs, T. W., Marshall, M., & Messina, A. (2016). Mapping daily and seasonal evapotranspiration from irrigated crops using global climate grids and satellite imagery: Automation and methods comparison. *Water Resources Research*, 52(9), 7311-7326.
- Biggs, T., Petropoulos, G. P., Velpuri, N. M., Marshall, M., Glenn, E. P., Nagler, P., & Messina, A. (2015). Remote sensing of actual evapotranspiration from croplands. *Remote Sensing of Water Resources, Disasters and Urban Studies; Thenkabail, PS, Ed*, 59-100.
- Black, T. A., Den Hartog, G., Neumann, H. H., Blanken, P. D., Yang, P. C., Russell, C., ... & Novak, M. D. (1996). Annual cycles of water vapour and carbon dioxide fluxes in and above a boreal aspen forest. *Global Change Biology*, 2(3), 219-229.
- Boden, T. A., Krassovski, M., & Yang, B. (2013). The AmeriFlux data activity and data system: an evolving collection of data management techniques, tools, products and services. *Geoscientific Instrumentation, Methods and Data Systems*, 2(1), 165-176.
- Bodesheim, P., Jung, M., Gans, F., Mahecha, M. D., & Reichstein, M. (2018). Upscaled diurnal cycles of land-atmosphere fluxes: a new global half-hourly data product. *Earth System Science Data*, 10(3), 1327-1365.
- Bonan, G. B., Lawrence, P. J., Oleson, K. W., Levis, S., Jung, M., Reichstein, M., ... & Swenson, S. C. (2011). Improving canopy processes in the Community Land Model version 4 (CLM4) using global flux fields empirically inferred from FLUXNET data. *Journal of Geophysical Research: Biogeosciences*, 116(G2).
- Bonan, G. B., Patton, E. G., Finnigan, J. J., Baldocchi, D. D., & Harman, I. N. (2021). Moving beyond the incorrect but useful paradigm: reevaluating big-leaf and multilayer plant canopies to model biosphere-atmosphere fluxes—a review. *Agricultural and Forest Meteorology*, 306, 108435.
- Borges, C. K., Carneiro, R. G., dos Santos, C. A., & dos Santos, C. A. (2021). Obtaining the daily actual evapotranspiration through remote sensing techniques application in Brazilian Semiarid. *Journal of Hyperspectral Remote Sensing v*, 11(1), 18-31.
- Braddock, T., & Hennessey, D. (2018). *Wetlands: an introduction*. Bernan Press.

Cadier, É. (1996). Small watershed hydrology in semi-arid north-eastern Brazil: basin typology and transposition of annual runoff data. *Journal of Hydrology*, 182(1-4), 117-141.

Cammalleri, C., Anderson, M. C., Ciraolo, G., D'Urso, G., Kustas, W. P., La Loggia, G., & Minacapilli, M. (2012). Applications of a remote sensing-based two-source energy balance algorithm for mapping surface fluxes without in situ air temperature observations. *Remote Sensing of Environment*, 124, 502-515.

Campos, S., Mendes, K. R., da Silva, L. L., Mutti, P. R., Medeiros, S. S., Amorim, L. B., ... & Bezerra, B. G. (2019). Closure and partitioning of the energy balance in a preserved area of a Brazilian seasonally dry tropical forest. *Agricultural and Forest Meteorology*, 271, 398-412.

Carpintero, E., Anderson, M. C., Andreu, A., Hain, C., Gao, F., Kustas, W. P., & González-Dugo, M. P. (2021). Estimating evapotranspiration of mediterranean oak savanna at multiple temporal and spatial resolutions. Implications for water resources management. *Remote Sensing*, 13(18), 3701.

Castelli, M. (2021). Evapotranspiration changes over the European Alps: Consistency of trends and their drivers between the MOD16 and SSEBop algorithms. *Remote Sensing*, 13(21), 4316.

Chen, J. M., & Liu, J. (2020). Evolution of evapotranspiration models using thermal and shortwave remote sensing data. *Remote Sensing of Environment*, 237, 111594.

Chen, J. M., & Liu, J. (2020). Evolution of evapotranspiration models using thermal and shortwave remote sensing data. *Remote Sensing of Environment*, 237, 111594.

Cheng, M., Jiao, X., Li, B., Yu, X., Shao, M., & Jin, X. (2021). Long time series of daily evapotranspiration in China based on the SEBAL model and multisource images and validation. *Earth System Science Data*, 13(8), 3995-4017.

Chu, H., Luo, X., Ouyang, Z., Chan, W. S., Dengel, S., Biraud, S. C., ... & Zona, D. (2021). Representativeness of Eddy-Covariance flux footprints for areas surrounding AmeriFlux sites. *Agricultural and Forest Meteorology*, 301, 108350.

Ciesla, W. (2011). *Forest entomology: a global perspective*. John Wiley & Sons.

Costa, J., Navarro-Hevia, J., Costa, C. A. G., & de Araujo, J. C. (2021). Temporal dynamics of evapotranspiration in semiarid native forests in Brazil and Spain using remote sensing. *Hydrological Processes*, 35(3), e14070.

Costa-Filho, E., Chávez, J. L., Zhang, H., & Andales, A. A. (2021). An optimized surface aerodynamic temperature approach to estimate maize sensible heat flux and evapotranspiration. *Agricultural and Forest Meteorology*, 311, 108683.

Coutinho, L. M. (2006). O conceito de bioma. *Acta botanica brasílica*, 20, 13-23.

Cunha, J., Nobrega, R. L., Rufino, I., Erasmi, S., Galvão, C., & Valente, F. (2020a). Surface albedo as a proxy for land-cover clearing in seasonally dry forests: Evidence from the Brazilian Caatinga. *Remote Sensing of Environment*, 238, 111250.

Cunha, J., Pereira, T. E., Pereira, E., Rufino, I., Galvão, C., Valente, F., & Brasileiro, F. (2020b). A high-throughput shared service to estimate evapotranspiration using Landsat imagery. *Computers & Geosciences*, 134, 104341.

Danelichen, V. H. D. M., Biudes, M. S., Souza, M. C., Machado, N. G., Silva, B. B. D., & Nogueira, J. D. S. (2014). Estimation of soil heat flux in a neotropical Wetland region using remote sensing techniques. *Revista Brasileira de Meteorologia*, 29, 469-482. <https://doi.org/10.1590/0102-778620120568>

Dansereau, P. (1957). *Biogeography. An ecological perspective.*

de Oliveira, F. R. V., & de Moraes Danelichen, V. H. (2022). Estudo da Evapotranspiração Sobre o Impacto de Preservação de uma Unidade de Área Protegida no Pantanal Mato-Grossense. *Ensaio e Ciência C Biológicas Agrárias e da Saúde*, 26(4), 418-422.

Dinerstein, E., Olson, D., Joshi, A., Vynne, C., Burgess, N. D., Wikramanayake, E., ... & Saleem, M. (2017). An ecoregion-based approach to protecting half the terrestrial realm. *BioScience*, 67(6), 534-545.

Dixon, A. P., Faber-Langendoen, D., Josse, C., Morrison, J., & Loucks, C. J. (2014). Distribution mapping of world grassland types. *Journal of biogeography*, 41(11), 2003-2019.

Dolman, H., Durand, P., Noilhan, J., Sarrat, C., Brut, A., Butet, A., ... & Ceschia, E. (2006). CERES: the CarboEurope regional experiment strategy in the Landes, South West France. In *AGU Fall Meeting*.

Dombroski, J. L. D., Praxedes, S. C., de Freitas, R. M. O., & Pontes, F. M. (2011). Water relations of Caatinga trees in the dry season. *South African Journal of Botany*, 77(2), 430-434.

- Er-Raki, S., Chehbouni, A., & Duchemin, B. (2010). Combining satellite remote sensing data with the FAO-56 dual approach for water use mapping in irrigated wheat fields of a semi-arid region. *Remote Sensing*, 2(1), 375-387.
- Fang, Y., Sun, G., Caldwell, P., McNulty, S. G., Noormets, A., Domec, J. C., ... & Chen, J. (2016). Monthly land cover-specific evapotranspiration models derived from global eddy flux measurements and remote sensing data. *Ecohydrology*, 9(2), 248-266.
- Farias, A. A. D., & Xavier, R. A. (2023). Eventos Extremos de Secas na Sub-Bacia Hidrográfica do Rio Sucuru, Cariri Paraibano. *Revista Brasileira de Meteorologia*.
- Feng, L. (2015). Sensitivity analysis of hot/cold pixel selection in SEBAL model for ET estimation (Doctoral dissertation, Virginia Tech).
- Ferreira, T. R., Da Silva, B. B., De Moura, M. S., Verhoef, A., & Nobrega, R. L. (2020). The use of remote sensing for reliable estimation of net radiation and its components: a case study for contrasting land covers in an agricultural hotspot of the Brazilian semiarid region. *Agricultural and Forest Meteorology*, 291, 108052.
- Fisher, J. B., Melton, F., Middleton, E., Hain, C., Anderson, M., Allen, R., ... & Wood, E. F. (2017). The future of evapotranspiration: Global requirements for ecosystem functioning, carbon and climate feedbacks, agricultural management, and water resources. *Water resources research*, 53(4), 2618-2626.
- French, A. N., Hunsaker, D. J., & Thorp, K. R. (2015). Remote sensing of evapotranspiration over cotton using the TSEB and METRIC energy balance models. *Remote Sensing of Environment*, 158, 281-294.
- Friend, A. D., Arneth, A., Kiang, N. Y., Lomas, M., Ogee, J., Rödenbeck, C., ... & Zaehle, S. (2007). FLUXNET and modelling the global carbon cycle. *Global Change Biology*, 13(3), 610-633.
- Funk, C., Peterson, P., Landsfeld, M., Pedreros, D., Verdin, J., Shukla, S., ... & Michaelsen, J. (2015). The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. *Scientific data*, 2(1), 1-21.
- Gentry, A. H. (1995). Diversity and floristic composition of neotropical dry forests. *Seasonally dry tropical forests*, 1, 146-194.

- Gokmen, M., Vekerdy, Z., Verhoef, A., Verhoef, W., Batelaan, O., & van der Tol, C. (2012). Integration of soil moisture in SEBS for improving evapotranspiration estimation under water stress conditions. *Remote sensing of environment*, 121, 261-274.
- Gonzalez, A. Z. D., Rosestolato Filho, A., & da Silva Andrade, L. N. P. (2023). Variabilidade das precipitações no setor noroeste da Bacia do Alto Paraguai. *Revista Geoaraguaia*, 13(Especial), 266-286.
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote sensing of Environment*, 202, 18-27.
- Gowda, P. H., Chavez, J. L., Colaizzi, P. D., Evett, S. R., Howell, T. A., & Tolk, J. A. (2008). ET mapping for agricultural water management: present status and challenges. *Irrigation science*, 26, 223-237.
- Graham, R., Rossi, A., & Hubbert, R. (2010). Rock to regolith conversion: Producing hospitable substrates for terrestrial ecosystems. *GSA today*, 20, 4-9.
- Gu, C., Ma, J., Zhu, G., Yang, H., Zhang, K., Wang, Y., & Gu, C. (2018). Partitioning evapotranspiration using an optimized satellite-based ET model across biomes. *Agricultural and forest meteorology*, 259, 355-363.
- Hasnat, G. T., & Hossain, M. K. (2020). Global overview of tropical dry forests. *Handbook of research on the conservation and restoration of tropical dry forests*, 1-23.
- Henderson-Sellers A, Robinson PJ (1991) *Contemporary Climatology*. Longman, London
- Holdridge, L. R., & Tosi Jr, J. A. (1967). Tropical Science Center: San Jose, Costa Rica. *Life Zone Ecology; Tropical Science Center: San Jose, Costa Rica*.
- Hu, G., Jia, L., & Menenti, M. (2015). Comparison of MOD16 and LSA-SAF MSG evapotranspiration products over Europe for 2011. *Remote Sensing of Environment*, 156, 510-526.
- Hu, X., Shi, L., Lin, G., & Lin, L. (2021). Comparison of physical-based, data-driven and hybrid modeling approaches for evapotranspiration estimation. *Journal of Hydrology*, 601, 126592.
- Hunsaker, D. J., Barnes, E. M., Clarke, T. R., Fitzgerald, G. J., & Pinter Jr, P. J. (2005). Cotton irrigation scheduling using remotely sensed and FAO-56 basal crop coefficients. *Transactions of the ASAE*, 48(4), 1395-1407.

