

VITOR CUNHA FONTES

**CALIBRAÇÃO AUTOMÁTICA MULTI-SÍTIO E MULTI-OBJETIVA DE UM
MODELO DE SUPERFÍCIE TERRESTRE**

**Dissertação apresentada à Universidade
Federal de Viçosa, como parte das
exigências do Programa de Pós-Graduação
em Meteorologia Aplicada, para obtenção do
título de *Magister Scientiae*.**

**VIÇOSA
MINAS GERAIS – BRASIL
2015**

AGRADECIMENTOS

A Universidade Federal de Viçosa e ao Programa de Pós-Graduação em Meteorologia Aplicada, pela oportunidade.

Ao professor e orientador Marcos Heil Costa, pelos ensinamentos e pela confiança.

Ao meu pai Juarez, minha mãe Maria do Carmo e minha irmã Bárbara, pelo apoio incondicional.

A minha noiva Camila, pelo incentivo e por ser um exemplo de dedicação e trabalho.

Aos amigos do Grupo de Pesquisa em Interação Atmosfera-Biosfera da UFV, por toda a ajuda recebida.

A banca examinadora por ter aceitado o convite.

Enfim, a todos aqueles que contribuíram para a realização deste trabalho, o meu muito obrigado.

ÍNDICE

LISTA DE ABREVIATURAS.....	iv
LISTA DE FIGURAS.....	v
LISTA DE TABELAS.....	vi
RESUMO.....	vii
ABSTRACT.....	viii
1 INTRODUÇÃO.....	1
1.1 Objetivo.....	4
1.1.1 Objetivos Específicos.....	5
2 REVISÃO DE LITERATURA.....	6
2.1 Problemas de Otimização.....	6
2.2 Calibração Multi-Sítio.....	8
3 MATERIAL E MÉTODOS.....	11
3.1 Optis.....	11
3.1.1 Ampliação do Optis.....	13
3.2 Dados Observados.....	14
3.2.1 Sítios Experimentais.....	15
3.3 Modelo INLAND.....	15
3.4 Experimento Numérico.....	16
4 RESULTADOS E DISCUSSÃO.....	23
5 CONCLUSÕES.....	33
5.1 Resumo.....	33
5.2 Conclusões.....	35
5.3 Recomendações para trabalhos futuros.....	36
6 REFERÊNCIAS.....	40

LISTA DE ABREVIATURAS

AMSMO:	<i>Average Multiple Sites Multiple Objectives.</i>
Bmax:	Viés máximo da soma cumulativa.
D	Índice de desempenho relativo.
FNS:	Fazenda Nossa Senhora Aparecida.
H:	Fluxo de calor sensível.
IBIS:	<i>Integrated Biosphere Simulator.</i>
INLAND:	Modelo Integrado de Processos Superficiais.
K34:	Reserva do Cuieiras no km 34.
K67:	Floresta Nacional do Tapajós no km 67.
K77:	Floresta Nacional do Tapajós no km 77.
LBA:	Experimento de Grande Escala da Biosfera-Atmosfera na Amazônia.
LE:	Fluxo de calor latente.
LSM:	<i>Land Surface Model.</i>
MAE:	Erro absoluto médio.
MSMO:	<i>Multiple Sites Multiple Objectives.</i>
NEE:	Troca líquida do ecossistema.
NSGA-II:	<i>Nondominated Sorting Genetic Algorithm.</i>
RMSE:	Raiz do erro quadrático médio.
Rn:	Saldo de radiação.
SSMO:	<i>Single Site Multiple Objectives.</i>
SSSO:	<i>Single Site Single Objective.</i>
SWAT:	<i>Soil and Water Assessment Tool.</i>

LISTA DE FIGURAS

Figura 1: Estrutura do Optis.....12

LISTA DE TABELAS

Tabela 1: Resumo das calibrações.....	18
Tabela 2: Parâmetros do NSGA-II para cada calibração.....	19
Tabela 3: Número de anos simulados em cada sítio.....	19
Tabela 4: Descrição dos parâmetros calibrados do INLAND.....	20
Tabela 5: Resultados das calibrações simultâneas para os sítios de pastagem (FNS e K77).....	24
Tabela 6: Resultados das calibrações hierárquicas {Rn} {H-LE-NEE} para os sítios de pastagem (FNS e K77).....	25
Tabela 7: Resultados das calibrações hierárquicas {H-LE-NEE} {Rn} para os sítios de pastagem (FNS e K77).....	25
Tabela 8: Resultados das calibrações simultâneas para os sítios de floresta (K67 e K34).....	26
Tabela 9: Resultados das calibrações hierárquicas {Rn} {H-LE-NEE} para os sítios de floresta (K67 e K34).....	26
Tabela 10: Resultados das calibrações hierárquicas {H-LE-NEE} {Rn} para os sítios de floresta (K67 e K34).....	27
Tabela 11: Calibração multi-objetivo com o menor MAE de cada variável em cada sítio.....	27
Tabela 12: Índice D das calibrações realizadas nos sítios de pastagem (FNS e K77).....	28
Tabela 13: Índice D das calibrações realizadas nos sítios de floresta (K34 e K67).....	29
Tabela 14: Média do índice D para ambos os sítios de pastagem (FNS e K77).....	31
Tabela 15: Média do índice D para ambos os sítios de floresta (K34 e K67).....	32

RESUMO

FONTES, Vitor Cunha, M.Sc., Universidade Federal de Viçosa, setembro de 2015. **Calibração automática multi-sítio e multi-objetiva de um modelo de superfície terrestre**. Orientador: Marcos Heil Costa.

Os modelos de interação atmosfera-biosfera (LSMs) são ferramentas fundamentais em pesquisas relacionadas a superfície terrestre, atmosfera, hidrologia, previsão do tempo e clima. Desde o surgimento dos primeiros modelos na década de 60, esses modelos sofreram uma grande evolução e estão se tornando cada vez mais complexos. Esses LSMs simulam uma grande quantidade dos processos que ocorrem na biosfera, como os fluxos de radiação, calor, vapor de água e momentum. Cada um desses processos possui um ou mais parâmetros e o uso correto desses parâmetros são de suma importância para se obter uma simulação realista (confiável). Mas nem sempre é possível coletar ou inferir o valor desses parâmetros. Nesses casos pode-se realizar uma calibração do modelo, que é um conjunto de testes (simulações), com valores aleatórios de parâmetros, que são realizados até que se encontre um bom ajuste do modelo. No entanto, uma calibração simples acaba ajustando o modelo apenas localmente. Para se obter uma calibração que represente toda uma região (com características similares) é preciso realizar uma calibração multi-sítio. Este trabalho apresenta uma ampliação do Optis (software de calibração automática) que possibilita a realização de calibrações multi-sítio do modelo INLAND. Duas técnicas de calibração multi-sítio foram desenvolvidas, a MSMO (*Multiple Site Multiple Objectives*) e a AMSMO (*Average Multiple Sites Multiple Objectives*). A diferença entre elas é que, enquanto a MSMO leva em consideração cada sítio de forma independente, a AMSMO faz uma média dos sítios. Um experimento numérico foi realizado comparando as técnicas multi-sítio com calibrações realizadas em um único sítio. Os resultados mostraram que a calibração AMSMO é a que gera uma melhor representação dos sítios usados na calibração, atingindo mais de 80% de ajuste.

ABSTRACT

FONTES, Vitor Cunha, M.Sc., Universidade Federal de Viçosa, September, 2015. **Multi-site and multi-objective automatic calibration of a land surface model**. Adviser: Marcos Heil Costa.

Land surface models (LSMs) are important tools for research on land surface, atmosphere, hydrology, weather forecast and climate. Since the emergence of the first models in the 1960s, these models experienced substantial evolution and are becoming increasingly complex. A large number of biosphere processes, such as radiation, sensible heat, water vapor and momentum fluxes are simulated by these LSMs. Each process has one or more parameters and the correct choice of these parameters are very important to obtain a realistic simulation. However, collect (or infer) the parameters values is not always possible. In this case, it is suggested to perform a model calibration, which is a set of tests (simulations), with random parameters values, repeated until a good model fit is achieved. However, a simple calibration only adjusts the model locally. To obtain a calibration that represents an entire region (with similar characteristics), it is necessary a multi-site calibration. This work presents an extension of the Optis (an automatic calibration software) that allows multi-site calibrations of the INLAND model. Two multi-site calibration techniques were developed, MSMO (Multiple Site Multiple Objectives) and AMSMO (Average Multiple Sites Multiple Objectives). The difference between them is that MSMO considers the results of each site independently, while AMSMO makes an average of the sites. A numerical experiment was conducted comparing multi-site techniques with calibrations performed in a single site. The results showed that AMSMO calibration generates a better representation of the sites used for calibration, with model performance greater than 80% of the best model performance.

1 INTRODUÇÃO

A modelagem computacional é uma ferramenta que, por meio de conhecimentos matemáticos e físicos, auxilia no estudo de sistemas complexos. Isto porque, na maioria dos casos, é mais simples e rápido testar diferentes hipóteses utilizando o computador. Um modelo é, normalmente, uma representação simplificada da realidade, expressa por meio de fórmulas e parâmetros. Com o ajuste desses parâmetros pode-se realizar as simulações. A análise dos resultados de diferentes simulações ajuda a compreender o fenômeno modelado.

O uso da modelagem pode ser visto na medicina [Celada e Seiden, 1992; Mallet e De Pillis, 2006], no estudo da aerodinâmica [Menter, 1993; Richards e Hoxey, 1993], em estudos sociais [Mui et al., 2002; Miller e Page, 2007], etc. O foco deste trabalho está nos modelos de interação atmosfera-biosfera, ferramenta fundamental em pesquisas relacionadas a superfície terrestre, atmosfera, hidrologia, previsão do tempo e clima.

Estes modelos de interação atmosfera-biosfera, também conhecidos como *Land Surface Models* (LSMs), surgiram na década de 60. Um dos primeiros trabalhos nessa área foi o de Manabe e Bryan [1969]. Desde então, esses modelos tiveram uma grande evolução. Segundo Sellers et al. [1997], a primeira geração de LSMs era baseada em fórmulas de transferência de massa simples, a segunda geração inseriu os efeitos da vegetação no cálculo do balanço de energia, e a terceira (e atual) usa teorias modernas sobre fotossíntese e relações planta-água fornecendo descrições consistentes sobre evapotranspiração, e troca de energia e carbono pelas plantas.

