

# ANÁLISE BAYESIANA APLICADA À MODELAGEM DOS PROCESSOS DE INTERCEPTAÇÃO E CHUVA-VAZÃO EM DUAS BACIAS FLORESTAIS

---



Debora Yumi de Oliveira  
Prof. Pedro Luiz Borges Chaffe



Florianópolis, 27 de março de 2018

# MODELAGEM DE SISTEMAS AMBIENTAIS

Sistemas ambientais são extremamente complexos e apenas uma quantidade limitada de variáveis são passíveis de serem monitoradas

 $\mathfrak{I}(\theta)$ 

SISTEMA



SÁ (2015)



CHAFFE (2009)



MOTA (2017)

# MODELAGEM DE SISTEMAS AMBIENTAIS

Os dados coletados sempre estarão sujeitos a erros de medição, fazendo com que haja uma divergência entre a resposta medida,  $\mathbf{y}$ , e a resposta real do sistema,  $\mathfrak{I}(\theta)$ .

$$\mathbf{y} \leftarrow \mathfrak{I}(\theta) + \varepsilon$$

SISTEMA

ERRO DE MEDIÇÃO



SÁ (2015)



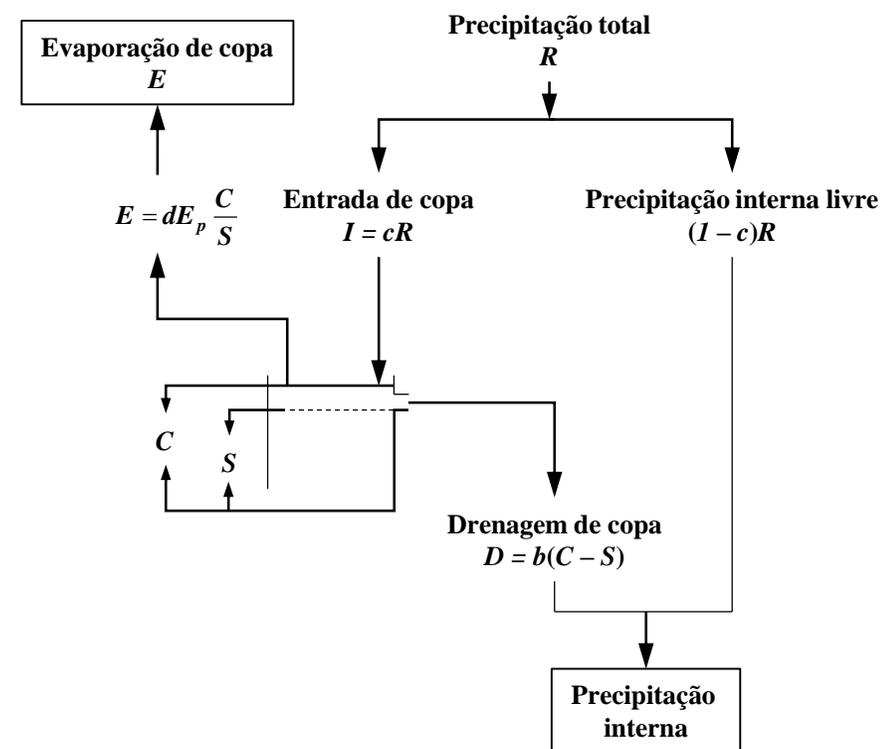
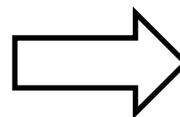
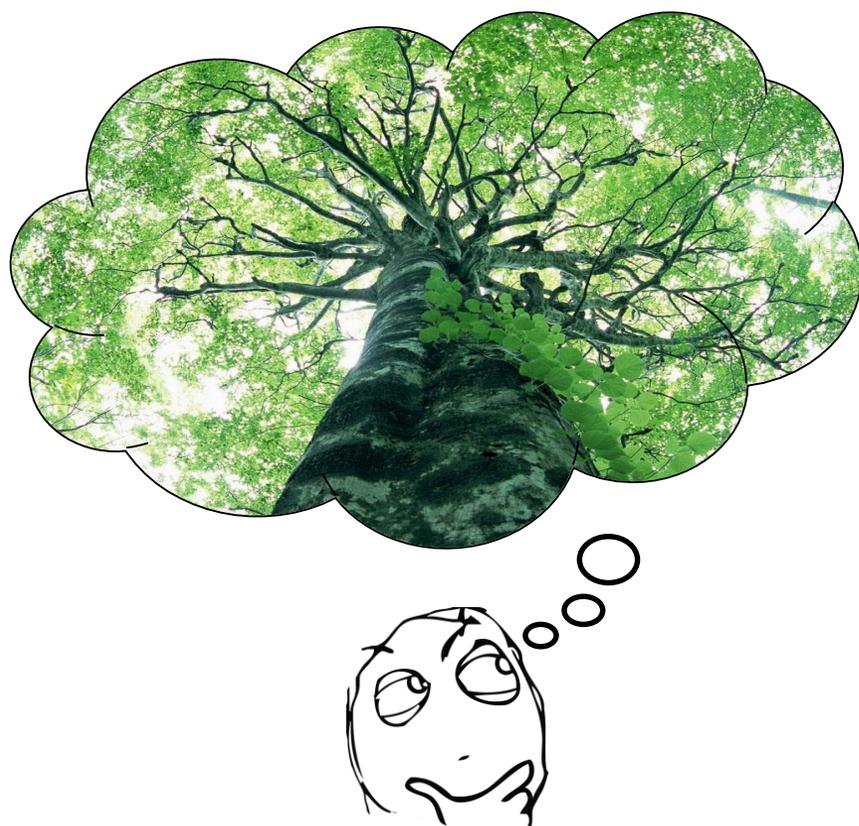
CHAFFE (2009)



MOTA (2017)

# MODELAGEM DE SISTEMAS AMBIENTAIS

A análise dos dados de monitoramento nos permite desenvolver modelos para testar nossas hipóteses sobre o funcionamento do sistema estudado



Como os modelos são representações simplificadas da realidade, a relação entre as observações,  $\mathbf{y}$ , e a resposta do modelo,  $f(\boldsymbol{\theta})$ , fica sujeita a erros devido a esta simplificação

$$\mathbf{y} \leftarrow f(\boldsymbol{\theta}) + \mathbf{e}$$

MODELO      ERRO DE MEDIÇÃO + ERRO NA ESTRUTURA DO MODELO

Como os modelos são representações simplificadas da realidade, a relação entre as observações,  $\mathbf{y}$ , e a resposta do modelo,  $f(\boldsymbol{\theta})$ , fica sujeita a erros devido a esta simplificação

$$\mathbf{y} \leftarrow f(\boldsymbol{\theta}) + \mathbf{e}$$

MODELO      ERRO DE MEDIÇÃO + ERRO NA ESTRUTURA DO MODELO

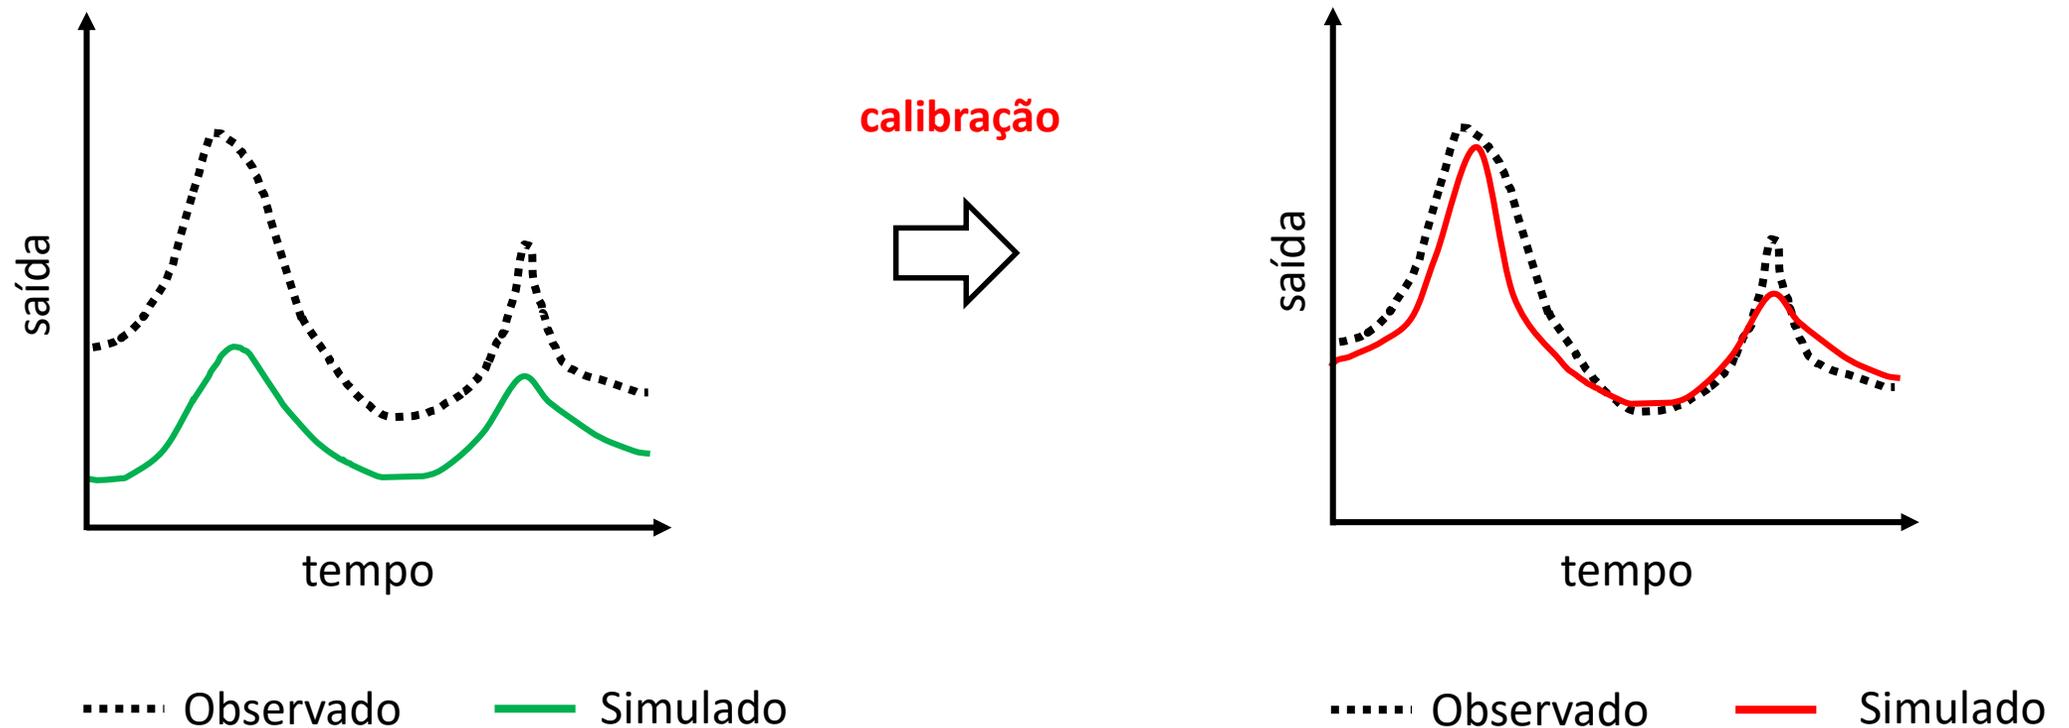
PARÂMETROS

$\boldsymbol{\theta}$

Parâmetros precisam ser ajustados para que a resposta simulada se aproxime da resposta observada

## CALIBRAÇÃO DE MODELOS: CALIBRAÇÃO TRADICIONAL

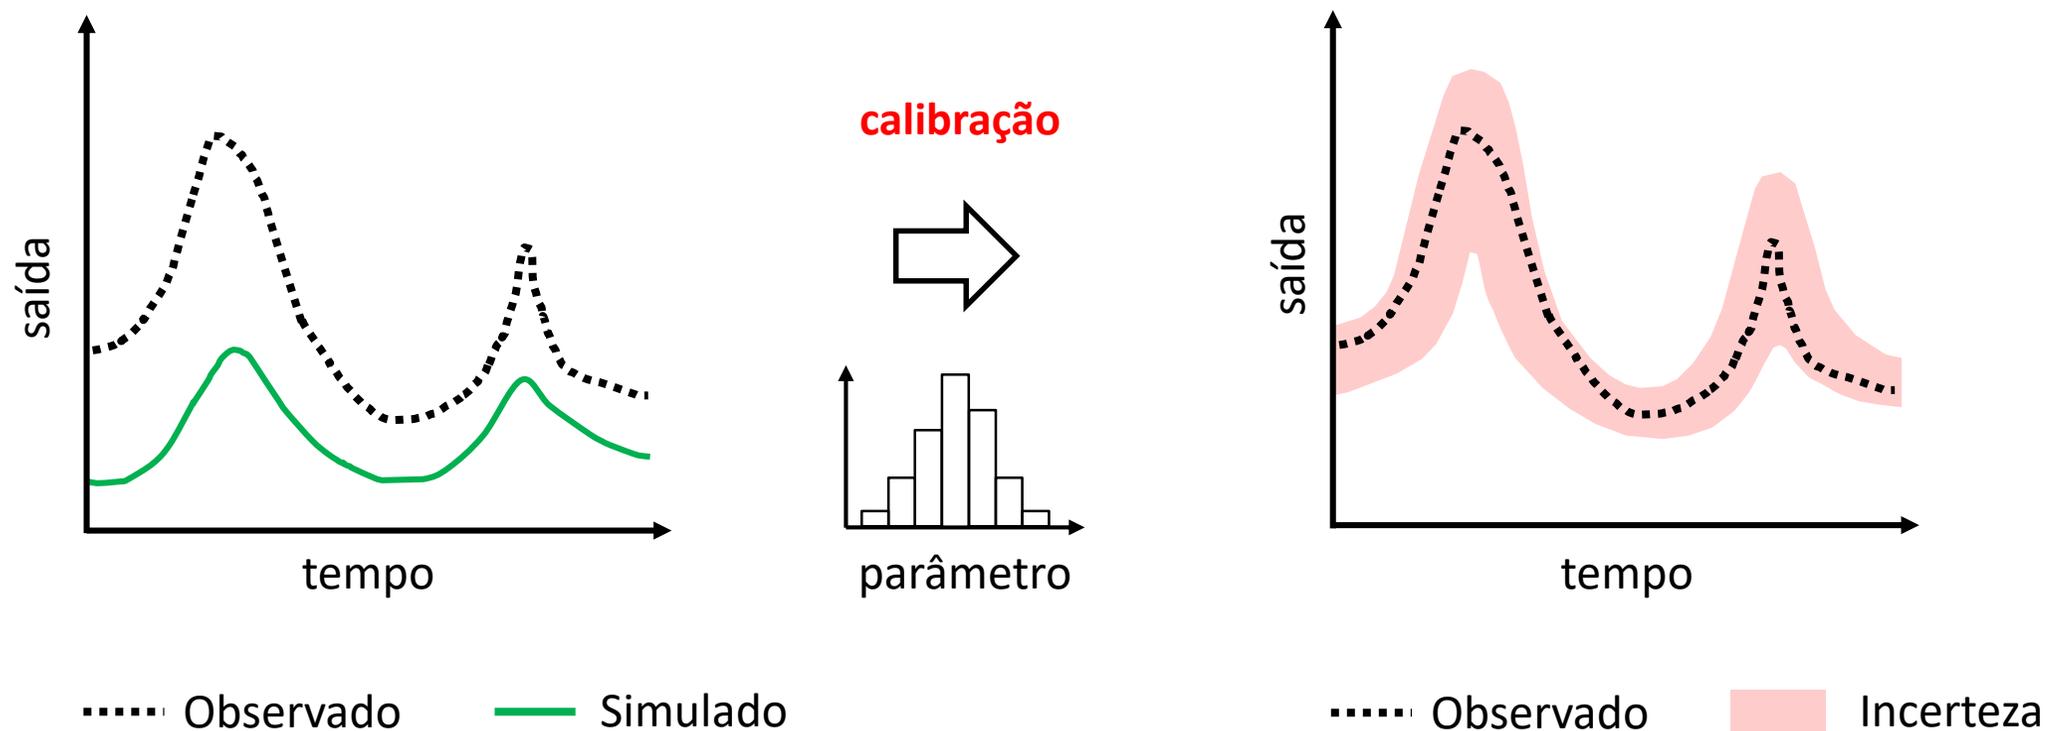
Objetivo é encontrar um conjunto de parâmetros que minimize a distância entre a saída do modelo e as observações



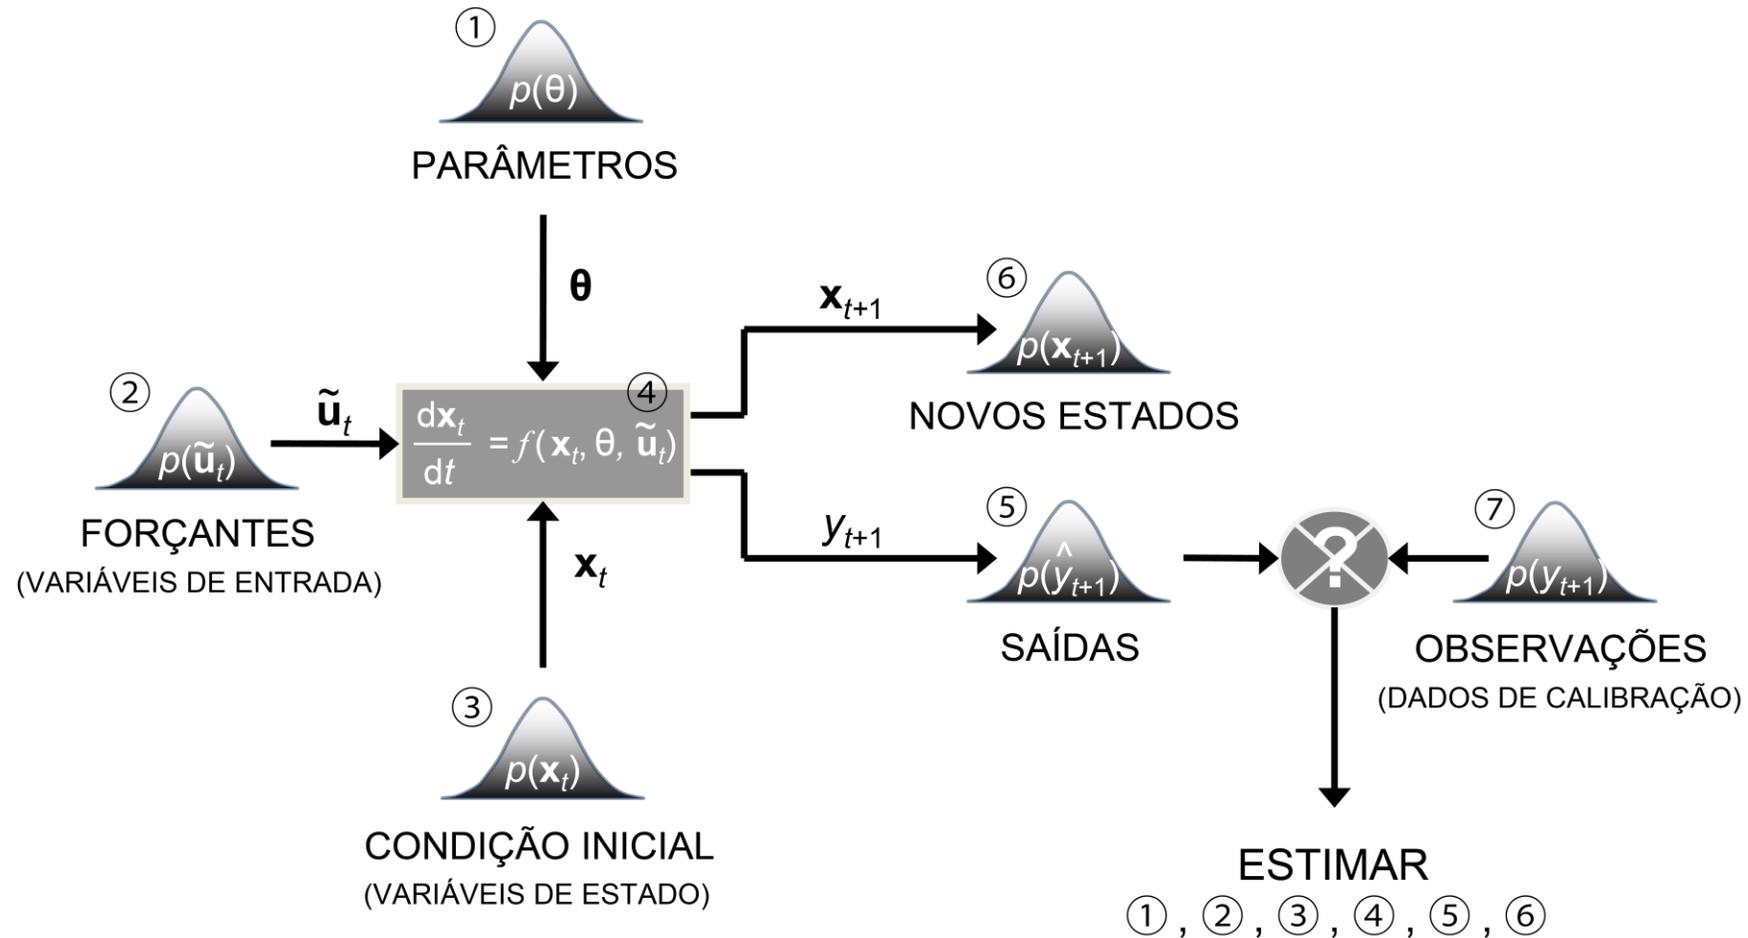
# MODELAGEM DE SISTEMAS AMBIENTAIS

## CALIBRAÇÃO DE MODELOS

Diversas fontes de erro envolvidas no processo de modelagem: inferência dos parâmetros deve ser acompanhada da **estimativa de incerteza**

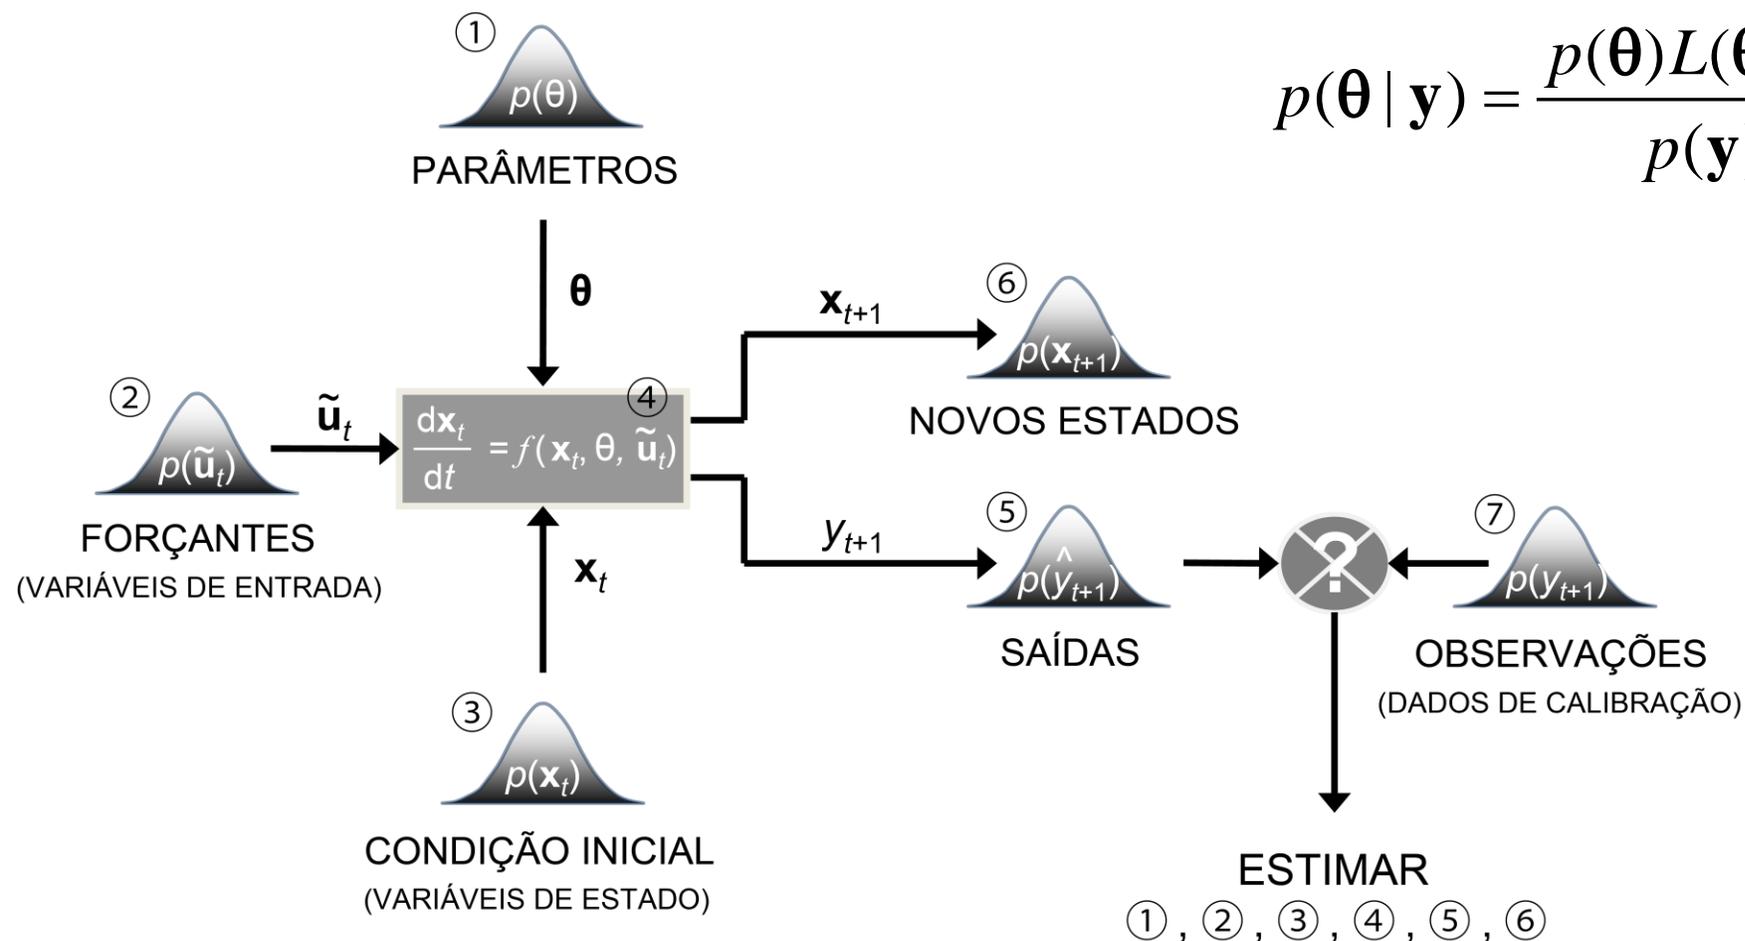


## FONTES DE INCERTEZA



# MODELAGEM DE SISTEMAS AMBIENTAIS

## FONTES DE INCERTEZA



TEOREMA DE BAYES

$$p(\theta | \mathbf{y}) = \frac{p(\theta)L(\theta | \mathbf{y})}{p(\mathbf{y})}$$