- Jaafar, H. H., & Ahmad, F. A. (2020). Time series trends of Landsat-based ET using automated calibration in METRIC and SEBAL: The Bekaa Valley, Lebanon. *Remote Sensing of Environment*, 238, 111034.
- Jang, K., Kang, S., Lim, Y. J., Jeong, S., Kim, J., Kimball, J. S., & Hong, S. Y. (2013). Monitoring daily evapotranspiration in Northeast Asia using MODIS and a regional Land Data Assimilation System. *Journal of Geophysical Research: Atmospheres*, 118(23), 12-927.
- Jia, Z., Liu, S., Xu, Z., Chen, Y., & Zhu, M. (2012). Validation of remotely sensed evapotranspiration over the Hai River Basin, China. *Journal of Geophysical Research: Atmospheres*, 117(D13).
- Jiang, C., & Ryu, Y. (2016). Multi-scale evaluation of global gross primary productivity and evapotranspiration products derived from Breathing Earth System Simulator (BESS). *Remote Sensing of Environment*, 186, 528-547.
- Jiménez-Bello, M. Á., Castel, J. R., Testi, L., & Intrigliolo, D. S. (2015). Assessment of a remote sensing energy balance methodology (SEBAL) using different interpolation methods to determine evapotranspiration in a citrus orchard. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(4), 1465-1477.
- Joffre, R., Rambal, S., & Damesin, C. (2007). Functional attributes in Mediterranean-type ecosystems. In *Functional plant ecology* (pp. 285-312). CRC Press.
- Jung, M., Koirala, S., Weber, U., Ichii, K., Gans, F., Camps-Valls, G., ... & Reichstein, M. (2019). The FLUXCOM ensemble of global land-atmosphere energy fluxes. *Scientific data*, 6(1), 74.
- Jung, M., Schwalm, C., Migliavacca, M., Walther, S., Camps-Valls, G., Koirala, S., ... & Reichstein, M. (2020). Scaling carbon fluxes from eddy covariance sites to globe: synthesis and evaluation of the FLUXCOM approach. *Biogeosciences*, 17(5), 1343-1365.
- Keenan, T. F., Baker, I., Barr, A., Ciais, P., Davis, K., Dietze, M., ... & Richardson, A. D. (2012). Terrestrial biosphere model performance for inter-annual variability of land-atmosphere CO₂ exchange. *Global Change Biology*, 18(6), 1971-1987.
- Khoshnood, S., Loffata, A., Mombeni, M., Daneshi, A., Verrelst, J., & Ghorbani, K. (2023). A spatial and temporal correlation between remotely sensing evapotranspiration with land use and land cover. *Water*, 15(6), 1068.

- Kim, H. W., Hwang, K., Mu, Q., Lee, S. O., & Choi, M. (2012). Validation of MODIS 16 global terrestrial evapotranspiration products in various climates and land cover types in Asia. *KSCE Journal of Civil Engineering*, 16, 229-238.
- Kite, G. (1998). INTEGRATION OF FOREST ECOSYSTEM AND CLIMATIC MODELS WITH A HYDROLOGIC MODEL 1. *JAWRA Journal of the American Water Resources Association*, 34(4), 743-753.
- Kite, G. W., & Droogers, P. (2000). Comparing evapotranspiration estimates from satellites, hydrological models and field data. *Journal of Hydrology*, 229(1-2), 3-18.
- Knudsen, M. T., Hermansen, J. E., Cederberg, C., Herzog, F., Vale, J., Jeanneret, P., ... & Dennis, P. (2017). Characterization factors for land use impacts on biodiversity in life cycle assessment based on direct measures of plant species richness in European farmland in the 'Temperate Broadleaf and Mixed Forest' biome. *Science of the Total Environment*, 580, 358-366.
- Korner, C. (2003). *Alpine Plant Life: Functional Plant Ecology of High Mountain Ecosystems*. Springer-Verlag
- Kustas, W. P. (1990). Estimates of evapotranspiration with a one-and two-layer model of heat transfer over partial canopy cover. *Journal of Applied Meteorology and Climatology*, 29(8), 704-715.
- Laing, A., Hamidou, H., Diop-Kane, M., & Wardle, T. (2017). Remote Sensing. *Meteorology of Tropical West Africa: The Forecasters' Handbook*, 323-379.
- Laipelt, L., Kayser, R. H. B., Fleischmann, A. S., Ruhoff, A., Bastiaanssen, W., Erickson, T. A., & Melton, F. (2021). Long-term monitoring of evapotranspiration using the SEBAL algorithm and Google Earth Engine cloud computing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 178, 81-96.
- Li, X., Liu, S., Xiao, Q., Ma, M., Jin, R., Che, T., ... & Wang, L. (2017). A multiscale dataset for understanding complex eco-hydrological processes in a heterogeneous oasis system. *Scientific data*, 4(1), 1-11.
- Lieth, H., & Whittaker, R. H. (Eds.). (2012). *Primary productivity of the biosphere* (Vol. 14). Springer Science & Business Media.
- Lima, C. E. S., de Oliveira Costa, V. S., Galvíncio, J. D., da Silva, R. M., & Santos, C. A. G. (2021). Assessment of automated evapotranspiration estimates obtained using the

GP-SEBAL algorithm for dry forest vegetation (Caatinga) and agricultural areas in the Brazilian semiarid region. *Agricultural Water Management*, 250, 106863.

Liou, Y. A., & Kar, S. K. (2014). Evapotranspiration estimation with remote sensing and various surface energy balance algorithms—A review. *Energies*, 7(5), 2821-2849.

Liu, S., Li, X., Xu, Z., Che, T., Xiao, Q., Ma, M., ... & Ren, Z. (2018). The Heihe Integrated Observatory Network: A basin-scale land surface processes observatory in China. *Vadose Zone Journal*, 17(1), 1-21.

Liu, S., Xu, Z., Song, L., Zhao, Q., Ge, Y., Xu, T., ... & Zhang, F. (2016). Upscaling evapotranspiration measurements from multi-site to the satellite pixel scale over heterogeneous land surfaces. *Agricultural and Forest Meteorology*, 230, 97-113.

Liu, Y., Guo, W., Huang, H., Ge, J., & Qiu, B. (2021). Estimating global aerodynamic parameters in 1982–2017 using remote-sensing data and a turbulent transfer model. *Remote Sensing of Environment*, 260, 112428.

Long, D., Singh, V. P., & Li, Z. L. (2011). How sensitive is SEBAL to changes in input variables, domain size and satellite sensor?. *Journal of Geophysical Research: Atmospheres*, 116(D21).

Mahecha, M. D., Reichstein, M., Carvalhais, N., Lasslop, G., Lange, H., Seneviratne, S. I., ... & Richardson, A. D. (2010). Global convergence in the temperature sensitivity of respiration at ecosystem level. *science*, 329(5993), 838-840.

Martens, B., Miralles, D. G., Lievens, H., Van Der Schalie, R., De Jeu, R. A., Fernández-Prieto, D., ... & Verhoest, N. E. (2017). GLEAM v3: Satellite-based land evaporation and root-zone soil moisture. *Geoscientific Model Development*, 10(5), 1903-1925.

Miehe, G., & Miehe, S. (2000). Comparative High-Mountain Research on the Flora and Vegetation of the Andes and the Himalayas. *Mountain Research and Development*, 20(4), 280-287.

Miettinen, J., Shi, C., & Liew, S. C. (2019). Towards automated 10–30 m resolution land cover mapping in insular South-East Asia. *Geocarto International*, 34(4), 443-457.

Miralles, D. G., Holmes, T. R. H., De Jeu, R. A. M., Gash, J. H., Meesters, A. G. C. A., & Dolman, A. J. (2011). Global land-surface evaporation estimated from satellite-based observations. *Hydrology and Earth System Sciences*, 15(2), 453-469.

- Miranda, R. de Q., Nóbrega, R. L. B., Moura, M. S. B. de, Raghavan, S., & Galvíncio, J. D. (2020). Realistic and simplified models of plant and leaf area indices for a seasonally dry tropical forest. *International Journal of Applied Earth Observation and Geoinformation*, 85, 101992.
- Mohan, M. P., Kanchirapuzha, R., & Varma, M. R. (2020). Review of approaches for the estimation of sensible heat flux in remote sensing-based evapotranspiration models. *Journal of Applied Remote Sensing*, 14(4), 041501-041501.
- Moro, M. F., Silva, I. A., Araújo, F. S. D., Nic Lughadha, E., Meagher, T. R., & Martins, F. R. (2015). The role of edaphic environment and climate in structuring phylogenetic pattern in seasonally dry tropical plant communities. *PLoS One*, 10(3), e0119166.
- Morton, C. G., Huntington, J. L., Pohl, G. M., Allen, R. G., McGwire, K. C., & Bassett, S. D. (2013). Assessing calibration uncertainty and automation for estimating evapotranspiration from agricultural areas using METRIC. *JAWRA Journal of the American Water Resources Association*, 49(3), 549-562.
- Mu, Q., Heinsch, F. A., Zhao, M., & Running, S. W. (2007). Development of a global evapotranspiration algorithm based on MODIS and global meteorology data. *Remote sensing of Environment*, 111(4), 519-536.
- Mu, Q., Zhao, M., & Running, S. W. (2011). Improvements to a MODIS global terrestrial evapotranspiration algorithm. *Remote sensing of environment*, 115(8), 1781-1800.
- Murphy, P. G., & Lugo, A. E. (1986). Ecology of tropical dry forest. *Annual review of ecology and systematics*, 67-88.
- Norman, J. M., Kustas, W. P., & Humes, K. S. (1995). Source approach for estimating soil and vegetation energy fluxes in observations of directional radiometric surface temperature. *Agricultural and Forest Meteorology*, 77(3-4), 263-293.
- Nouvelot, J. F. (1974). Planificação da implantação de Bacias Representativas. Aplicação à área da Sudene. SUDENE, Recife.
- Novais, J. W. Z., Sanches, L., Silva, L. B. D., Machado, N. G., Aquino, A. M., & Pinto Junior, O. B. (2016). Albedo do Solo abaixo do Dossel em Área de *Vochysia divergens* Pohl no Norte do Pantanal. *Revista Brasileira de Meteorologia*, 31, 157-166.

Novick, K. A., Biederman, J. A., Desai, A. R., Litvak, M. E., Moore, D. J., Scott, R. L., & Torn, M. S. (2018). The AmeriFlux network: A coalition of the willing. *Agricultural and Forest Meteorology*, 249, 444-456.

Ongaratto, J. M., & Bortolin, T. A. (2021). Comparação entre métodos de estimativa de evapotranspiração de referência no município de São José dos Ausentes (RS), Brasil. *Engenharia Sanitaria e Ambiental*, 26, 979-987.

Osborne, C. P., Mitchell, P. L., Sheehy, J. E., & Woodward, F. I. (2000). Modelling the recent historical impacts of atmospheric CO₂ and climate change on Mediterranean vegetation. *Global Change Biology*, 6(4), 445-458.

Oliveira, M. L., & Santos, C. A. C. (2023). AVALIAÇÃO BASEADA EM SENSORIAMENTO REMOTO DOS FLUXOS DE ÁGUA E CARBONO SOBRE OS ECOSISTEMAS TERRESTRES NO NORDESTE DO BRASIL.

Paço, T. A., Pôças, I., Cunha, M., Silvestre, J. C., Santos, F. L., Paredes, P., & Pereira, L. S. (2014). Evapotranspiration and crop coefficients for a super intensive olive orchard. An application of SIMDualKc and METRIC models using ground and satellite observations. *Journal of Hydrology*, 519, 2067-2080.

Padilha, A. L., Vitorello, Í., Pádua, M. B., & Fuck, R. A. (2016). Deep magnetotelluric signatures of the early Neoproterozoic Cariris Velhos tectonic event within the Transversal sub-province of the Borborema Province, NE Brazil. *Precambrian Research*, 275, 70-83.

Paloschi, R. A., Ramos, D. M., Ventura, D. J., Souza, R., Souza, E., Morellato, L. P. C., ... & Borma, L. D. S. (2020). Environmental drivers of water use for caatinga woody plant species: combining remote sensing phenology and sap flow measurements. *Remote Sensing*, 13(1), 75.

Papale, D. (2020). Ideas and perspectives: enhancing the impact of the FLUXNET network of eddy covariance sites. *Biogeosciences*, 17(22), 5587-5598.

Paruelo, J. M., Jobbágy, E. G., Sala, O. E., Lauenroth, W. K., & Burke, I. C. (1998). Functional and structural convergence of temperate grassland and shrubland ecosystems. *Ecological Applications*, 8(1), 194-206.

Pastorello, G., Trotta, C., Canfora, E., Chu, H., Christianson, D., Cheah, Y. W., ... & Law, B. (2020). The FLUXNET2015 dataset and the ONEFlux processing pipeline for eddy covariance data. *Scientific data*, 7(1), 225.