Outro fator que contribuiu para o aumento de complexidade dos LSMs foi a evolução da capacidade de processamento dos computadores. Essa evolução computacional possibilitou aos modelos uma maior resolução temporal e espacial nos cálculos dos processos simulados [McGuffie e Henderson-Sellers, 2001].

Os LSMs mais complexos simulam uma grande quantidade dos processos que ocorrem na biosfera, como os fluxos de radiação, calor, vapor de água e momentum. Isto torna esses modelos mais completos. Porém, de uma maneira geral, quanto mais fluxos modelados mais parâmetros são necessários, exigindo mais conhecimento para se realizar uma simulação.

Os parâmetros de um modelo são de suma importância para se realizar uma simulação realista e, assim, obter resultados confiáveis. Nos LSMs isso não é diferente. Liu et al. [2003], por exemplo, mostram o impacto negativo que uma deficiência nos parâmetros de evaporação do dossel pode causar ao modelo. Isto mostra que, nos LSMs, os parâmetros precisam ser especificamente obtidos para cada situação (região, ecossistema, tipo de vegetação) modelada.

Existem algumas tentativas de se criar banco de dados globais de parâmetros, como Masson et al. [2003]. Entretanto, ainda existe uma vasta quantidade deles não mapeados. Outra alternativa seria a coleta dos parâmetros diretamente do local desejado, ou ainda o uso de algum conhecimento prévio para inferi-los. Porém, essas opções nem sempre são possíveis ou viáveis.

Nessas situações, onde não se sabem os valores reais dos parâmetros pode-se realizar uma calibração do modelo. De uma maneira simples, uma calibração pode ser descrita como um conjunto de testes (simulações), com valores aleatórios de parâmetros, que são realizados até que se encontre um resultado aceitável do modelo. Normalmente, um resultado é considerado aceitável quando está a uma distância pré-estabelecida do esperado (observado), ou, quando não for possível atingir essa distância pré-estabelecida, estiver à menor distância possível.

Além de aumentar o ajuste do modelo, a calibração permite estudar cada caso de forma detalhada, para que os modelos sejam melhorados conforme as necessidades e recursos disponíveis [Pitman, 2003]. O processo de calibração, visto de uma ótica matemática, se torna, portanto, um problema de otimização, uma vez que é uma tentativa de minimizar a diferença entre o resultado simulado e o esperado.

Dependendo do número de parâmetros que se deseja calibrar, este processo pode ser tedioso e cansativo. Para tanto, foi desenvolvido o software Optis [Varejão et al., 2013], que faz a calibração automática dos parâmetros de maneira hierárquica e multi-objetiva. Hierárquico porque ele consegue lidar com níveis diferentes de calibração e multi-objetivo porque consegue otimizar mais de um processo na calibração dos parâmetros.

O Optis realiza a calibração de maneira pontual, ou seja, ele consegue calibrar os parâmetros para um local específico apenas. Isto faz com que os parâmetros representem as características daquele local. Desta maneira, eles acabam não sendo representativos de toda uma região [Groenendijk et al., 2011] mesmo que essa região tenha o ecossistema ou tipo de vegetação igual ao do sítio calibrado.

Para encontrar parâmetros que representem toda uma região é necessário uma calibração mais ampla. Uma tentativa de se obter esse resultado é a realização de uma calibração multi-sítio. Existem na literatura alguns trabalhos com abordagens multi-sítio, como Bekele e Nicklow [2007], Cao et al. [2006], Choi et al. [2015], Saeidifarzad et al. [2014] e Zhang et al. [2015]. Porém, a maioria deles são na área hidrológica. Fischer et al. [2013] apresentam uma discussão sobre a calibração multi-sítio de um LSM, comparando diferentes métricas e diferentes modos de realizar essa calibração.

Dando seguimento as idéias apresentadas por Fischer et al. [2013], este trabalho tem como foco principal a ampliação do Optis, mantendo as funcionalidades existentes e inserindo a possibilidade de se fazer uma calibração multi-sítio.

1.1 Objetivo

O objetivo deste trabalho é avaliar a qualidade da calibração multi-sítio utilizando a metodologia de calibração automática Optis, aplicada ao modelo de superfície INLAND.

1.1.1 Objetivos Específicos

- (a) Acoplar o Optis, que inicialmente foi elaborado para funcionar no IBIS, ao INLAND;
- (b) Implementar a calibração multi-sítio;
- (c) Utilizando o Optis, calibrar de forma individual dois pares de sítios, sendo cada par de um tipo de vegetação diferente;
- (d) Calibrar ambos os pares de sítios de forma simultânea (multi-sítio);
- (e) Comparar os ajustes da calibração individual e multi-sítio utilizando métricas matemáticas;

2 REVISÃO DE LITERATURA

2.1 Problemas de Otimização

Otimização é o estudo de problemas onde se busca maximizar (ou minimizar) uma ou mais funções. Nesse contexto, essas funções são denominadas de funções objetivo. Por intermédio do número de funções objetivo podemos classificar o problema de otimização em mono-objetivo (uma função) ou multi-objetivo (duas ou mais funções). Quanto maior o número de funções objetivas mais complexo é o problema de otimização.

A otimização de funções bem definidas (que podem ser escritas como uma fórmula matemática) é realizada por meio de métodos matemáticos como o Teorema do Valor Extremo ou Teorema de Fermat. Porém, algumas vezes a função objetivo pode ser desconhecida impossibilitando a aplicação desses métodos. Este é o caso quando, por exemplo, se está otimizando um modelo complexo. Só é possível saber o resultado de uma função depois de realizar

uma simulação. Além disso, não é possível prever como ela irá se comportar.

O problema com este tipo de otimização é que, normalmente, é inviável testar todas as opções possíveis em busca da melhor solução. Uma forma de resolver esse problema é utilizar heurísticas de busca. Essas heurísticas são métodos que procuram por boas soluções, mas sem garantir que elas são as melhores possíveis.

Da natureza veio a inspiração para o desenvolvimento de várias dessas heurísticas. Existem algoritmos baseados em técnicas derivadas de enxame de partículas [Poli et al., 2007], em que, por exemplo, imita-se o movimento dos pássaros em busca de comida. Outros estão baseados na organização e no modo de comunicação das formigas [Dorigo et al., 1996]. Existe, ainda, uma grande quantidade de heurísticas baseadas na evolução genética [Lücken et al., 2014], denominadas de algoritmos genéticos.

Uma diferença entre estes métodos é a forma como se constrói o resultado. Enquanto que as técnicas de enxame de partículas e colônia de formigas convergem para uma única solução, o algoritmo genético trabalha sempre com um conjunto de soluções. Este fator torna o algoritmo genético mais desejável na resolução de problemas multi-objetivos. Isto porque, nesse tipo de problema, os objetivos podem, eventualmente, ser conflitantes, ou seja, a otimização de um objetivo não gera resultados satisfatórios para outro. Impossibilitando, assim, a definição da melhor solução.

Os algoritmos genéticos buscam como solução o conjunto ótimo de Pareto. O ótimo de Pareto é uma fronteira no espaço de busca em que: (i) não existe nenhuma solução melhor que as soluções que estão na fronteira e (ii) as soluções que pertencem a ela são equivalentes. Porém, nem sempre é possível encontrar o ótimo de Pareto bem como todas as soluções da fronteira

[Lücken et al., 2014]. Outro problema existente é que há uma queda no desempenho com relação ao aumento do número de funções objetivo otimizadas simultaneamente [Veldhuizen e Lamont, 2000; Vrugt et al., 2003].

2.2 Calibração Multi-Sítio

A calibração multi-sítio (ou seja, utilizando mais de um sítio) é um método de calibração ainda pouco explorado. A maioria dos trabalhos encontrados utilizando esse método são da área hidrológica. Um dos estudos mais recentes foi publicado por Choi et al. [2015] e faz a calibração de um modelo *rainfall-runoff* utilizando dados de uma bacia hidrográfica. O trabalho foi feito dividindo a bacia hidrográfica em sub-bacias e comparando o resultado do modelo quando é calibrado com dados de uma ou duas sub-bacias. O resultado obtido foi que o modelo apresenta melhores resultados (representa melhor a bacia hidrográfica ao todo) quando calibrado com duas sub-bacias.

Saeidifarzad et al. [2014] testam a calibração multi-sítio em dois modelos hidrológicos diferentes (UECR e GUHN). Os autores utilizam duas estratégias diferentes de calibração (semi-aglomerada e semi-distribuída), variando os parâmetros calibrados e as funções objetivo. Os resultados mostraram que a calibração multi-sítio foi eficiente para os dois modelos, sendo que o melhor resultado foi encontrado utilizando a estratégia semi-distribuída no modelo GUHN.

Noor et al. [2014], Bekele e Nicklow [2007] e Cao et al. [2006] apresentam uma comparação entre a calibração mono-sítio e a calibração multi-sítio do modelo SWAT (*Soil and Water Assessment Tool*) com dados de bacias hidrográficas. A conclusão dos trabalhos foi que, apesar da calibração mono-sítio apresentar resultados satisfatórios, a calibração multi-

sítio foi superior tanto no ajuste dos dados quanto no processo de validação.

Wang et al. [2012] comparam a calibração hidrológica mono-sítio com a calibração multi-sítio. Nesse trabalho foi simulada uma bacia hidrográfica do norte da China em três estações diferentes, utilizando o modelo MIKE SHE (*Systeme Hydrologique European*). No experimento foram feitas duas calibrações, uma mono-sítio (utilizando uma estação) e outra multi-sítio (utilizando duas estações). Depois, as calibrações foram validadas utilizando todas as três estações e então, comparadas. A conclusão foi que a calibração mono-sítio obteve melhor resultado na estação na qual ela foi calibrada, porém, de um modo geral, levando em consideração todas as estações, a calibração multi-sítio obteve o melhor resultado.

Zhang et al. [2008] conduziram um estudo sobre esquemas de calibração do modelo SWAT. Utilizando três sítios diferentes os autores analisaram calibrações mono-objetiva mono-sítio (uma função objetivo por sítio), mono-objetiva multi-sítio (sendo a função objetivo a soma das funções nos três sítios) e multi-objetiva multi-sítio (contendo todas as funções objetivo citadas). Os autores concluíram que a melhor opção é a calibração multi-sítio. Eles acreditam, também, na importância da coleta de dados espacialmente distribuídos para que o modelo calibrado represente melhor a área de estudo.