## TEOREMA DE BAYES

$$p(\boldsymbol{\theta} | \mathbf{y}) = \frac{p(\boldsymbol{\theta})L(\boldsymbol{\theta} | \mathbf{y})}{p(\mathbf{y})}$$

distribuição a posteriori

distribuição a priori

função de verossimilhança

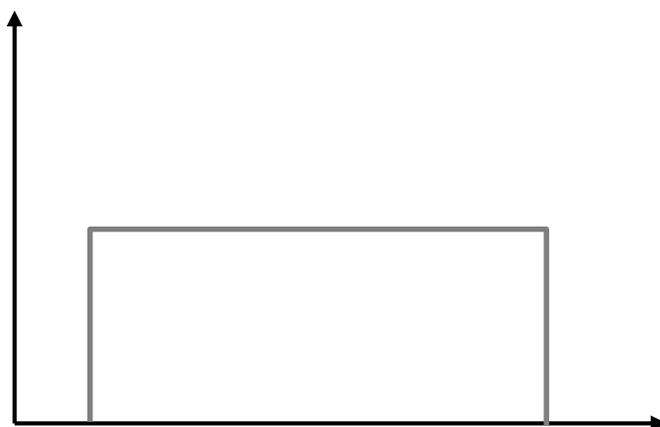
evidência

# MODELAGEM DE SISTEMAS AMBIENTAIS

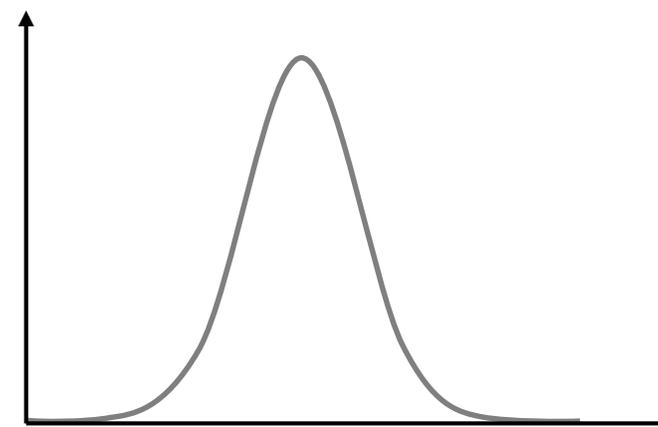
## TEOREMA DE BAYES

$$p(\theta | \mathbf{y}) = \frac{\overset{\text{distribuição}}{\underset{\text{a priori}}{p(\theta)}} L(\theta | \mathbf{y})}{p(\mathbf{y})}$$

A **distribuição a priori** sumariza o conhecimento prévio sobre o valor dos parâmetros  $\theta$  (antes da obtenção dos dados observados)



NÃO INFORMATIVA



INFORMATIVA

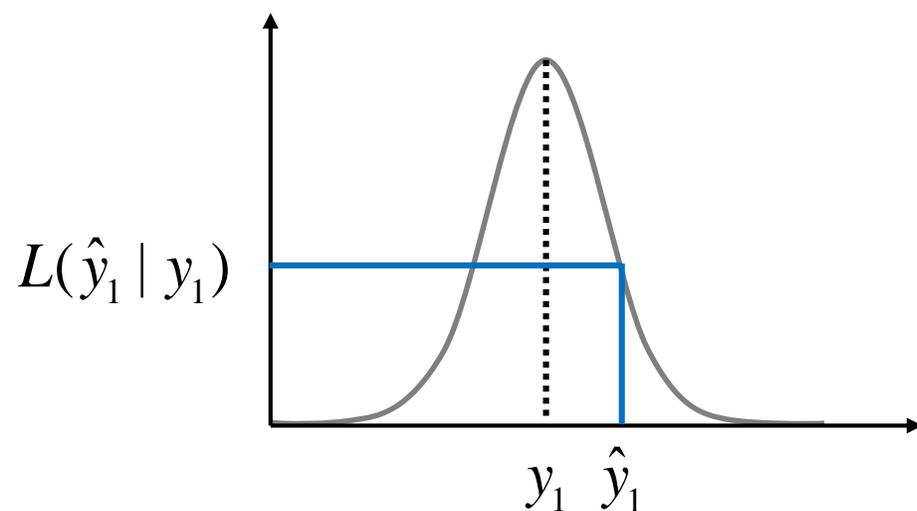
# MODELAGEM DE SISTEMAS AMBIENTAIS

## TEOREMA DE BAYES

$$p(\boldsymbol{\theta} | \mathbf{y}) = \frac{p(\boldsymbol{\theta}) \boxed{L(\boldsymbol{\theta} | \mathbf{y})}}{p(\mathbf{y})}$$

função de verossimilhança

A **função de verossimilhança** mede em termos probabilísticos a diferença entre as saídas do modelo  $\hat{\mathbf{y}} = f(\boldsymbol{\theta}) = \{\hat{y}_1, \hat{y}_2, \dots, \hat{y}_n\}$  e as observações  $\mathbf{y} = \{y_1, y_2, \dots, y_n\}$



Quanto mais próximo  $\hat{y}_1$  de  $y_1$ , maior será o valor de  $L(\hat{y}_1 | y_1)$

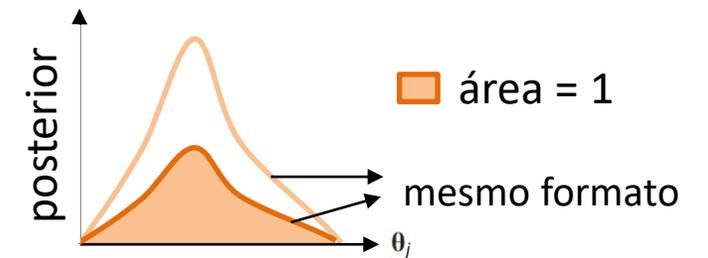
## TEOREMA DE BAYES

distribuição a posteriori

$$p(\boldsymbol{\theta} | \mathbf{y}) = \frac{p(\boldsymbol{\theta})L(\boldsymbol{\theta} | \mathbf{y})}{p(\mathbf{y})}$$

distribuição a priori      função de verossimilhança

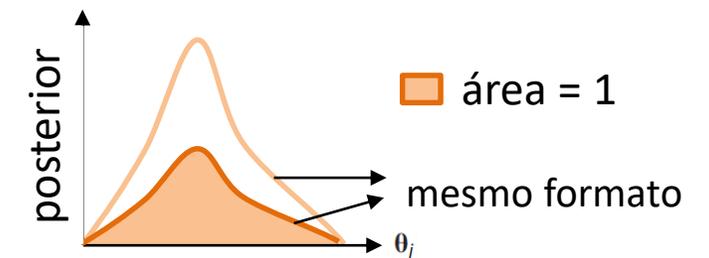
evidência



## TEOREMA DE BAYES

$$p(\boldsymbol{\theta} | \mathbf{y}) = \frac{p(\boldsymbol{\theta})L(\boldsymbol{\theta} | \mathbf{y})}{p(\mathbf{y})}$$

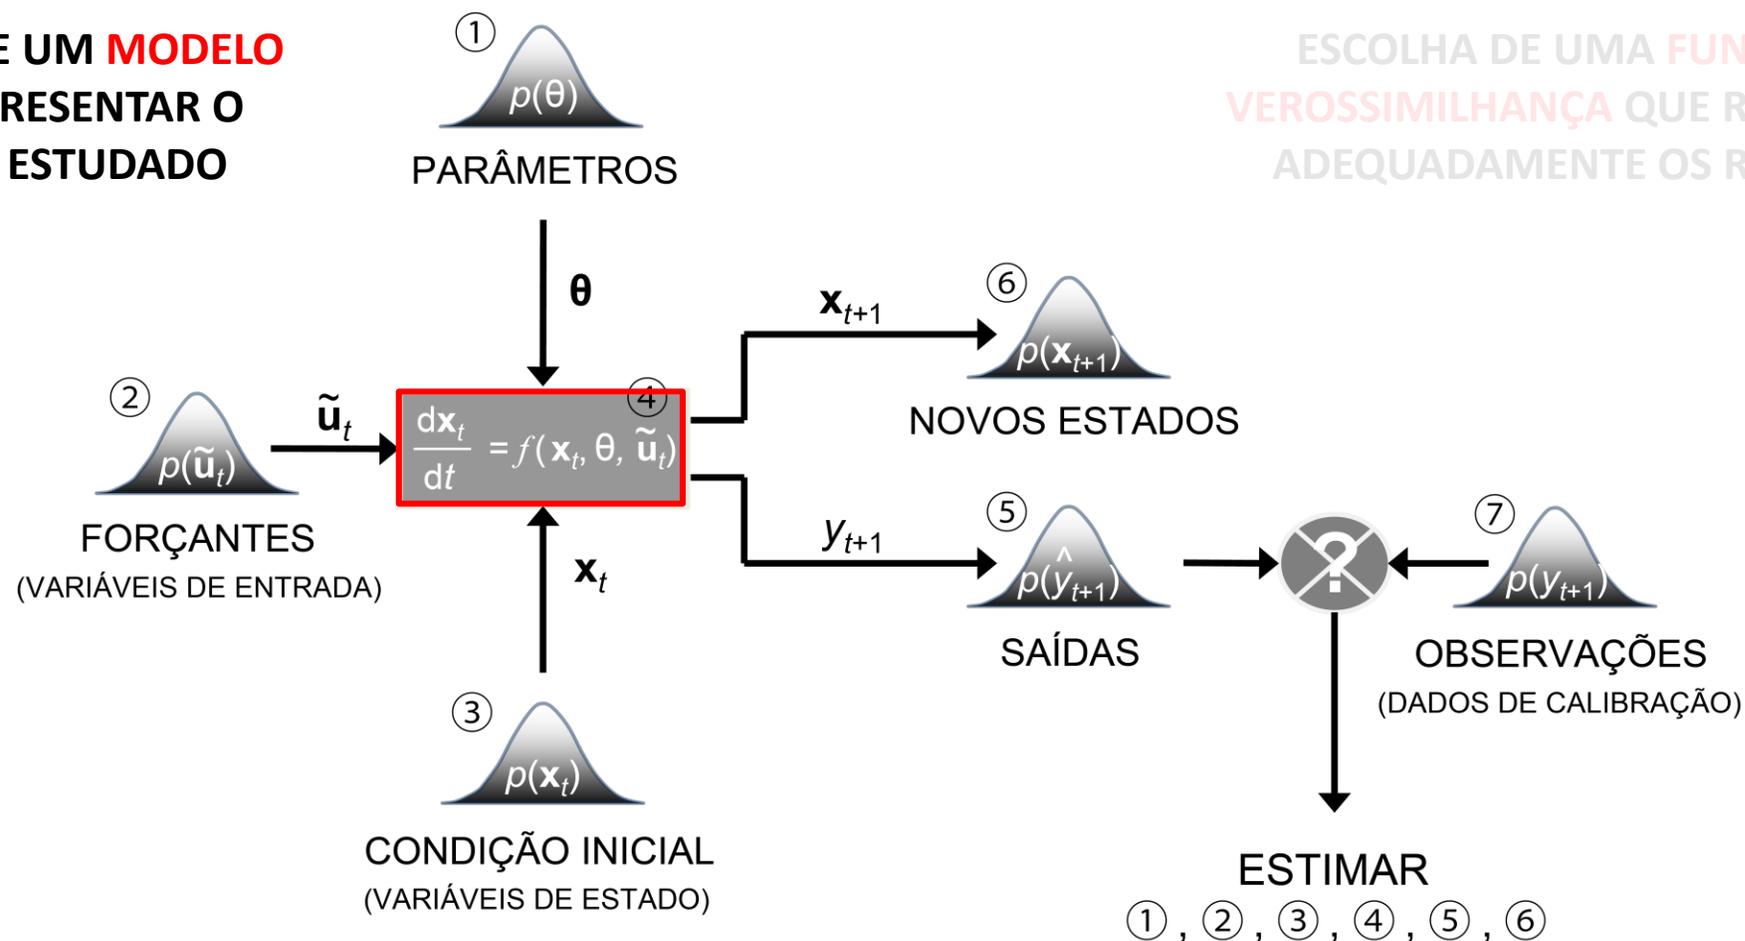
distribuição a posteriori      distribuição a priori      função de verossimilhança      evidência



$$p(\boldsymbol{\theta} | \mathbf{y}) \propto p(\boldsymbol{\theta})L(\boldsymbol{\theta} | \mathbf{y})$$

# MODELAGEM DE SISTEMAS AMBIENTAIS

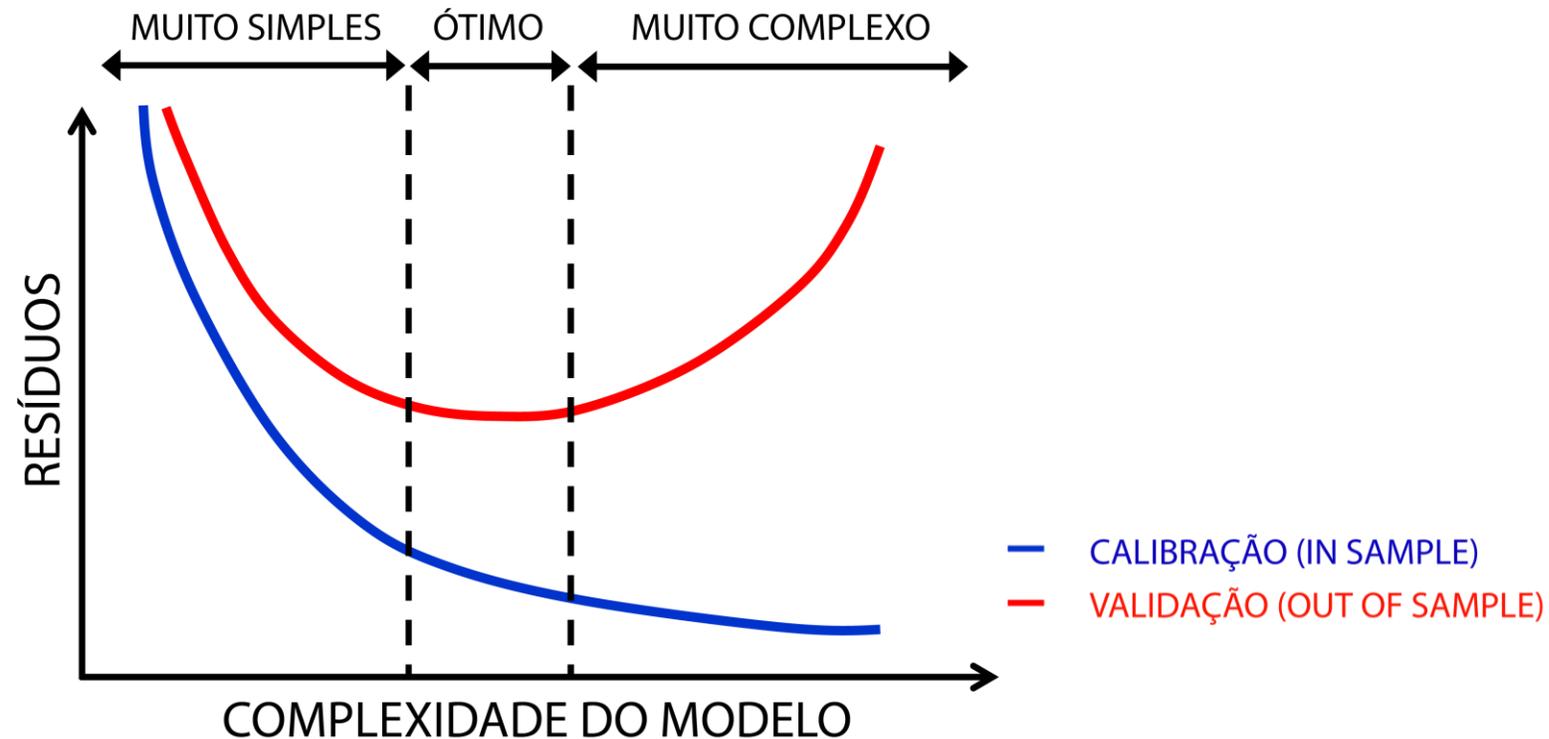
ESCOLHA DE UM **MODELO**  
PARA REPRESENTAR O  
SISTEMA ESTUDADO



ESCOLHA DE UMA **FUNÇÃO DE**  
**VEROSSIMILHANÇA** QUE REPRESENTA  
ADEQUADAMENTE OS RESÍDUOS

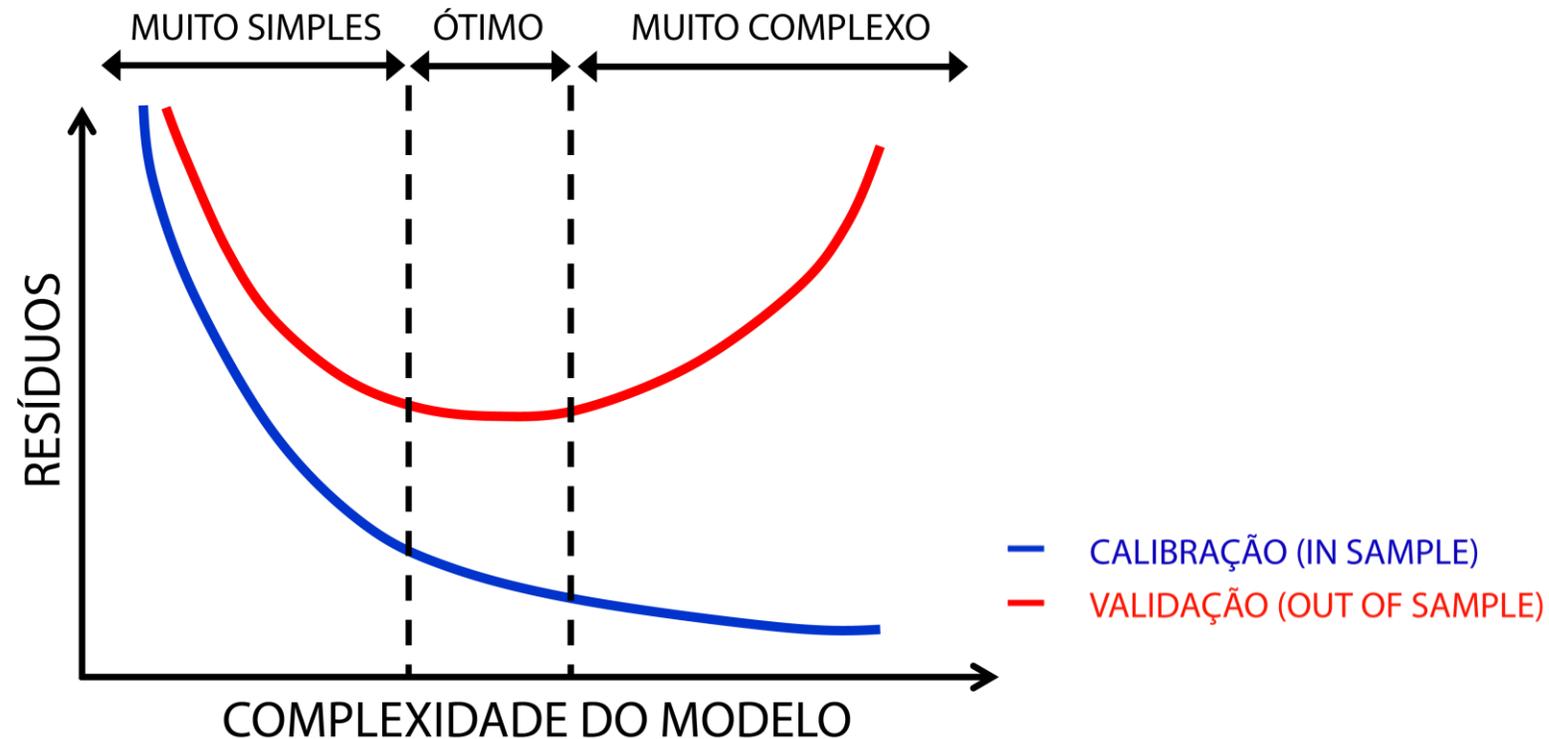
## CONTROLE DA COMPLEXIDADE DE MODELOS

O aumento de complexidade do modelo geralmente acarreta em um melhor ajuste da série simulada à série observada



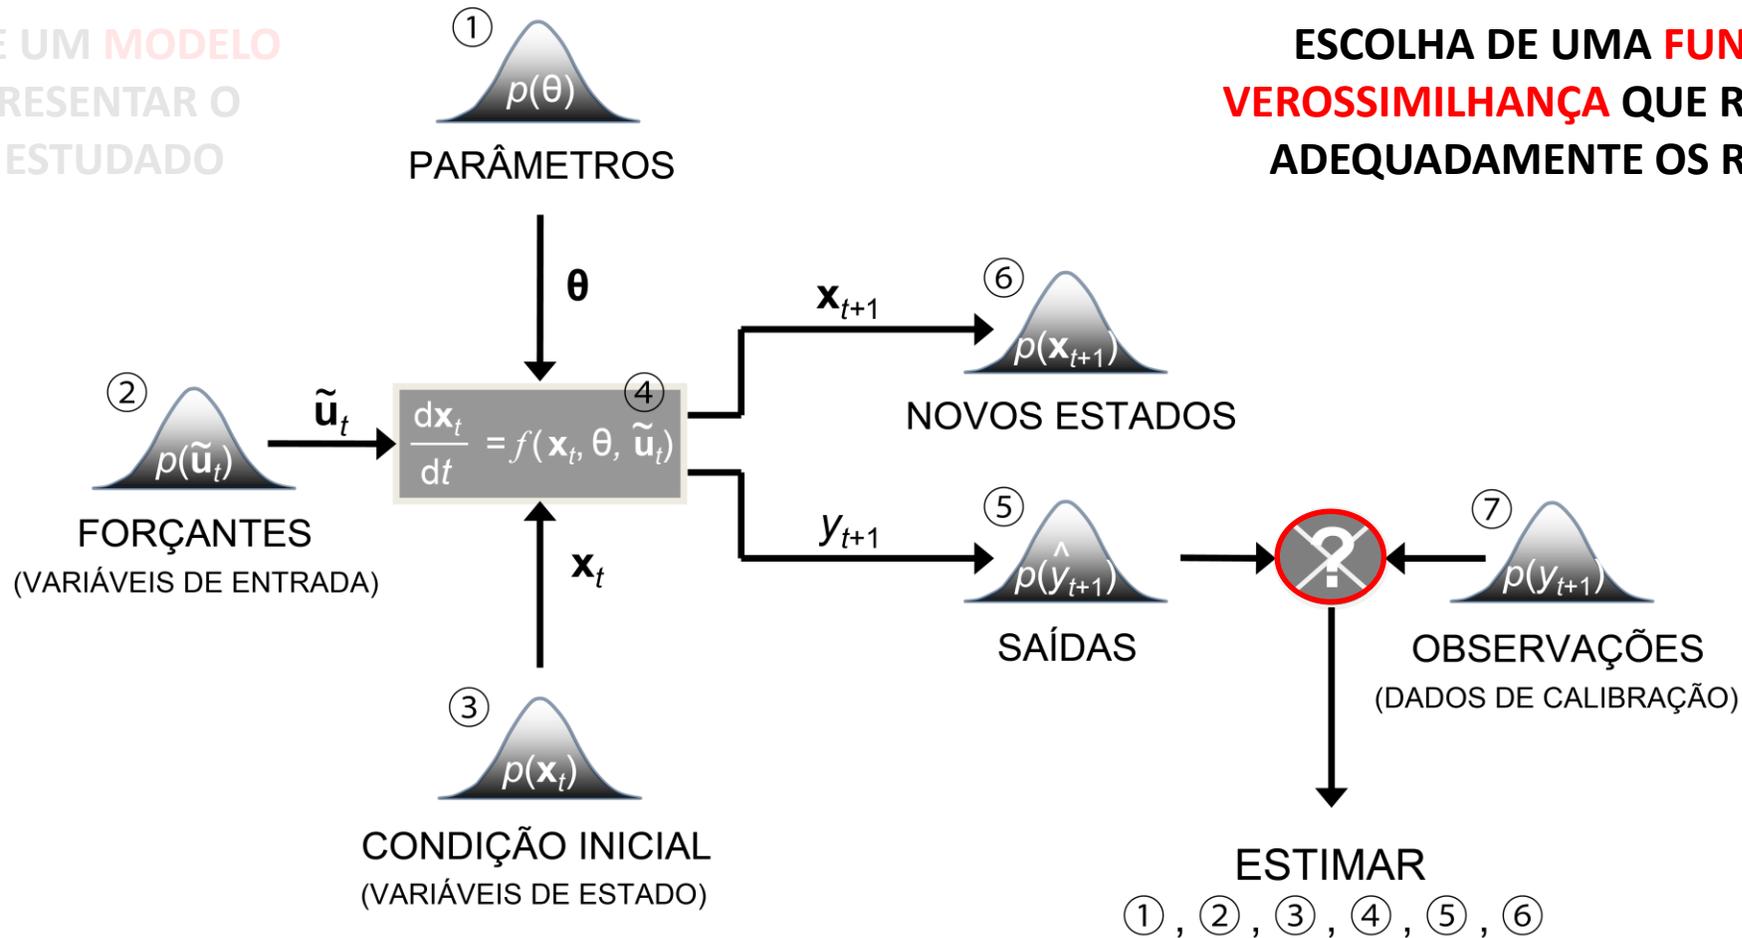
## CONTROLE DA COMPLEXIDADE DE MODELOS

Um aumento de complexidade excessivo pode reduzir a habilidade do modelo em simular o sistema estudado em um período diferente do utilizado na calibração



ESCOLHA DE UM **MODELO**  
PARA REPRESENTAR O  
SISTEMA ESTUDADO

ESCOLHA DE UMA **FUNÇÃO DE  
VEROSSIMILHANÇA** QUE REPRESENTA  
ADEQUADAMENTE OS RESÍDUOS



1 MODELAGEM DO PROCESSO DE INTERCEPTAÇÃO

2 MODELAGEM DO PROCESSO CHUVA-VAZÃO

3 ANÁLISE DA INFLUÊNCIA DO PROCESSO DE INTERCEPTAÇÃO  
NA MODELAGEM CHUVA-VAZÃO

## “FERRAMENTAS”

CONSIDERAÇÃO DE DIFERENTES MODELOS → **IDENTIFICAÇÃO DOS PROCESSOS DOMINANTES**

- **ANÁLISE BAYESIANA** PARA CALIBRAÇÃO DOS MODELOS E ANÁLISE DE INCERTEZA
- **CRITÉRIOS DE INFORMAÇÃO** PARA COMPARAÇÃO ENTRE MODELOS

# ESTRUTURA DO TRABALHO

1 MODELAGEM DO PROCESSO DE INTERCEPTAÇÃO

2 MODELAGEM DO PROCESSO CHUVA-VAZÃO

3 ANÁLISE DA INFLUÊNCIA DO PROCESSO DE INTERCEPTAÇÃO  
NA MODELAGEM CHUVA-VAZÃO

## “FERRAMENTAS”

CONSIDERAÇÃO DE DIFERENTES MODELOS → **IDENTIFICAÇÃO DOS PROCESSOS DOMINANTES**

- **ANÁLISE BAYESIANA** PARA CALIBRAÇÃO DOS MODELOS E ANÁLISE DE INCERTEZA
- **CRITÉRIOS DE INFORMAÇÃO** PARA COMPARAÇÃO ENTRE MODELOS

## POR QUE ANÁLISE BAYESIANA?

A ANÁLISE BAYESIANA PERMITE ESTIMAR OS PARÂMETROS DO MODELO E A FAIXA DE INCERTEZA DAS SIMULAÇÕES CONSIDERANDO DE MANEIRA EXPLÍCITA A EXISTÊNCIA DE DIVERSAS FONTES DE ERRO NO PROCESSO DE MODELAGEM

### “FERRAMENTAS”

CONSIDERAÇÃO DE DIFERENTES MODELOS → **IDENTIFICAÇÃO DOS PROCESSOS DOMINANTES**

- **ANÁLISE BAYESIANA** PARA CALIBRAÇÃO DOS MODELOS E ANÁLISE DE INCERTEZA
- **CRITÉRIOS DE INFORMAÇÃO** PARA COMPARAÇÃO ENTRE MODELOS