- Paul, G., Gowda, P. H., Prasad, P. V., Howell, T. A., Aiken, R. M., & Neale, C. M. (2014). Investigating the influence of roughness length for heat transport (zoh) on the performance of SEBAL in semi-arid irrigated and dryland agricultural systems. *Journal of Hydrology*, 509, 231-244.
- Paul, G., Gowda, P. H., Prasad, P. V., Howell, T. A., Staggenborg, S. A., & Neale, C. M. (2013). Lysimetric evaluation of SEBAL using high resolution airborne imagery from BEAREX08. *Advances in Water Resources*, 59, 157-168
- Paulson, C. A. (1970). The mathematical representation of wind speed and temperature profiles in the unstable atmospheric surface layer. *Journal of Applied Meteorology* (1962-1982), 857-861.
- Pérez-Cabello, F., Echeverría, M. T., Ibarra, P., & de la Riva, J. (2009). Effects of fire on vegetation, soil and hydrogeomorphological behavior in Mediterranean ecosystems. *Earth observation of wildland fires in Mediterranean ecosystems*, 111-128.
- Peroni Venancio, L., França da Cunha, F., Chartuni Mantovani, E., Hummel do Amaral, C., & Fialho do Reis, E. (2019). Evapotranspiração de cultura: Uma abordagem dos principais métodos aplicados às pesquisas científicas e na agricultura. *Revista IRRIGA - Brazilian Journal of Irrigation & Drainage*, 24(4).
- Pizzato, J. A., Dallacort, R., Tieppo, R. C., Modolo, A. J., Cremon, C., & Moreira, P. S. P. (2012). Distribuição e probabilidade de ocorrência de precipitação em Cáceres (MT). *Pesquisa Agropecuária Tropical*, 42, 137-142.
- Potapov, P., Li, X., Hernandez-Serna, A., Tyukavina, A., Hansen, M. C., Kommareddy, A., ... & Hofton, M. (2021). Mapping global forest canopy height through integration of GEDI and Landsat data. *Remote Sensing of Environment*, 253, 112165.
- Priestley, C. H. B., & Taylor, R. J. (1972). On the assessment of surface heat flux and evaporation using large-scale parameters. *Monthly weather review*, 100(2), 81-92.
- Ramoelo, A., Majozi, N., Mathieu, R., Jovanovic, N., Nickless, A., & Dziki, S. (2014). Validation of global evapotranspiration product (MOD16) using flux tower data in the African savanna, South Africa. *Remote Sensing*, 6(8), 7406-7423.
- Reichstein, M., Papale, D., Valentini, R., Aubinet, M., Bernhofer, C., Knohl, A., ... & Seufert, G. (2007). Determinants of terrestrial ecosystem carbon balance inferred from European eddy covariance flux sites. *Geophysical research letters*, 34(1).

- Resende, E. K. (2008). Pulso de inundação: processo ecológico essencial à vida no Pantanal. *Embrapa Pantanal-Documentos*.
- RIBEIRO, G. D. N. (2014). Uso de geotecnologias no estudo da degradação das terras no município de Sumé-PB.
- Richardson, D. M. (Ed.). (2000). *Ecology and biogeography of Pinus*. Cambridge University Press.
- Rocha, N. S. D., Käfer, P. S., Skokovic, D., Veeck, G., Diaz, L. R., Kaiser, E. A., ... & Rolim, S. B. A. (2020). The Influence of Land Surface Temperature in Evapotranspiration Estimated by the S-SEBI Model. *Atmosphere*, 11(10), 1059.
- Rodell, M., Houser, P. R., Jambor, U. E. A., Gottschalck, J., Mitchell, K., Meng, C. J., ... & Toll, D. (2004). The global land data assimilation system. *Bulletin of the American Meteorological society*, 85(3), 381-394.
- Roerink, G. J., Su, Z., & Menenti, M. (2000). S-SEBI: A simple remote sensing algorithm to estimate the surface energy balance. *Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere*, 25(2), 147-157.
- Sabater, J. M. (2019). ERA5-Land hourly data from 1981 to present. Copernicus climate change service (C3S) climate data store (CDS). Eur. Centre Medium-Range Weather Forecasts, Eur. Union, Tech. Rep.
- Saboori, M., Mousivand, Y., Cristóbal, J., Shah-Hosseini, R., & Mokhtari, A. (2022). An automated and improved methodology to retrieve long-time series of evapotranspiration based on remote sensing and reanalysis data. *Remote Sensing*, 14(24), 6253.
- Sala, O. E. (2001). Temperate grasslands. In *Global biodiversity in a changing environment: scenarios for the 21st century* (pp. 121-137). New York, NY: Springer New York.
- Salazar-Martínez, D., Holwerda, F., Holmes, T. R., Yépez, E. A., Hain, C. R., Alvarado-Barrientos, S., ... & Vivoni, E. R. (2022). Evaluation of remote sensing-based evapotranspiration products at low-latitude eddy covariance sites. *Journal of Hydrology*, 610, 127786.
- Santos, C. A. C. D., & Silva, B. B. D. (2010). Obtenção dos fluxos de energia à superfície utilizando o algoritmo S-SEBI. *Revista Brasileira de Meteorologia*, 25, 365-374.

- Santos, C. A., Mariano, D. A., Francisco das Chagas, A., Dantas, F. R. D. C., de Oliveira, G., Silva, M. T., ... & Neale, C. M. (2020a). Spatio-temporal patterns of energy exchange and evapotranspiration during an intense drought for drylands in Brazil. *International Journal of Applied Earth Observation and Geoinformation*, 85, 101982.
- Santos, É. G., dos Santos, C. A. C., Bezerra, B. G., & das Chagas Araújo, F. (2014). Análise de parâmetros ambientais no núcleo de desertificação de Irauçuba-CE usando imagens de satélite.
- Santos, E. I., de Alencar, M. L. S., Schramm, V. B., dos Santos, J. S., & do Nascimento, M. T. C. C. (2020b). Uso de geotecnologias no estudo da degradação das terras da bacia do rio Sucuru, na Paraíba. *Ciência e Natura*, 42, e57-e57.
- Santos, R. B., Santos, B. S., de Almeida Souza, R. T., Ricarte, T. L., & Júnior, J. J. F. C. (2022). Estimativas da evapotranspiração de referência por equações empíricas para o município de Nossa Senhora da Glória–SE. *Revista de Geociências do Nordeste*, 8(2), 147-155.
- Scherer-Warren, M. (2012). Desmembramento de estimativas de evapotranspiração obtidas por sensoriamento remoto nas componentes de evaporação e transpiração vegetal. *Revista Brasileira de Geografia Física*, 2, 361-373.
- Schwinning, S. (2010). The ecohydrology of roots in rocks. *Ecohydrology: Ecosystems, land and water process interactions, Ecohydrogeomorphology*, 3(2), 238-245.
- Senay, G. B., Bohms, S., Singh, R. K., Gowda, P. H., Velpuri, N. M., Alemu, H., & Verdin, J. P. (2013). Operational evapotranspiration mapping using remote sensing and weather datasets: A new parameterization for the SSEB approach. *JAWRA Journal of the American Water Resources Association*, 49(3), 577-591.
- Shurpali, N. J., Biasi, C., Jokinen, S., Hyvönen, N., & Martikainen, P. J. (2013). Linking water vapor and CO₂ exchange from a perennial bioenergy crop on a drained organic soil in eastern Finland. *Agricultural and forest meteorology*, 168, 47-58.
- Shuttleworth, W. J., Gurney, R. J., Hsu, A. Y., & Ormsby, J. P. (1989). FIFE: The variation in energy partition at surface flux sites. *IAHS Publ*, 186(6), 523-534.
- Silans, A. M. B. P., & Silva, F. M. (2007). Fluxo de calor sensível e evapotranspiração na Caatinga: Estudo experimental.. *Revista Brasileira de Recursos Hídricos*, 12(1), 177–188.

- Silans, A. M. B. P., Werlang, L. M., & Goldfarb, M. C (2008). Desenvolvimento de um Modelo SVATS para a Região Semi-Árida do Cariri Paraibano. ISSN 1414-381X, 5.
- Silva, A. M., da Silva, R. M., & Santos, C. A. G. (2019). Automated surface energy balance algorithm for land (ASEBAL) based on automating endmember pixel selection for evapotranspiration calculation in MODIS orbital images. *International Journal of Applied Earth Observation and Geoinformation*, 79, 1-11.
- Silva, G. J. F. D. (2020). Modelagem dos componentes do balanço hídrico e monitoramento da seca em bacia hidrográfica no bioma caatinga. Tese (Doutorado em Engenharia Civil e Ambiental) – Universidade Federal da Paraíba, João Pessoa – PB. 180f. 2020.
- SILVEIRA, P. M., & STONE, L. F. (1994). Manejo da irrigação do feijoeiro: uso do tensiômetro e avaliação do desempenho do pivô central. EMBRAPA-SPI.
- Singh, R. K., & Irmak, A. (2011). Treatment of anchor pixels in the METRIC model for improved estimation of sensible and latent heat fluxes. *Hydrological sciences journal*, 56(5), 895-906.
- Sobrino, J. A., Gómez, M., Jiménez-Muñoz, J. C., Oliso, A., & Chehbouni, G. (2005). A simple algorithm to estimate evapotranspiration from DAIS data: Application to the DAISEX campaigns. *Journal of hydrology*, 315(1-4), 117-125.
- Sousa, J. H. S. D. (2023). Aplicação do algoritmo Random Forest para classificação do uso e cobertura da terra na Bacia Hidrográfica do Rio Sucuru utilizando o Google Earth Engine.
- Specht, R. L. (1988). Mediterranean-type ecosystems: A data source book. 248.
- Srivastava, P. K., Han, D., Islam, T., Petropoulos, G. P., Gupta, M., & Dai, Q. (2016). Seasonal evaluation of evapotranspiration fluxes from MODIS satellite and mesoscale model downscaled global reanalysis datasets. *Theoretical and applied climatology*, 124, 461-473.
- Strömberg, C. A. (2011). Evolution of grasses and grassland ecosystems. *Annual review of Earth and planetary sciences*, 39(1), 517-544.
- Su, Z. (2002). The Surface Energy Balance System (SEBS) for estimation of turbulent heat fluxes. *Hydrology and earth system sciences*, 6(1), 85-100.

- Su, Z., Schmugge, T., Kustas, W. P., & Massman, W. J. (2001). An evaluation of two models for estimation of the roughness height for heat transfer between the land surface and the atmosphere. *Journal of applied meteorology and climatology*, 40(11), 1933-1951.
- Sullivan, R. C., Cook, D. R., Ghate, V. P., Kotamarthi, V. R., & Feng, Y. (2019). Improved spatiotemporal representativeness and bias reduction of satellite-based evapotranspiration retrievals via use of in situ meteorology and constrained canopy surface resistance. *Journal of Geophysical Research: Biogeosciences*, 124(2), 342-352. <https://doi.org/10.1029/2018JG004744>
- Talleg, T., Béziat, P., Jarosz, N., Rivalland, V., & Ceschia, E. (2013). Crops' water use efficiencies in temperate climate: Comparison of stand, ecosystem and agronomical approaches. *Agricultural and Forest Meteorology*, 168, 69-81.
- Tang, H., & Li, Z. L. (2014). *Quantitative remote sensing in thermal infrared: theory and applications*. Springer Science & Business Media.
- Tang, R., Peng, Z., Liu, M., Li, Z. L., Jiang, Y., Hu, Y., ... & Fisher, J. B. (2024). Spatial-temporal patterns of land surface evapotranspiration from global products. *Remote Sensing of Environment*, 304, 114066.
- Tang, R., Shao, K., Li, Z. L., Wu, H., Tang, B. H., Zhou, G., & Zhang, L. (2015). Multiscale validation of the 8-day MOD16 evapotranspiration product using flux data collected in China. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(4), 1478-1486.
- Teixeira, A. D. C., Bastiaanssen, W. G., Ahmad, M., & Bos, M. G. (2009). Reviewing SEBAL input parameters for assessing evapotranspiration and water productivity for the Low-Middle Sao Francisco River basin, Brazil: Part A: Calibration and validation. *Agricultural and forest meteorology*, 149(3-4), 462-476.
- Trebs, I., Mallick, K., Bhattarai, N., Sulis, M., Cleverly, J., Woodgate, W., ... & Boulet, G. (2021). The role of aerodynamic resistance in thermal remote sensing-based evapotranspiration models. *Remote sensing of environment*, 264, 112602.
- Uddin, J., Hancock, N. H., Smith, R. J., & Foley, J. P. (2013). Measurement of evapotranspiration during sprinkler irrigation using a precision energy budget (Bowen ratio, eddy covariance) methodology. *Agricultural Water Management*, 116, 89-100.