Li et al. [2010] procuraram fazer uma calibração de um modelo hidrológico utilizando a média dos resultados de vários sítios. Na tentativa de encontrar um grupo de parâmetros que melhor representa toda uma bacia hidrográfica, os autores utilizaram resultados de calibrações mono-sítio de vários locais diferentes dentro da bacia. O grupo de parâmetros final é uma média ponderada dos melhores parâmetros encontrados em cada local. Os pesos utilizados variam de acordo com a qualidade de cada calibração. Os

sítios com melhores resultados receberam os maiores pesos. Os parâmetros obtidos por essa metodologia obteve melhores resultados que os parâmetros encontrados nas calibrações mono-sítio.

Saindo da área hidrológica temos os trabalhos de Hashimoto et al. [2011] e Fischer et al. [2013]. Hashimoto et al. [2011] desenvolveram um modelo simples com fluxos de CO_2 , CH_4 e N_2O . Foram utilizados dados de 36 sítios diferentes, situados em florestas no Japão, em uma calibração bayesiana multi-sítio. Com essas calibrações, os autores concluíram que os fluxos modelados possuem diferentes níveis de sensibilidade em relação ao conteúdo de água e temperatura do solo.

Fischer et al. [2013] apresentam um trabalho sobre calibração multi-sítio de um modelo de superfície terrestre (LSM). Nele são calibrados seis parâmetros em dois sítios localizados na região da Amazônia. A calibração foi realizada por meio de uma busca no espaço dos parâmetros, sendo analisadas várias combinações de parâmetros diferentes. Como medida de comparação, foram feitos quatro tipos de calibrações. Foram duas calibrações mono-sítio (uma em cada sítio) e duas multi-sítio. Nas calibrações multi-sítio as funções objetivo são a média das medidas de erros em ambos os sítios. A diferença entre as duas calibrações multi-sítio é que em uma é feita uma média normal e na outra é feita uma média ponderada. Na média ponderada o peso utilizado é a quantidade total de dados disponíveis em cada sítio. Os autores concluíram que a calibração multi-sítio, apesar de ter valores abaixo da calibração mono-sítio quando comparado diretamente, apresenta bons resultados. Além disso, a calibração multi-sítio não ponderada obteve melhor rendimento que o método ponderado.

3 MATERIAL E MÉTODOS

O trabalho aqui apresentado consistiu na ampliação do código do Optis, acrescentando as rotinas necessárias para a realização da calibração multi-sítio. Além disso, foi feito o acoplamento ao modelo de superfície INLAND, uma vez que o código original estava acoplado ao modelo IBIS. Utilizando os dados observados, foram realizadas sucessivas calibrações que foram comparadas entre si por meio de métricas matemáticas.

3.1 Optis

O Optis, uma metodologia desenvolvida por Varejão et al. [2013], é um algoritmo de otimização multi-objetivo baseado no algoritmo genético NSGA-II [Deb et al., 2002]. De maneira resumida, o Optis funciona da seguinte maneira: o algoritmo recebe uma lista de parâmetros a serem calibrados; utilizando técnicas baseadas na evolução genética cria várias configurações de parâmetros diferentes; executa o modelo com cada uma dessas configurações;

e, por fim, verifica o melhor resultado gerado. A Figura 1 exemplifica este funcionamento.

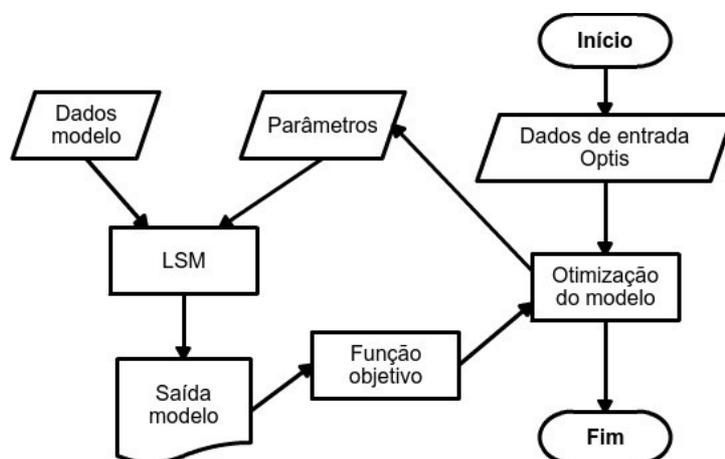


Figura 1: Estrutura do Optis

As técnicas genéticas utilizadas no Optis simulam a teoria da evolução. Cria-se uma população inicial, em que cada indivíduo representa um conjunto diferente de parâmetros. Estes indivíduos são testados e os melhores são selecionados para gerar uma nova população, por meio de cruzamento e mutação. Este ciclo se repete um número pré-determinado de vezes. Ao final, o Optis escolhe como configuração ideal o indivíduo da última geração que resulta na solução com menor distância da origem. Essa distância é normalizada de acordo com os resultados obtidos pelos indivíduos da última geração.

Os melhores indivíduos de cada geração são encontrados comparando os resultados simulados com dados observados. Esta comparação pode ser feita utilizando medidas de erro como MAE (erro absoluto médio), RMSE (raiz do erro quadrático médio) ou Bmax (viés máximo da soma cumulativa). Cada medida de erro aplicada a uma saída (variável) do modelo é considerada uma função objetiva. Os melhores indivíduos são aqueles que minimizam o erro, ou

seja,

$$\min_{\theta \in \Theta} F(\theta) = \{f_1(\theta), f_2(\theta), \dots, f_m(\theta)\}$$

em que $F(\theta)$ é o conjunto das m diferentes funções objetivo $\{f_1(\theta), f_2(\theta), \dots, f_m(\theta)\}$ a serem simultaneamente minimizadas, θ são os parâmetros do modelo e Θ é o conjunto de restrições, que pode ser fornecido explicitamente ou definido implicitamente.

Existem duas maneiras de se realizar uma calibração utilizando o Optis, a calibração simultânea e a calibração hierárquica. Na calibração simultânea todas as funções objetivo são minimizadas em conjunto, sendo calibrado todo o conjunto de parâmetros. Na calibração hierárquica são criados níveis de calibração, sendo que as funções objetivas e os parâmetros são divididos nesses grupos. Cada nível é calibrado separadamente, porém, a calibração encontrada em cada nível é utilizada no nível posterior.

O Optis foi originalmente implementado para calibrar de forma automática o modelo de superfície terrestre IBIS (*Integrated Biosphere Simulator*) [Foley et al., 1996]. Como pode ser visto na Figura 1, a interação entre eles é mínima, já que o Optis interage com o modelo apenas por meio da alteração dos seus parâmetros de entrada e da leitura dos seus dados de saída. Desta forma, o modelo é executado externamente ao algoritmo de otimização, o que torna o Optis praticamente independente do modelo que está sendo calibrado.

3.1.1 Ampliação do Optis

Para realização deste trabalho foram feitas alterações no código original do Optis. Uma das alterações realizadas foi a troca do modelo a ser calibrado.

O IBIS foi substituído pelo modelo INLAND, sendo alterada a lista de parâmetros possíveis de calibração. Além disso, foram necessários ajustes nas ações de execução e leitura do modelo realizadas pelo Optis.

Outra alteração do código original foi a implementação da calibração multi-sítio, possibilitando ao usuário escolher em qual sítio será aplicada a medida de erro. Cada sítio adicionado ao processo implica em uma execução a mais do modelo. Ou seja, em uma calibração com dois sítios o modelo é executado o dobro de vezes de uma calibração com um único sítio.

Ainda na implementação do multi-sítio, foi inserida a opção de decidir se duas (ou mais) medidas de erro de uma mesma variável, em sítios diferentes, serão consideradas funções objetivas independentes ou uma única função objetiva. Neste último caso, é usado como função objetivo uma média das medidas de erro.

3.2 Dados Observados

Os dados observados são uma parte importante do processo de calibração, pois é com base nesses dados que os erros do modelo são determinados. Além disso, eles também são necessários para execução do modelo. Para calcular o erro foram utilizados os seguintes dados: saldo de radiação R_n (Wm^{-2}), fluxo de calor sensível H (Wm^{-2}), fluxo de calor latente LE (Wm^{-2}) e troca líquida de carbono do ecossistema NEE ($\mu mol\ m^{-2}\ s^{-1}$).

Para executar o INLAND são necessários dados de temperatura e umidade específica do ar, precipitação, velocidade do vento, radiação de onda curta, radiação de onda longa, localização e altitude.

Para serem utilizados como entrada do INLAND os dados foram pré-processados. As falhas foram preenchidas por interpolação, de acordo com as

relações propostas por Senna et al. [2009] .

3.2.1 Sítios Experimentais

Todos os dados utilizados neste trabalho foram retirados do Experimento de Grande Escala da Biosfera-Atmosfera na Amazônia (LBA, *Large-Scale Biosphere-Atmosphere Experiment in Amazonia*). O LBA é um experimento internacional que estuda a interação entre a biosfera e a atmosfera na Amazônia e dispõe de 13 sítios experimentais com medições de fluxos e elementos meteorológicos.

Neste trabalho, são utilizados os dados obtidos na Floresta Nacional do Tapajós (Santarém – PA) nos km 67 e km 77 da BR-163, Reserva do Cuieiras no km 34 (Manaus – AM) e Fazenda Nossa Senhora Aparecida (Ji-Paraná – RO). Deste ponto em diante esses sítios serão identificados como K67, K77, K34 e FNS respectivamente. Dentre esses quatro sítios, dois estão situados em áreas de pastagens (FNS e K77) e dois em áreas de floresta tropical (K67 e K34).

3.3 Modelo INLAND

O Modelo Integrado de Processos Superficiais (INLAND) é o pacote de superfície do Modelo Brasileiro do Sistema Climático Global. Ele é baseado no modelo IBIS (*Integrated Biosphere Simulator*), modelo de superfície desenvolvido pela Universidade de Wisconsin-Madison [Foley et al., 1996]. O modelo é forçado por dados meteorológicos horários (versão pontual) ou dados climáticos regionais diários ou mensais (versão em grade), podendo ainda ser acoplado a modelos atmosféricos regionais ou globais. Neste trabalho, é

utilizada sua versão pontual.