# ESTRUTURA DO TRABALHO

1 MODELAGEM DO PROCESSO DE INTERCEPTAÇÃO

2 MODELAGEM DO PROCESSO CHUVA-VAZÃO

3 ANÁLISE DA INFLUÊNCIA DO PROCESSO DE INTERCEPTAÇÃO  
NA MODELAGEM CHUVA-VAZÃO

## “FERRAMENTAS”

CONSIDERAÇÃO DE DIFERENTES MODELOS → **IDENTIFICAÇÃO DOS PROCESSOS DOMINANTES**

- **ANÁLISE BAYESIANA** PARA CALIBRAÇÃO DOS MODELOS E ANÁLISE DE INCERTEZA
- **CRITÉRIOS DE INFORMAÇÃO** PARA COMPARAÇÃO ENTRE MODELOS

## POR QUE UTILIZAR CRITÉRIOS DE INFORMAÇÃO?

OS CRITÉRIOS DE INFORMAÇÃO PERMITEM QUE A COMPARAÇÃO DE DESEMPENHO DOS MODELOS DE DIFERENTES COMPLEXIDADES POSSA SER REALIZADA DE MANEIRA “JUSTA”, SENDO APLICADA UMA PENALIDADE A MODELOS MAIS COMPLEXOS

### “FERRAMENTAS”

CONSIDERAÇÃO DE DIFERENTES MODELOS → **IDENTIFICAÇÃO DOS PROCESSOS DOMINANTES**

- **ANÁLISE BAYESIANA** PARA CALIBRAÇÃO DOS MODELOS E ANÁLISE DE INCERTEZA
- **CRITÉRIOS DE INFORMAÇÃO** PARA COMPARAÇÃO ENTRE MODELOS

# OBJETIVOS

---

Analisar como a inferência Bayesiana pode auxiliar na modelagem dos processos de interceptação e chuva-vazão

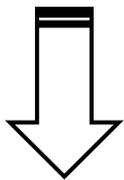
## OBJETIVO ESPECÍFICO 1

- Identificar funções de verossimilhança que representem de maneira adequada os resíduos de modelos de interceptação e chuva-vazão

## OBJETIVO ESPECÍFICO 1

- Identificar funções de verossimilhança que representem de maneira adequada os resíduos de modelos de interceptação e chuva-vazão

**FUNÇÃO DE  
VEROSSIMILHANÇA 1**

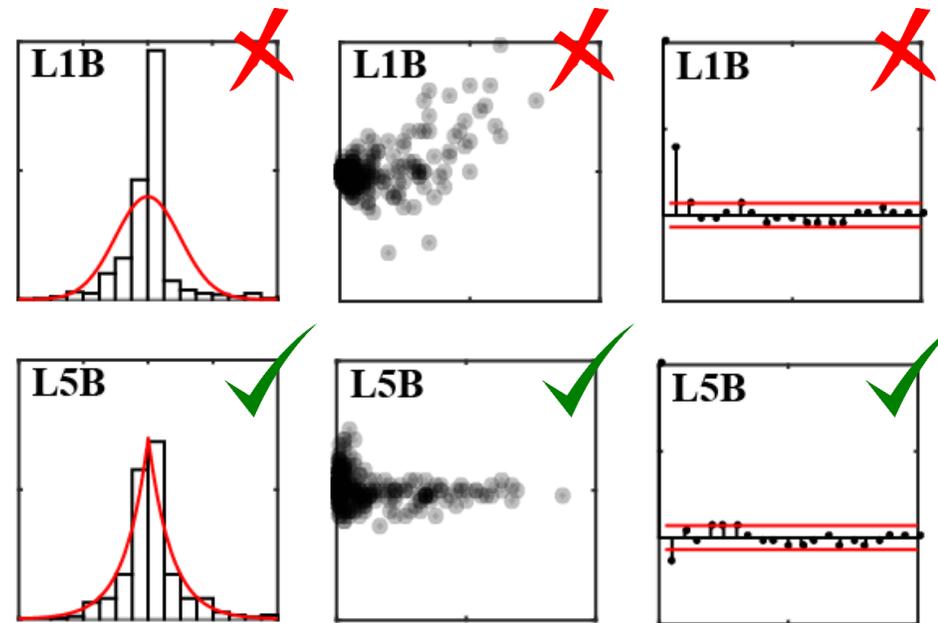


**FUNÇÃO DE  
VEROSSIMILHANÇA 5**

+ SIMPLES

AUMENTO  
INCREMENTAL DE  
COMPLEXIDADE

+ COMPLEXO



## OBJETIVO ESPECÍFICO 1

- Identificar funções de verossimilhança que representem de maneira adequada os resíduos de modelos de interceptação e chuva-vazão

FUNÇÃO DE

+ SIMPLES

L1B

L1B

L1B

Quais características dos resíduos de modelos de interceptação e chuva-vazão devem ser incorporadas na função de verossimilhança?



FUNÇÃO DE  
VEROSSIMILHANÇA 5

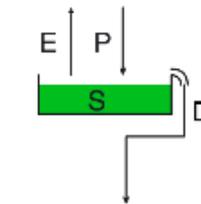
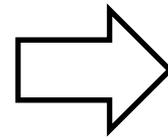
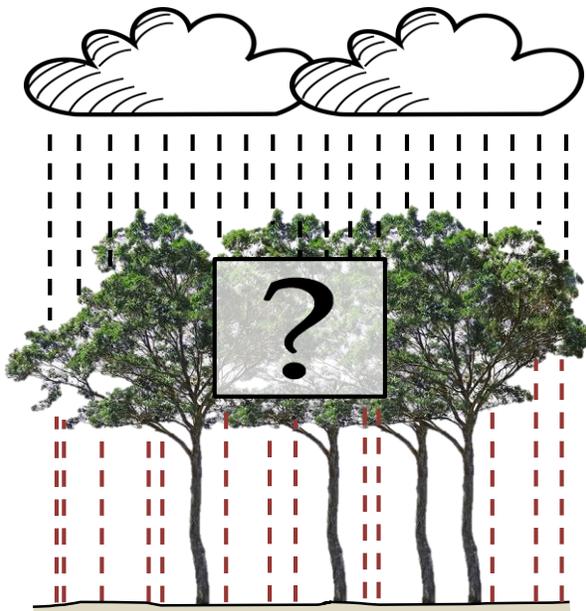
+ COMPLEXO



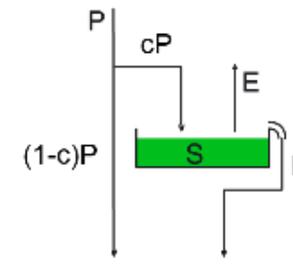
# OBJETIVOS ESPECÍFICOS

## OBJETIVO ESPECÍFICO 2

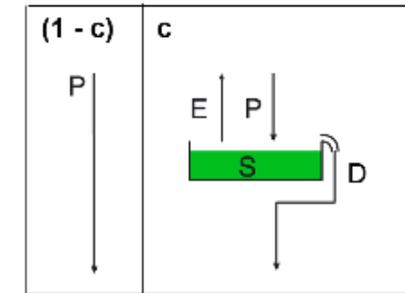
- Avaliar o desempenho de diferentes formulações do processo de interceptação



S02



S03



S04

## OBJETIVO ESPECÍFICO 2

- Avaliar o desempenho de diferentes formulações do processo de interceptação

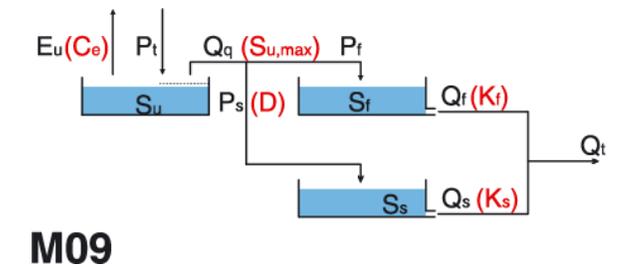
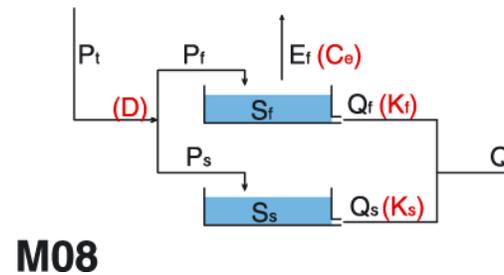
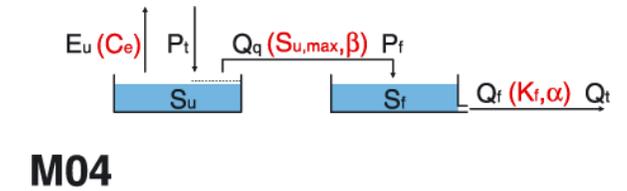
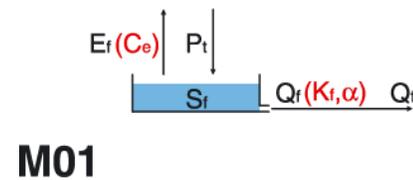
Qual formulação melhor representa o processo de interceptação nas duas bacias florestais?



# OBJETIVOS ESPECÍFICOS

## OBJETIVO ESPECÍFICO 3

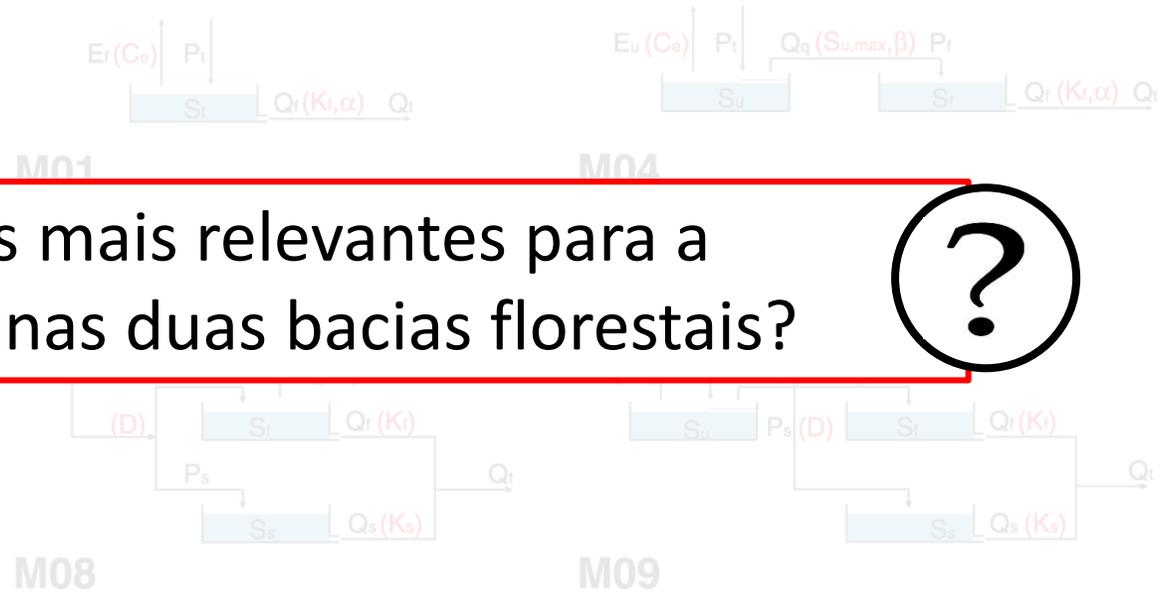
- Avaliar o desempenho de diferentes estruturas de modelos chuva-vazão quando aplicados a duas bacias florestais



## OBJETIVO ESPECÍFICO 3

- Avaliar o desempenho de diferentes estruturas de modelos chuva-vazão quando aplicados a duas bacias florestais

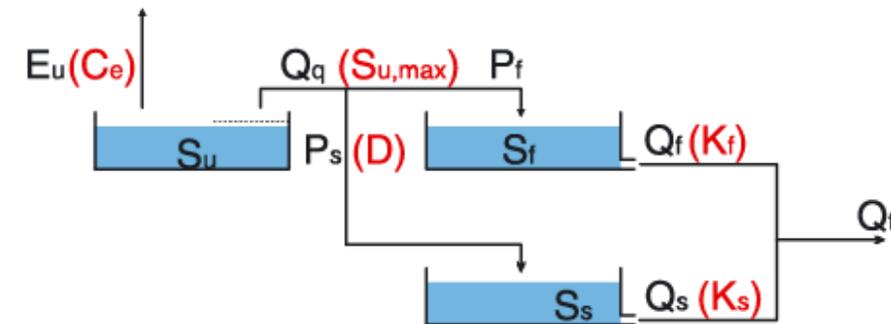
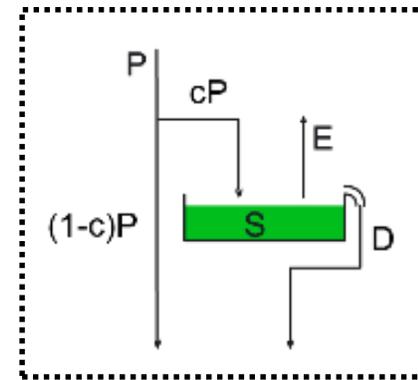
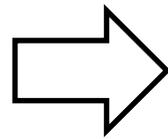
Quais são os processos mais relevantes para a modelagem chuva-vazão nas duas bacias florestais?



# OBJETIVOS ESPECÍFICOS

## OBJETIVO ESPECÍFICO 4

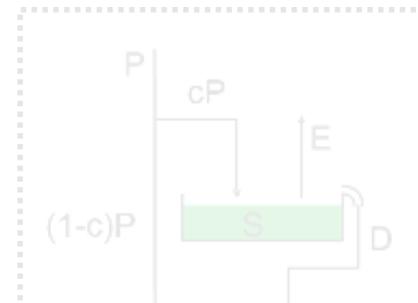
- Avaliar a influência da interceptação na modelagem do processo chuva-vazão



## OBJETIVO ESPECÍFICO 4

- Avaliar a influência da interceptação na modelagem do processo chuva-vazão

Qual é o impacto da consideração explícita do processo de interceptação na modelagem chuva-vazão?



# MATERIAIS E MÉTODOS

---

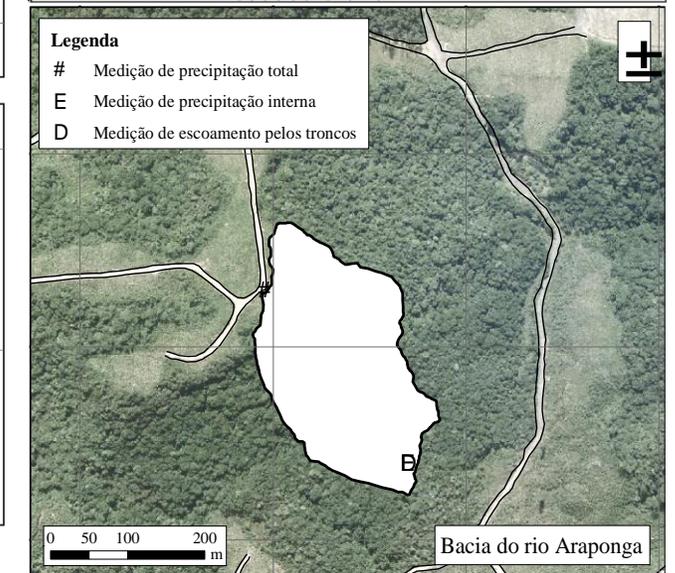
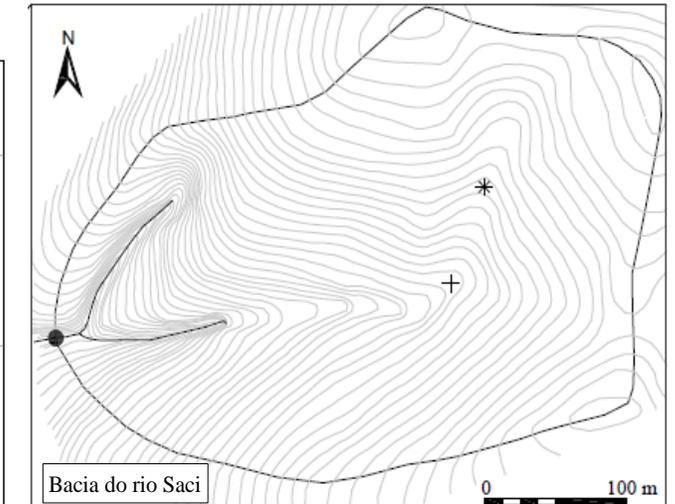
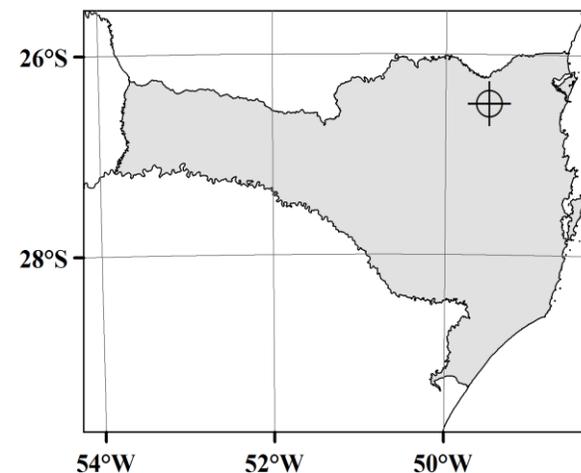
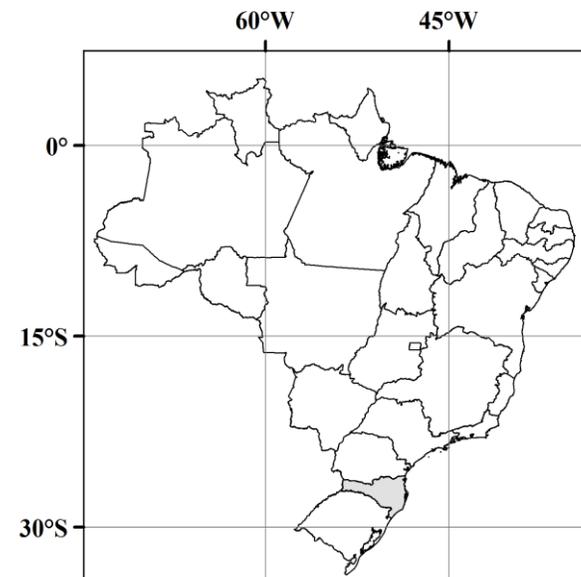
# ÁREA DE ESTUDO

## BACIA DO RIO SACI

- Reflorestamento de pinus
- 10,2 ha
- 23/08/2008 a 17/11/2008
- Vazão: Chaffe (2009)
- Interceptação: Chaffe (2009)
- $\Delta t = 10$  min

## BACIA DO RIO ARAPONGA

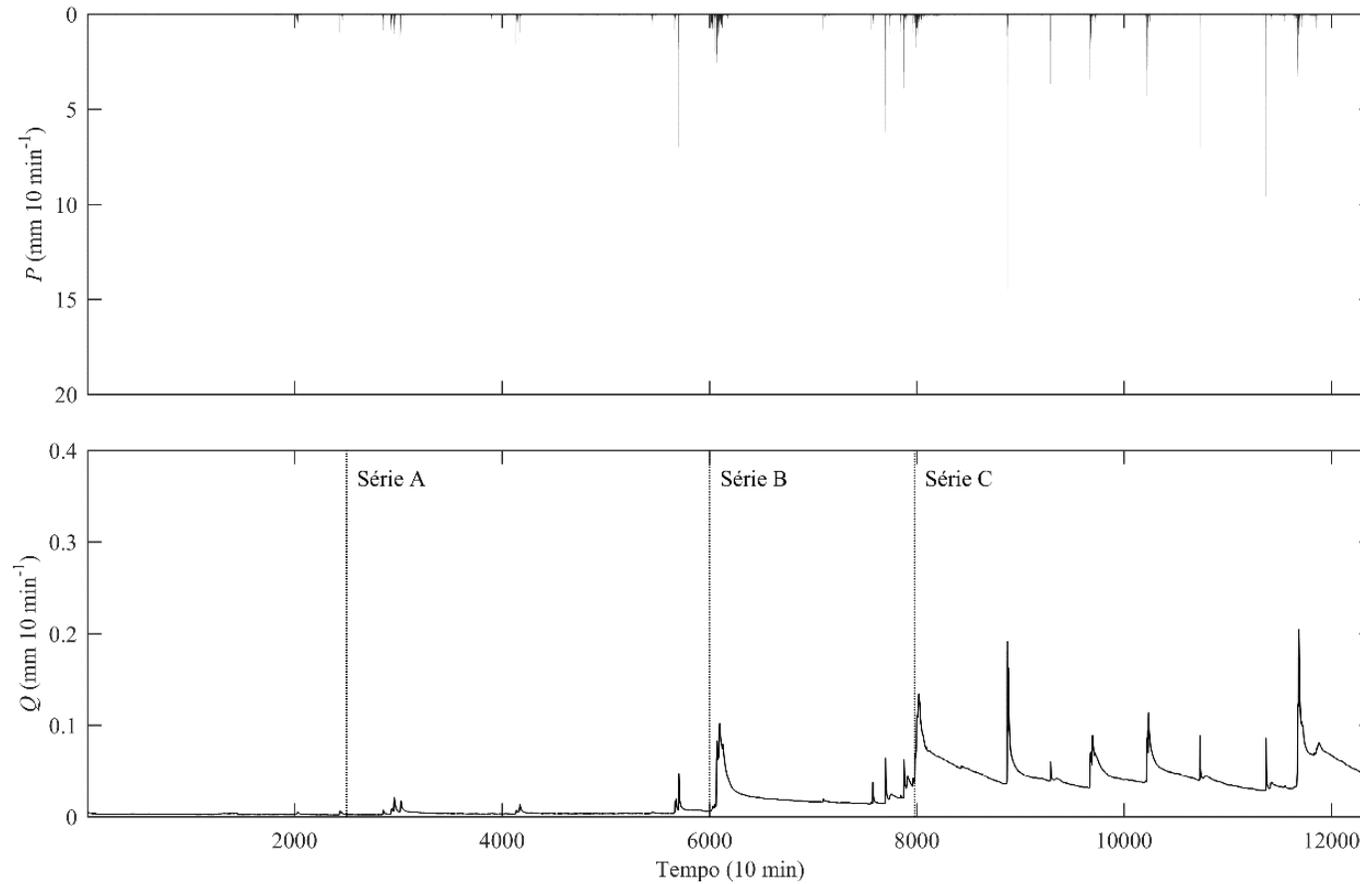
- Vegetação nativa
- 5,26 ha
- 26/02/2014 a 06/10/2014
- Vazão: Mota (2017)
- Interceptação: Sá (2015)
- $\Delta t = 5$  min