- Valentini, R., De Angelis, P., Matteucci, G., Monaco, R., Dore, S., & Mucnozza, G. S. (1996). Seasonal net carbon dioxide exchange of a beech forest with the atmosphere. *Global Change Biology*, 2(3), 199-207.
- Velpuri, N. M., Senay, G. B., Singh, R. K., Bohms, S., & Verdin, J. P. (2013). A comprehensive evaluation of two MODIS evapotranspiration products over the conterminous United States: Using point and gridded FLUXNET and water balance ET. *Remote Sensing of Environment*, 139, 35-49.
- Verhoef, A., De Bruin, H. A. R., & Van Den Hurk, B. J. J. M. (1997a). Some practical notes on the parameter $k_B - 1$ for sparse vegetation. *Journal of Applied Meteorology*, 36(5), 560-572.
- Verhoef, A.; McNaughton, K. G. & Jacobs, A. F. G. (1997b). A parameterization of momentum roughness length and displacement height for a wide range of canopy densities. *Hydrology and Earth System Sciences*, 1(1), 81–91.
- Walter, H. (1986). *Vegetação e zonas climáticas: tratado de ecologia global*.
- Wang, C., Yang, J., Myint, S. W., Wang, Z. H., & Tong, B. (2016). Empirical modeling and spatio-temporal patterns of urban evapotranspiration for the Phoenix metropolitan area, Arizona. *GIScience & Remote Sensing*, 53(6), 778-792.
- Wang, S., Pan, M., Mu, Q., Shi, X., Mao, J., Brümmer, C., ... & Black, T. A. (2015). Comparing evapotranspiration from eddy covariance measurements, water budgets, remote sensing, and land surface models over Canada. *Journal of Hydrometeorology*, 16(4), 1540-1560.
- Wang, W., & Lu, Y. (2018). Analysis of the mean absolute error (MAE) and the root mean square error (RMSE) in assessing rounding model. In *IOP conference series: materials science and engineering* (Vol. 324, p. 012049). IOP Publishing.
- Whitmore, T. C. (1998). *An Introduction to Tropical Rain Forests*. Oxford University Press.
- Williams, M., Richardson, A. D., Reichstein, M., Stoy, P. C., Peylin, P., Verbeeck, H., ... & Wang, Y. P. (2009). Improving land surface models with FLUXNET data. *Biogeosciences*, 6(7), 1341-1359.
- Wilson, K. B., Hanson, P. J., Mulholland, P. J., Baldocchi, D. D., & Wullschleger, S. D. (2001). A comparison of methods for determining forest evapotranspiration and its

components: sap-flow, soil water budget, eddy covariance and catchment water balance. *Agricultural and forest Meteorology*, 106(2), 153-168.

Yang, X., Zhou, Q., & Melville, M. (1997). Estimating local sugarcane evapotranspiration using Landsat TM image and a VITT concept. *International Journal of Remote Sensing*, 18(2), 453-459.

Yang, X., Zhou, Q., & Melville, M. D. (1996). Estimating local sugarcane evapotranspiration using Landsat TM imagery. *Proceeding of 8th Australian Remote Sensing Conference*, 2, 262-269.

Yee, M. S., Pauwels, V. R., Daly, E., Beringer, J., Rüdiger, C., McCabe, M. F., & Walker, J. P. (2015). A comparison of optical and microwave scintillometers with eddy covariance derived surface heat fluxes. *Agricultural and Forest Meteorology*, 213, 226-239.

Yu, G. R., Wen, X. F., Sun, X. M., Tanner, B. D., Lee, X., & Chen, J. Y. (2006). Overview of ChinaFLUX and evaluation of its eddy covariance measurement. *Agricultural and Forest Meteorology*, 137(3-4), 125-137.

Zhang, K., Kimball, J. S., & Running, S. W. (2016). A review of remote sensing based actual evapotranspiration estimation. *Wiley Interdisciplinary Reviews: Water*, 3(6), 834-853.

Zhang, Y., Kong, D., Gan, R., Chiew, F. H., McVicar, T. R., Zhang, Q., & Yang, Y. (2019). Coupled estimation of 500 m and 8-day resolution global evapotranspiration and gross primary production in 2002–2017. *Remote sensing of environment*, 222, 165-182.

Zhao, L., Xia, J., Xu, C. Y., Wang, Z., Sobkowiak, L., & Long, C. (2013). Evapotranspiration estimation methods in hydrological models. *Journal of Geographical Sciences*, 23, 359-369.

Zhao, M., Heinsch, F. A., Nemani, R. R., & Running, S. W. (2005). Improvements of the MODIS terrestrial gross and net primary production global data set. *Remote sensing of Environment*, 95(2), 164-176.

Zhu, W., Tian, S., Wei, J., Jia, S., & Song, Z. (2022). Multi-scale evaluation of global evapotranspiration products derived from remote sensing images: Accuracy and uncertainty. *Journal of Hydrology*, 611, 127982.

APÊNDICE A - MÉTRICAS ESTATÍSTICAS E DIAGRAMAS DE DENSIDADE DAS TORRES DE FLUXO SELECIONADAS

Tabela A1. Métricas Estatísticas BR-SA1.

Modelo	R ²	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,250611	10,203352	-21,648066	-11,572830	50,061025
STEEP_spf	0,647600	7,796323	-24,514275	-6,340523	80,473592
SEBAL	0,482027	5,031147	-11,134378	-2,056901	69,428187
S-SEBI	0,481883	5,672286	9,769155	-2,885649	69,417829
MOD16	0,588053	9,099378	-28,694919	-8,999327	76,684596

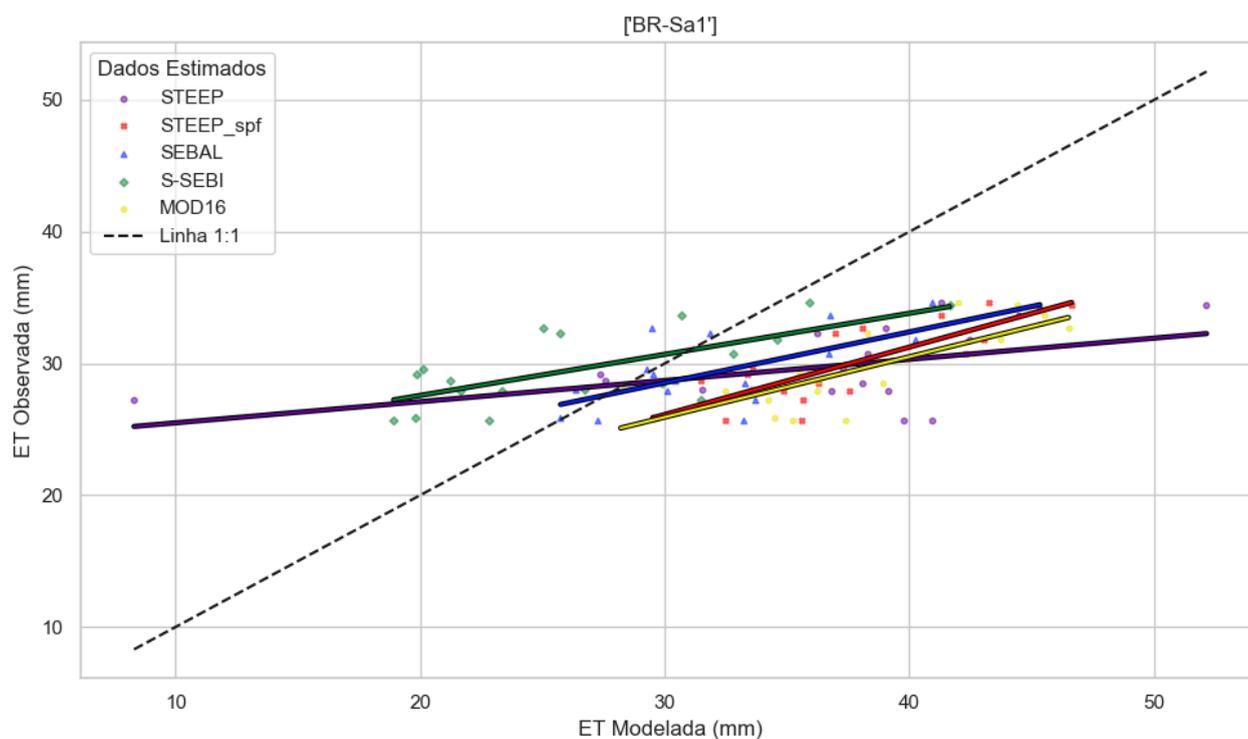


Figura A1. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo BR-SA1 localizada em FUTS na escala temporal de ET acumulada de 8 dias.

Tabela A2. Métricas Estatísticas CN-Qia.

Modelo	R ²	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,510517	6,667457	0,977603	0,460497	71,450488
STEEP_spf	0,407346	10,873583	-42,811505	-0,434892	63,823679
SEBAL	0,363111	8,625290	-23,990736	0,097138	60,258714
S-SEBI	0,335097	7,417494	1,923683	0,332290	57,887584
MOD16	0,588668	6,101679	1,146014	0,548173	76,724723

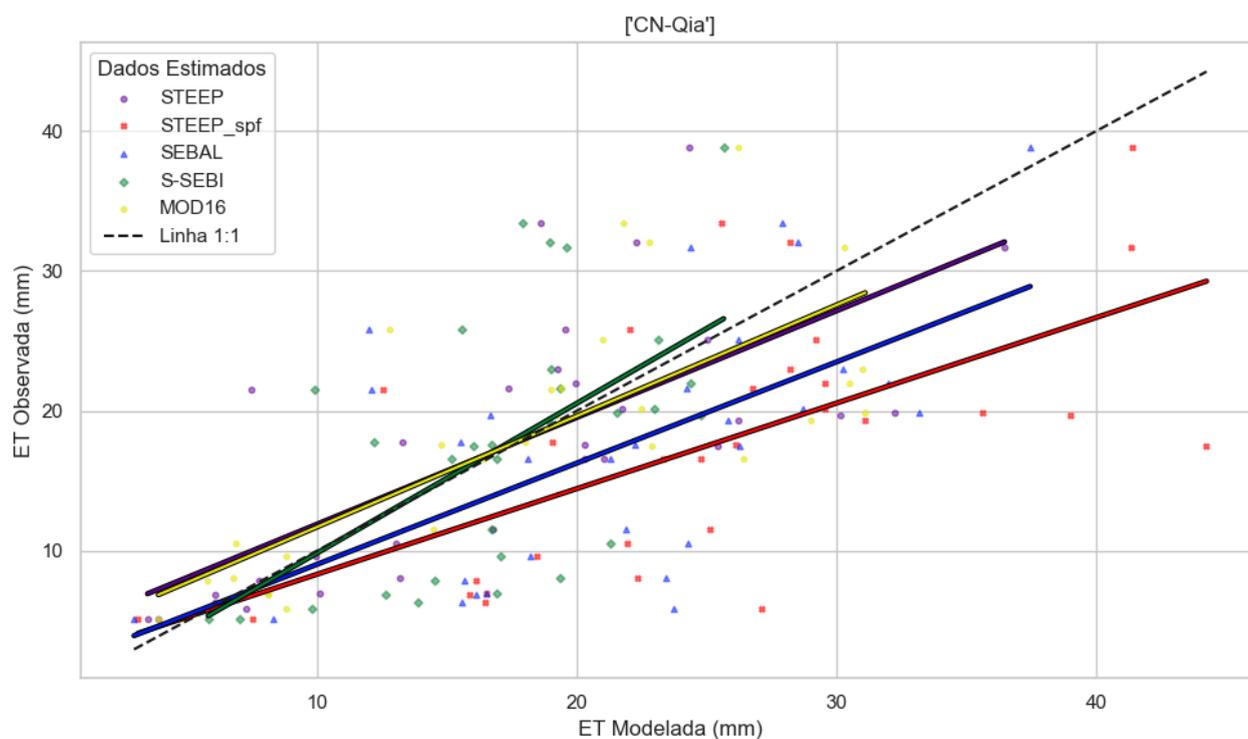


Figura A2. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo CN-Qia localizada em FUTS na escala temporal de ET acumulada de 8 dias.

Tabela A3. Métricas Estatísticas BR-Npw.

Modelo	R ²	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,534647	11,120343	33,127916	-1,355384	73,119539
STEEP_spf	0,613691	4,967124	0,831431	0,530068	78,338435
SEBAL	0,559505	6,238916	13,552462	0,258615	74,800038
S-SEBI	0,530682	8,679666	25,689887	-0,434932	72,847948
MOD16	0,421398	10,698793	-24,560585	-1,180193	64,915139

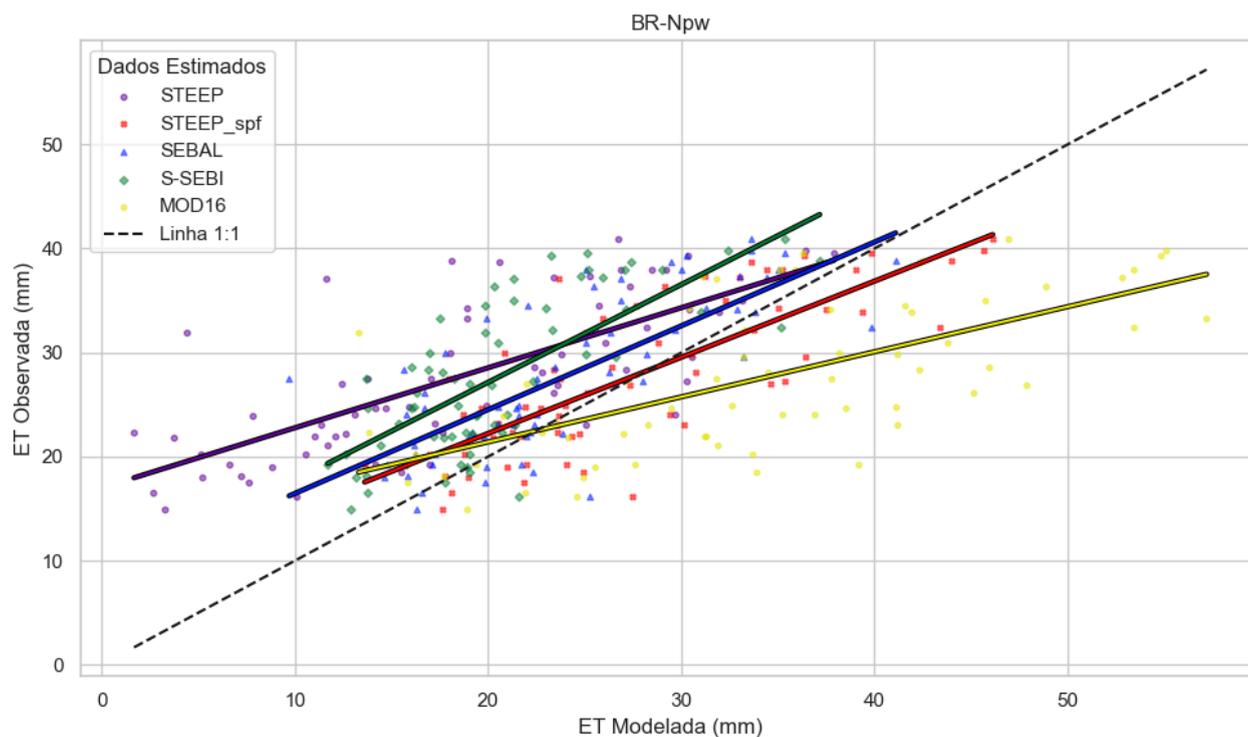


Figura A3. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo BR-Npw localizada em PSI na escala temporal de ET acumulada de 8 dias.