3.4 Experimento Numérico

O experimento numérico realizado neste trabalho consistiu em avaliar a qualidade da calibração multi-sítio quando comparada a calibrações individuais. Para tanto, foram feitas diversas configurações de calibrações diferentes:

- *Single Site Single Objective* (SSSO): calibração contendo uma única função objetivo que é avaliada em um único sítio.
- *Single Site Multiple Objectives* (SSMO): calibração multi-objetivo, contendo quatro funções objetivo (R_n , H, LE e NEE), sendo todas essas funções objetivo avaliadas em um mesmo sítio. Esta calibração foi analisada de modo simultâneo e hierárquico. No modo simultâneo todas as funções objetivo são minimizadas no mesmo nível, enquanto que, no modo hierárquico elas são divididas em dois níveis diferentes.
- *Multiple Sites Multiple Objectives* (MSMO): calibração multi-objetivo avaliada em dois sítios contendo o mesmo tipo de vegetação. Cada medida de erro sobre uma variável gera duas funções objetivo, uma para cada sítio. Ou seja, cada variável é avaliada de maneira independente em cada um dos sítios. Analogamente à calibração anterior, esta calibração foi analisada de modo simultâneo e hierárquico.
- *Average Multiple Sites Multiple Objectives* (AMSMO): calibração multi-objetivo avaliada em dois sítios contendo o mesmo tipo de vegetação. Diferentemente da calibração anterior, cada medida de erro sobre uma variável gera uma única função objetivo para todos os sítios. O valor dessa função objetivo é a média dos valores encontrados nos dois

sítios. Analogamente às duas calibrações anteriores, esta calibração foi analisada de modo simultâneo e hierárquico.

A métrica utilizada para comparar as calibrações foi o índice de desempenho relativo (D), que é definido do seguinte modo:

$$D = \frac{1}{n} \sum_{i=1}^n \frac{f_i^{\text{mono}}}{f_i^{\text{multi}}}$$

sendo f_i^{mono} o resultado da função objetivo da variável i em uma calibração mono-objetivo, f_i^{multi} o resultado da função objetivo da variável i em uma calibração multi-objetivo, e n o total de variáveis. O foco principal desse índice é avaliar quão próximo da calibração mono-objetivo está a multi-objetivo. Isto porque, como nas calibrações mono-objetivo todos os parâmetros são calibrados de forma a otimizar uma única função objetivo, assume-se que seus resultados são os melhores resultados possíveis. Portanto, este índice varia de $0 \leq D \leq 1$ e, quanto maior for o seu valor, maior será a eficiência da calibração multi-objetivo em relação à mono-objetivo.

Para verificar se a calibração multi-sítio atinge um índice D maior que a calibração feita utilizando apenas um único sítio, o experimento foi realizado em dois tipos de vegetação diferentes. Os tipos utilizados foram pastagem (com os sítios FNS e K77) e floresta tropical (com os sítios K34 e K67). Estes quatro sítios foram apresentados na Seção 3.2.1. Foi escolhido como medida de erro o erro absoluto médio (MAE). As variáveis que tiveram seus erros minimizados foram as quatro variáveis citadas na Seção 3.2 (Rn, H, LE e NEE).

Foram realizadas um total de 40 calibrações (Tabela 1), sendo 16 SSSO, em que as quatro variáveis foram calibradas uma a uma em cada um dos quatro sítios; 12 SSMO, em que foram calibradas as quatro variáveis (Rn, H, LE e NEE) em cada um dos quatro sítios; seis MSMO e seis AMSMO, em que

foram calibradas as quatro variáveis (Rn, H, LE e NEE) em dois sítios por vez.

As calibrações multi-objetivo (SSMO, MSMO e AMSMO), além de serem feitas de modo simultâneo, também foram realizadas de modo hierárquico, porém alternando a ordem de otimização ($\{Rn\}\{H-LE-NEE\}$ e $\{H-LE-NEE\}\{Rn\}$). Em ambas as calibrações hierárquicas, foram criados dois níveis de calibração, um com a variável Rn e outro com as variáveis H, LE e NEE. A diferença entre elas é a ordem dos níveis.

Tabela 1: Resumo das calibrações

	Simultânea	$\{Rn\}\{H-LE-NEE\}$	$\{H-LE-NEE\}\{Rn\}$	Total
SSSO	16	-	-	16
SSMO	4	4	4	12
MSMO	2	2	2	6
AMSMO	2	2	2	6
Total	24	8	8	40

Para realizar as comparações, cada calibração multi-objetivo (SSMO, MSMO e AMSMO) feita em um tipo de vegetação, foi testada em ambos os sítios desse mesmo tipo de vegetação. Ou seja, uma calibração multi-sítio (MSMO e AMSMO) calibrada com os sítios A e B (do mesmo tipo de vegetação) foi testada nos dois sítios, assim como uma calibração mono-sítio (SSMO) calibrada com o sítio A também foi testada nos sítios A e B.

Neste trabalho, o teste de uma calibração tipo X no sítio A significa que, utilizando os parâmetros resultantes da calibração tipo X, foi feita uma simulação do sítio A e depois calculado o MAE de todas as variáveis (Rn, H, LE e NEE).

Para executar o Optis é preciso definir os parâmetros específicos do NSGA-II. Ele possui os seguintes parâmetros: eta_m, eta_c, pmut_real, pcross_real, número de gerações e tamanho da população. Os parâmetros eta_m, eta_c, pmut_real e pcross_real foram definidos com os mesmos valores

para todas as calibrações. Os valores utilizados foram: $\eta_m = 10$; $\eta_c = 10$; $p_{mut_real} = 0,5$; $p_{cross_real} = 0,9$. Estes foram os valores utilizados por Varejão et al. [2013]. O número de gerações e o tamanho da população variam de acordo com o número de objetivos e sítios utilizados, como pode ser visto na Tabela 2.

Tabela 2: Parâmetros do NSGA-II para cada calibração

	SSSO	SSMO	MSMO	AMSMO
Número de gerações	100	200	300	300
Tamanho da população	60	100	160	160

Para cada sítio simulado no INLAND é preciso informar algumas características como, por exemplo, a localização, altitude e o tempo de duração de cada simulação. Esses dados foram todos retirados do LBA. Porém, foi utilizada a técnica de spin-up para aumentar o tempo de duração de cada simulação. Neste caso, os dados de todos os sítios foram replicados 3 vezes, quadruplicando o número de anos simulados. A Tabela 3, a seguir, exibe o número de anos simulados e o número total de *time steps* em cada sítio.

Tabela 3: Número de anos simulados em cada sítio

Sítio	FNS	K77	K34	K67
Número de anos simulados	12	20	16	12
Número total de <i>time steps</i>	105120	175200	140160	105120

A Tabela 4 apresenta uma lista com todos os parâmetros do INLAND que foram calibrados, bem como uma descrição de cada um. Nos sítios de floresta (K34 e K67) foram utilizados todos os 53 parâmetros. Sendo que na calibração simultânea todos os parâmetros foram calibrados em conjunto, enquanto que nas calibrações hierárquicas eles foram distribuídos entre os níveis hierárquicos {Rn} e {H-LE-NEE}. Os parâmetros 3, 9, 10, 32, 33, 34, 35, 45, 46, 47 e 48 ficaram no nível {Rn} e o restante no nível {H-LE-NEE}.

Na calibração dos sítios de pastagem (FNS e K77) foram utilizados 42 parâmetros da Tabela 4. Do total de 53 parâmetros listados, não foram utilizados os parâmetros 6, 10, 12, 13, 27, 30, 33, 35, 46, 48 e 49, que são parâmetros exclusivos de árvores. Na calibração simultânea todos os parâmetros foram calibrados em conjunto, enquanto que nas calibrações hierárquicas eles foram distribuídos entre os dois níveis hierárquicos. Os parâmetros 3, 9, 32, 34, 45 e 47 ficaram no nível {Rn} e o restante no nível {H-LE-NEE}.

Tabela 4: Descrição dos parâmetros calibrados do INLAND

Nome	Descrição
1 AEP	Potencial de entrada de ar do solo
2 aleaf	Fração de alocação de carbono nas folhas
3 avmuir	Coefficiente para o cálculo da emissividade do dossel
4 awood	Fração de alocação de carbono na madeira
5 beta1	Distribuição vertical de raízes do dossel inferior
6 beta2	Distribuição vertical de raízes do dossel superior
7 bexp	Expoente b de Campbell
8 bperm	Difusividade hidráulica do solo
9 chiflz	Fator de orientação da folha do dossel inferior
10 chifuz	Fator de orientação da folha do dossel superior
11 chl	Capacidade térmica das folhas e galhos do dossel inferior
12 chs	Capacidade térmica dos galhos do dossel superior
13 chu	Capacidade térmica das folhas do dossel superior
14 clitll	Carbono inicial no reservatório de liteira de folha - lignina
15 clitlm	Carbono inicial no reservatório de liteira de folha - metabólico
16 clitls	Carbono inicial no reservatório de liteira de folha - estrutural
17 clitrl	Carbono inicial no reservatório de liteira de raízes finas - lignina
18 clitrm	Carbono inicial no reservatório de liteira de raízes finas - metabólico
19 clitrs	Carbono inicial no reservatório de liteira de raízes finas - estrutural
20 clitwl	Carbono inicial no reservatório de liteira de madeira - lignina
21 clitwm	Carbono inicial no reservatório de liteira de madeira - metabólico
22 clitws	Carbono inicial no reservatório de liteira de madeira - estrutural
23 coefm	Coefficiente m relacionado a condutância estomática
24 csoipas	Carbono inicial no solo – húmus passivo
25 csoislon	Carbono inicial no solo – húmus não protegido lento
26 csoislop	Carbono inicial no solo – húmus protegido lento