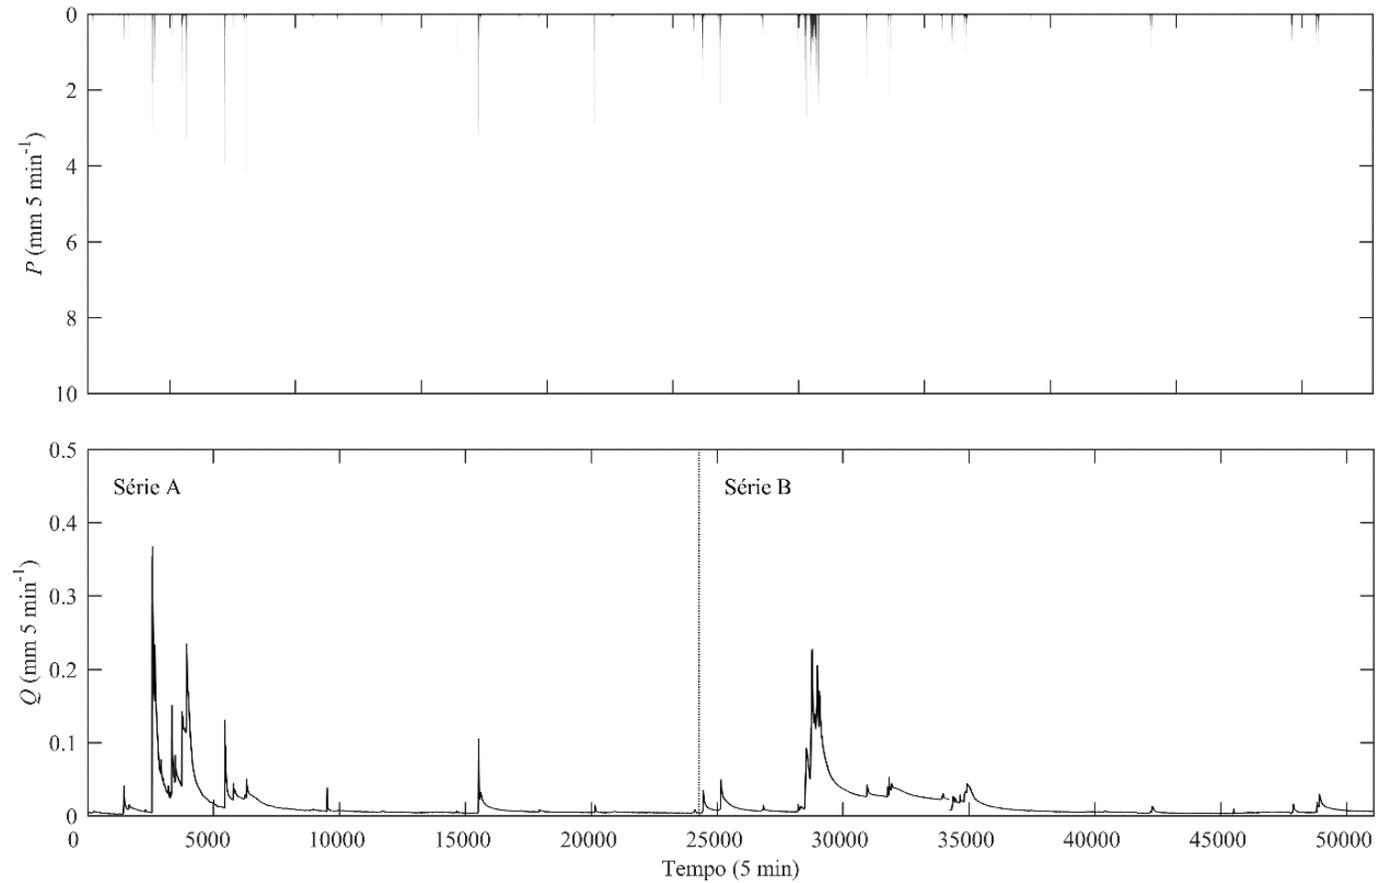
## BACIA DO RIO SACI

23/08/2008 a 17/11/2008

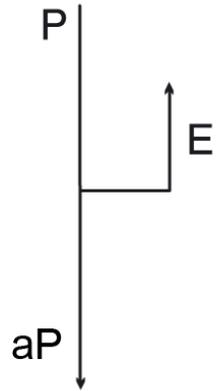


## BACIA DO RIO ARAPONGA

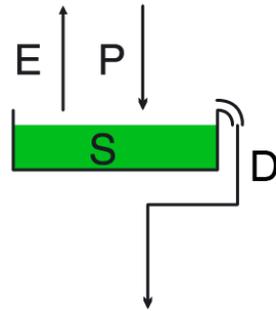
26/02/2014 a 06/10/2014



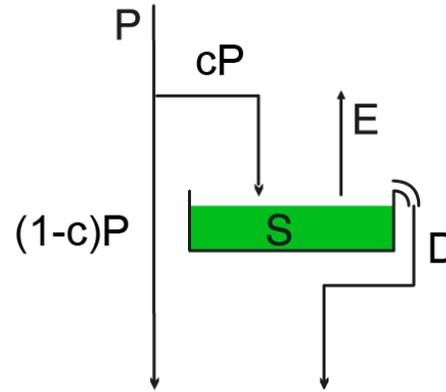
# MODELOS DE INTERCEPTAÇÃO



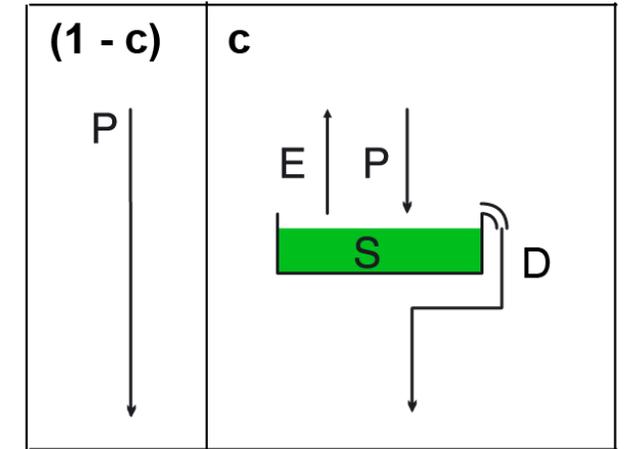
**S01**



**S02**

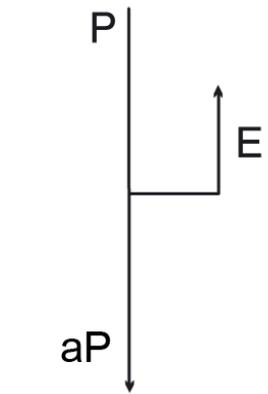


**S03**

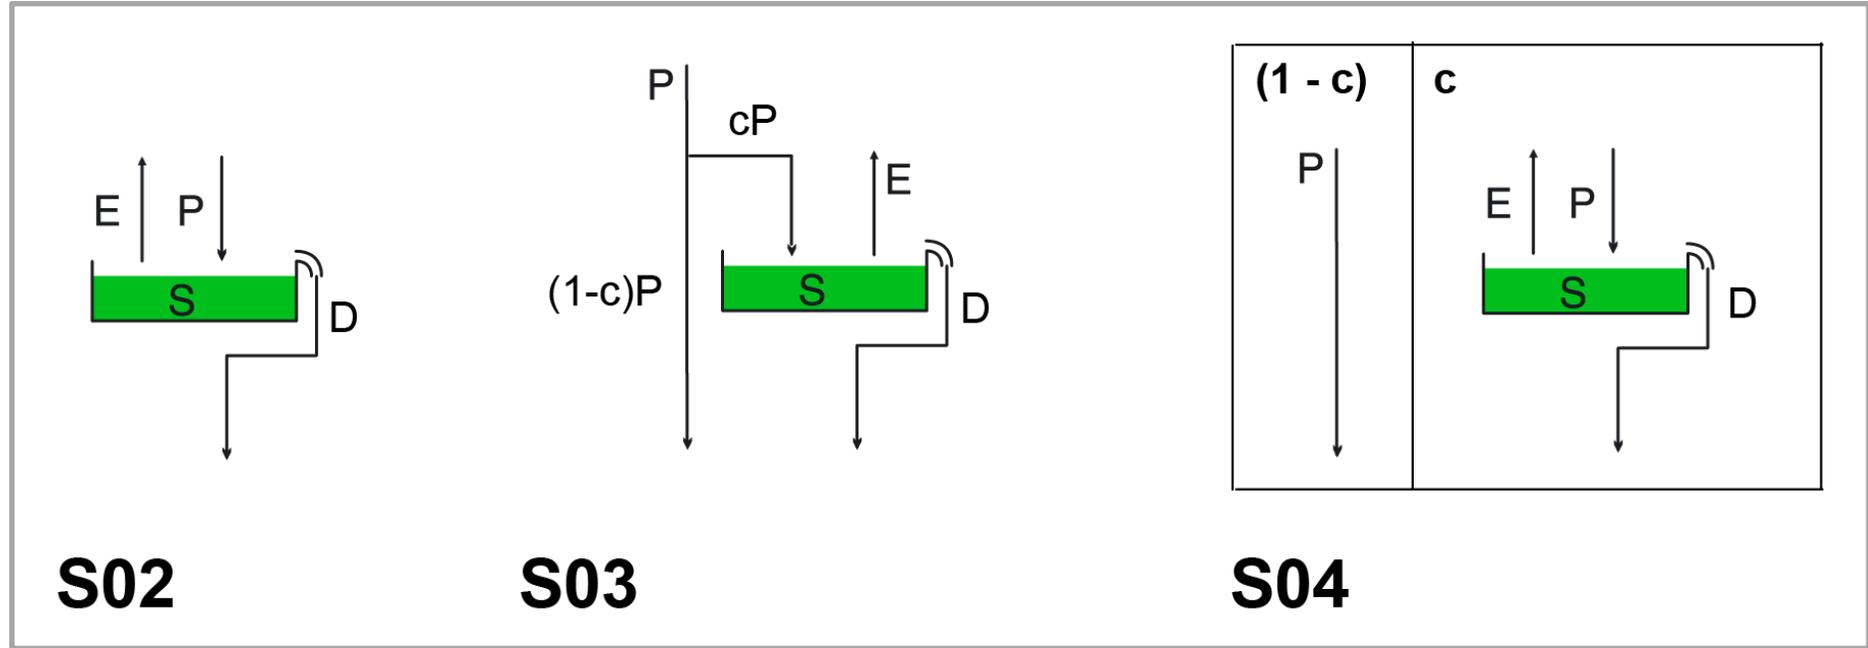


**S04**

# MODELOS DE INTERCEPTAÇÃO



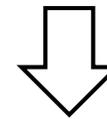
**S01**



**S02**

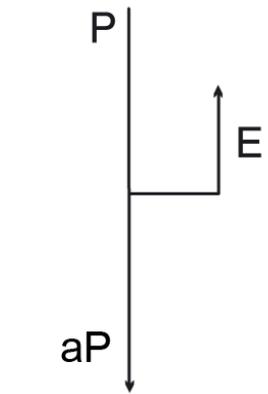
**S03**

**S04**

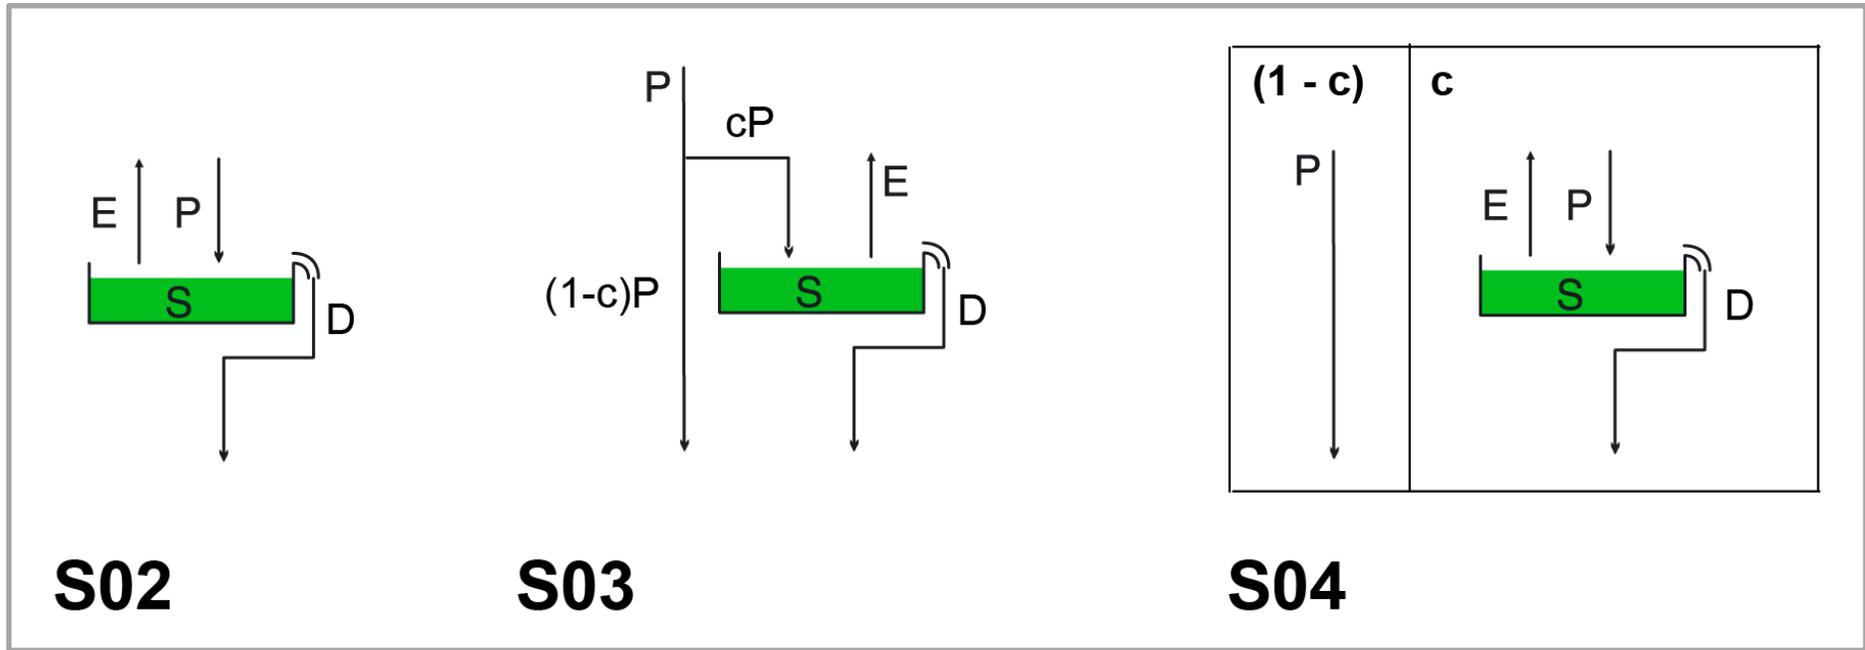


$$\frac{dS}{dt} = \text{entradas} - \text{saídas}$$

# MODELOS DE INTERCEPTAÇÃO



**S01**



**S02**

**S03**

**S04**

+

$$D = Pf_h(\bar{S} | m_1)$$

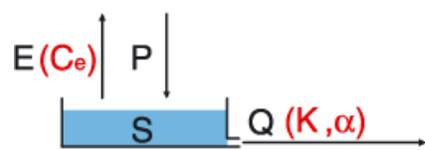
**D01**

$$D = b(S - C)$$

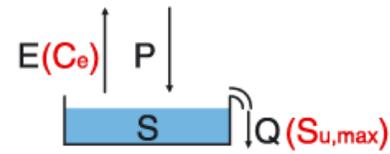
**D02**

## SUPERFLEX

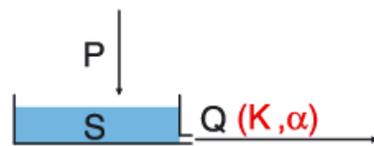
### 1 RESERVATÓRIOS



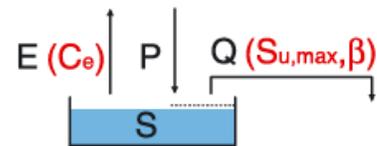
R01



R02

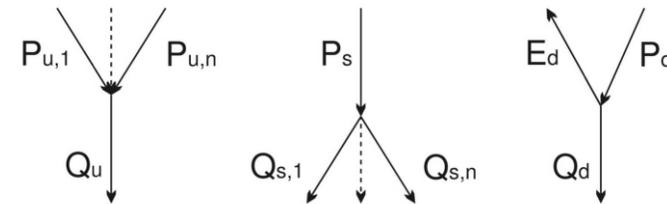


R03

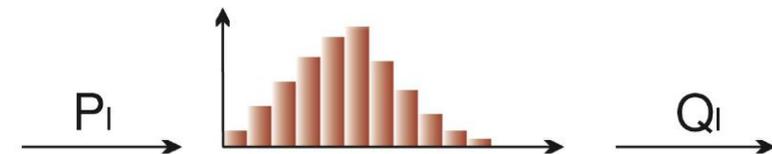


R04

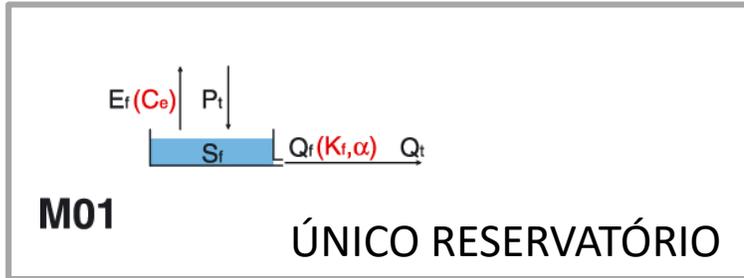
### 2 JUNÇÕES



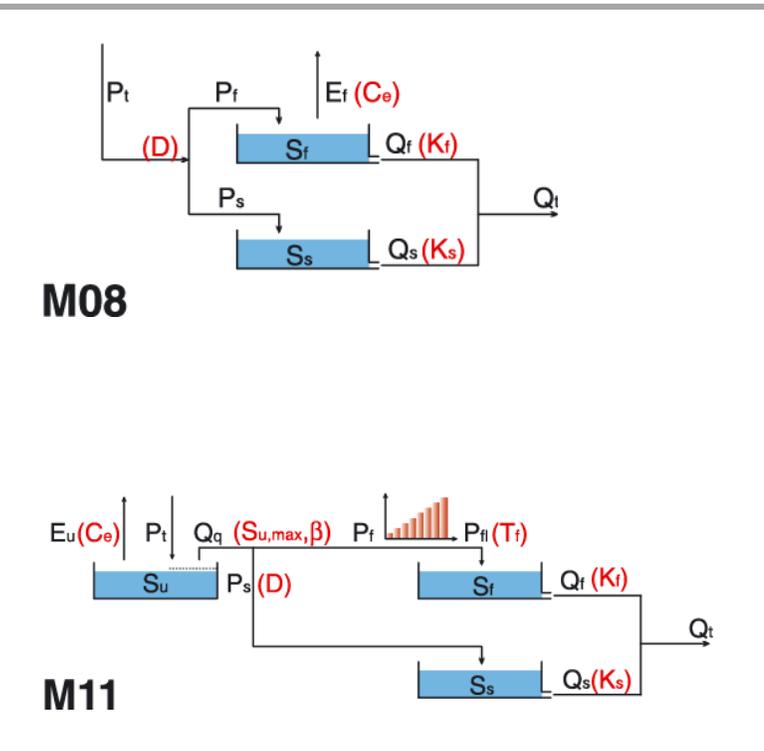
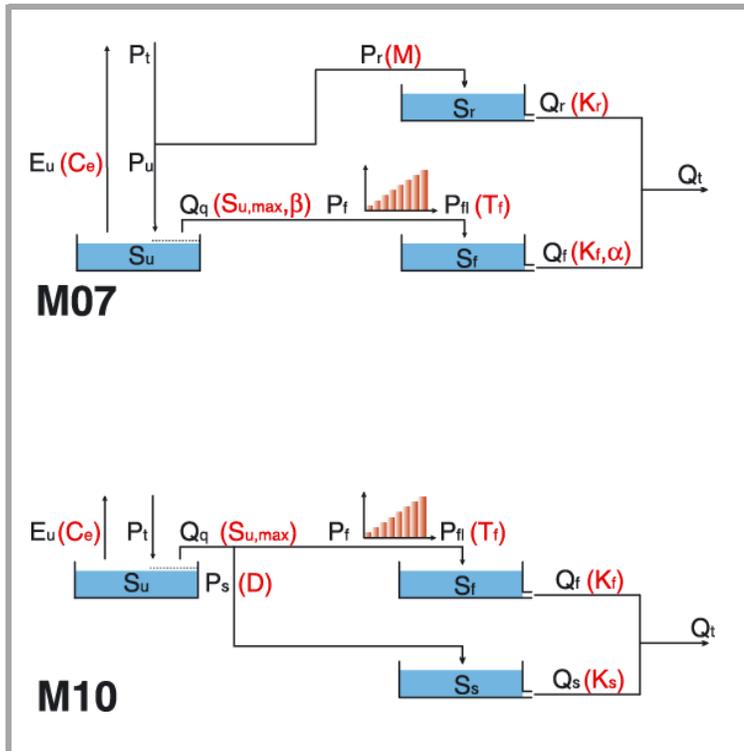
### 3 FUNÇÕES DE PROPAGAÇÃO



# MODELOS CHUVA-AVAZÃO



**M04** EM SÉRIE



**M09** EM PARALELO



FENICIA et al. (2014)

# INTERCEPTAÇÃO E CHUVA-VAZÃO

## ANÁLISE DA INFLUÊNCIA DO PROCESSO DE INTERCEPTAÇÃO NA MODELAGEM CHUVA-VAZÃO

- ① Modelo chuva-vazão com chuva total como entrada
- ② Modelo chuva-vazão com chuva líquida como entrada
- ③ Modelo chuva-vazão + modelo de interceptação (parâmetros fixos)
- ④ Modelo chuva-vazão + modelo de interceptação (parâmetros calibrados)

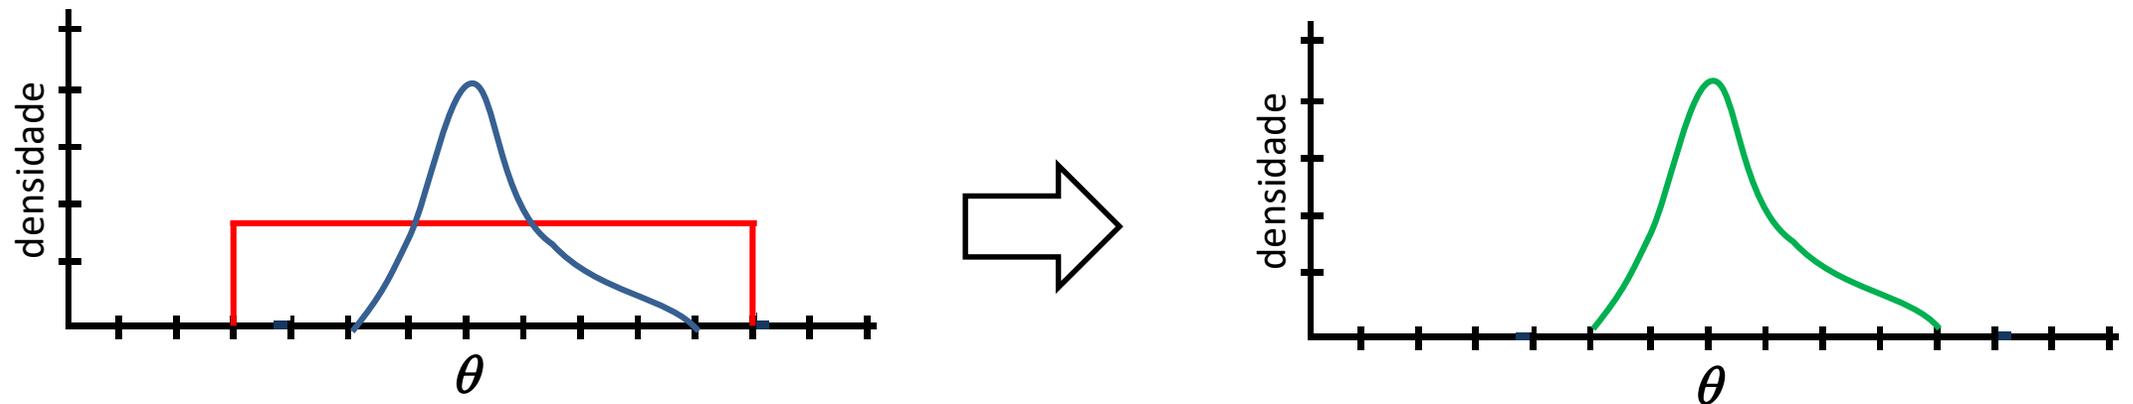
# CALIBRAÇÃO DOS MODELOS

## DIFFERENTIAL EVOLUTION ADAPTIVE METROPOLIS (DREAM)

- Amostrador do tipo Markov Chain Monte Carlo
- Permite a inferência conjunta dos parâmetros do modelo ( $\theta$ ) e da incerteza

distribuição a posteriori  $p(\theta | \mathbf{y}) \propto p(\theta)L(\theta | \mathbf{y})$

distribuição a priori      função de verossimilhança

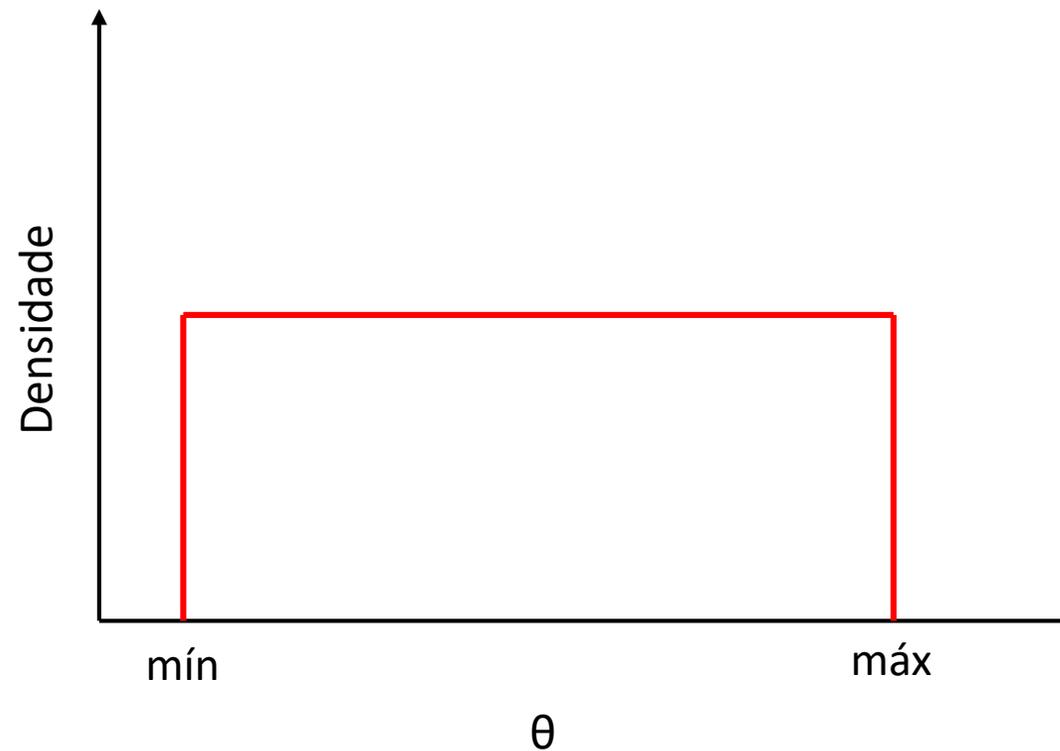


# CALIBRAÇÃO DOS MODELOS

## DISTRIBUIÇÃO A PRIORI

distribuição a posteriori  $p(\boldsymbol{\theta} | \mathbf{y}) \propto p(\boldsymbol{\theta})L(\boldsymbol{\theta} | \mathbf{y})$

distribuição a priori      função de verossimilhança



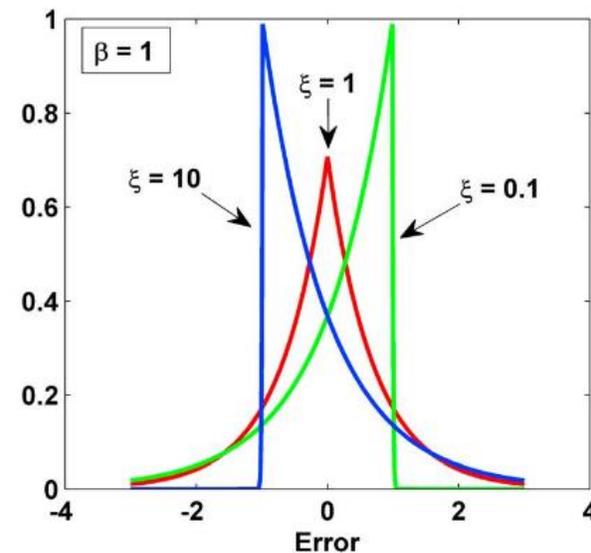
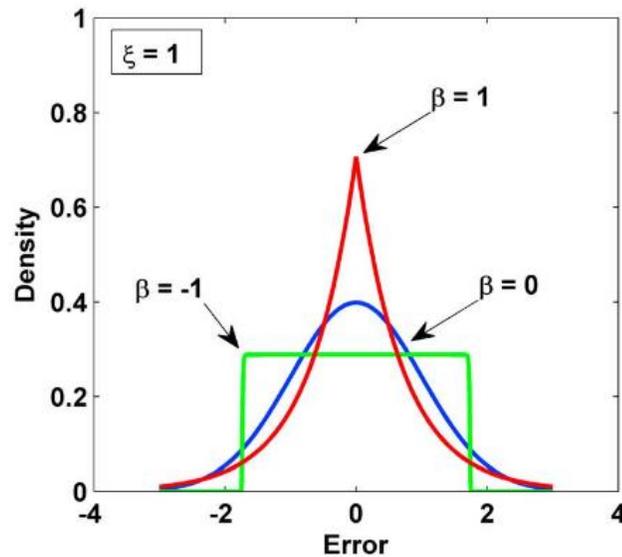
# CALIBRAÇÃO DOS MODELOS

## FUNÇÃO DE VEROSSIMILHANÇA

distribuição a priori    função de verossimilhança  
 distribuição a posteriori     $p(\boldsymbol{\theta} | \mathbf{y}) \propto p(\boldsymbol{\theta})L(\boldsymbol{\theta} | \mathbf{y})$

## GENERALIZED LIKELIHOOD FUNCTION (SCHOUPS & VRUGT, 2010)

$$\ell = n \log \frac{2\sigma_\xi \omega_\beta}{\xi + \xi^{-1}} - \sum_{t=1}^n \log \sigma_t - c_\beta \sum_{t=1}^n |a_{\xi,t}|^{2/(1+\beta)}$$



# CALIBRAÇÃO DOS MODELOS

## FUNÇÃO DE VEROSSIMILHANÇA

distribuição a priori      função de verossimilhança  
 distribuição a posteriori       $p(\boldsymbol{\theta} | \mathbf{y}) \propto p(\boldsymbol{\theta})L(\boldsymbol{\theta} | \mathbf{y})$

## GENERALIZED LIKELIHOOD FUNCTION

(SCHOUPS & VRUGT, 2010)

$$\ell = n \log \frac{2\sigma_{\xi}\omega_{\beta}}{\xi + \xi^{-1}} - \sum_{t=1}^n \log \sigma_t - c_{\beta} \sum_{t=1}^n |a_{\xi,t}|^{2/(1+\beta)}$$

## ZERO-INFLATED GENERALIZED LIKELIHOOD FUNCTION

$$\ell = n_1 \log \rho + n_2 \log(1 - \rho) + n_2 \log \frac{2\sigma_{\xi}\omega_{\beta}}{\xi + \xi^{-1}} - \sum_{t_2=1}^{n_2} \log \sigma_{t_2} - c_{\beta} \sum_{t_2=1}^{n_2} |a_{\xi,t_2}|^{2/(1+\beta)} + n_3 \log \frac{2\sigma_{\xi}\omega_{\beta}}{\xi + \xi^{-1}} - \sum_{t_3=1}^{n_3} \log \sigma_{t_3} - c_{\beta} \sum_{t_3=1}^{n_3} |a_{\xi,t_3}|^{2/(1+\beta)}$$

resíduo = 0      resíduo ≠ 0 para simulado = 0      resíduo ≠ 0 para simulado ≠ 0