Tabela A4. Métricas Estatísticas AR-Vir.

Modelo	R ²	RMSE	PBIAS (%)	NSE	PC (%)
STEOP	0,696485	7,628689	-9,355740	0,079341	83,455658
STEOP_spf	0,739175	7,386697	-9,792693	0,136823	85,975300
SEBAL	0,727355	7,244395	-4,429044	0,169761	85,285093
S-SEBI	0,689971	6,468143	6,012203	0,338152	83,064479
MOD16	0,566442	10,376446	-30,005949	-0,703320	75,262366

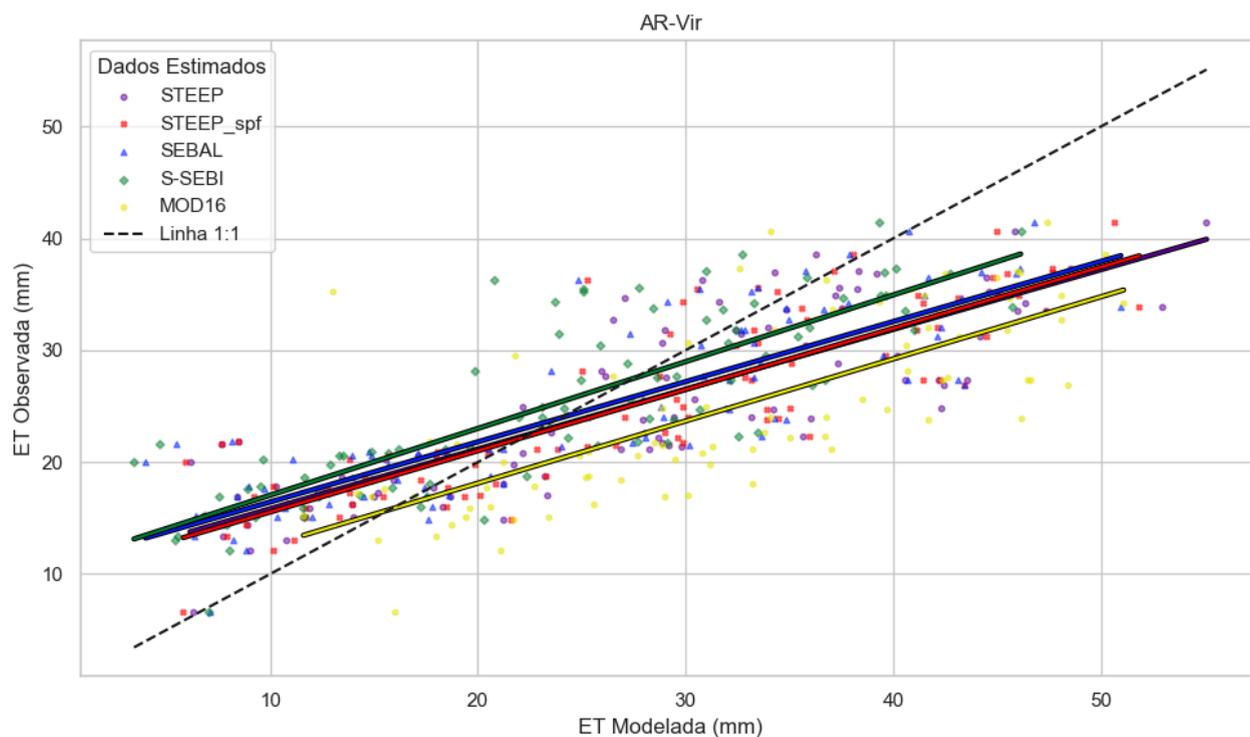


Figura A4. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo AR-Vir localizada em PSI na escala temporal de ET acumulada de 8 dias.

Tabela A5. Métricas Estatísticas AU-Gin.

Modelo	R ²	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,195419	9,305273	5,449648	-5,939793	-44,206223
STEEP_spf	0,007332	20,385656	-90,974336	-32,307166	-8,562905
SEBAL	0,224156	21,426035	-102,048547	-35,793567	-47,345123
S-SEBI	0,307829	13,400060	-55,828838	-13,391357	-55,482354
MOD16	0,215748	7,250196	33,694629	-3,212964	46,448632

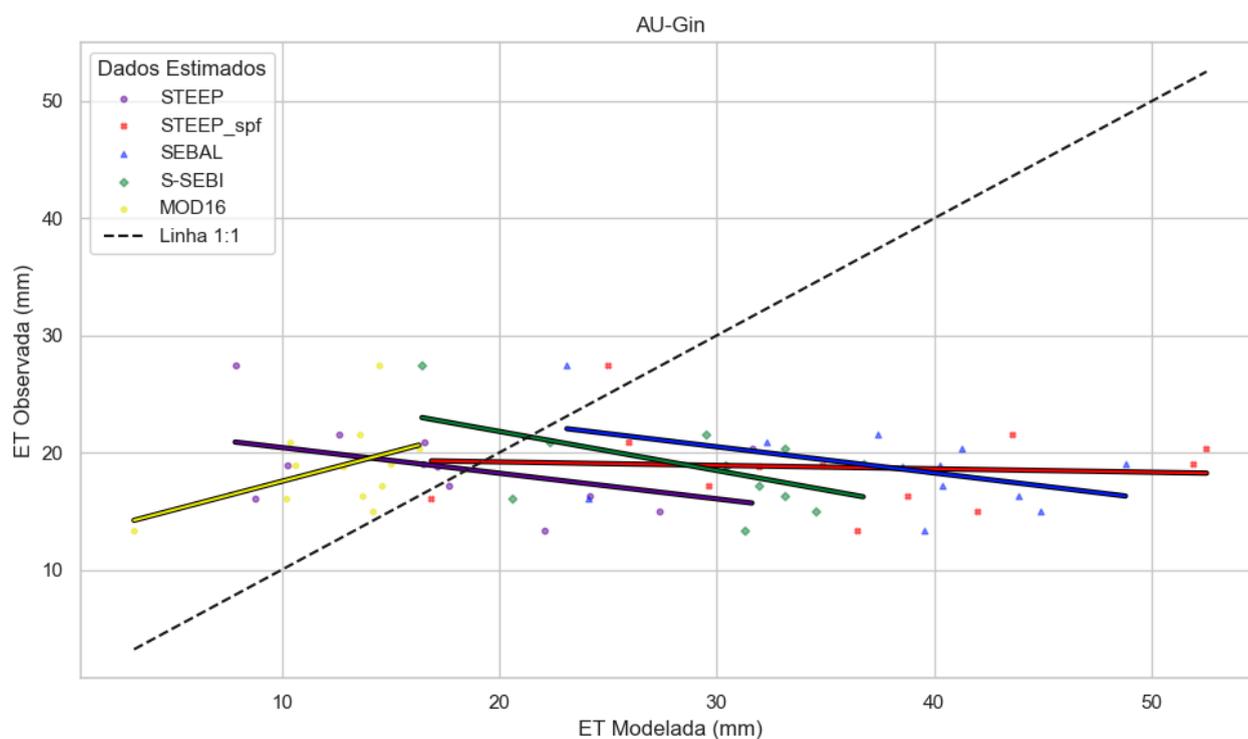


Figura A5. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo AU-Gin localizada em FBMM na escala temporal de ET acumulada de 8 dias.

Tabela A6. Métricas Estatísticas IT-SRo.

Modelo	R ²	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,473269	9,684439	0,079918	0,281055	68,794579
STEEP_spf	0,494946	12,211544	-17,503361	-0,143109	70,352370
SEBAL	0,468085	10,636407	0,755904	0,132766	68,416741
S-SEBI	0,443440	10,957971	13,279960	0,079536	66,591288
MOD16	0,411540	11,072711	25,422412	0,060159	64,151352

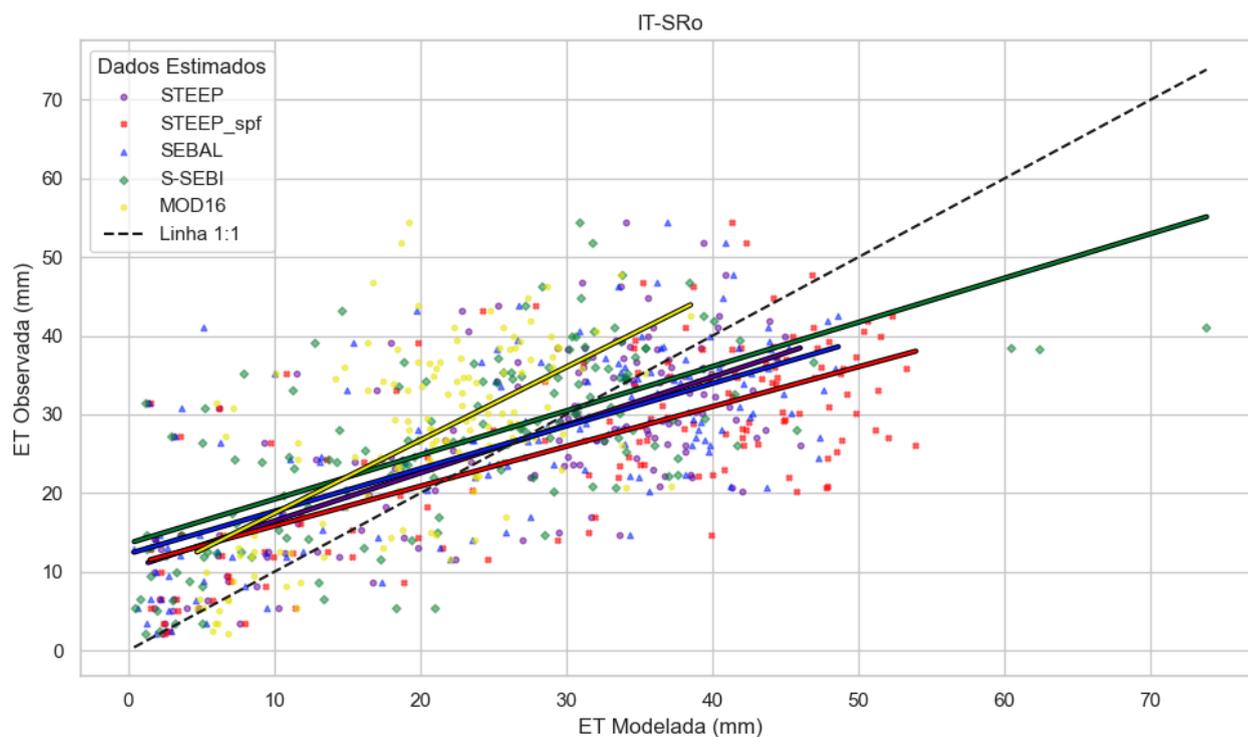


Figura A6. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo IT-SRo localizada em FBMM na escala temporal de ET acumulada de 8 dias.

Tabela A7. Métricas Estatísticas BR-IAB.