Tabela 4 (Continuação)		
27	dispuhf	Altura de deslocamento do plano zero para o dossel superior
28	FC	Capacidade de campo do solo
29	ialoglhf	Coeficiente para o cálculo da rugosidade do dossel inferior
30	ialoguhf	Coeficiente para o cálculo da rugosidade do dossel superior
31	rgrowth	Coeficiente de respiração de crescimento
32	rhonegnirl	Refletância da folha no dossel inferior (infravermelho próximo)
33	rhonegniru	Refletância da folha no dossel superior (infravermelho próximo)
34	rhonegvisl	Refletância da folha no dossel inferior (visível)
35	rhonegvisu	Refletância da folha no dossel superior (visível)
36	rootae	Coeficiente da função de temperatura da biomassa das raízes
37	rrootpy	Coeficiente de manutenção de respiração das raízes
38	rwoodpy	Coeficiente de manutenção de respiração dos troncos
39	SHC	Condutividade hidráulica saturada do solo
40	specla	Área foliar específica
41	stemaef	Coeficiente da função de temperatura da biomassa dos galhos
42	stressfac	Coeficiente relacionado ao estresse hídrico do solo
43	tauleaf	Constante de tempo de retorno da biomassa de folhas
44	tauroot	Constante de tempo de retorno da biomassa de raízes finas
45	tauegnirl	Transmitância da folha no dossel inferior (infravermelho próximo)
46	tauegniru	Transmitância da folha no dossel superior (infravermelho próximo)
47	tauegvisl	Transmitância da folha no dossel inferior (visível)
48	tauegvisu	Transmitância da folha no dossel superior (visível)
49	tauwood0	Constante de tempo de retorno da biomassa de madeira
50	tempvm_nec	Parâmetro de estresse térmico do Vmax
51	vmax_pft	Capacidade de atividade máxima da enzima Rubisco
52	WP	Ponto de murcha permanente do solo
53	wsoi	Umidade inicial do solo

Os parâmetros FC, WP, bexp, AEP e SHC são específicos para cada classe de textura do solo. As classes de textura de cada sítio foram definidas de acordo com os dados coletados no LBA e com o modelo INLAND. Assim, o sítio FNS obteve a classe de textura Franco-arenoso (*Sandy Loam*), o K77 e o K67 a classe Muito Argiloso (*Clay*) e o K34 a classe Franco-siltoso (*Silty Loam*).

Os parâmetros vmax_pft, tauleaf, tauroot, aleaf, awood, spleca e coefm são específicos para cada tipo funcional de planta (PFT). Para os sítios de pastagem foi considerado apenas o PFT gramíneas C4. Para os sítios de

floresta foram considerados cinco PFTs : (i) floresta tropical sempre verde (perene), (ii) floresta tropical decídua, (iii) arbustos sempre verde (perene), (iv) gramíneas C4 e (v) gramíneas C3.

4 RESULTADOS E DISCUSSÃO

As Tabelas 5 a 10 apresentam os resultados das 40 calibrações descritas anteriormente. As Tabelas 5 a 7 apresentam os resultados obtidos para os sítios de pastagem (FNS e K77), enquanto as Tabelas 8 a 10 apresentam os resultados obtidos para os sítios de floresta (K34 e K67). As Tabelas 5 e 8 apresentam os resultados das calibrações simultâneas, as Tabelas 6 e 9 os resultados das calibrações hierárquicas $\{R_n\}_{H-LE-NEE}$ e as Tabelas 7 e 10 os resultados das calibrações hierárquicas $\{H-LE-NEE\}_{R_n}$.

Em todas essas seis tabelas, a primeira coluna exhibe os sítios onde as calibrações foram testadas. A segunda coluna exhibe qual tipo de calibração realizada. A terceira exhibe o número de funções objetivo. Da quarta até sétima coluna são exibidos os erros absolutos médios de cada variável. A oitava, e última, coluna exhibe o índice de desempenho relativo (D) obtido de cada tipo de calibração. As calibrações SSSO não possuem índice D pois elas servem como base para o cálculo.

Vale ressaltar que, na nomenclatura utilizada na segunda coluna dessas seis tabelas, os sítios sobrescritos representam o sítio onde a calibração foi realizada, e os sítios subscritos representam onde a calibração foi testada. Assim, a nomenclatura $MSMO_{FNS}^{FNS, K77}$, por exemplo, indica que foi realizada uma calibração multi-sítio utilizando os sítios FNS e K77 e que os MAEs das variáveis foram obtidos em relação ao sítio FNS.

Tabela 5: Resultados das calibrações simultâneas para os sítios de pastagem (FNS e K77)

		n	MAE(Rn) W m ⁻²	MAE(H) W m ⁻²	MAE(LE) W m ⁻²	MAE(NEE) μmol m ⁻² s ⁻¹	D
FNS	$SSSO_{FNS}^{FNS}$	1	5,847	15,00	24,27	3,999	-
	$SSMO_{FNS}^{FNS}$	4	6,322	19,89	31,57	5,469	0,7947
	$SSMO_{FNS}^{K77}$	4	13,15	21,86	40,71	5,440	0,6155
	$MSMO_{FNS}^{FNS, K77}$	8	15,36	18,59	46,43	5,998	0,5942
	$AMSMO_{FNS}^{FNS, K77}$	4	6,276	19,91	35,29	4,924	0,7962
K77	$SSSO_{K77}^{K77}$	1	22,66	21,39	37,72	3,686	-
	$SSMO_{K77}^{K77}$	4	25,82	22,47	38,99	3,868	0,9375
	$SSMO_{K77}^{FNS}$	4	35,54	22,06	43,59	4,290	0,8329
	$MSMO_{K77}^{FNS, K77}$	8	36,13	21,49	40,12	4,188	0,8607
	$AMSMO_{K77}^{FNS, K77}$	4	28,32	22,48	40,42	3,879	0,9088

Tabela 6: Resultados das calibrações hierárquicas {Rn} {H-LE-NEE} para os sítios de pastagem (FNS e K77)

		n	MAE(Rn) W m ⁻²	MAE(H) W m ⁻²	MAE(LE) W m ⁻²	MAE(NEE) μmol m ⁻² s ⁻¹	D
FNS	SSSO _{FNS} ^{FNS}	1	5,847	15,00	24,27	3,999	-
	SSMO _{FNS} ^{FNS}	4	13,38	16,12	30,34	5,177	0,7350
	SSMO _{FNS} ^{K77}	4	16,91	18,71	55,65	4,939	0,5983
	MSMO _{FNS} ^{FNS,K77}	8	8,222	18,78	41,54	5,911	0,6927
	AMSMO _{FNS} ^{FNS,K77}	4	16,30	16,40	25,07	5,985	0,7274
K77	SSSO _{K77} ^{K77}	1	22,66	21,39	37,72	3,686	-
	SSMO _{K77} ^{K77}	4	26,98	22,63	38,47	3,730	0,9384
	SSMO _{K77} ^{FNS}	4	43,87	26,65	41,74	4,045	0,7835
	MSMO _{K77} ^{FNS,K77}	8	30,85	21,72	39,01	3,796	0,9143
	AMSMO _{K77} ^{FNS,K77}	4	30,86	22,51	39,29	3,849	0,9006

Tabela 7: Resultados das calibrações hierárquicas {H-LE-NEE} {Rn} para os sítios de pastagem (FNS e K77)

		n	MAE(Rn) W m ⁻²	MAE(H) W m ⁻²	MAE(LE) W m ⁻²	MAE(NEE) μmol m ⁻² s ⁻¹	D
FNS	SSSO _{FNS} ^{FNS}	1	5,847	15,00	24,27	3,999	-
	SSMO _{FNS} ^{FNS}	4	6,470	21,97	27,10	4,963	0,8219
	SSMO _{FNS} ^{K77}	4	18,43	26,40	39,34	5,142	0,5700
	MSMO _{FNS} ^{FNS,K77}	8	7,686	32,29	32,06	5,331	0,6831
	AMSMO _{FNS} ^{FNS,K77}	4	7,956	26,96	25,60	5,715	0,7348
K77	SSSO _{K77} ^{K77}	1	22,66	21,39	37,72	3,686	-
	SSMO _{K77} ^{K77}	4	23,81	27,14	39,65	3,727	0,9200
	SSMO _{K77} ^{FNS}	4	34,42	24,06	41,17	4,148	0,8380
	MSMO _{K77} ^{FNS,K77}	8	25,48	25,65	41,25	4,436	0,8671
	AMSMO _{K77} ^{FNS,K77}	4	25,02	24,99	40,09	3,827	0,9164

Tabela 8: Resultados das calibrações simultâneas para os sítios de floresta (K67 e K34)

		n	MAE(Rn) W m ⁻²	MAE(H) W m ⁻²	MAE(LE) W m ⁻²	MAE(NEE) μmol m ⁻² s ⁻¹	D
K34	SSSO ^{K34} _{K34}	1	33,48	18,41	25,72	4,000	-
	SSMO ^{K34} _{K34}	4	38,05	19,81	27,89	5,035	0,8815
	SSMO ^{K67} _{K34}	4	39,18	22,28	38,09	5,552	0,7691
	MSMO ^{K34,K67} _{K34}	8	35,76	27,48	31,85	5,196	0,7959
	AMSMO ^{K34,K67} _{K34}	4	35,30	21,80	30,96	5,433	0,8400
K67	SSSO ^{K67} _{K67}	1	18,99	12,15	23,72	2,860	-
	SSMO ^{K67} _{K67}	4	24,90	13,85	24,87	3,235	0,8694
	SSMO ^{K34} _{K67}	4	41,68	19,98	36,65	3,979	0,6074
	MSMO ^{K34,K67} _{K67}	8	32,99	15,52	25,69	2,939	0,8137
	AMSMO ^{K34,K67} _{K67}	4	21,53	19,03	24,98	3,291	0,8348

Tabela 9: Resultados das calibrações hierárquicas {Rn} {H-LE-NEE} para os sítios de floresta (K67 e K34)

		n	MAE(Rn) W m ⁻²	MAE(H) W m ⁻²	MAE(LE) W m ⁻²	MAE(NEE) μmol m ⁻² s ⁻¹	D
K34	SSSO ^{K34} _{K34}	1	33,48	18,41	25,72	4,000	-
	SSMO ^{K34} _{K34}	4	35,33	20,73	30,34	4,988	0,8713
	SSMO ^{K67} _{K34}	4	39,63	23,14	36,86	5,224	0,7760
	MSMO ^{K34,K67} _{K34}	8	37,95	18,75	31,36	4,371	0,8998
	AMSMO ^{K34,K67} _{K34}	4	50,56	19,74	26,80	7,073	0,7800
K67	SSSO ^{K67} _{K67}	1	18,99	12,15	23,72	2,860	-
	SSMO ^{K67} _{K67}	4	24,56	15,30	24,86	3,142	0,8579
	SSMO ^{K34} _{K67}	4	29,83	34,66	40,57	4,909	0,5386
	MSMO ^{K34,K67} _{K67}	8	39,13	17,48	30,05	4,048	0,6691
	AMSMO ^{K34,K67} _{K67}	4	28,91	16,03	24,27	3,898	0,7815