# CALIBRAÇÃO DOS MODELOS

## FUNÇÃO DE VEROSSIMILHANÇA

$$p(\boldsymbol{\theta} | \mathbf{y}) \propto p(\boldsymbol{\theta})L(\boldsymbol{\theta} | \mathbf{y})$$

distribuição a posteriori      distribuição a priori      função de verossimilhança

## INTERCEPTAÇÃO

- *Generalized Likelihood function (GL)*
- *Generalized Likelihood function para  $\mathbf{y} > 0$  ( $GL^{\mathbf{y} > 0}$ )*
- *Zero-Inflated Generalized Likelihood function (ZI-GL)*

## CHUVA-VAZÃO

- *Generalized Likelihood function (GL)*

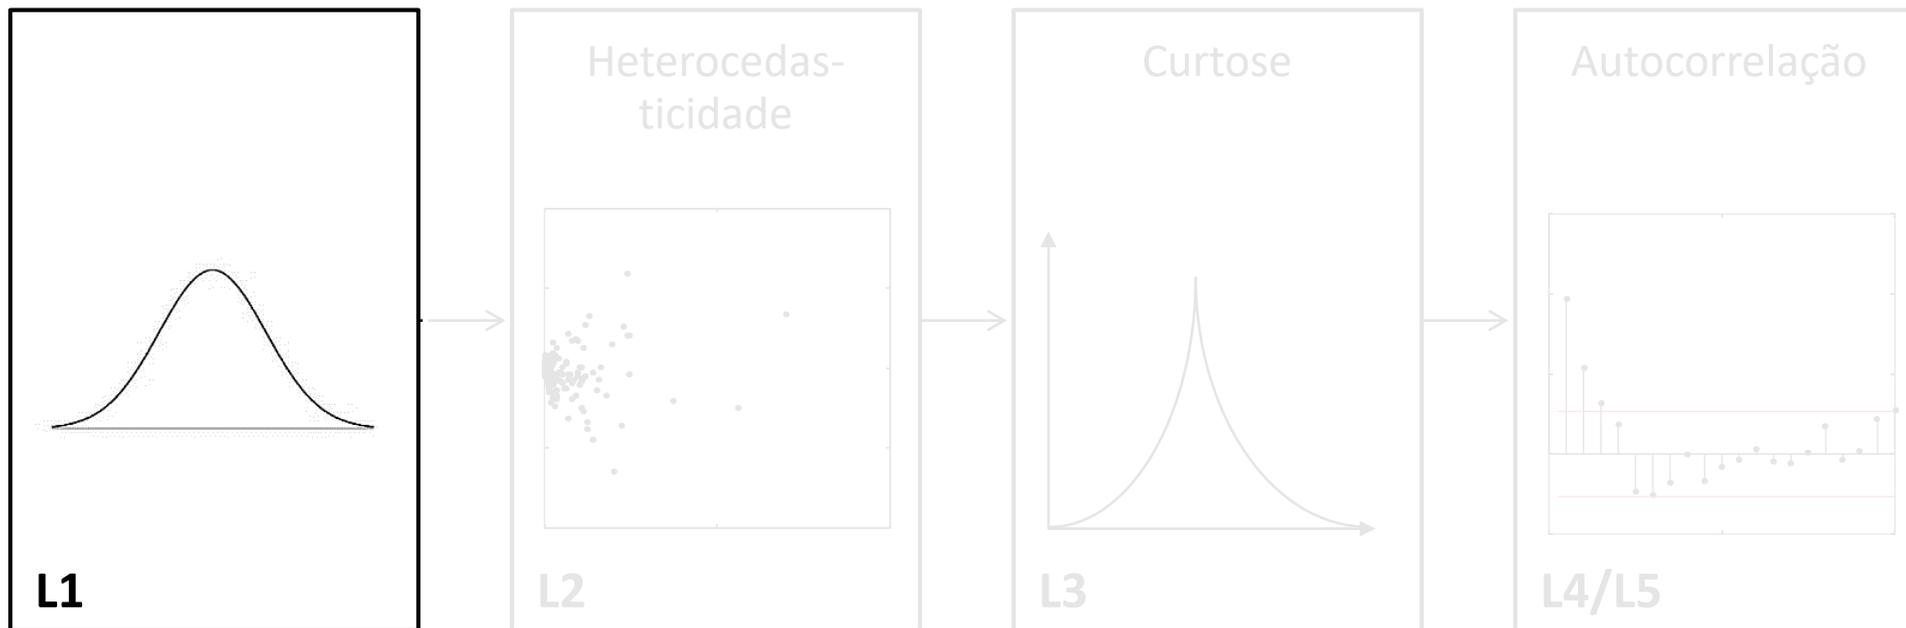
# CALIBRAÇÃO DOS MODELOS

## FUNÇÃO DE VEROSSIMILHANÇA

distribuição a posteriori  $p(\theta | y) \propto p(\theta)L(\theta | y)$

distribuição a priori      função de verossimilhança

**Aumento gradual da complexidade** do modelo para resíduos



**PREMISSAS: HOMOSCEDASTICIDADE, DISTRIBUIÇÃO GAUSSIANA, RESÍDUOS INDEPENDENTES**

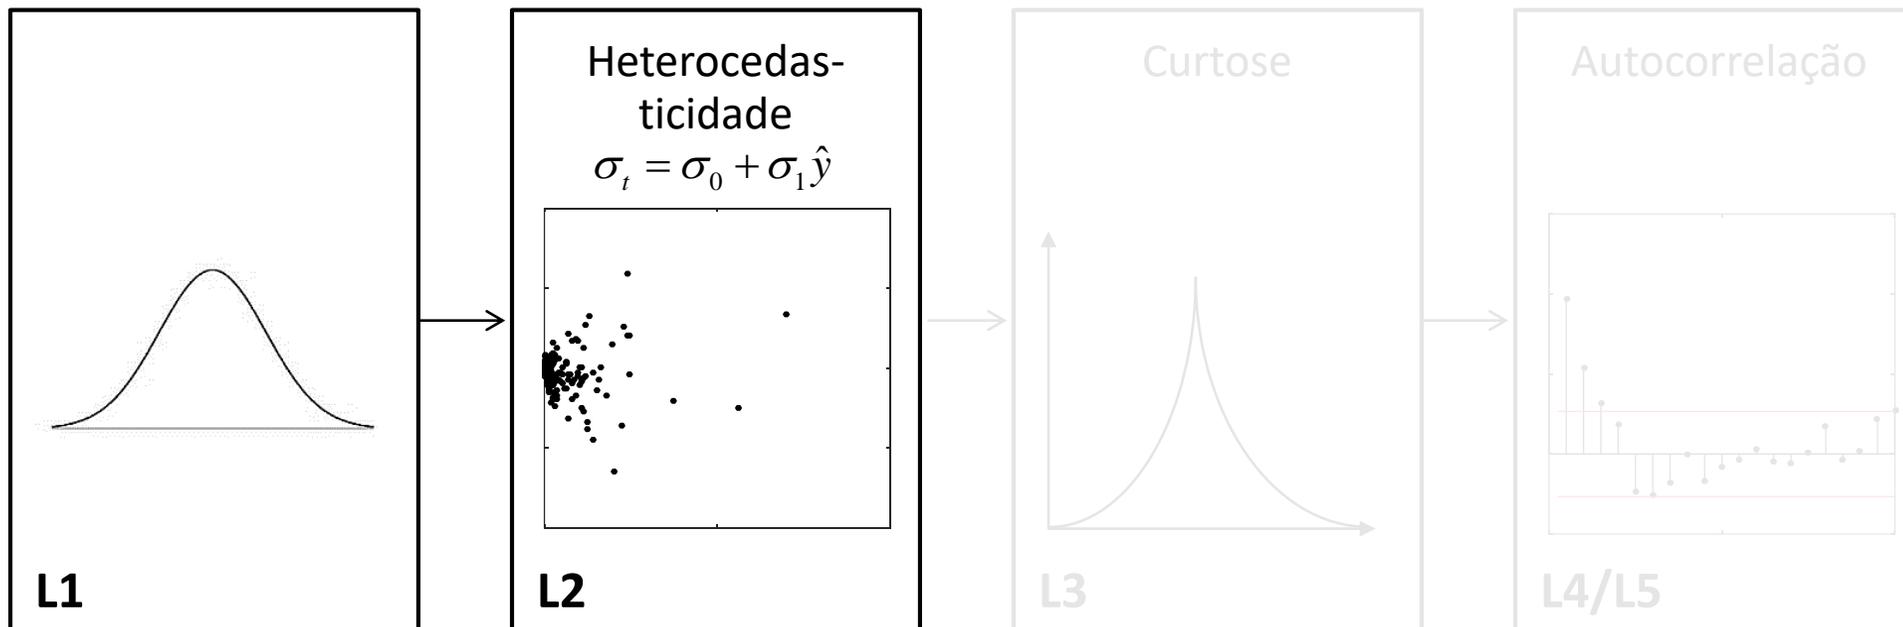
# CALIBRAÇÃO DOS MODELOS

## FUNÇÃO DE VEROSSIMILHANÇA

$$p(\boldsymbol{\theta} | \mathbf{y}) \propto p(\boldsymbol{\theta})L(\boldsymbol{\theta} | \mathbf{y})$$

distribuição a posteriori      distribuição a priori      função de verossimilhança

**Aumento gradual da complexidade** do modelo para resíduos



PREMISSAS: HETEROSCEDASTICIDADE, DISTRIBUIÇÃO GAUSSIANA, RESÍDUOS INDEPENDENTES

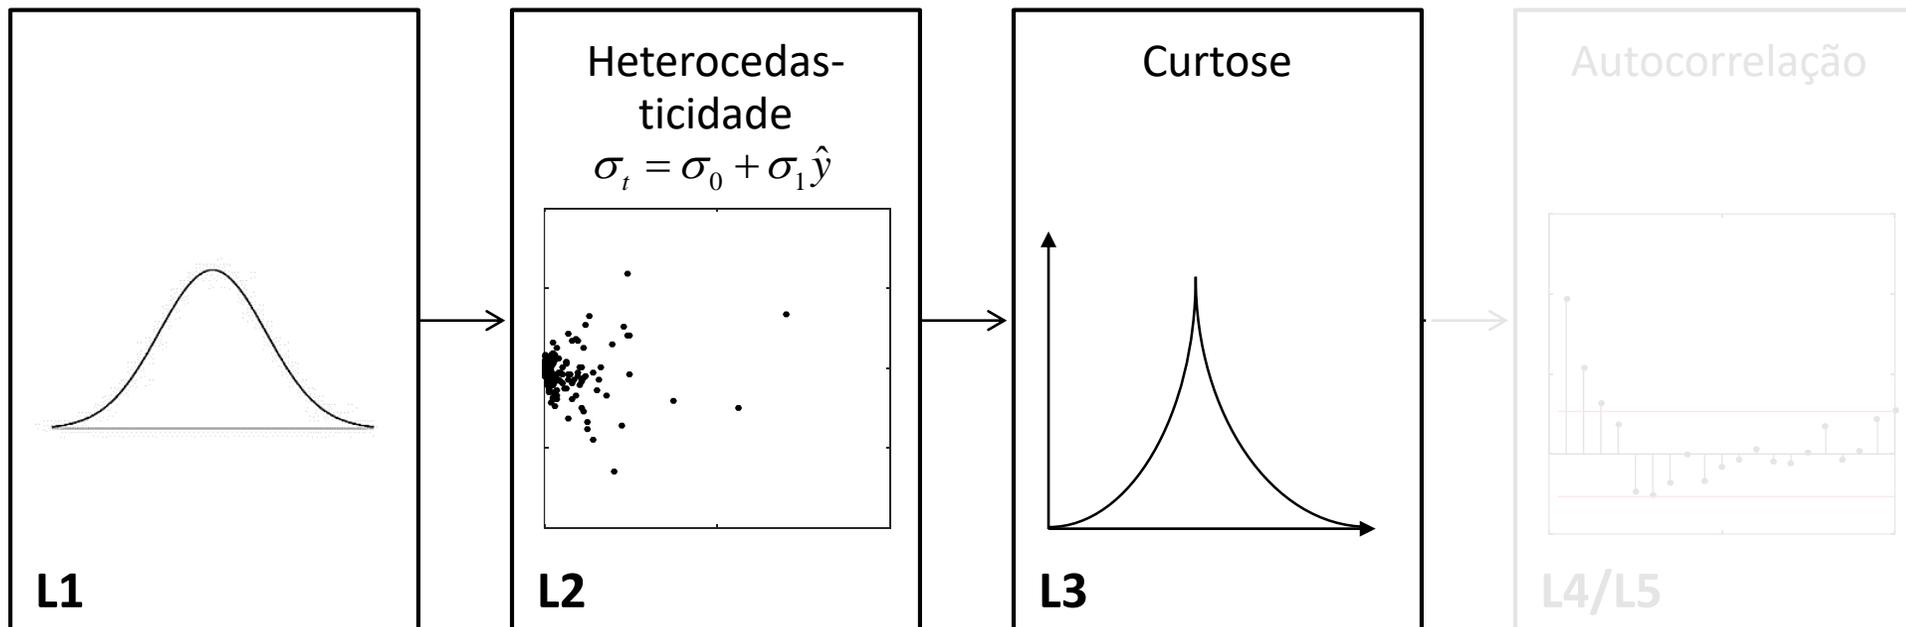
# CALIBRAÇÃO DOS MODELOS

## FUNÇÃO DE VEROSSIMILHANÇA

$$p(\boldsymbol{\theta} | \mathbf{y}) \propto p(\boldsymbol{\theta})L(\boldsymbol{\theta} | \mathbf{y})$$

distribuição a posteriori      distribuição a priori      função de verossimilhança

**Aumento gradual da complexidade** do modelo para resíduos



PREMISSAS: HETEROSCEDASTICIDADE, DISTRIBUIÇÃO SEP, RESÍDUOS INDEPENDENTES

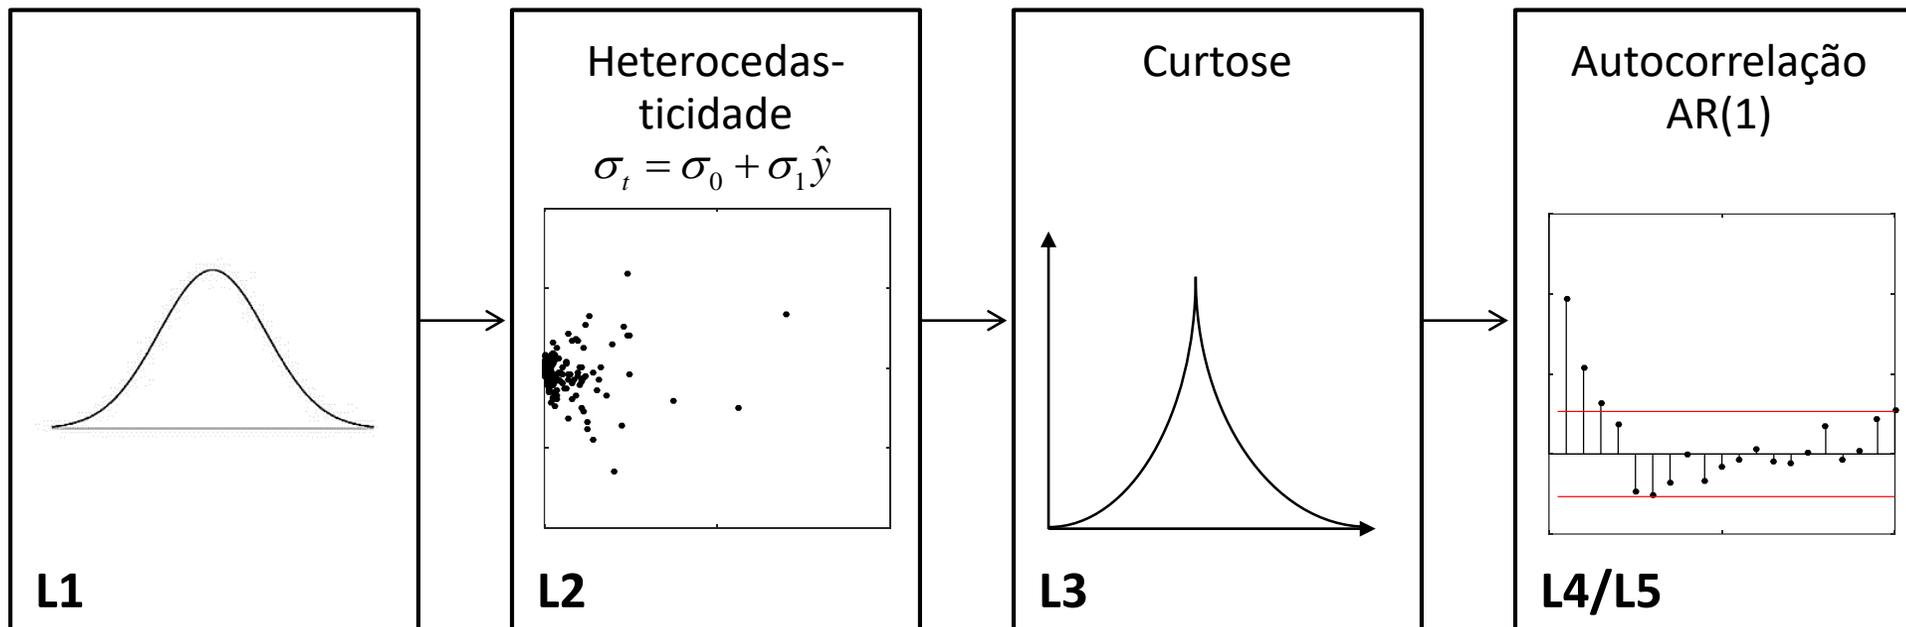
# CALIBRAÇÃO DOS MODELOS

## FUNÇÃO DE VEROSSIMILHANÇA

distribuição a posteriori  $p(\theta | y) \propto p(\theta)L(\theta | y)$

distribuição a priori  $p(\theta)$       função de verossimilhança  $L(\theta | y)$

**Aumento gradual da complexidade** do modelo para resíduos



**PREMISSAS: HETEROSCEDASTICIDADE, DISTRIBUIÇÃO SEP, RESÍDUOS CORRELACIONADOS**

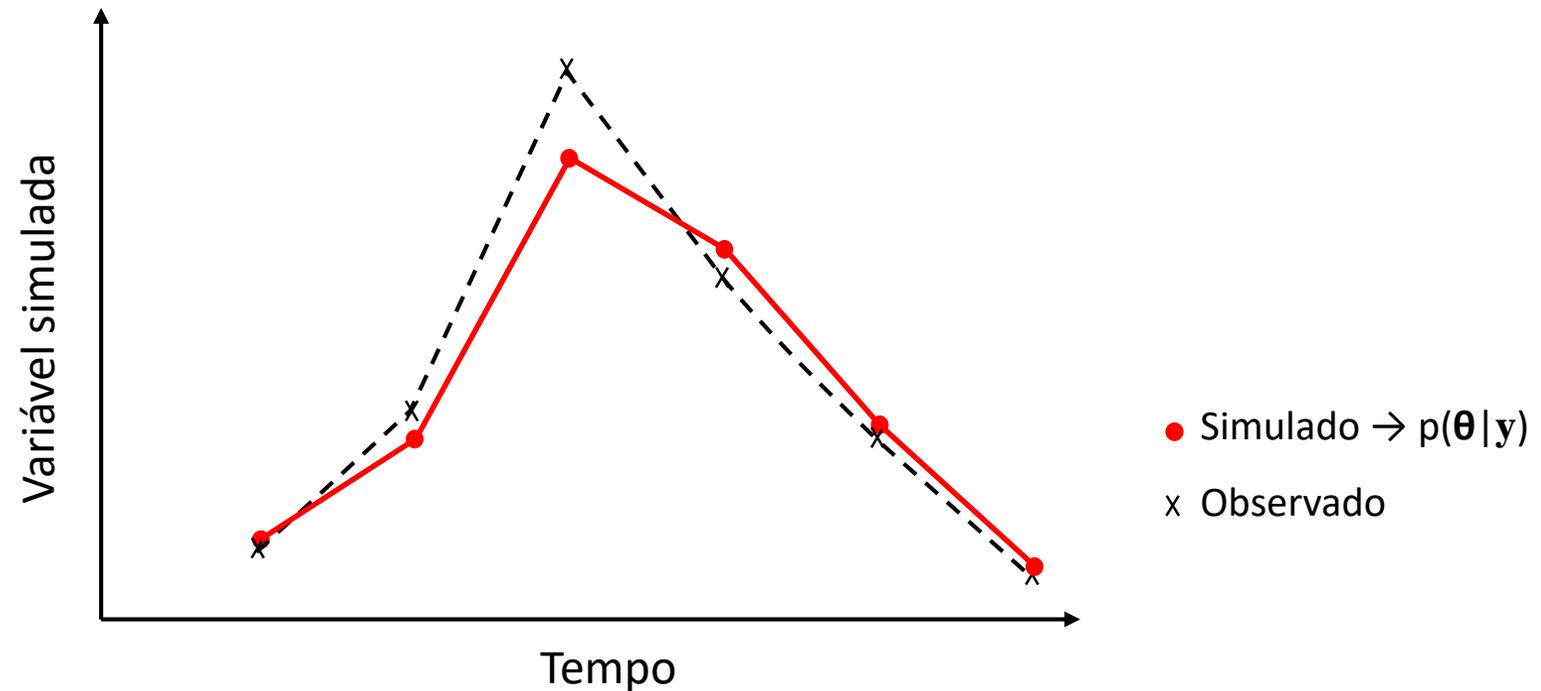
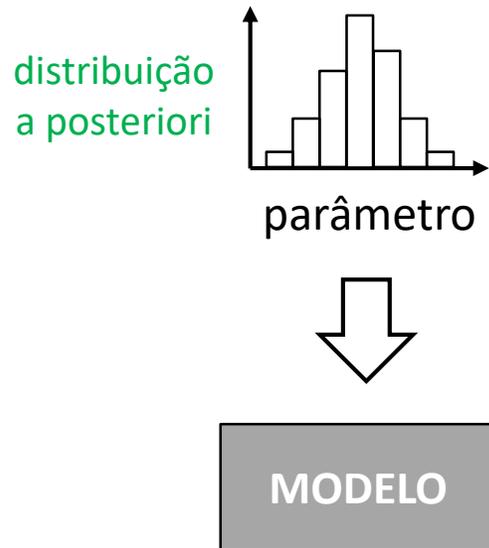
## GERAÇÃO DA FAIXA DE INCERTEZA

- ① INCERTEZA EM RELAÇÃO AOS VALORES DOS PARÂMETROS  $\rightarrow p(\boldsymbol{\theta} | \mathbf{y})$
- ② INCERTEZA TOTAL

# ANÁLISE DE INCERTEZA

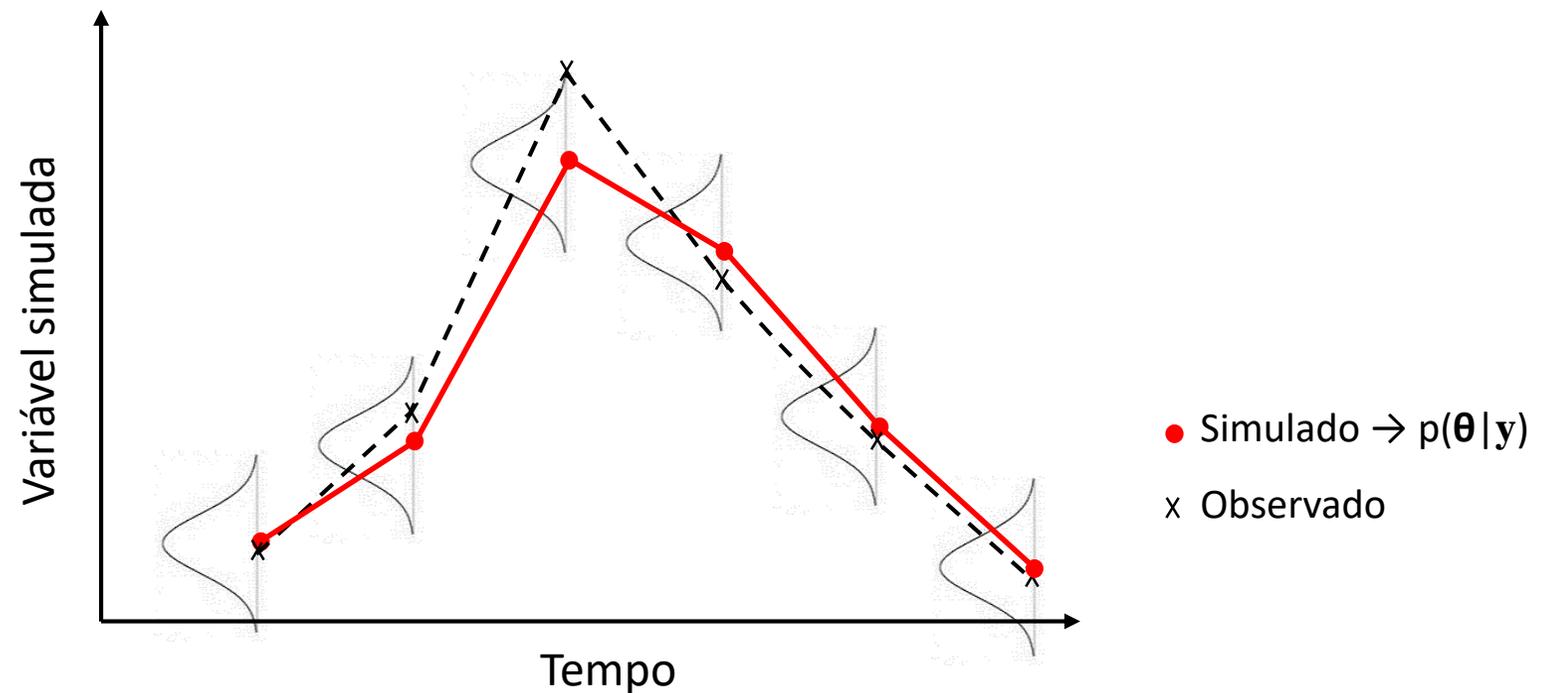
## GERAÇÃO DA FAIXA DE INCERTEZA

- ① INCERTEZA EM RELAÇÃO AOS VALORES DOS PARÂMETROS  $\rightarrow p(\theta | y)$
- ② INCERTEZA TOTAL