Modelo	R ²	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,594361	7,870238	-6,512495	-0,374289	77,094833
STEEP_spf	0,557955	8,241625	-25,323709	-0,507051	74,696371
SEBAL	0,560139	8,166278	-27,183087	-0,479622	74,842406
S-SEBI	0,553010	5,511621	-5,263537	0,325998	74,364665
MOD16	0,468794	12,588409	-41,533927	-2,515961	68,468526

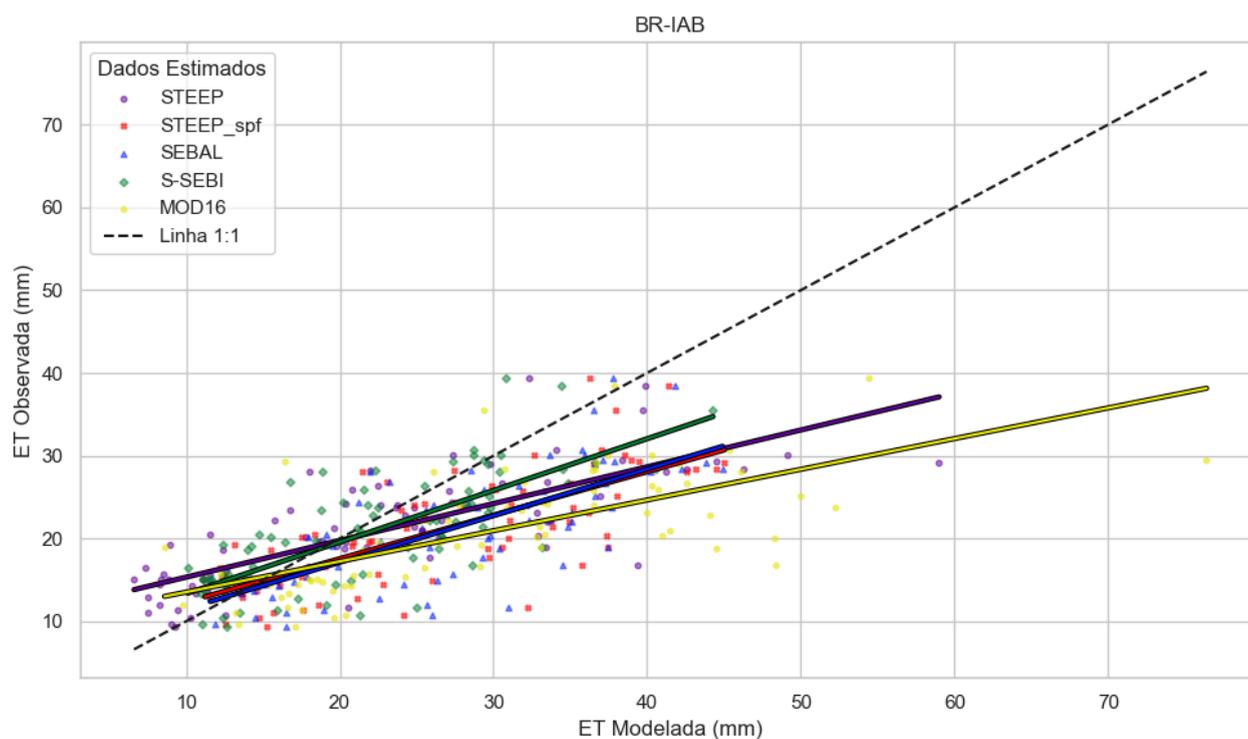


Figura A7. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo BR-IAB localizada em PTS na escala temporal de ET acumulada de 8 dias.

Tabela A8. Métricas Estatísticas ZM-Mon.

Modelo	R ²	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,085948	6,470204	24,539514	-4,094459	29,316906
STEEP_spf	0,043153	9,949493	-36,062381	-11,046588	20,773354
SEBAL	0,000246	7,444599	-4,562415	-5,744423	1,567681
S-SEBI	0,060808	6,277112	8,143866	-3,794926	24,659253
MOD16	0,340894	8,551142	-26,313948	-7,898369	58,386124

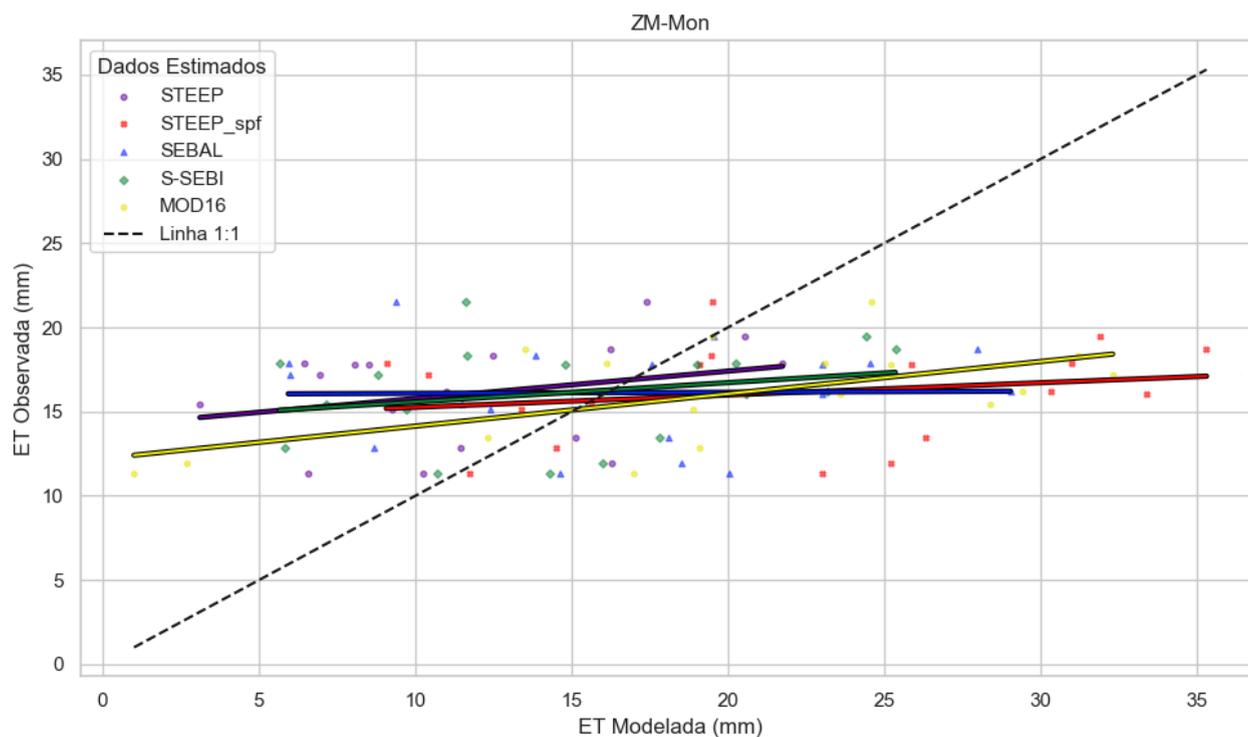


Figura A8. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo ZM-Mon localizada em PTS na escala temporal de ET acumulada de 8 dias.

Tabela A9. Métricas Estatísticas AU-Stp.

Modelo	R ²	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,358643	5,057617	-1,041211	0,299724	59,886803
STEEP_spf	0,464893	6,053485	-24,008138	-0,003202	68,183098
SEBAL	0,596544	4,005270	6,784906	0,560821	77,236293
S-SEBI	0,116762	7,181248	7,413360	-0,411814	34,170501
MOD16	0,508522	7,815889	43,036732	-0,672377	71,310720

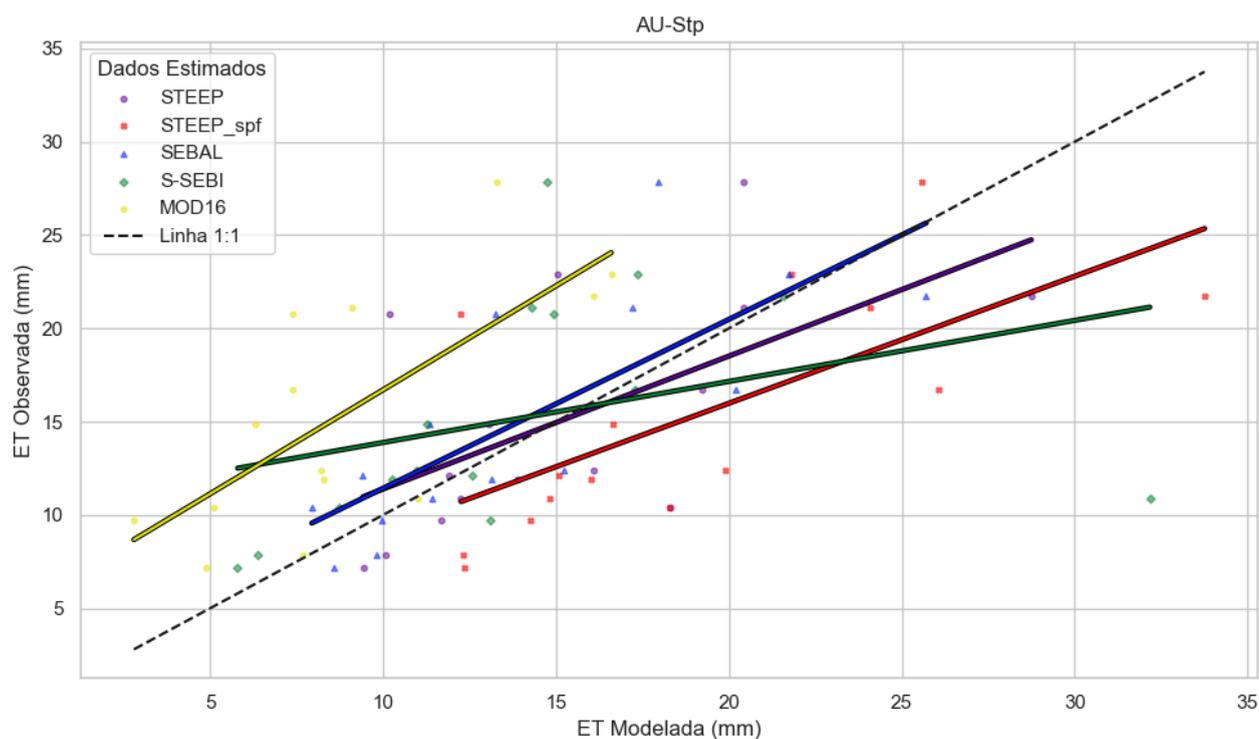


Figura A9. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo AU-Stp localizada em PTS na escala temporal de ET acumulada de 8 dias.

Tabela A10. Métricas Estatísticas CH-Dav.

Modelo	R ²	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,0271948	10,7017125	36,2152355	-1,9837275	16,4908349
STEEP_spf	0,4006335	13,7656378	-58,9921618	-3,9367971	63,2956140
SEBAL	0,4024110	14,3396389	-65,5971932	-4,3570911	63,4358757
S-SEBI	0,3823749	13,9540935	-65,1764371	-4,0728948	61,8364696
MOD16	0,5270781	4,7902320	-4,8189838	0,4021865	72,6001468

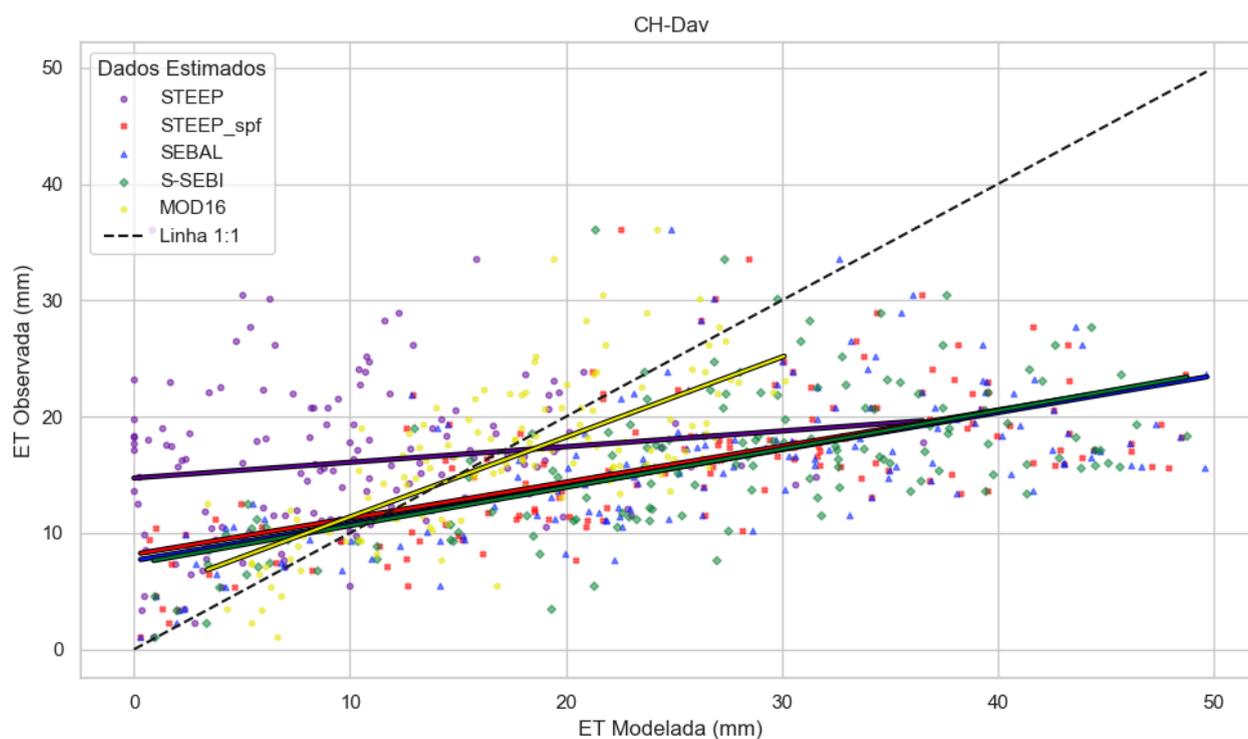


Figura A10. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo CH-Dav localizada em FTC na escala temporal de ET acumulada de 8 dias.