Tabela 10: Resultados das calibrações hierárquicas {H-LE-NEE} {Rn} para os sítios de floresta (K67 e K34)

		n	MAE(Rn) W m ⁻²	MAE(H) W m ⁻²	MAE(LE) W m ⁻²	MAE(NEE) μmol m ⁻² s ⁻¹	D
K34	SSSO ^{K34} _{K34}	1	33,48	18,41	25,72	4,000	-
	SSMO ^{K34} _{K34}	4	34,83	20,89	29,37	5,306	0,8680
	SSMO ^{K67} _{K34}	4	40,89	24,86	40,16	5,308	0,7383
	MSMO ^{K34,K67} _{K34}	8	39,42	24,73	33,31	5,859	0,7622
	AMSMO ^{K34,K67} _{K34}	4	39,60	24,68	34,20	6,134	0,7489
K67	SSSO ^{K67} _{K67}	1	18,99	12,15	23,72	2,860	-
	SSMO ^{K67} _{K67}	4	22,79	16,94	25,38	3,533	0,8237
	SSMO ^{K34} _{K67}	4	33,62	28,41	40,05	4,892	0,5423
	MSMO ^{K34,K67} _{K67}	8	21,07	41,55	39,84	5,611	0,5747
	AMSMO ^{K34,K67} _{K67}	4	25,29	21,17	27,11	3,876	0,7344

Os melhores resultados, ou seja menor MAE, de cada variável, em cada sítio, foram encontrados na calibração SSSO. Isto era o esperado uma vez que, nesses casos, foi calibrada uma variável por vez. Levando em consideração apenas os métodos multi-objetivo (SSMO, MSMO e AMSMO), as calibrações com os menores erros de cada variável em cada sítio são apresentadas na Tabela 11.

Tabela 11: Calibração multi-objetivo com o menor MAE de cada variável em cada sítio

	Rn	H	LE	NEE
FNS	AMSMO ^{FNS,K77} _{FNS} (simultânea)	SSMO ^{FNS} _{FNS} ({Rn} {H-LE-NEE})	AMSMO ^{FNS,K77} _{FNS} ({Rn} {H-LE-NEE})	AMSMO ^{FNS,K77} _{FNS} (simultânea)
K77	SSMO ^{K77} _{K77} ({H-LE-NEE} {Rn})	MSMO ^{FNS,K77} _{K77} (simultânea)	SSMO ^{K77} _{K77} ({Rn} {H-LE-NEE})	SSMO ^{K77} _{K77} ({H-LE-NEE} {Rn})
K34	SSMO ^{K34} _{K34} ({H-LE-NEE} {Rn})	MSMO ^{K34,K67} _{K34} ({Rn} {H-LE-NEE})	AMSMO ^{K34,K67} _{K34} ({Rn} {H-LE-NEE})	MSMO ^{K34,K67} _{K34} ({Rn} {H-LE-NEE})
K67	MSMO ^{K34,K67} _{K67} ({H-LE-NEE} {Rn})	SSMO ^{K67} _{K67} (simultânea)	AMSMO ^{K34,K67} _{K67} ({Rn} {H-LE-NEE})	MSMO ^{K34,K67} _{K67} (simultânea)

Com a Tabela 11 observa-se em primeiro lugar que, em nenhum dos casos, uma calibração mono-sítio realizada em um sítio e testada em outro obteve o menor erro. Ou seja, os menores erros sempre foram obtidos quando o sítio testado foi usado na calibração. Além disso, em nenhum dos sítios, uma mesma calibração obteve os menores erros para todas as variáveis. Para o sítio FNS, por exemplo, apesar da calibração $AMSMO_{FNS}^{FNS,K77}$ obter o menor erro para três variáveis (Rn, LE e NEE), em duas (Rn e NEE) foi por meio da calibração simultânea e na outra (LE) foi por meio da calibração hierárquica {Rn} {H-LE-NEE}.

Essa falta de convergência para um tipo de calibração ótima justifica o uso de uma outra métrica, neste caso o índice D, para a análise das calibrações. As Tabelas 12 e 13 apresentam um resumo dos resultados anteriores, contendo apenas o índice D de cada tipo de calibração. A Tabela 12 se refere aos sítios de pastagem (FNS e K77), sendo uma síntese das Tabelas 5 a 7. A Tabela 13 se refere aos sítios de floresta (K34 e K67), sendo uma síntese das Tabelas 8 a 10.

Tabela 12: Índice D das calibrações realizadas nos sítios de pastagem (FNS e K77)

	Simultânea	{Rn} {H-LE-NEE}	{H-LE-NEE} {Rn}
$SSMO_{FNS}^{FNS}$	0,7947	0,7350	0,8219
$SSMO_{K77}^{FNS}$	0,8329	0,7835	0,8380
$SSMO_{K77}^{K77}$	0,9375	0,9384	0,9200
$SSMO_{FNS}^{K77}$	0,6155	0,5983	0,5700
$MSMO_{FNS}^{FNS,K77}$	0,5942	0,6927	0,6831
$MSMO_{K77}^{FNS,K77}$	0,8607	0,9143	0,8671
$AMSMO_{FNS}^{FNS,K77}$	0,7962	0,7274	0,7348
$AMSMO_{K77}^{FNS,K77}$	0,9088	0,9006	0,9164

Tabela 13: Índice D das calibrações realizadas nos sítios de floresta (K34 e K67)

	Simultânea	{Rn} {H-LE-NEE}	{H-LE-NEE} {Rn}
SSMO ^{K34} _{K34}	0,8815	0,8713	0,8680
SSMO ^{K34} _{K67}	0,6074	0,5386	0,5423
SSMO ^{K67} _{K67}	0,8694	0,8579	0,8237
SSMO ^{K67} _{K34}	0,7691	0,7760	0,7383
MSMO ^{K34,K67} _{K34}	0,7959	0,8998	0,7622
MSMO ^{K34,K67} _{K67}	0,8137	0,6691	0,5747
AMSMO ^{K34,K67} _{K34}	0,8400	0,7800	0,7489
AMSMO ^{K34,K67} _{K67}	0,8348	0,7815	0,7344

Para a pastagem (Tabela 12) pode-se verificar que os resultados obtidos no sítio K77 foram sempre superiores aos resultados obtidos no FNS. Inclusive, a SSMO^{FNS} (calibração realizada no sítio FNS) foi melhor quando testada no sítio K77 que no próprio FNS. Este padrão não foi observado nos sítios de floresta (Tabela 13). Uma possível explicação para essa diferença entre pastagem e floresta é a qualidade dos dados coletados. Os dados de floresta aparentam estar mais consistentes porque uma calibração apresenta menor erro em um sítio quando o mesmo é utilizado no processo de calibração (situação que não ocorre em alguns casos dos dados de pastagem). Novamente, em ambos os tipos de vegetação, não existe um tipo de calibração com resultados superiores em todos os sítios.

Com essas tabelas pode-se observar que as calibrações multi-sítio (AMSMO e MSMO) atingem valores de índice D próximos aos valores das calibrações mono-sítio (SSMO). Para o sítio FNS o melhor resultado SSMO é 0,8219 e o melhor resultado multi-sítio é 0,7962. Para o K77, o melhor resultado SSMO é 0,9384 e o melhor resultado multi-sítio é 0,9164. Para o K34 o melhor resultado SSMO é 0,8815 e o melhor resultado multi-sítio é 0,8998.

Para o K67 o melhor resultado SSMO é 0,8694 e o melhor resultado multi-sítio é 0,8348.

Mesmo que uma calibração obtenha bons resultados no sítio calibrado não significa que ela também consegue bons resultados quando testada em outro sítio com mesmo tipo de vegetação. Um bom exemplo dessa situação pode ser visto nos resultados dos sítios de floresta. Na Tabela 13, na coluna das calibrações simultâneas, o melhor resultado encontrado para o sítio K34 é a $SSMO_{K34}^{K34}$ (0,8815) e o melhor resultado para o sítio K67 é a $SSMO_{K67}^{K67}$ (0,8694). Porém, quando testadas no sítio oposto, essas calibrações conseguem os piores resultados: 0,6074 ($SSMO_{K67}^{K34}$) para o sítio K67 e 0,7691 ($SSMO_{K34}^{K67}$) para o sítio K34.

Com a finalidade de analisar qual calibração obtém o melhor resultado levando em consideração os dois sítios com o mesmo tipo de vegetação, foi feito uma média do índice D. Para fazer essa média os resultados foram agrupados de acordo com os sítios utilizados na calibração. As Tabelas 14 e 15 apresentam a média dos resultados das Tabelas 12 e 13 respectivamente. Por exemplo, o valor da calibração AMSMO simultânea na Tabela 14 (0,8525) é a média das calibrações simultâneas $AMSMO_{FNS}^{FNS,K77}$ (0,7962) e $AMSMO_{K77}^{FNS,K77}$ (0,9088) da Tabela 12.

Nas Tabelas 14 e 15 pode-se observar que, em ambos os tipos de vegetação, o melhor resultado encontrado foi com a calibração AMSMO simultânea. Ou seja, essa seria a calibração mais indicada caso fosse necessário escolher um conjunto de parâmetros para simular ambos os sítios de um mesmo tipo de vegetação.

Com relação aos diferentes modos de calibração, pode-se observar que, para os sítios de pastagem (Tabela 14), a calibração simultânea foi melhor para

AMSMO e $SSMO^{K77}$ enquanto a hierárquica foi melhor para MSMO e $SSMO^{FNS}$. Para os sítios de floresta (Tabela 15), a calibração simultânea foi melhor em todos os casos.

Na comparação entre as calibrações mono-sítio (SSMO) e multi-sítio (AMSMO e MSMO) observa-se que as calibrações multi-sítio, no modo simultâneo, possuem os melhores resultados tanto para pastagem (0,8525) quanto para floresta (0,8374). Porém, nos modos hierárquicos, as calibrações multi-sítio só foram melhores no modo $\{Rn\}\{H-LE-NEE\}$ para pastagem (0,8140). Nas demais calibrações hierárquicas os melhores resultados foram obtidos usando um sítio. Para pastagem no modo $\{H-LE-NEE\}\{Rn\}$ o melhor resultado foi obtido pela $SSMO^{FNS}$ (0,8300). Para floresta os melhores resultados hierárquicos foram obtidos pela calibração $SSMO^{K67}$, 0,8170 ($\{Rn\}\{H-LE-NEE\}$) e 0,7810 ($\{H-LE-NEE\}\{Rn\}$).