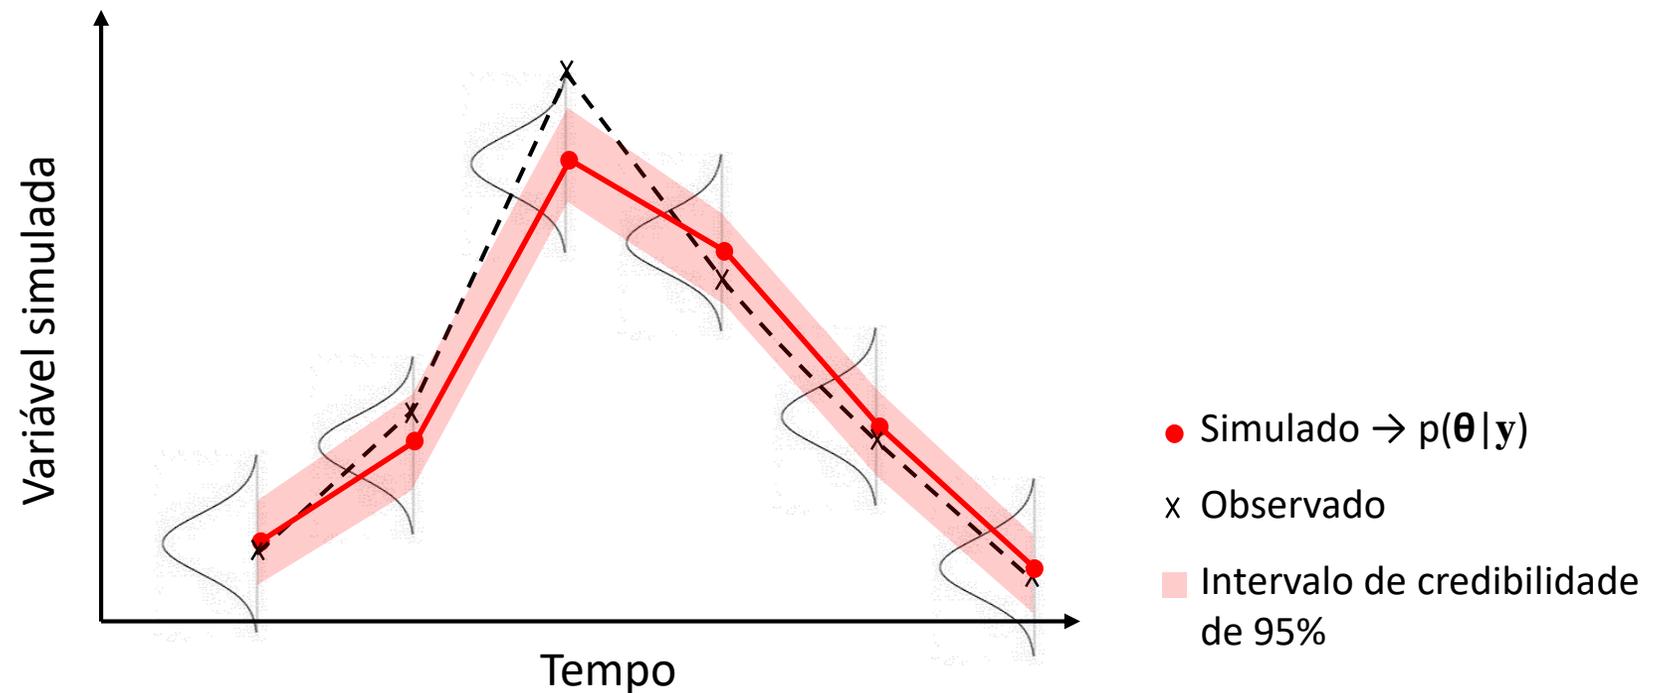
## GERAÇÃO DA FAIXA DE INCERTEZA

- ① INCERTEZA EM RELAÇÃO AOS VALORES DOS PARÂMETROS  $\rightarrow p(\theta | y)$
- ② INCERTEZA TOTAL



## GERAÇÃO DA FAIXA DE INCERTEZA

- ① INCERTEZA EM RELAÇÃO AOS VALORES DOS PARÂMETROS  $\rightarrow p(\theta | y)$
- ② INCERTEZA TOTAL



# ANÁLISE DE INCERTEZA

## MÉTRICAS DE AVALIAÇÃO DA QUALIDADE DA FAIXA DE INCERTEZA

$$\textcircled{1} \text{ Confiabilidade}[\hat{\mathbf{y}}, \mathbf{y}] = \frac{2}{n} \sum_{t=1}^n \left| F_U \left[ F_{\hat{y}(t)}(y_t) \right] - F_{\Omega} \left[ F_{\hat{y}(t)}(y_t) \right] \right|$$

$$\textcircled{2} \text{ Precisão}[\hat{\mathbf{y}}, \mathbf{y}] = \frac{1}{n} \sum_{t=1}^n \text{sdev } \hat{y}_t \bigg/ \frac{1}{n} \sum_{t=1}^n y_t$$

$$\textcircled{3} \text{ Bias}[\hat{\mathbf{y}}, \mathbf{y}] = \left| \frac{\sum_{t=1}^n y_t - \sum_{t=1}^n \hat{y}_{t,\text{mean}}}{\sum_{t=1}^n y_t} \right|$$

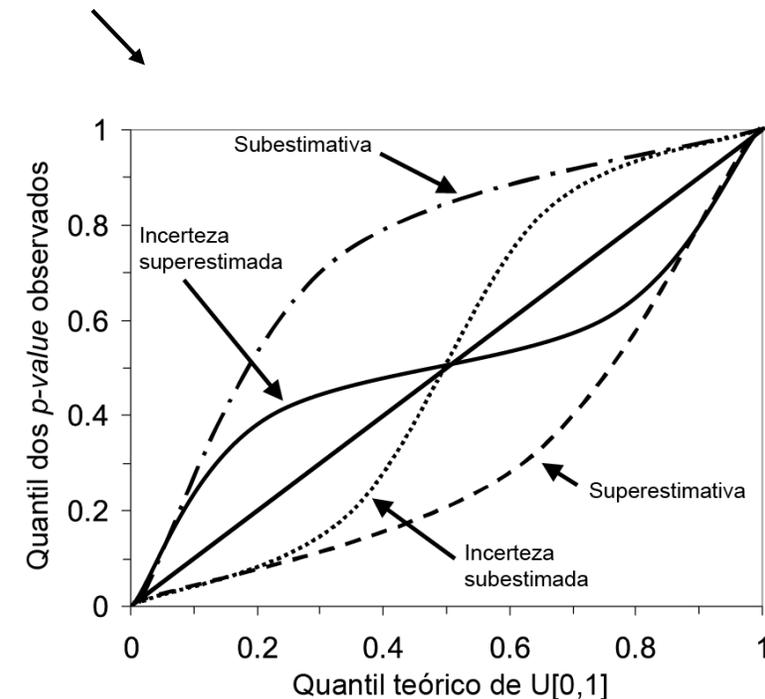
# ANÁLISE DE INCERTEZA

## MÉTRICAS DE AVALIAÇÃO DA QUALIDADE DA FAIXA DE INCERTEZA

$$\textcircled{1} \text{ Confiabilidade}[\hat{\mathbf{y}}, \mathbf{y}] = \frac{2}{n} \sum_{t=1}^n \left| F_U \left[ F_{\hat{y}(t)}(y_t) \right] - F_{\Omega} \left[ F_{\hat{y}(t)}(y_t) \right] \right|$$

$$\textcircled{2} \text{ Precisão}[\hat{\mathbf{y}}, \mathbf{y}] = \frac{1}{n} \sum_{t=1}^n \text{sdev } \hat{y}_t \bigg/ \frac{1}{n} \sum_{t=1}^n y_t$$

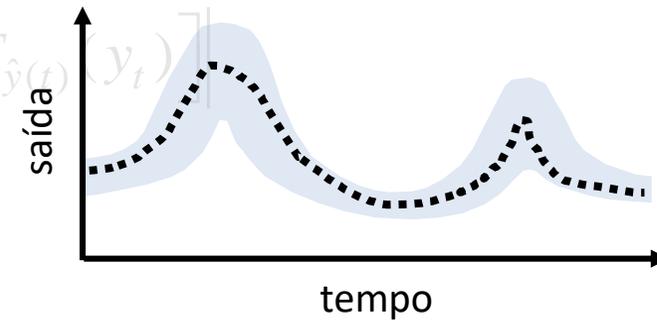
$$\textcircled{3} \text{ Bias}[\hat{\mathbf{y}}, \mathbf{y}] = \left| \frac{\sum_{t=1}^n y_t - \sum_{t=1}^n \hat{y}_{t,\text{mean}}}{\sum_{t=1}^n y_t} \right|$$



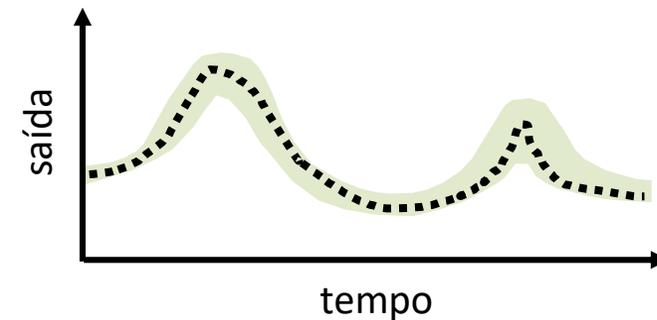
# ANÁLISE DE INCERTEZA

## MÉTRICAS DE AVALIAÇÃO DA QUALIDADE DA FAIXA DE INCERTEZA

$$\textcircled{1} \text{ Confiabilidade}[\hat{y}, \mathbf{y}] = \frac{2}{n} \sum_{t=1}^n \left| F_U [F_{\hat{y}(t)}(y_t)] - F_{\Omega} [F_{\hat{y}(t)}(y_t)] \right|$$



$$\textcircled{2} \text{ Precisão}[\hat{y}, \mathbf{y}] = \frac{1}{n} \sum_{t=1}^n \text{sdev } \hat{y}_t \bigg/ \frac{1}{n} \sum_{t=1}^n y_t$$



$$\textcircled{3} \text{ Bias}[\hat{y}, \mathbf{y}] = \left| \frac{\sum_{t=1}^n y_t - \sum_{t=1}^n \hat{y}_{t, \text{mean}}}{\sum_{t=1}^n y_t} \right|$$

# ANÁLISE DE INCERTEZA

## MÉTRICAS DE AVALIAÇÃO DA QUALIDADE DA FAIXA DE INCERTEZA

$$\textcircled{1} \text{ Confiabilidade}[\hat{\mathbf{y}}, \mathbf{y}] = \frac{2}{n} \sum_{t=1}^n \left| F_U \left[ F_{\hat{y}(t)}(y_t) \right] - F_{\Omega} \left[ F_{\hat{y}(t)}(y_t) \right] \right|$$

$$\textcircled{2} \text{ Precisão}[\hat{\mathbf{y}}, \mathbf{y}] = \frac{1}{n} \sum_{t=1}^n \text{sdev } \hat{y}_t \bigg/ \frac{1}{n} \sum_{t=1}^n y_t$$

$$\textcircled{3} \text{ Bias}[\hat{\mathbf{y}}, \mathbf{y}] = \left| \frac{\sum_{t=1}^n y_t - \sum_{t=1}^n \hat{y}_{t,\text{mean}}}{\sum_{t=1}^n y_t} \right|$$

# COMPARAÇÃO ENTRE MODELOS

## CRITÉRIOS DE INFORMAÇÃO

Medem a perda de informação que ocorre ao se utilizar o modelo para descrever a resposta do sistema ao invés dos dados observados

$$I_k = -2\ln(L^*) + \psi$$

↓  
Termo relacionado ao  
ajuste do modelo aos dados

↓  
Termo que penaliza  
a complexidade

Critério de informação de Akaike

$$\psi = 2k$$

Critério de informação Bayesiano

$$\psi = k \ln n$$

# COMPARAÇÃO ENTRE MODELOS

## CRITÉRIOS DE INFORMAÇÃO

Medem a perda de informação que ocorre ao se utilizar o modelo para descrever a resposta do sistema ao invés dos dados observados

$$I_k = -2\ln(L^*) + \psi$$

↓  
Termo relacionado ao  
ajuste do modelo aos dados

↓  
Termo que penaliza  
a complexidade

É UMA MEDIDA  
RELATIVA!