Tabela A11. Métricas Estatísticas CZ-BK1.

Modelo	R ²	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,600726	7,307028	-10,847846	0,456730	77,506493
STEEP_spf	0,599055	12,031338	-45,749656	-0,472863	77,398658
SEBAL	0,583615	12,525043	-48,151982	-0,596220	76,394729
S-SEBI	0,495561	12,763150	-47,543799	-0,657487	70,396107
MOD16	0,394889	8,809406	6,640689	0,210363	62,840167

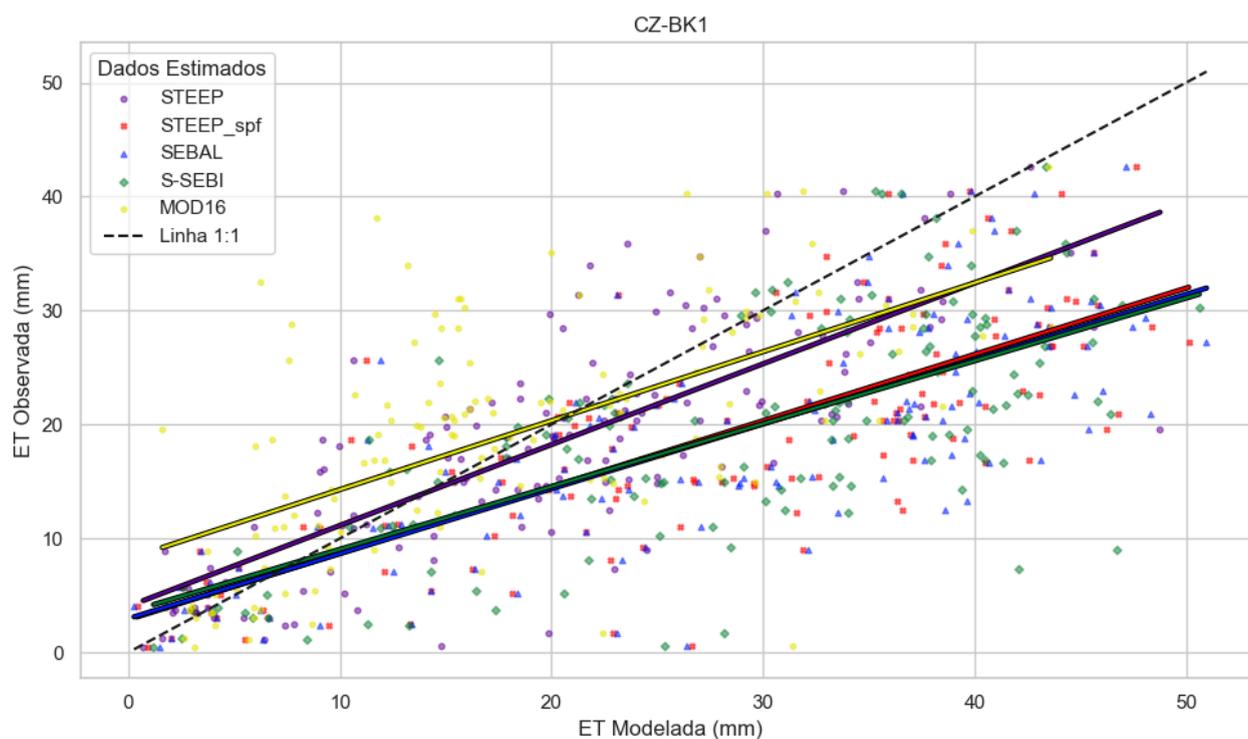


Figura A11. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo CZ-BK1 localizada em FTC na escala temporal de ET acumulada de 8 dias.

Tabela A12. Métricas Estatísticas BE-Vie.

Modelo	R ²	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,710671	4,238265	-17,847624	0,333507	84,301277
STEEP_spf	0,600983	5,851121	-40,749103	-0,270275	77,523111
SEBAL	0,687389	5,512984	-42,853520	-0,127699	82,908951
S-SEBI	0,626417	8,937514	-71,781826	-1,963829	79,146489
MOD16	0,785250	5,796260	-58,414071	-0,246566	88,614356

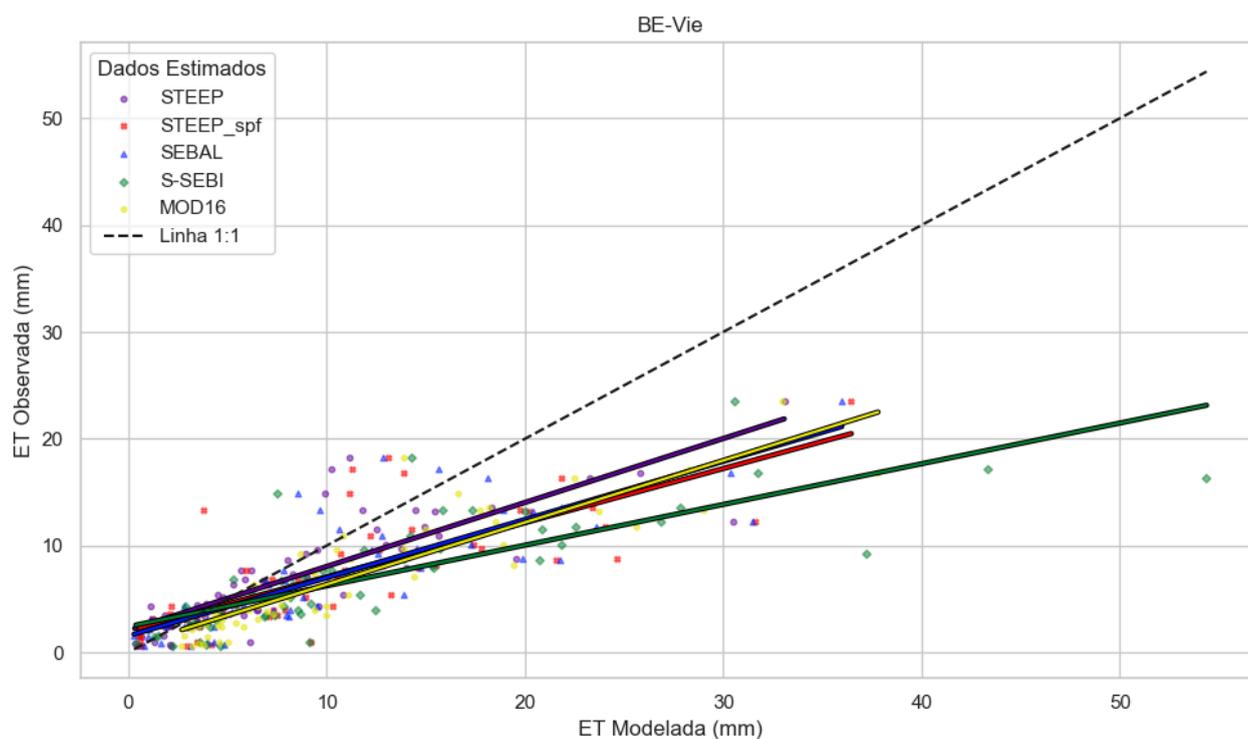


Figura A12. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo BE-Vie localizada em FTLM na escala temporal de ET acumulada de 8 dias.

Tabela A13. Métricas Estatísticas CA-Gro.

Modelo	R ²	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,564195	9,378310	-23,368479	-0,936639	75,112901
STEEP_spf	0,454475	12,273273	-54,436917	-2,316809	67,414770
SEBAL	0,330673	9,048886	-21,461711	-0,802975	57,504172
S-SEBI	0,346138	8,558294	-16,954608	-0,612776	58,833469
MOD16	0,854535	6,845474	-42,386993	-0,031827	92,441049

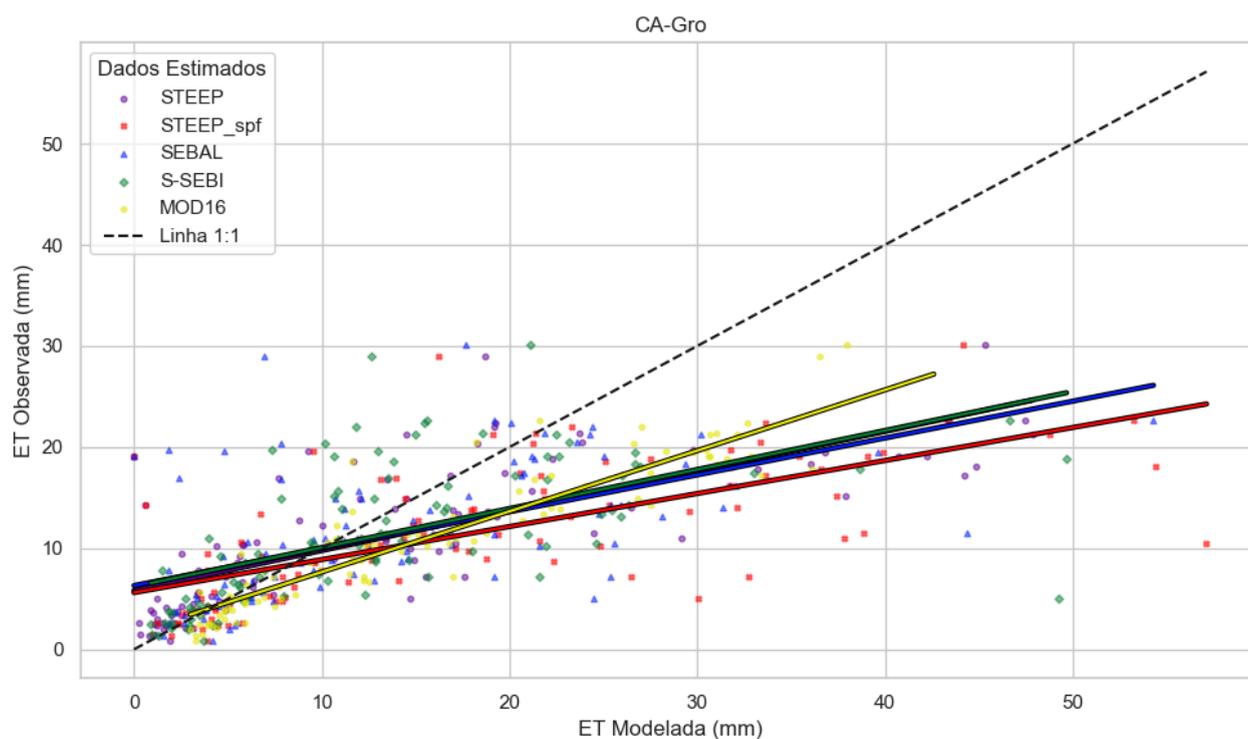


Figura A13. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo CA-Gro localizada em FTLM na escala temporal de ET acumulada de 8 dias.

Tabela A14. Métricas Estatísticas AU-Whr.