Também é possível notar que, na maioria dos casos, a calibração AMSMO foi melhor que a MSMO. Isto pode ser explicado pelo menor número de funções objetivo das calibrações AMSMO.

Tabela 14: Média do índice D para ambos os sítios de pastagem (FNS e K77)

	\bar{D}		
	Simultânea	$\{Rn\}\{H-LE-NEE\}$	$\{H-LE-NEE\}\{Rn\}$
$SSMO^{FNS}$	0,8138	0,7593	0,8300
$SSMO^{K77}$	0,7765	0,7684	0,7450
MSMO	0,7275	0,8035	0,7751
AMSMO	0,8525	0,8140	0,8256

Tabela 15: Média do índice D para ambos os sítios de floresta (K34 e K67)

	\bar{D}		
	Simultânea	{Rn} {H-LE-NEE}	{H-LE-NEE} {Rn}
SSMO ^{K34}	0,7445	0,7050	0,7052
SSMO ^{K67}	0,8193	0,8170	0,7810
MSMO	0,8048	0,7845	0,6685
AMSMO	0,8374	0,7808	0,7417

5 CONCLUSÕES

5.1 Resumo

Neste trabalho foi realizada a expansão do código do Optis, que é um software de calibração automático. O IBIS, modelo de superfície terrestre calibrado pelo algoritmo, foi substituído pelo INLAND. Além disso, foi implementado o modo de calibração multi-sítio. Esse novo modo permite calibrar o modelo utilizando dois ou mais sítios. Antes dessa implementação só era possível calibrar utilizando dados de um único sítio.

Foram apresentados dois métodos diferentes de calibração multi-sítio, o *Multiple Sites Multiple Objectives* (MSMO) e o *Average Multiple Sites Multiple Objectives* (AMSMO). O primeiro método avalia cada medida de erro em cada um dos sítios utilizado na calibração. Uma calibração com, por exemplo, três medidas de erro e dois sítios, terá seis funções objetivo. Assim, quanto mais sítios são adicionados mais funções objetivo serão otimizadas.

O método AMSMO usa como função objetivo a média obtida por uma medida de erro em todos os sítios utilizados na calibração. Deste modo, independente do número de sítios utilizados, o total de funções objetivo otimizadas será o mesmo. Isto é uma vantagem desse método em relação ao MSMO, uma vez que, a otimização multi-objetiva com um grande número de funções objetivo é um problema em aberto. Os métodos atuais perdem desempenho à medida que se aumenta o número dessas funções.

No Optis existe a possibilidade de escolher se a calibração será simultânea ou hierárquica. Na calibração simultânea todas as funções objetivo são otimizadas ao mesmo tempo. Na calibração hierárquica as funções são divididas em grupos com ordem de otimização pré-definida. No experimento numérico foram testados esses dois modos de calibração, sendo que a calibração hierárquica foi testada com duas ordens de otimização diferentes.

Os métodos de calibração multi-sítio tem como objetivo encontrar grupos de parâmetros que sejam eficientes para toda uma região com características similares. Neste trabalho, especificamente, esses métodos foram testados em áreas com o mesmo tipo de vegetação. O experimento numérico foi realizado utilizando quatro sítios diferentes, dois de pastagem e dois de floresta.

Para verificar a sua eficácia, os métodos multi-sítio, MSMO e AMSMO, foram comparados com calibrações multi-objetivo realizadas em um único sítio (SSMO). As calibrações SSMO foram realizadas com cada sítio de pastagem (ou floresta) e testadas em ambos os sítios de pastagem (ou floresta). Por meio da comparação dos resultados das calibrações SSMO, MSMO e AMSMO foi possível identificar qual calibração foi mais eficiente para simular todos os sítios de uma mesmo tipo de vegetação.

Para testar sua eficiência os métodos MSMO e AMSMO foram

comparados com calibrações mono-objetivo (SSSO). Elas foram utilizadas como base para o cálculo do índice D. Por serem uma otimização de uma única função objetivo, as SSSO foram consideradas como o melhor resultado que o modelo pode obter para aquela função objetivo naquele sítio.

Os resultados encontrados para os dois tipos de vegetação (pastagem e floresta) foi o mesmo: a calibração AMSMO simultânea é a mais eficaz. Ela obteve o maior índice D dentre todas as calibrações testadas. Com isso, ela se apresentou como a mais indicada para uma calibração multi-sítio.

5.2 Conclusões

O fato da calibração AMSMO simultânea ter obtido resultados melhores que as calibrações AMSMO hierárquicas pode ser visto como um indício de que os fluxos usados na otimização estão relacionados. Assim, pelo menos nesse tipo de problema, torna-se uma tarefa complicada tentar separar os parâmetros de acordo com os processos calibrados. Mesmo quando foi realizada uma análise de sensibilidade (não apresentada neste trabalho) utilizando o método de Morris [Morris, 1991] os resultados foram inconclusivos, indicando que todos os quatro processos (R_n , H, LE e NEE) são sensíveis aos parâmetros calibrados. Portanto os parâmetros precisam ser calibrados em conjunto.

Na comparação entre os métodos multi-sítio AMSMO e MSMO o resultado foi que, na grande maioria dos casos, o AMSMO obteve melhores resultados. Isto pode ser explicado pelo fato de que o MSMO possui oito funções objetivo enquanto o AMSMO possui quatro, sendo que, o algoritmo de otimização utilizado perde eficiência conforme se aumenta o número de funções objetivo.

O índice D obtido pela calibração simultânea AMSMO tanto para pastagem (0,8525) quanto para floresta (0,8374) foi maior que 80%. Um valor alto considerando-se que, com uma mesma calibração (ou seja, um mesmo conjunto de valores para os parâmetros), foi possível atingir esse índice de aproveitamento para quatro variáveis em dois sítios diferentes. O índice D de 100% representa o melhor resultado possível do modelo, que só foi atingido por calibrações mono-objetivo. Mesmo as calibrações SSMO, quando testadas em um sítio apenas, conseguiram atingir no máximo 0,9384 para pastagem e 0,8815 para floresta.

Diferentemente da maioria dos trabalhos citados na literatura, que são na área hidrológica, o método aqui proposto apresentou uma calibração multi-sítio de um LSM. Além disso, possui a opção de fazer a calibração de modo simultâneo ou hierárquico, sendo que esse último modo não foi visto em nenhum dos métodos de calibração multi-sítio. A utilização do algoritmo NSGA-II permite, ainda, a otimização automática dos parâmetros, possibilitando que uma grande quantidade de parâmetros e sítios possa ser usado na calibração.

5.3 Recomendações para trabalhos futuros

Segue, a seguir, sugestões de possíveis trabalhos futuros:

- Validar o método de calibração multi-sítio. O experimento realizado neste trabalho avaliou a calibração multi-sítio apenas em sítios utilizados no processo de calibração. Desta maneira, seria interessante verificar se essa calibração continua eficaz para sítios que não foram utilizados na calibração. Devido a natureza da calibração multi-sítio, espera-se encontrar bons resultados para esses novos sítios, desde que eles

possuam a mesma característica (que neste trabalho foi o tipo de vegetação) dos sítios utilizados na calibração. Porém, se os sítios escolhidos para o processo de calibração não representarem bem essa característica (talvez por não estarem espacialmente espalhados) os resultados podem ser ruins. Outra possível razão para se chegar em resultados ruins é usar na avaliação sítios que possuam outras características.

- Realizar a calibração multi-sítio com três ou mais sítios. No experimento apresentado neste trabalho a calibração multi-sítio foi realizada com dois sítios de cada tipo de vegetação. Espera-se que o aumento do número de sítios resulte em uma calibração mais genérica, melhor ajustada à característica calibrada e menos influenciada pelas variações locais. Porém, ainda é preciso identificar o número (ou talvez a disposição espacial) ideal de sítios necessários para se ter uma boa calibração genérica. Um grupo pequeno (ou pouco distribuído) pode levar a uma calibração mais local que genérica. Já o uso de um grande número de sítios vai de encontro ao objetivo da calibração multi-sítio, porque se for possível coletar dados de todos os sítios necessários é mais indicado realizar uma calibração individual em cada um deles.
- Ampliar o algoritmo do Optis para permitir a calibração da versão em grade do modelo. Como foi dito na Seção 3.3, o INLAND possui duas versões, uma que utiliza dados meteorológicos horários (versão pontual) e outra que utiliza dados climáticos regionais diários ou mensais (versão em grade). Neste trabalho foi calibrada a versão pontual, porém a calibração da versão em grade pode ser de grande interesse para estudos relacionados ao clima e à previsão do tempo, que fazem uso

dessa versão do modelo. A calibração dessa versão em grade do modelo levanta uma questão importante: como calcular as funções objetivo. Se as medidas de erro apresentadas são todas baseadas em dados pontuais, como seria feito o cálculo em grade.

- Testar outras medidas de erro. Avaliar se a calibração multi-sítio consegue um ajuste melhor com uma medida diferente do MAE. Talvez até combinar mais de uma medida de erro, para tentar entender melhor o comportamento do modelo. Porém, é importante ressaltar que, da maneira como o Optis está implementado, o aumento do número de medidas de erro leva a um aumento de funções objetivo, o que pode resultar numa perda de eficiência do algoritmo.
- Buscar formas mais eficientes de otimização. Os modelos de superfície terrestre, como o INLAND, possuem um grande número de processos. Para se ter um modelo bem ajustado à realidade é necessário calibrar o maior número de processos possíveis. Porém, o aumento de processos calibrados implica no aumento de funções objetivo e o Optis, que está baseado no NSGA-II, perde desempenho à medida que se aumenta o número dessas funções. Portanto, para se obter melhores ajustes é necessário encontrar outros algoritmos de otimização que não possuem essa deficiência. Uma opção é utilizar o algoritmo SPEA [Zitzler e Thiele, 1999] no processo de otimização, uma vez que esse algoritmo, em alguns casos, consegue melhores resultados que o NSGA-II.
- O processo de otimização tem como resultado um conjunto de soluções ótimas e o Optis escolhe uma dessas soluções como resultado final. Esta é a solução utilizada na comparação entre as calibrações, mas pode não ser a que melhor representa todo o conjunto. Sendo assim,

uma outra maneira de avaliar os resultados seria utilizar todas as soluções geradas no processo de otimização para fazer a comparação entre as calibrações, utilizando, para tanto, métodos de comparação de conjuntos.