Critério de informação de Akaike

$$\psi = 2k$$

Critério de informação Bayesiano

$$\psi = k \ln n$$

# RESULTADOS E DISCUSSÃO

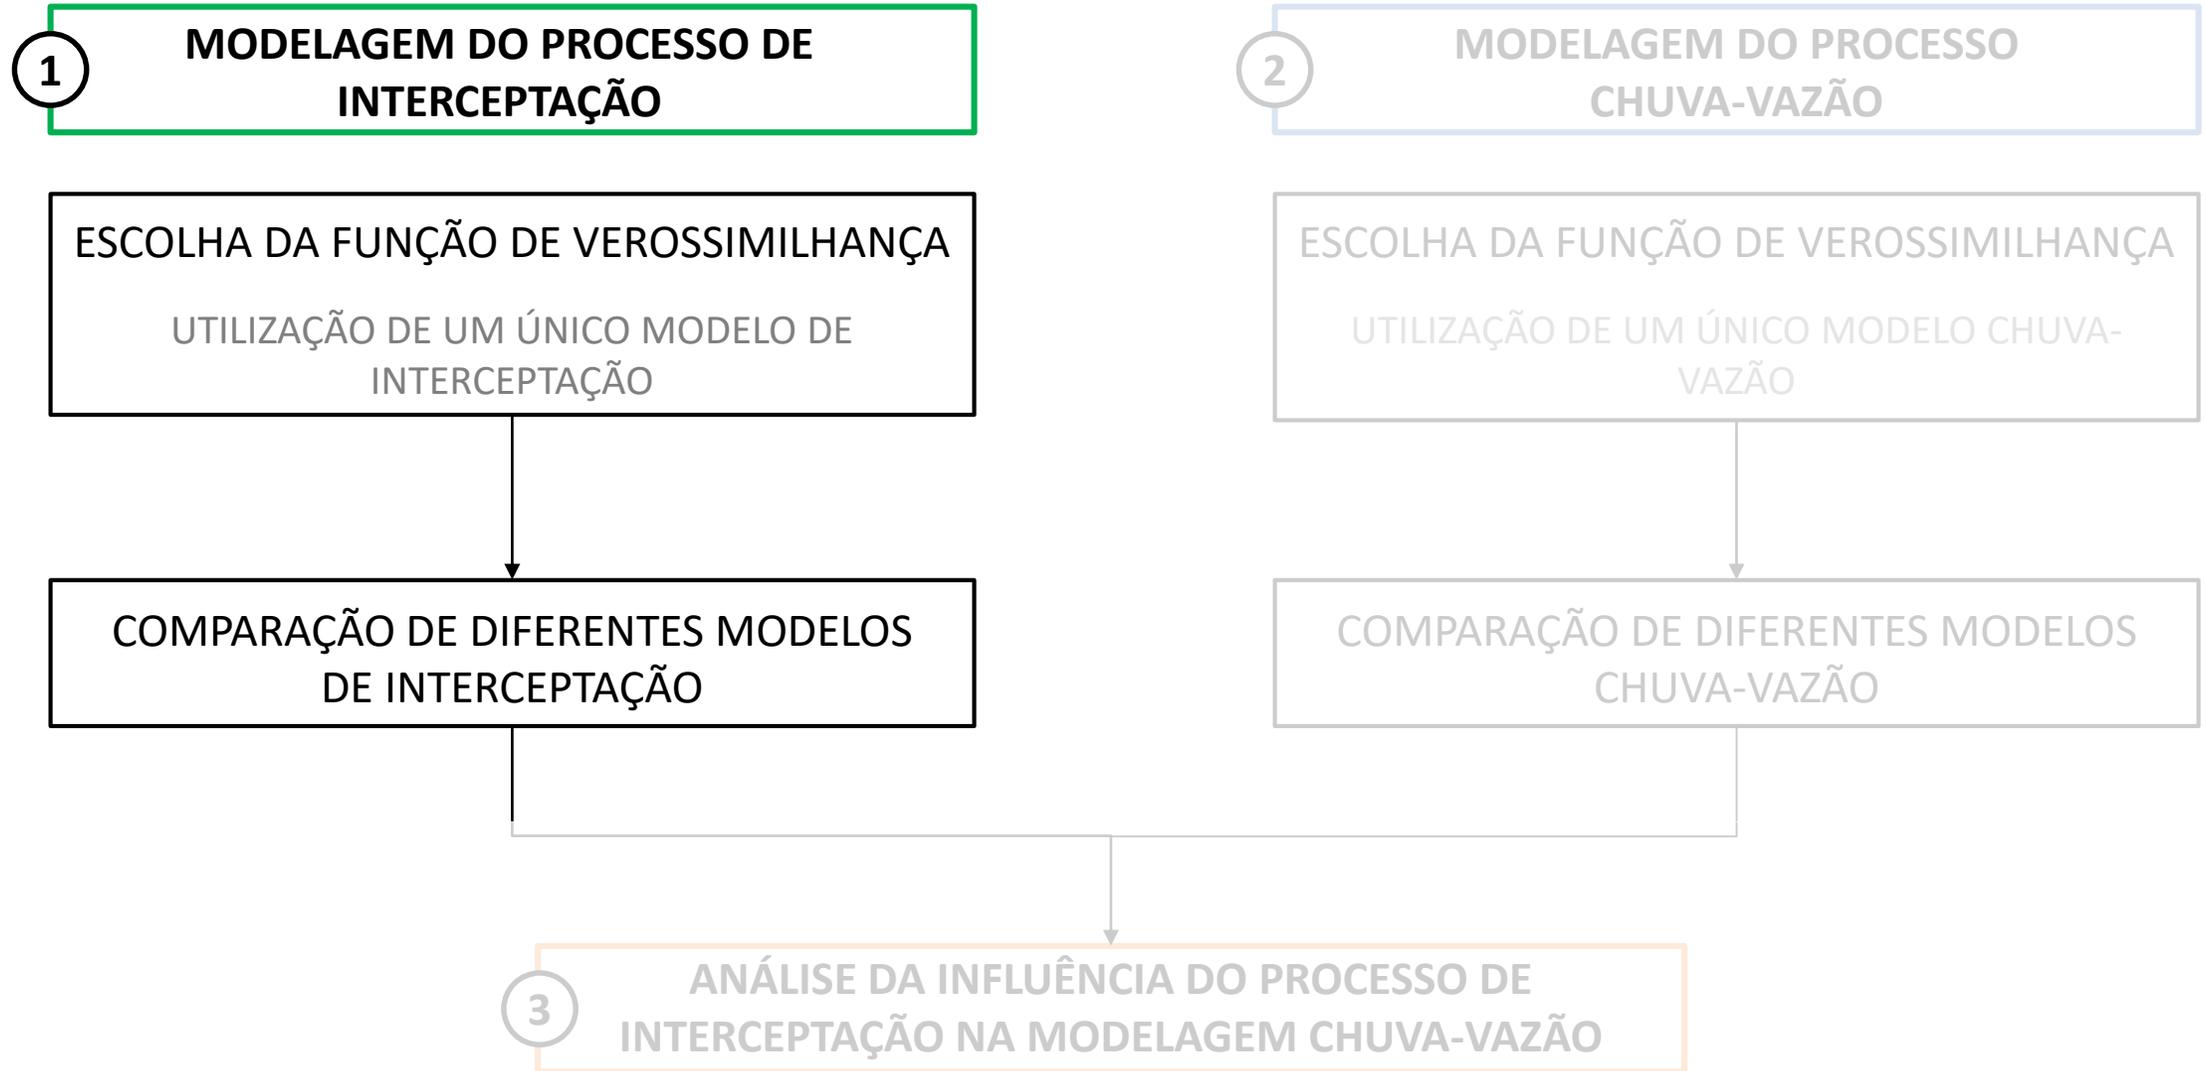
---

# 1. INTERCEPTAÇÃO

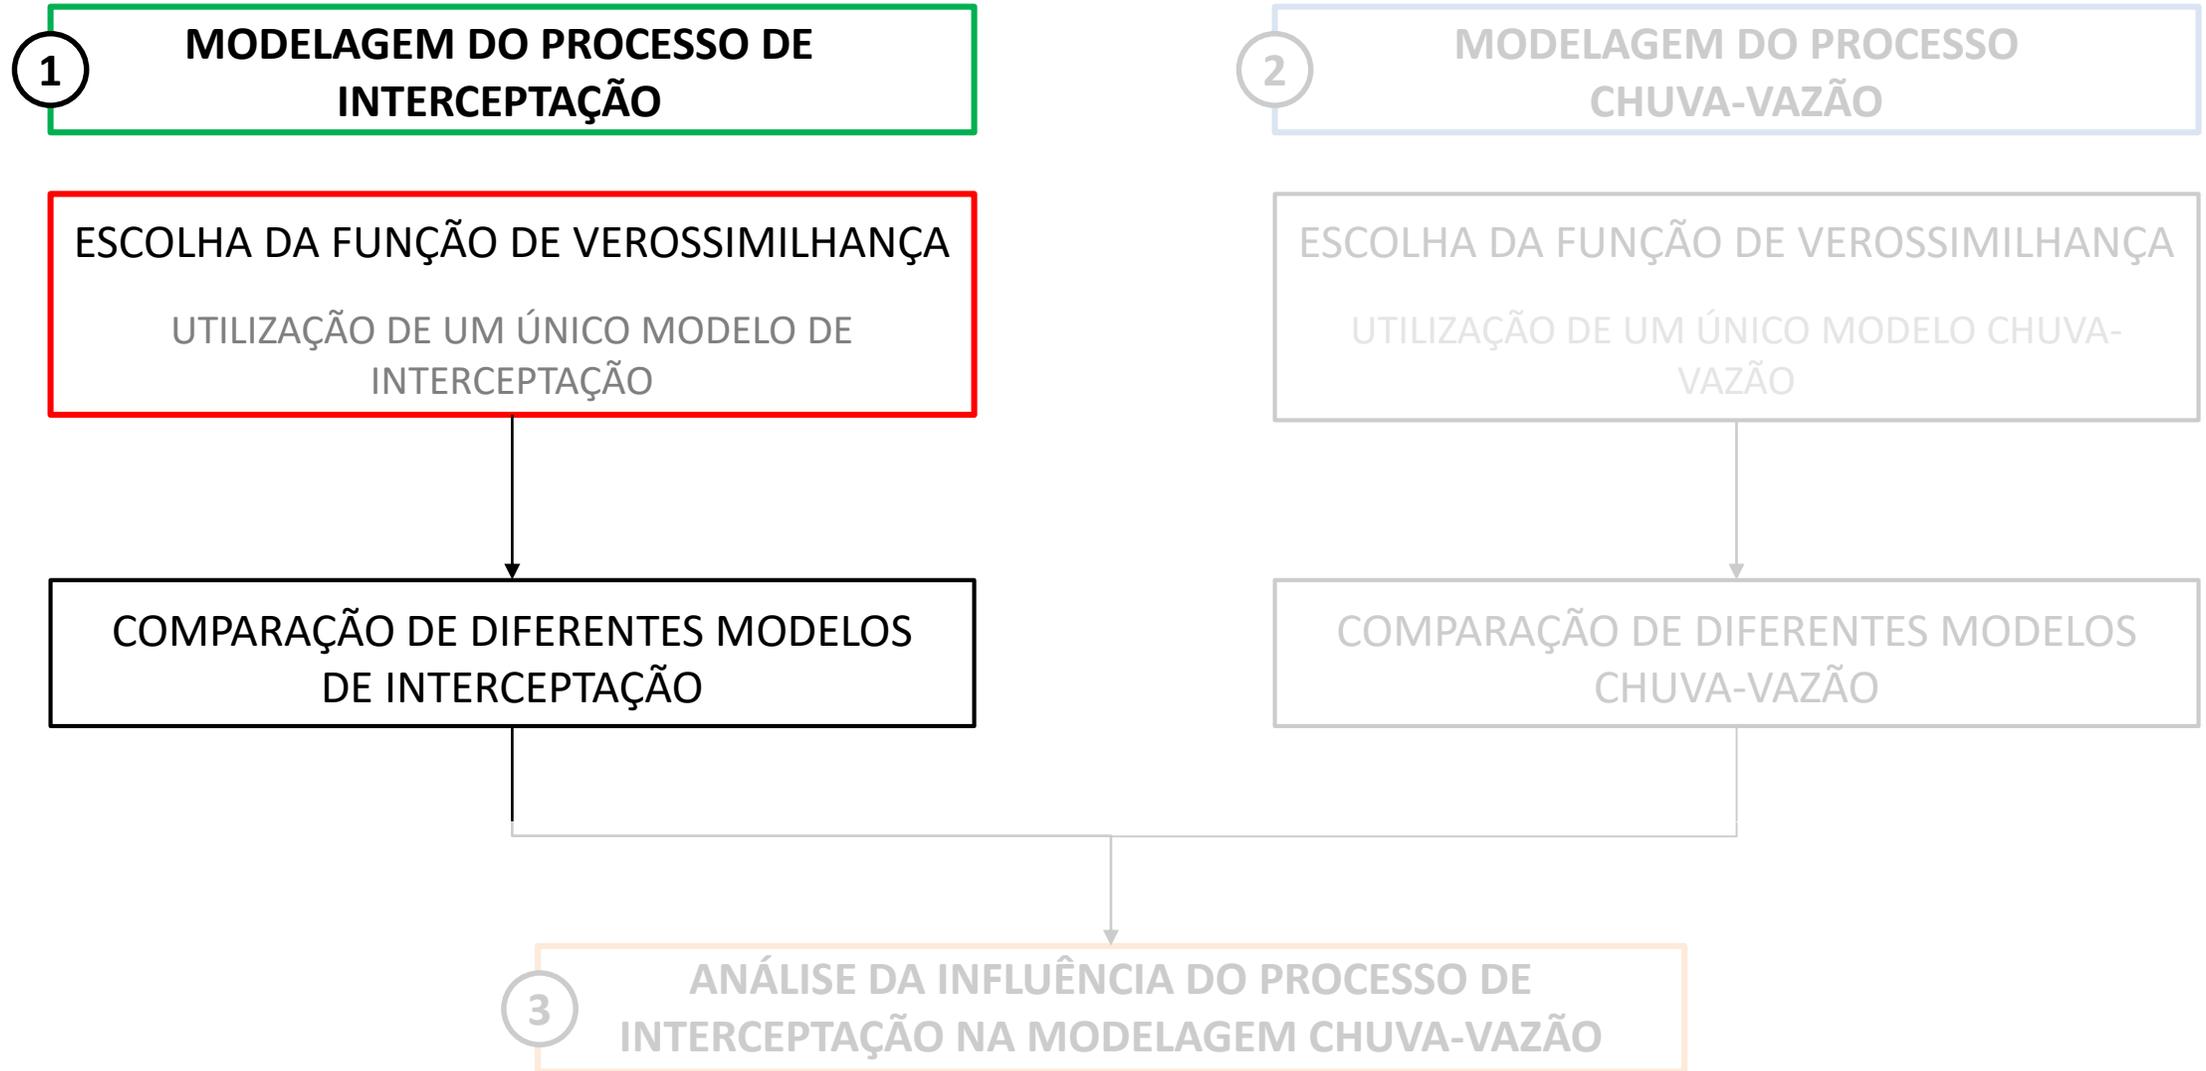
---

RESULTADOS E DISCUSSÃO

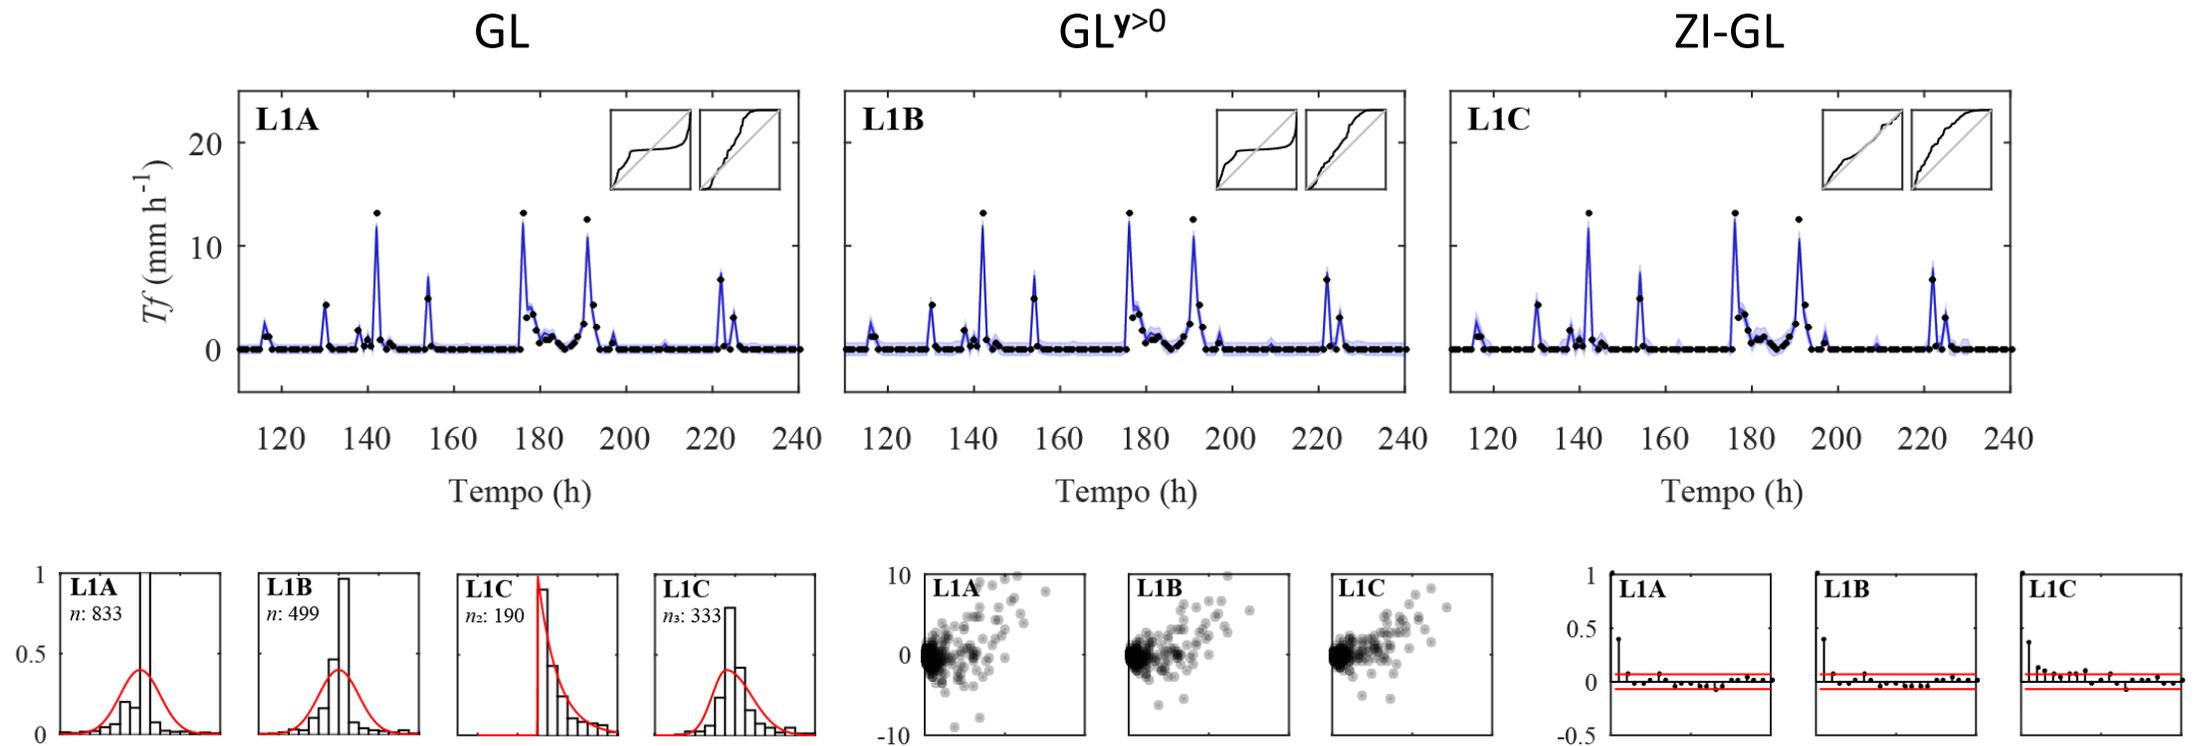
# FLUXOGRAMA



# FLUXOGRAMA

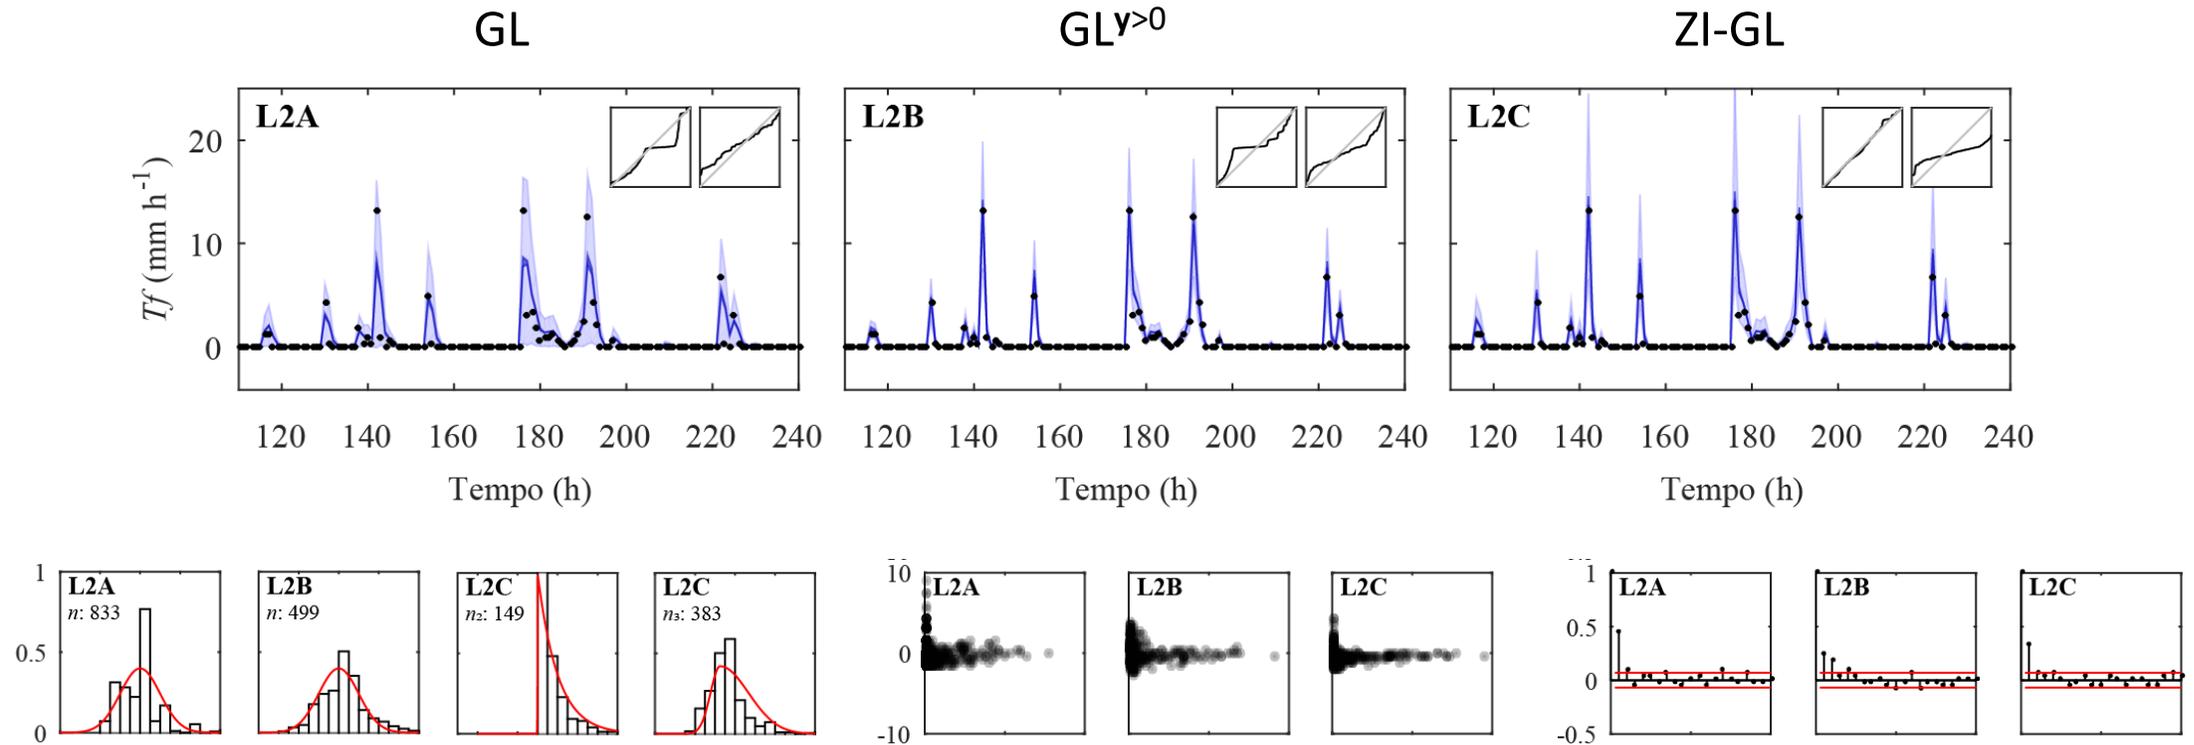


## ESCOLHA DA FUNÇÃO DE VEROSSIMILHANÇA



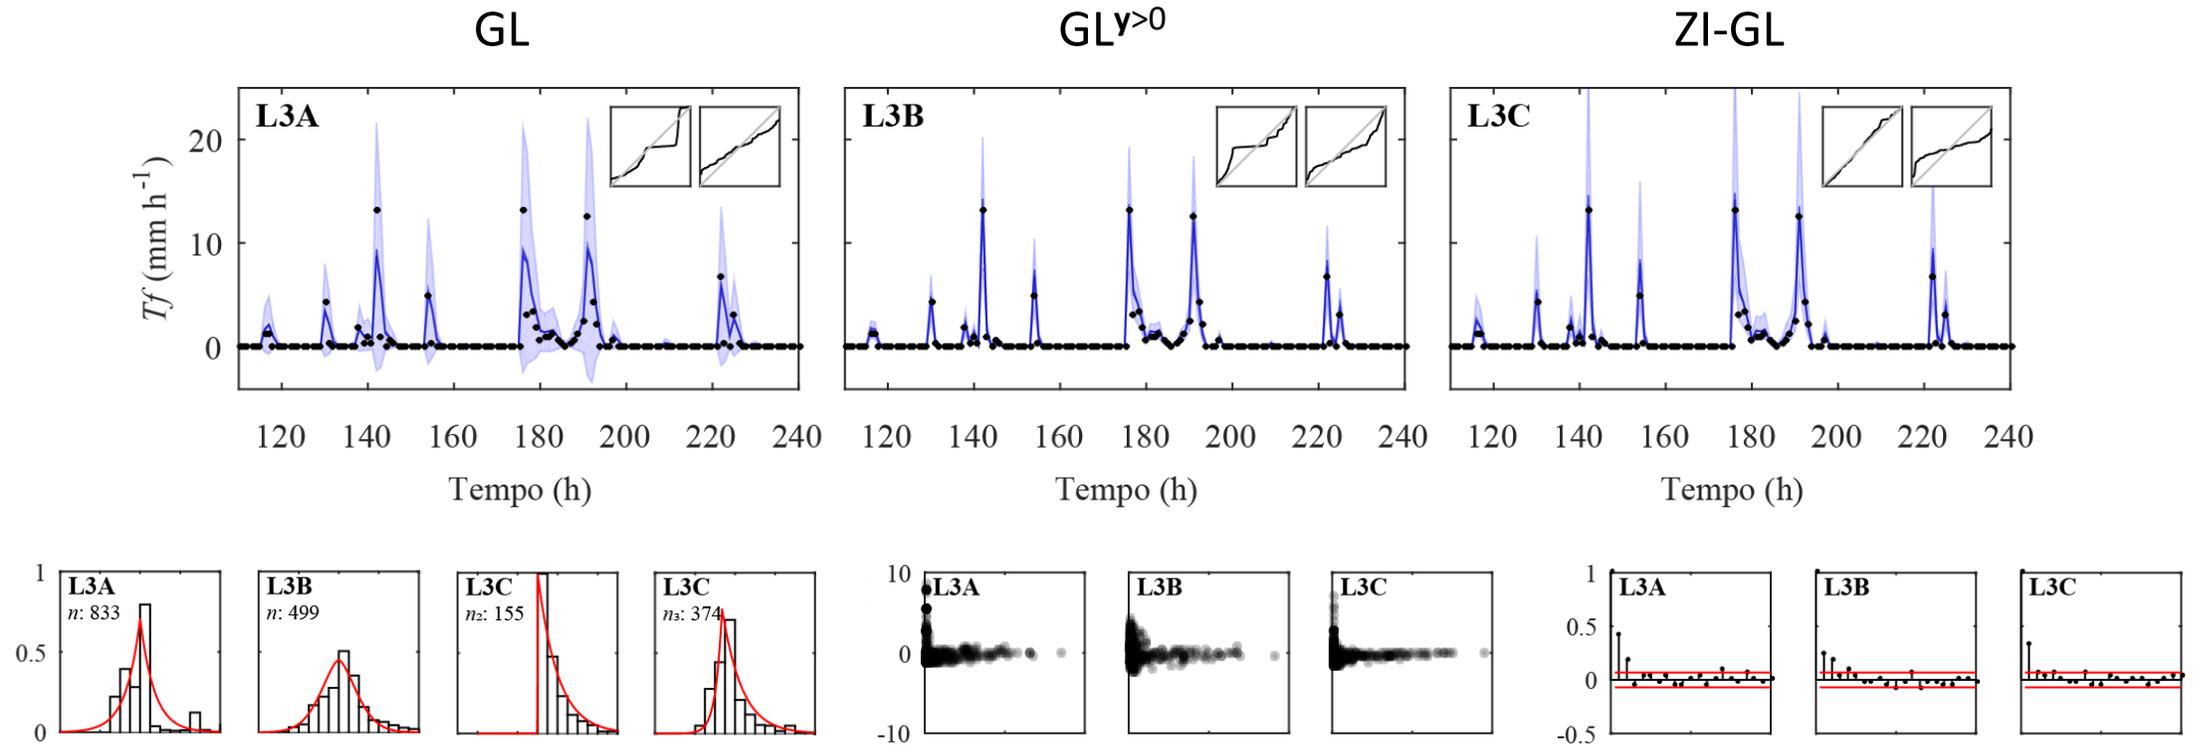
## HOMOSCEDASTICIDADE

## ESCOLHA DA FUNÇÃO DE VEROSSIMILHANÇA



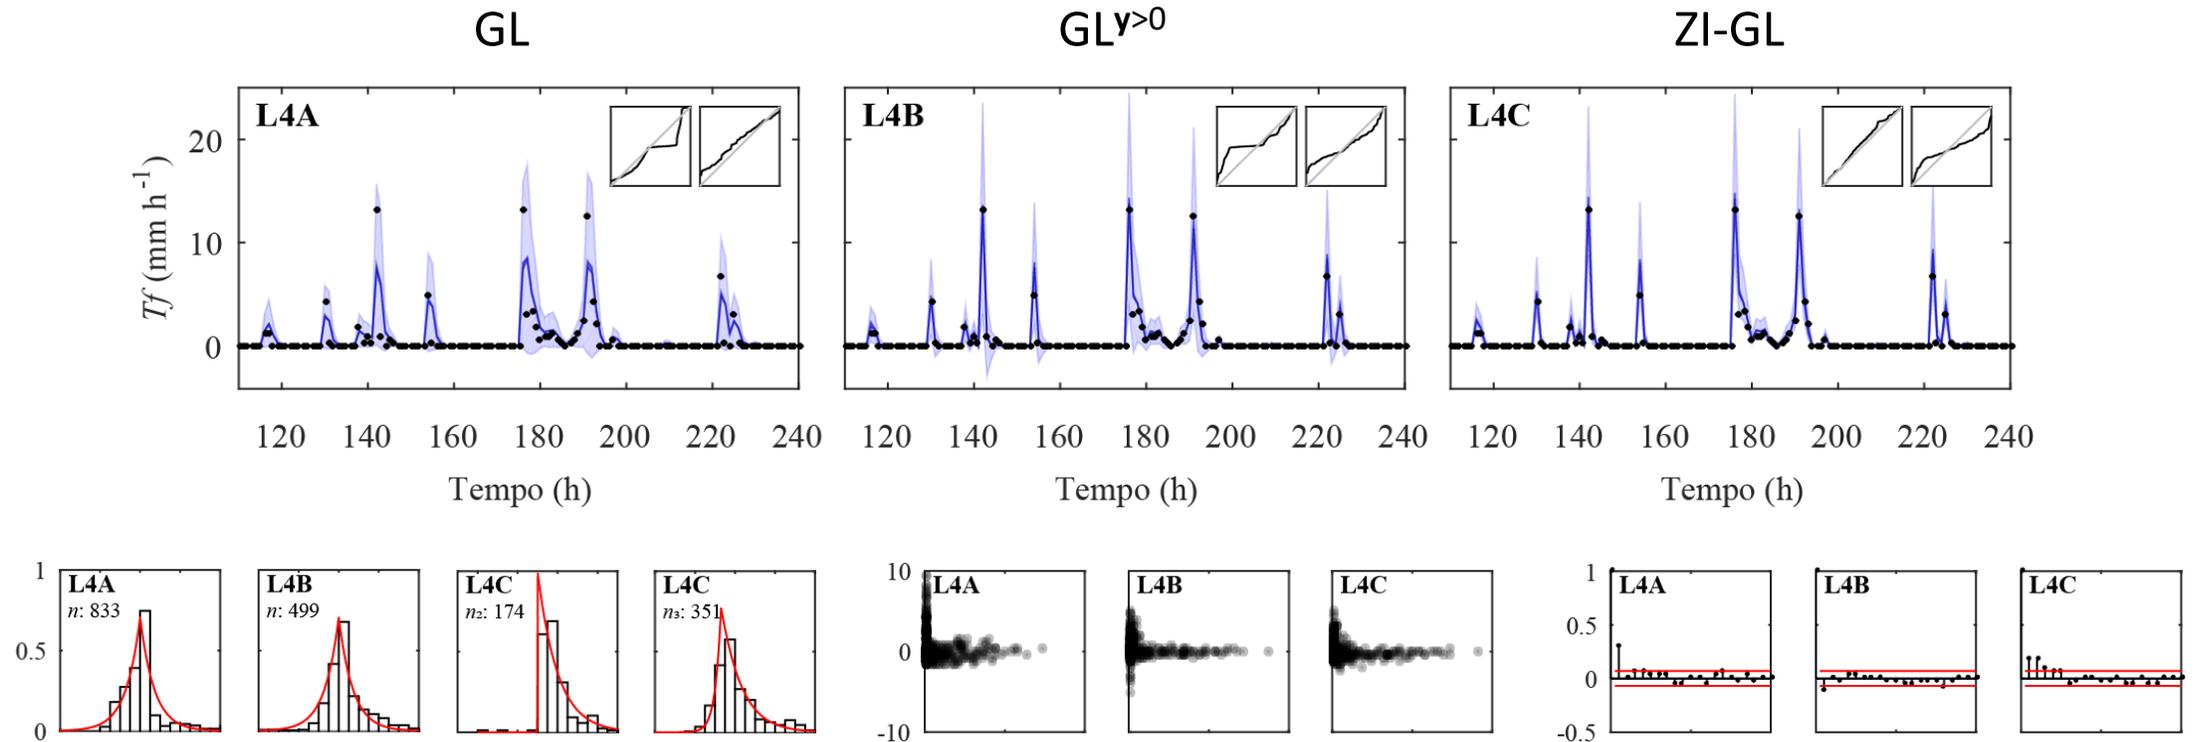
## HETEROSCEDASTICIDADE

## ESCOLHA DA FUNÇÃO DE VEROSSIMILHANÇA



## HETEROSCEDASTICIDADE + CURTOSE

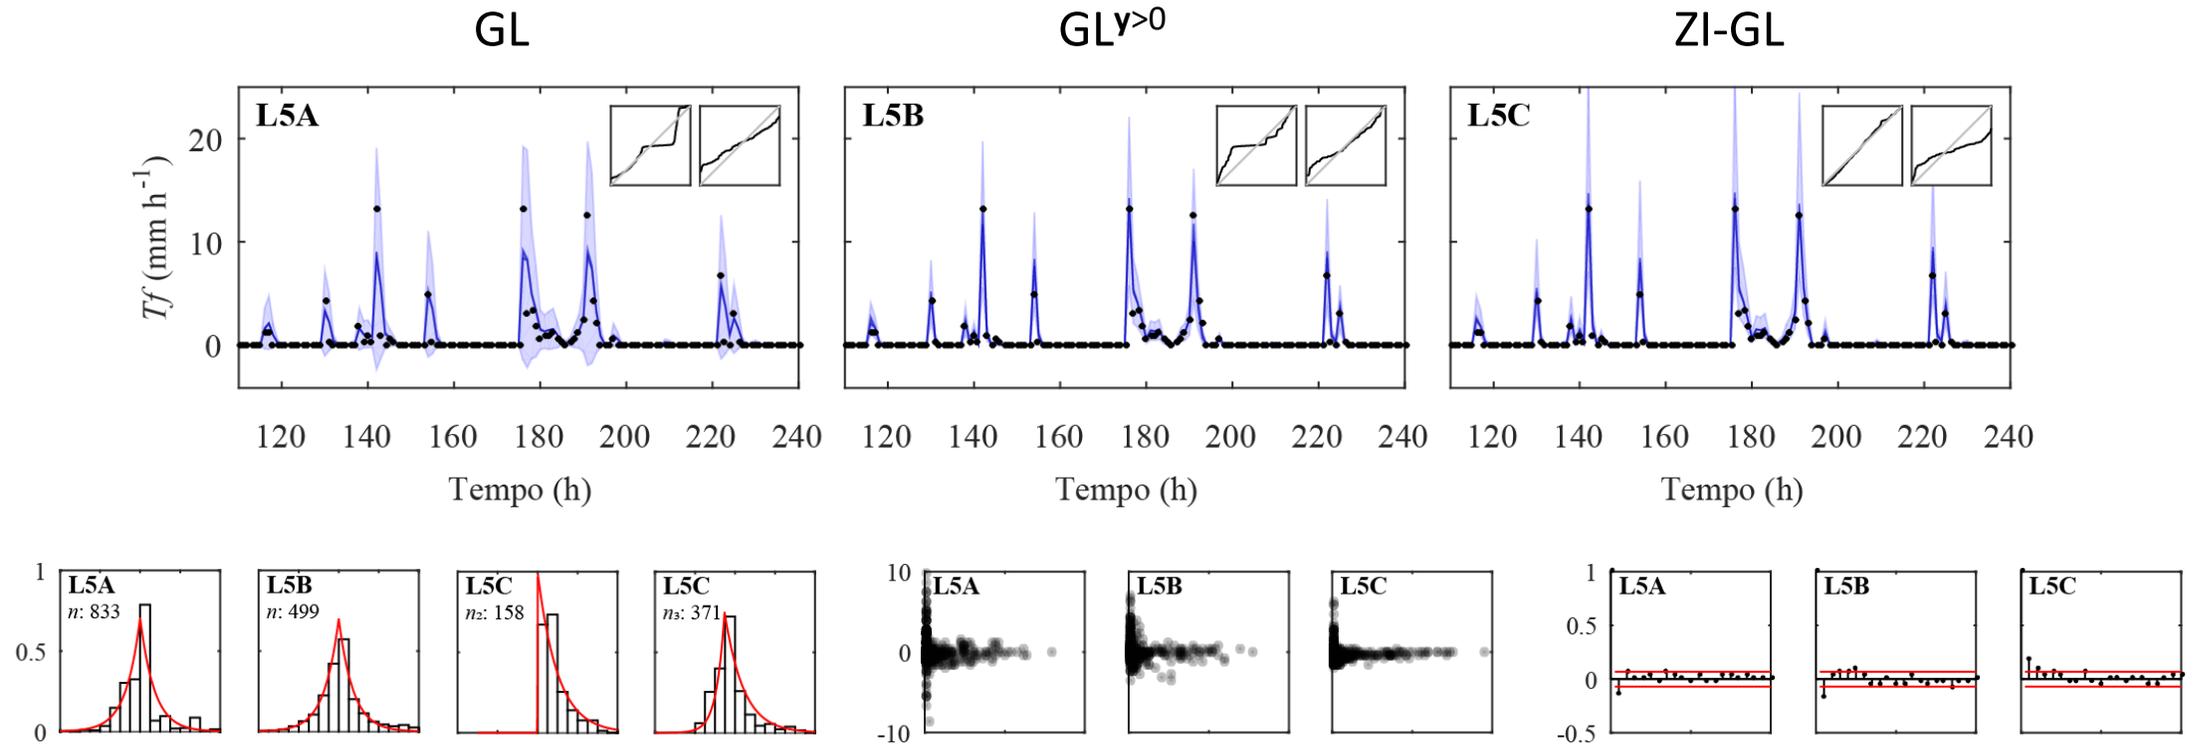
## ESCOLHA DA FUNÇÃO DE VEROSSIMILHANÇA



## HETEROSCEDASTICIDADE + CURTOSE + AUTOCORRELAÇÃO

# INTERCEPTAÇÃO

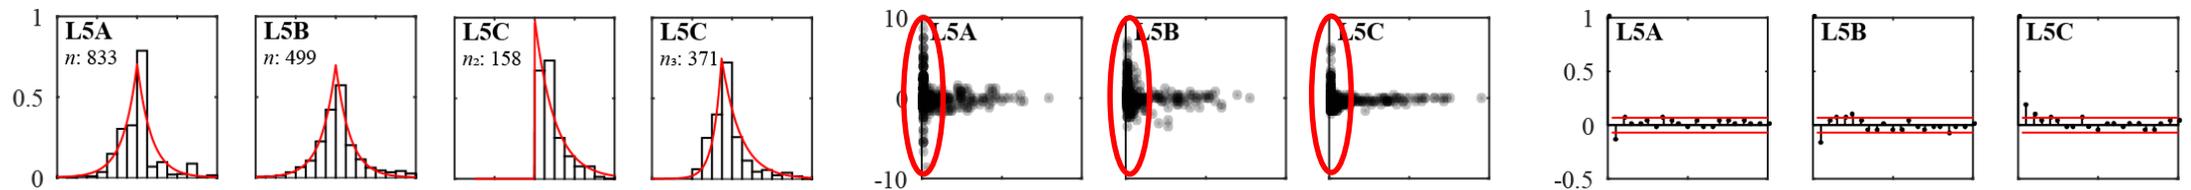
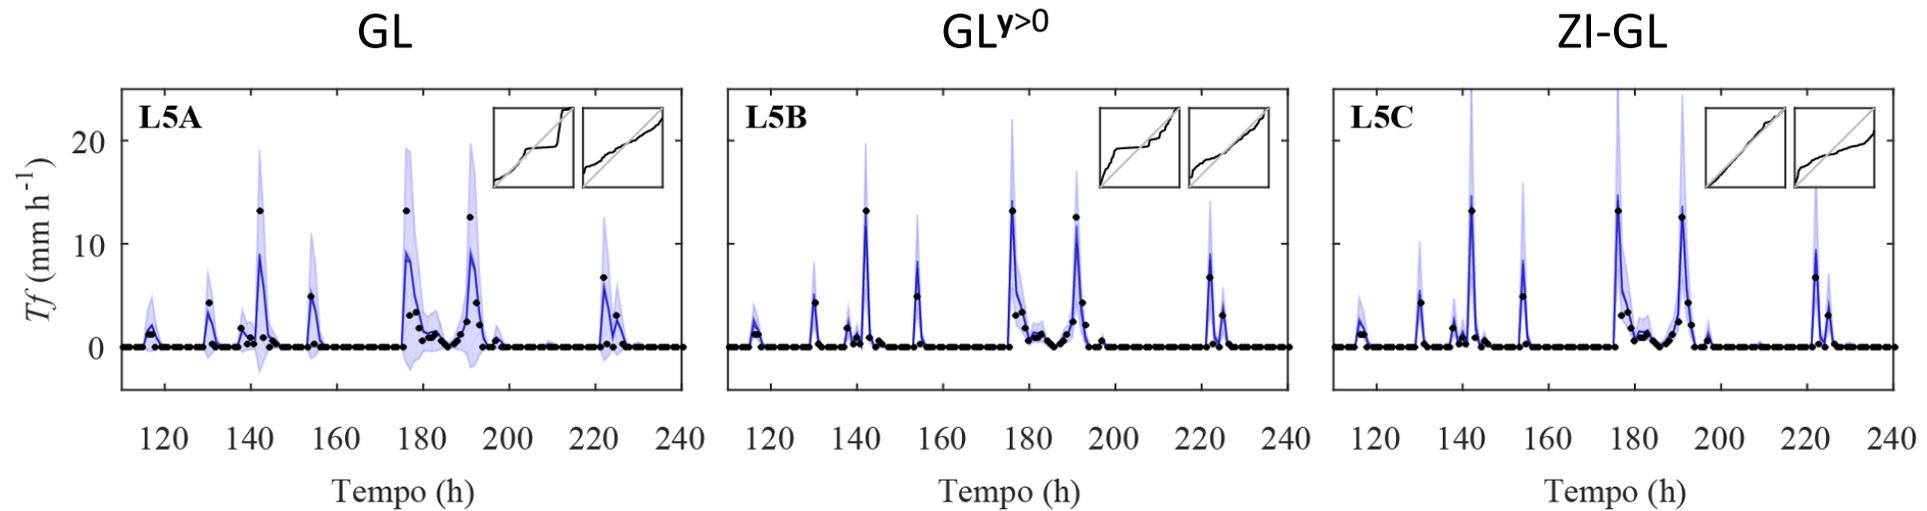
## ESCOLHA DA FUNÇÃO DE VEROSSIMILHANÇA