Modelo	R ²	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,357324	3,936598	25,669823	-1,774169	59,776588
STEEP_spf	0,332840	6,000195	-28,714222	-5,444980	57,692255
SEBAL	0,348995	6,223304	-34,554517	-5,933187	59,075832
S-SEBI	0,458224	7,510007	-57,130492	-9,096517	67,692257
MOD16	0,429265	1,961203	-9,613431	0,311449	65,518307

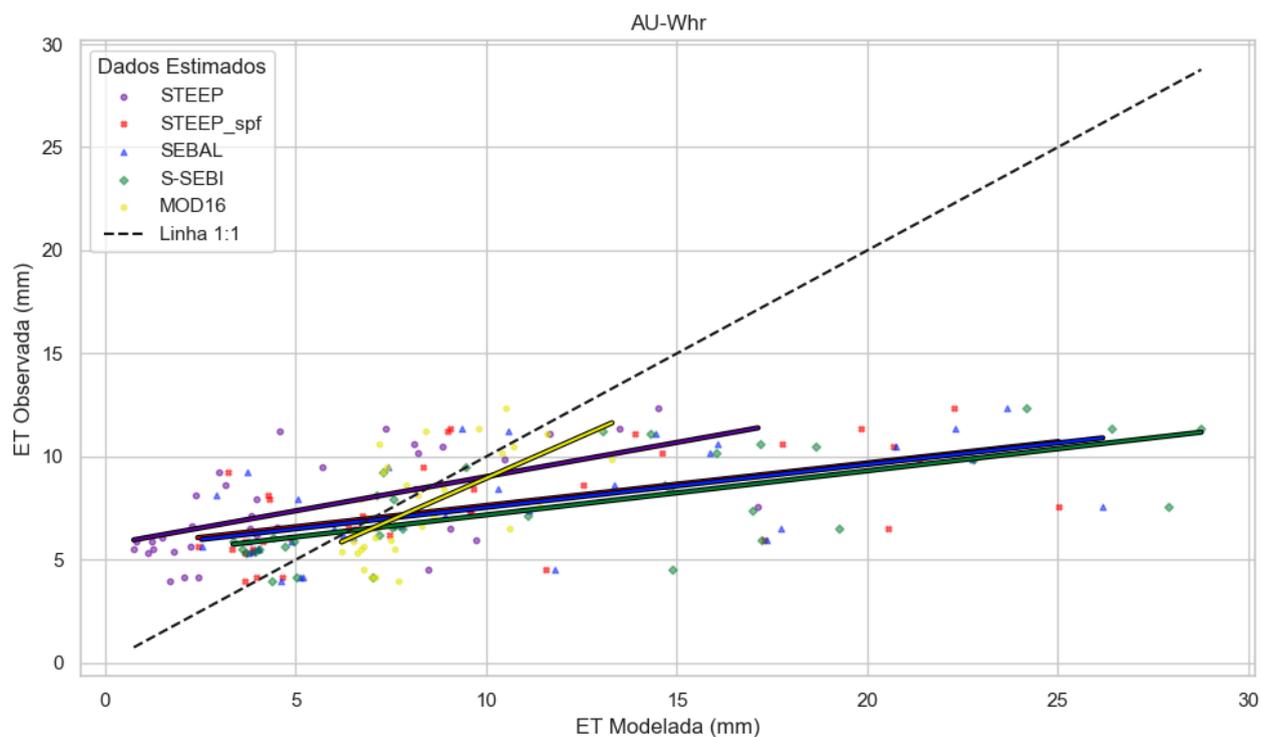


Figura A14. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo AU-Whr localizada em PTSM na escala temporal de ET acumulada de 8 dias.

Tabela A15. Métricas Estatísticas AU-Ync.

Modelo	R ²	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,231167	5,736245	-11,469246	-0,247937	48,079811
STEEP_spf	0,151566	11,587540	-72,474972	-4,092368	38,931482
SEBAL	0,123080	8,839694	-45,795649	-1,963547	35,082693
S-SEBI	0,209792	4,874264	4,875835	0,098937	45,803043
MOD16	0,041656	8,418696	55,358541	-1,687986	20,409857

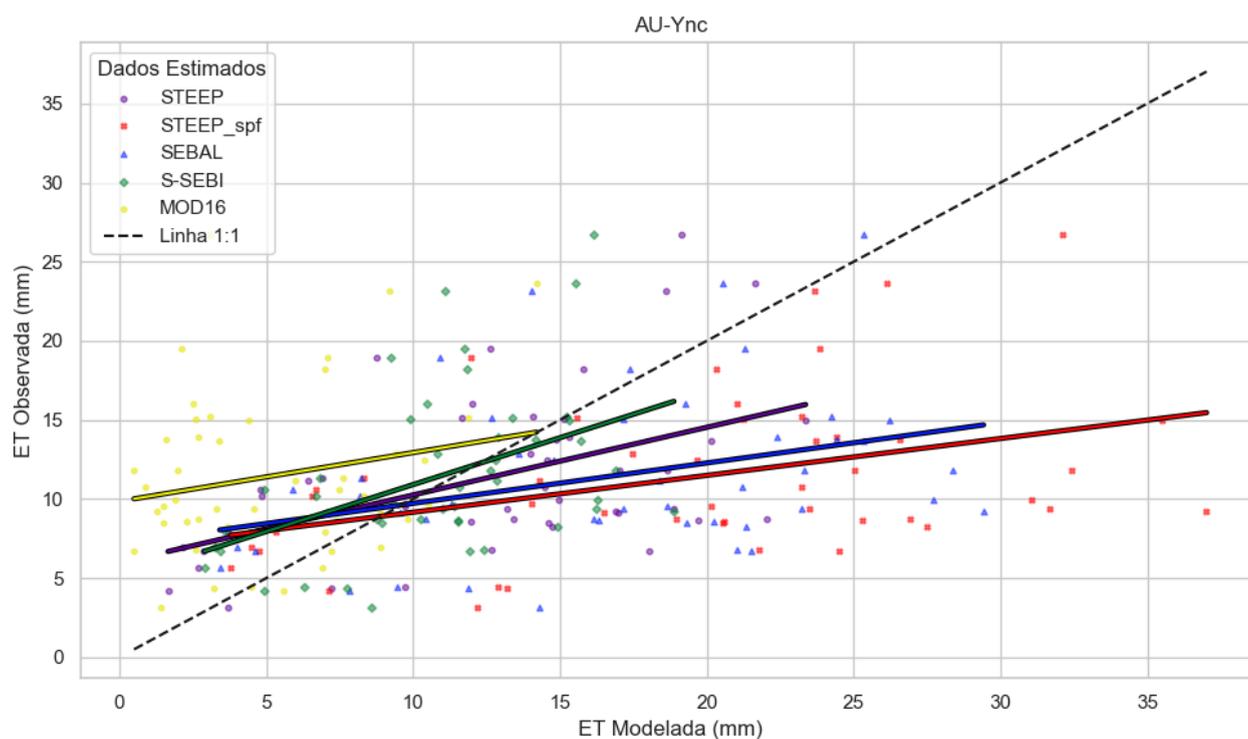


Figura A15. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo AU-Ync localizada em PTSM na escala temporal de ET acumulada de 8 dias.

Tabela A16. Métricas Estatísticas BR-CST.

Modelo	R ²	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,621661	5,105955	1,922950	0,575510	78,845510
STEEP_spf	0,621059	11,298570	-97,046756	-1,078551	78,807299
SEBAL	0,556691	8,889804	-68,795692	-0,286762	74,611726
S-SEBI	0,646021	5,458479	-24,824769	0,514871	80,375442
MOD16	0,612076	5,130780	-6,930605	0,571372	78,235277

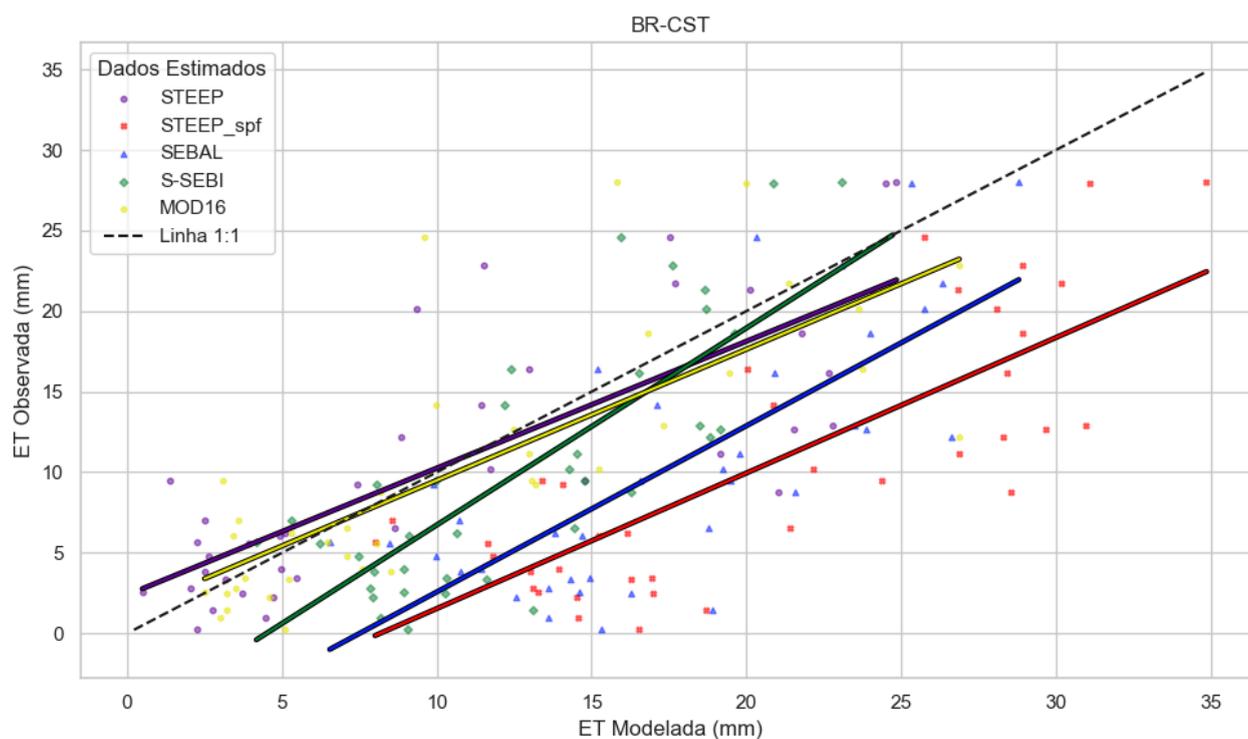


Figura A16. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo BR-CST localizada em FSTS na escala temporal de ET acumulada de 8 dias.

Tabela A17. Métricas Estatísticas BR-SNn.

Modelo	R ²	RMSE	PBIAS (%)	NSE	PC (%)
STEEP	0,779531	4,848707	1,263671	0,771711	88,291079
STEEP_spf	0,815820	7,295536	-56,455044	0,483170	90,322748
SEBAL	0,737533	6,112594	-28,321359	0,637186	85,879728
S-SEBI	0,823592	5,074137	7,284524	0,749990	90,751959
MOD16	0,729878	5,558749	-6,319034	0,699954	85,432909

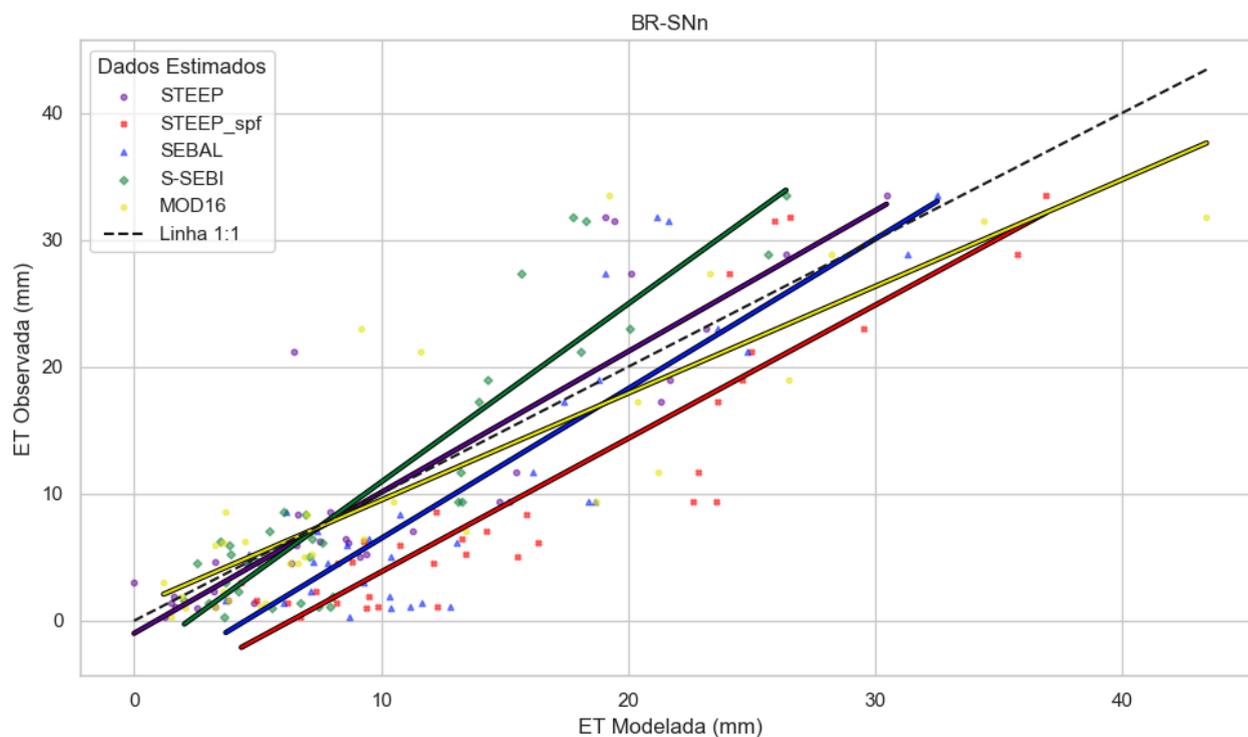


Figura A17. Diagramas de densidade de dispersão e regressão linear de 4 modelos de estimativa de ET em relação às observações da torre de fluxo BR-SNn localizada em FSTS na escala temporal de ET acumulada de 8 dias.