- Nem sempre é possível encontrar a divisão ideal dos parâmetros para fazer a calibração hierárquica. Isto implica que, alguns parâmetros podem influenciar nos resultados de fluxos que estão em níveis diferentes que o nível do próprio parâmetro. Desta maneira, a calibração realizada em um nível pode piorar os resultados obtidos nos níveis anteriores. Para evitar que isso aconteça, poderia ser inserido no código do Optis algumas restrições. Essas restrições fariam com que, em cada passo do processo de otimização, uma solução só é válida se ela não piora os resultados dos processos já calibrados nos níveis anteriores.

6 REFERÊNCIAS

- Bekele, E. G., e J. W. Nicklow (2007), Multi-objective automatic calibration of SWAT using NSGA-II, *Journal of Hydrology*, 341(3-4), 165-76, doi:10.1016/j.jhydrol.2007.05.014.
- Cao, W., W. B. Bowden, T. Davie, e A. Fenemor (2006), Multi-variable and multi-site calibration and validation of SWAT in a large mountainous catchment with high spatial variability, *Hydrological Processes*, 20(5), 1057-1073, doi:10.1002/hyp.5933.
- Celada, F., e P. E. Seiden (1992), A computer model of cellular interactions in the immune system, *Immunology Today*, 13(2), 56–62, doi:10.1016/0167-5699(92)90135-T.
- Choi, Y. S., C. K. Choi, H. S. Kim, K. T. Kim, e S. Kim (2015), Multi-site calibration using a grid-based event rainfall-runoff model: a case study of

the upstream areas of the Nakdong River basin in Korea, *Hydrological Processes*, 29(9), 2089-2099, doi:10.1002/hyp.10355.

Deb, K., A. Pratap, S. Agarwal, e T. Meyarivan (2002), A Fast and Elitist Multiobjective Genetic Algorithm: NSGA-II, *IEEE Transactions on Evolutionary Computation*, 6(2), 182-197, doi:10.1109/4235.996017.

Dorigo, M., V. Maniezzo, e A. Colorni (1996), The ant systems: optimization by a colony of cooperative agents, *IEEE Transactions on Systems, Man, and Cybernetics*, 26(1), 29-41, doi:10.1109/3477.484436.

Fischer, G. R., M. H. Costa, F. Z. Murta, A. C. M. Malhado, L. J. G. Aguiar, e R. J. Ladle (2013), Multi-site land surface model optimization: An exploration of objective functions, *Agricultural and Forest Meteorology*, 182(183), 168-176, doi:10.1016/j.agrformet.2012.11.021.

Foley, J. A., I. C. Prentice, N. Ramankutty, S. Levis, D. Pollard, S. Sitch, e A. Haxeltine (1996), An integrated biosphere model of land surface processes, terrestrial carbon balance, and vegetation dynamics, *Global Biogeochemical Cycles*, 10(4), 603-628, doi:10.1029/96GB02692.

Groenendijk, M., A. J. Dolman, M. K. van der Molen, R. Leuning, A. Arneth, N. Delapierre, J. H. C. Gash, A. Lindroth, A. D. Richardson, e H. Verbeeck (2011), Assessing parameter variability in a photosynthesis model within and between plant functional types using global Fluxnet eddy covariance data, *Agricultural and Forest Meteorology*, 151(1), 22-38, doi:10.1016/j.agrformet.2010.08.013.

Hashimoto, S., T. Morishita, T. Sakata, S. Ishizuka, S. Kaneko, e M. Takahashi

- (2011), Simple models for soil CO₂, CH₄, and N₂O fluxes calibrated using a Bayesian approach and multi-site data, *Ecological Modelling*, 222(7), 1283-1292, doi:10.1016/j.ecolmodel.2011.01.013.
- Li, X., D. E. Weller, e T. E. Jordan (2010), Watershed model calibration using multi-objective optimization and multi-site averaging, *Journal of Hydrology*, 380(3), 277-288, doi:10.1016/j.jhydrol.2009.11.003.
- Liu, Y., L. A. Bastidas, H. V. Gupta, e S. Sorooshian (2003), Impacts of a Parameterization Deficiency on Offline and Coupled Land Surface Model Simulations, *Journal of Hydrometeorology*, 4(5), 901-914, doi:10.1175/1525-7541(2003)004<0901:IOAPDO>2.0.CO;2.
- Lücken, C. Von, B. Barán, e C. Brizuela (2014), A survey on multi-objective evolutionary algorithms for many-objective problems, *Computational Optimization and Applications*, 58(3), 707-756, doi:10.1007/s10589-014-9644-1.
- Mallet, D. G., e L. G. De Pillis (2006), A cellular automata model of tumor-immune system interactions, *Journal of Theoretical Biology*, 239(3), 334-350, doi:10.1016/j.jtbi.2005.08.002.
- Manabe, S., e K. Bryan (1969), Climate Calculations with a Combined Ocean-Atmosphere Model, *Journal of the Atmospheric Sciences*, 26(4), 786-789, doi:10.1175/1520-0469(1969)026<0786:CCWACO>2.0.CO;2.
- Masson, V., J. L. Champeaux, F. Chauvin, C. Meriguet, e R. Lacaze (2003), A global database of land surface parameters at 1-km resolution in meteorological and climate models, *Journal of Climate*, 16(9), 1261-1282,

doi:10.1175/1520-0442-16.9.1261.

McGuffie, K., e A. Henderson-Sellers (2001), Forty years of numerical climate modelling, *International Journal of Climatology*, 21(9), 1067-1109, doi:10.1002/joc.632.

Menter, F. (1993), Zonal Two Equation k-w Turbulence Models for Aerodynamic Flows, in *AIAA Paper 93-2906, 23rd Fluid Dynamics, Plasmadynamics, and Lasers Conference, July 6-9, Orlando, Florida, USA*, doi:10.2514/6.1993-2906.

Miller, J. H., e S. E. Page (2007), Complex Adaptive Systems: An Introduction to Computational Models of Social Life, *Princeton University Press*.

Morris, M. D. (1991), Factorial Sampling Plans for Preliminary Computational Experiments, *Technometrics*, 33(2), 161-174, doi:10.2307/1269043.

Mui, L., M. Mohtashemi, e A. Halberstadt (2002), A computational model of trust and reputation, in *Proceedings of the 35th Annual Hawaii International Conference on System Sciences*, 7, 188.

Noor, H., M. Vafakhah, M. Taheriyoun, e M. Moghaddasi (2014), Comparison of Single-site and Multi-site Based Calibrations of SWAT in Taleghan Watershed, *International Journal of Engineering*, 27(11), 1645-1652.

Pitman, A. J. (2003), The evolution of, and revolution in, land surface schemes designed for climate models, *International Journal of Climatology*, 23(5), 479-510, doi:10.1002/joc.893.

Poli, R., J. Kennedy, e T. Blackwell (2007), Particle swarm optimization, *Swarm*

Intelligence, 1(1), 33–57, doi:10.1007/s11721-007-0002-0.

Richards, P. J., e R. P. Hoxey (1993), Appropriate boundary conditions for computational wind engineering models using the k-E turbulence model, *Journal of Wind Engineering and Industrial Aerodynamics*, 47, 145-153, doi:10.1016/0167-6105(93)90124-7.

Saeidifarzad, B., V. Nourani, M. Aalami, e K.-W. Chau (2014), Multi-Site Calibration of Linear Reservoir Based Geomorphologic Rainfall-Runoff Models, *Water*, 6(9), 2690–2716, doi:10.3390/w6092690.

Sellers, P. J., R. E. Dickinson, D. A. Randall, A. K. Betts, F. G. Hall, J. A. Berry, G. J. Collatz, A. S. Denning, H. A. Mooney, C. A. Nobre, N. Sato, C. B. Field, e A. Henderson-Sellers (1997), Modeling the Exchanges of Energy, Water, and Carbon Between Continents and the Atmosphere, *Science*, 275(5299), 502-509, doi:10.1126/science.275.5299.502.

Senna, M. C. A., M. H. Costa, e G. F. Pires (2009), Vegetation-atmosphere-soil nutrient feedbacks in the Amazon for different deforestation scenarios, *Journal of Geophysical Research Atmospheres*, 114(D4), 1-9, doi:10.1029/2008JDO10401.

Varejão, C. G., M. H. Costa, e C. C. S. Camargos (2013), A multi-objective hierarchical calibration procedure for land surface/ecosystem models, *Inverse Problems in Science and Engineering*, 21(3), 357-386, doi:10.1080/17415977.2011.639453.

Veldhuizen, D. A. Van, e G. B. Lamont (2000), On measuring multiobjective evolutionary algorithm performance, in *Proceedings of the Congress on*

Evolutionary Computation, 2000, 1, 204-211,
doi:10.1109/CEC.2000.870296.

Vrugt, J. A., H. V. Gupta, L. A. Bastidas, W. Bouten, e S. Sorooshian (2003),
Effective and efficient algorithm for multiobjective optimization of hydrologic
models, *Water Resources Research*, 39(8), 1214,
doi:10.1029/2002WR001746.

Wang, S., Z. Zhang, G. Sun, P. Strauss, J. Guo, Y. Tang, e A. Yao (2012), Multi-
site calibration, validation, and sensitivity analysis of the MIKE SHE Model
for a large watershed in northern China, *Hydrology and Earth System
Sciences*, 16(12), 462-4632, doi:10.5194/hess-16-4621-2012.

Zhang, J., Q. Li, B. Guo, e H. Gong (2015), The comparative study of multi-site
uncertainty evaluation method based on SWAT model, *Hydrological
Processes*, 29(13), 2994-3009, doi:10.1002/hyp.10380.

Zhang, X., R. Srinivasan, e M. Van Liew (2008), Multi-site calibration of the
SWAT model for hydrologic modeling, *Transactions of the American
Society of Agricultural and Biological Engineers*, 51(6), 2039–2049.

Zitzler, E., e L. Thiele (1999), Multiobjective evolutionary algorithms: a
comparative case study and the strength Pareto approach, *IEEE
Transactions on Evolutionary Computation*, 3(4), 257–271,
doi:10.1109/4235.797969.