## HETEROSCEDASTICIDADE + CURTOSE + AUTOCORRELAÇÃO

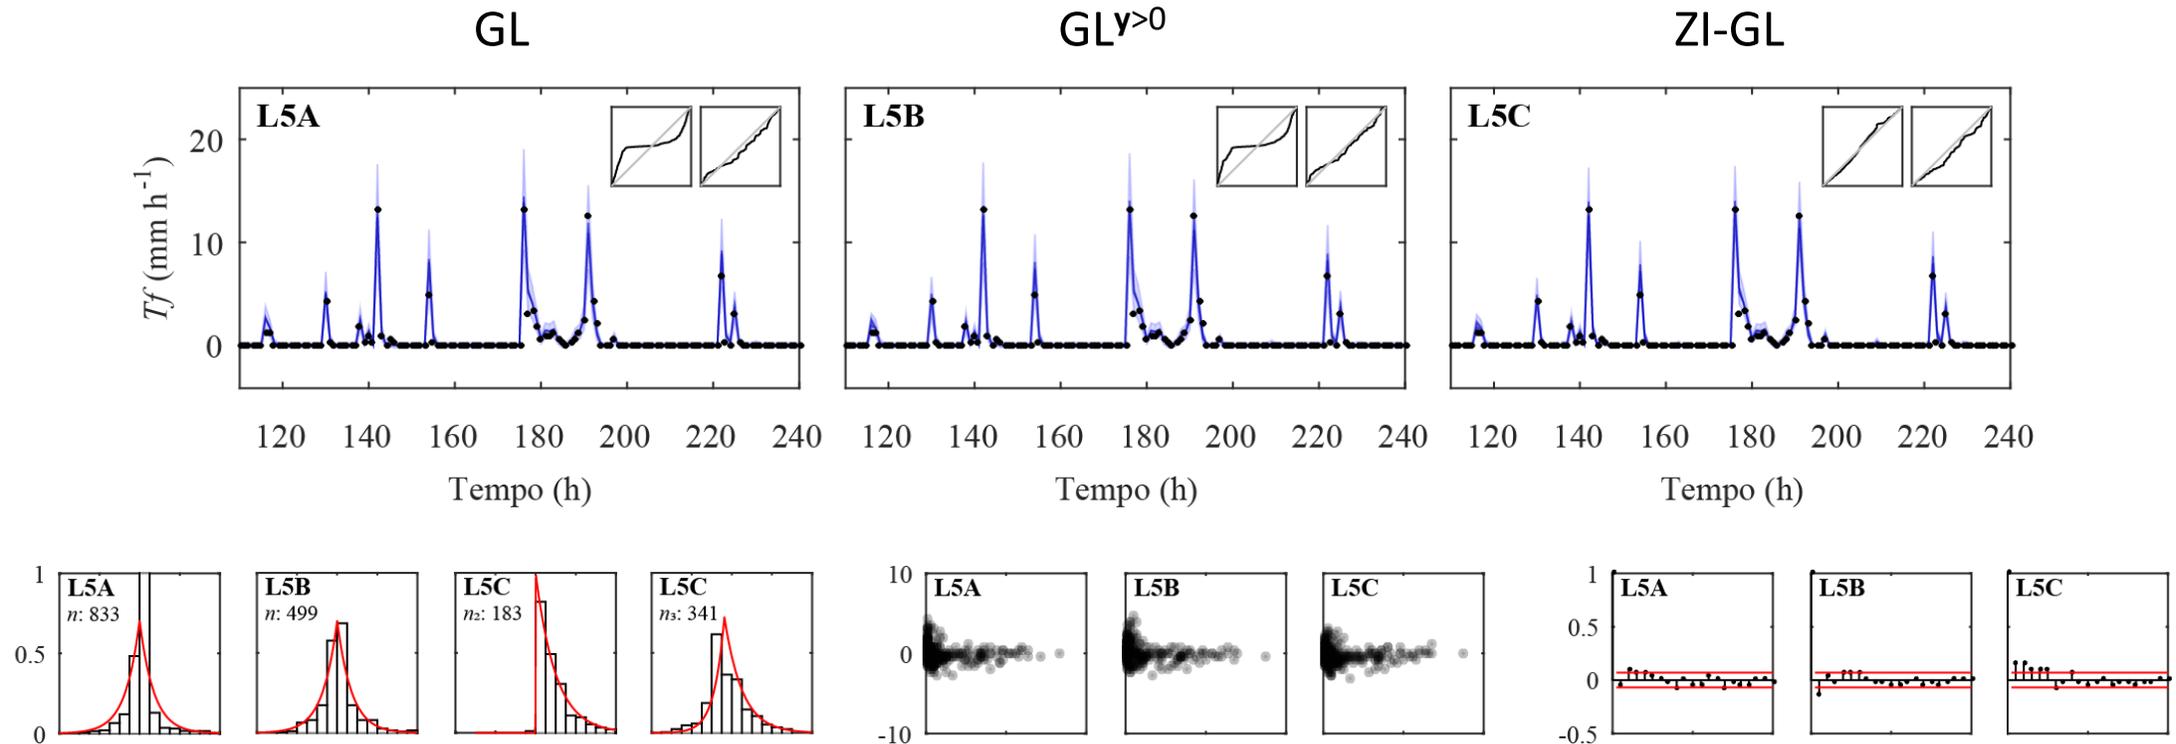
# INTERCEPTAÇÃO

## ESCOLHA DA FUNÇÃO DE VEROSSIMILHANÇA



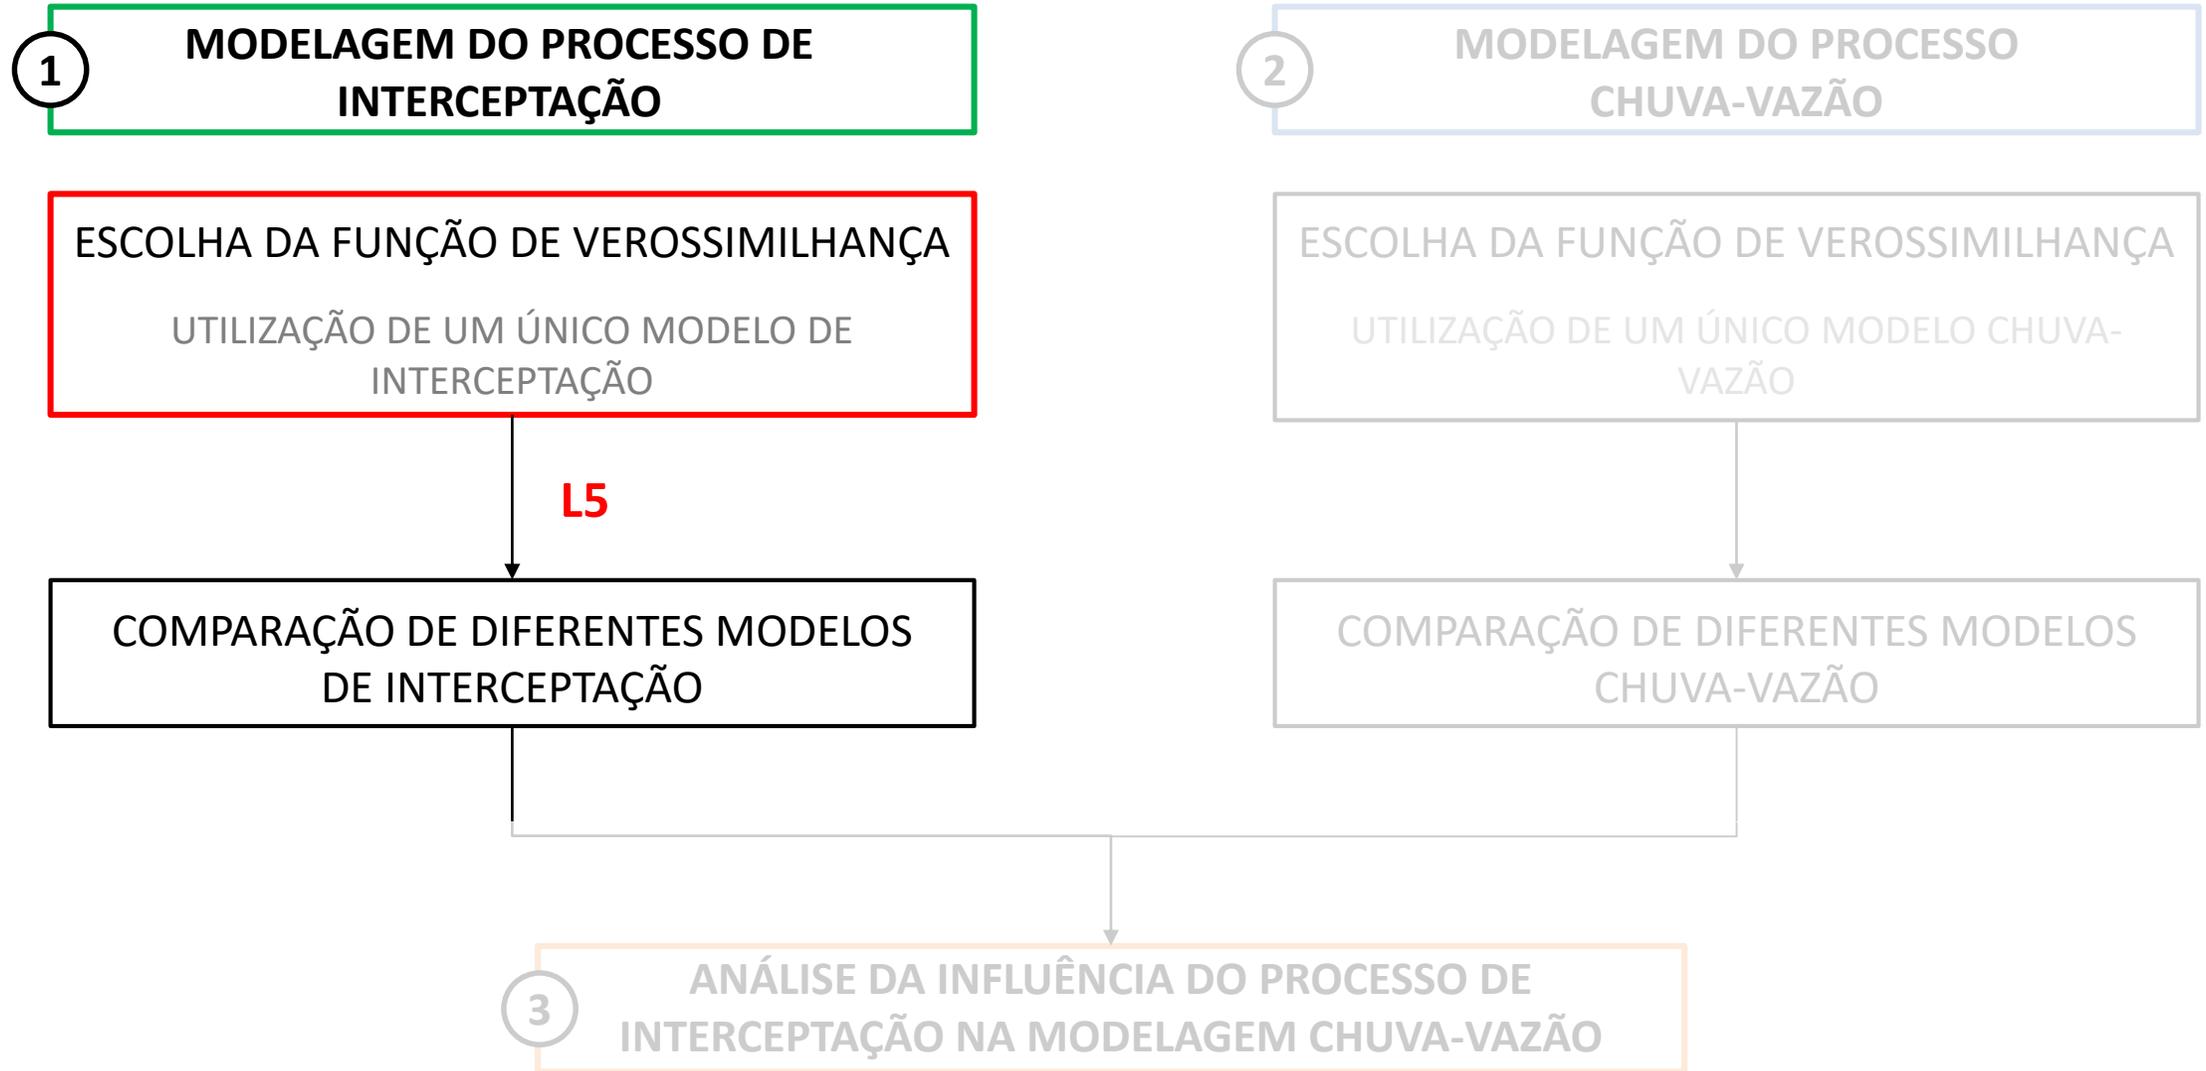
## HETEROSCEDASTICIDADE + CURTOSE + AUTOCORRELAÇÃO

## ESCOLHA DA FUNÇÃO DE VEROSSIMILHANÇA

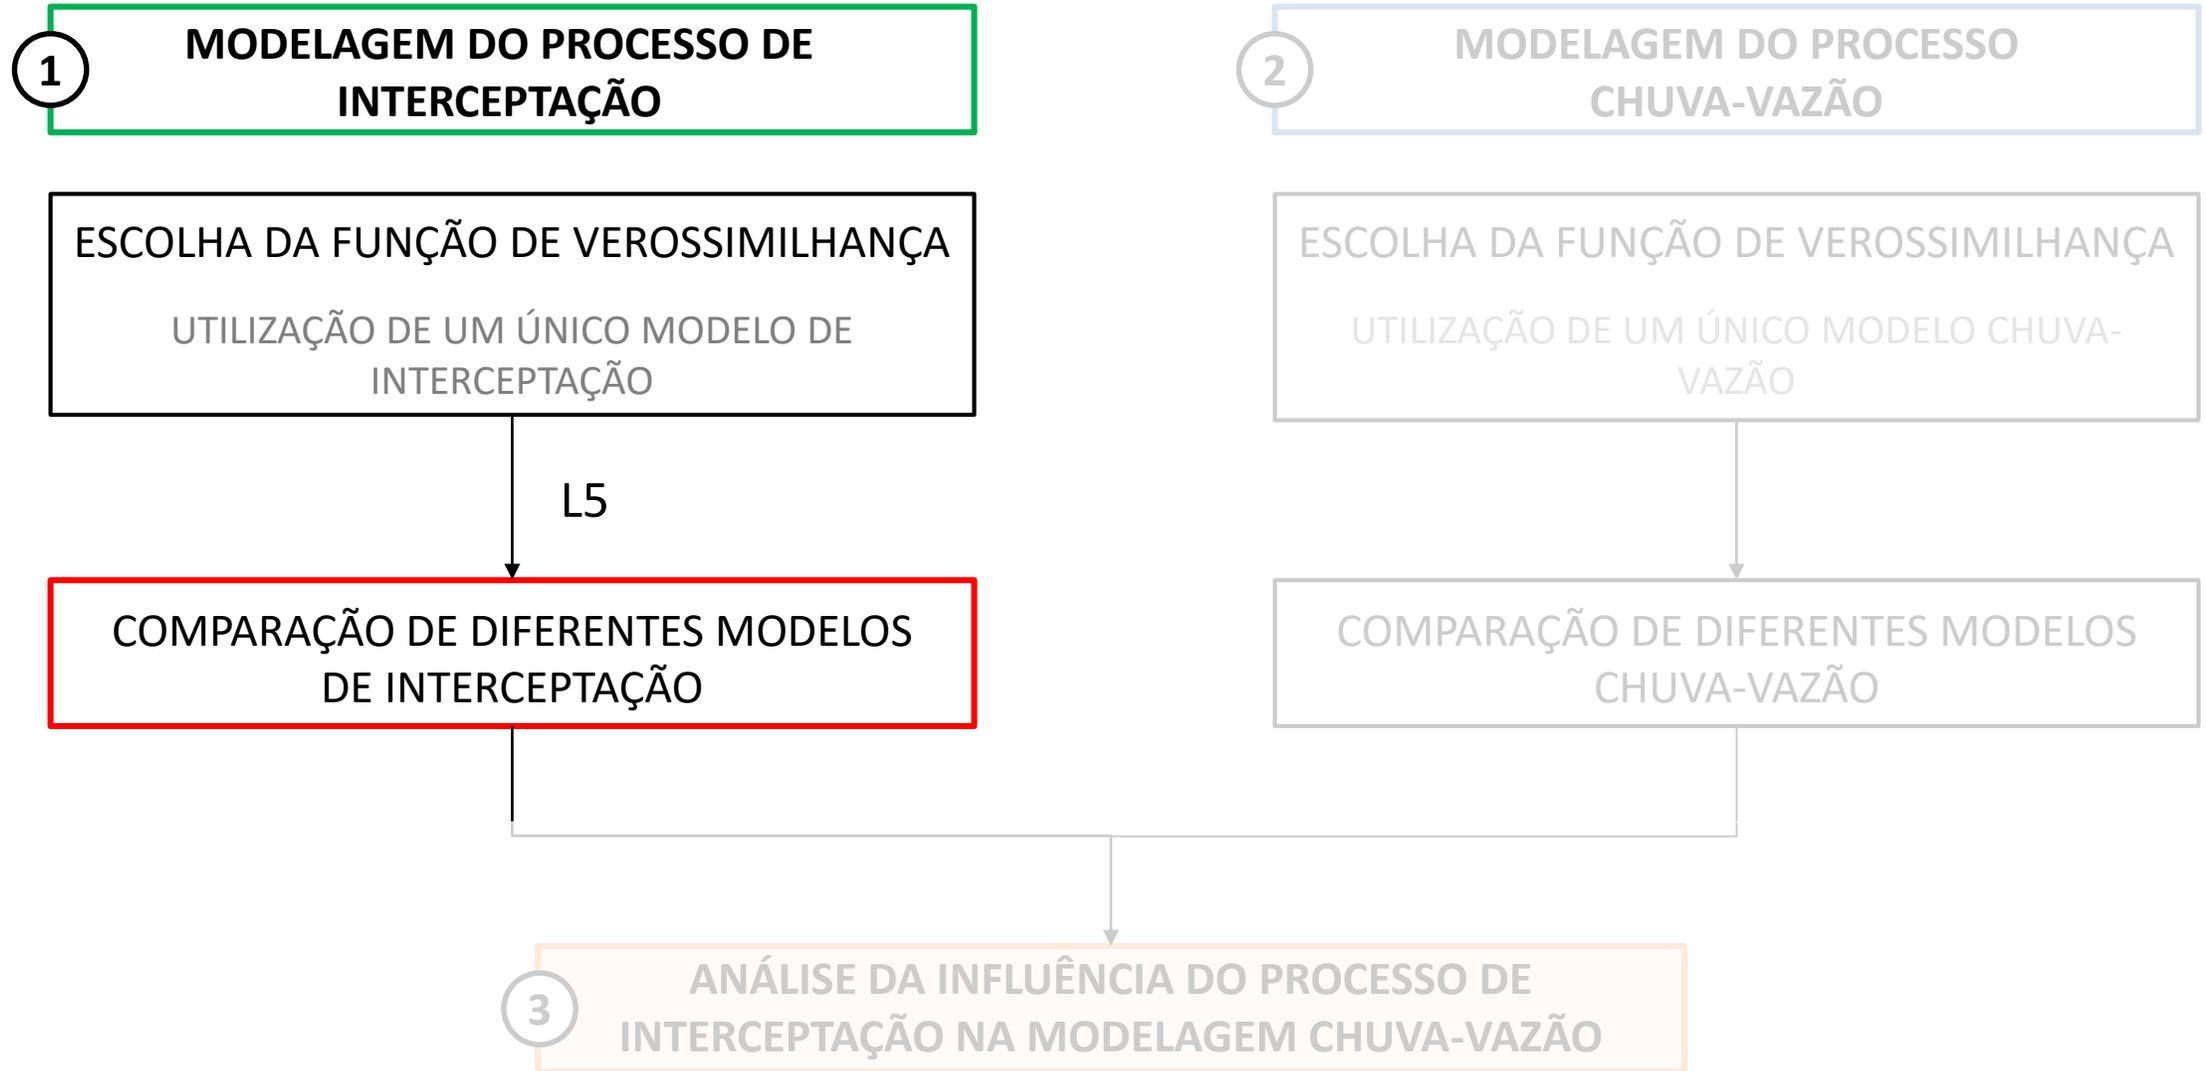


HETEROSCEDASTICIDADE + CURTOSE + AUTOCORRELAÇÃO +  $\sigma_0 = 0,12 \text{ mm h}^{-1}$

# FLUXOGRAMA



# FLUXOGRAMA



# INTERCEPTAÇÃO

## COMPARAÇÃO ENTRE MODELOS: REFLORESTAMENTO DE PINUS

Calibração

	P	B	C	$C^{y<2}$	$C^{y>2}$
S1	0.57	0.11	0.05	0.07	0.62
S2D1	0.71	0.26	0.03	0.03	0.22
S3D1	0.54	0.05	0.04	0.05	0.19
S4D1	0.52	0.04	0.04	0.05	0.21
S2D2	0.84	0.34	0.06	0.06	0.22
S3D2	0.62	0.19	0.07	0.07	0.13
S4D2	0.61	0.18	0.05	0.06	0.11

Validação

	P	B	C	$C^{y<2}$	$C^{y>2}$
S1	0.48	0.22	0.05	0.02	0.65
S2D1	0.62	0.14	0.05	0.05	0.27
S3D1	0.47	0.03	0.02	0.03	0.25
S4D1	0.46	0.04	0.03	0.04	0.26
S2D2	0.74	0.20	0.05	0.04	0.24
S3D2	0.55	0.09	0.03	0.03	0.14
S4D2	0.54	0.08	0.02	0.03	0.12

Formulação	$\ln L$	$k$	$n$	BIC		AIC	
				$\psi(k \ln n)$	$I_k$	$\psi(2k)$	$I_k$
<b>L1 na formulação GL</b>							
S1	-2045	3	533	8	4099	6	4097
S2D1	-2016	4	533	11	4043	8	4040
S3D1	-1956	5	533	14	3926	10	3922
S4D1	-1956	5	533	14	3926	10	3923
S2D2	-2045	4	533	11	4101	8	4098
S3D2	-1973	5	533	14	3959	10	3955
S4D2	-1973	5	533	14	3959	10	3955
<b>L5 na formulação ZI-GL</b>							
S1	-865	7	533	19	1749	14	1744
S2D1	-884	8	533	22	1790	16	1784
S3D1	-840	9	533	25	1704	18	1697
S4D1	-839	9	533	25	1703	18	1697
S2D2	-841	8	533	22	1703	16	1697
S3D2	-835	9	533	25	1695	18	1688
S4D2	-836	9	533	25	1696	18	1689

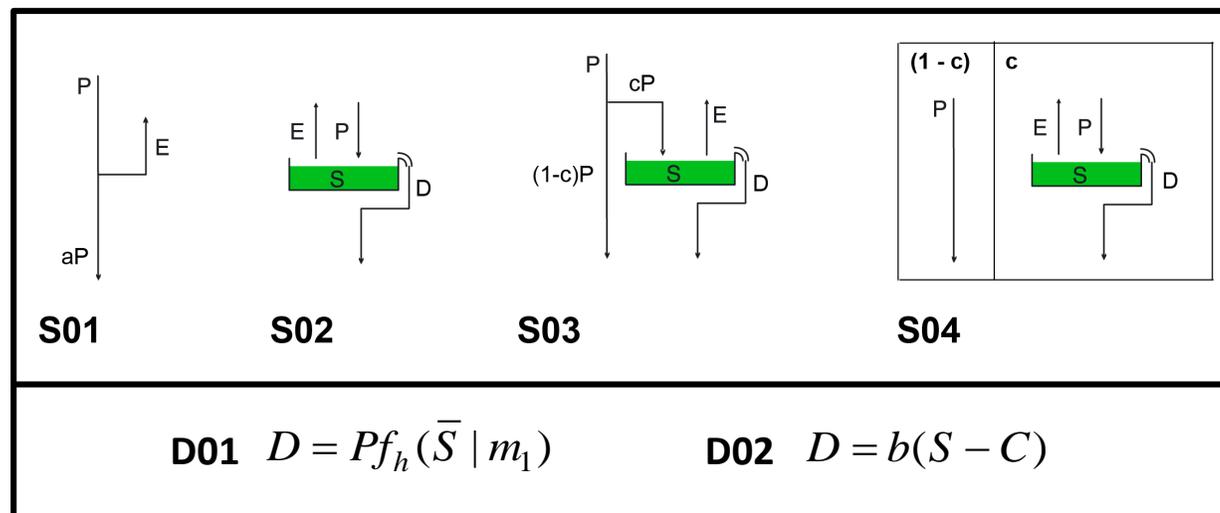
## COMPARAÇÃO ENTRE MODELOS: REFLORESTAMENTO DE PINUS

Calibração

S1	0.57	0.11	0.05	0.07	0.62
S2D1	0.71	0.26	0.03	0.03	0.22
S3D1	0.54	0.05	0.04	0.05	0.19
S4D1	0.52	0.04	0.04	0.05	0.21
S2D2	0.84	0.34	0.06	0.06	0.22
S3D2	0.62	0.19	0.07	0.07	0.13
S4D2	0.61	0.18	0.05	0.06	0.11
	P	B	C	$C^{y<2}$	$C^{y>2}$

Validação

S1	0.48	0.22	0.05	0.02	0.65
S2D1	0.62	0.14	0.05	0.05	0.27
S3D1	0.47	0.03	0.02	0.03	0.25
S4D1	0.46	0.04	0.03	0.04	0.26
S2D2	0.74	0.20	0.05	0.04	0.24
S3D2	0.55	0.09	0.03	0.03	0.14
S4D2	0.54	0.08	0.02	0.03	0.12
	P	B	C	$C^{y<2}$	$C^{y>2}$



### L5 na formulação ZI-GL

S1	-865	7	533	19	1749	14	1744
S2D1	-884	8	533	22	1790	16	1784
S3D1	-840	9	533	25	1704	18	1697
S4D1	-839	9	533	25	1703	18	1697
S2D2	-841	8	533	22	1703	16	1697
S3D2	-835	9	533	25	1695	18	1688
S4D2	-836	9	533	25	1696	18	1689

# INTERCEPTAÇÃO

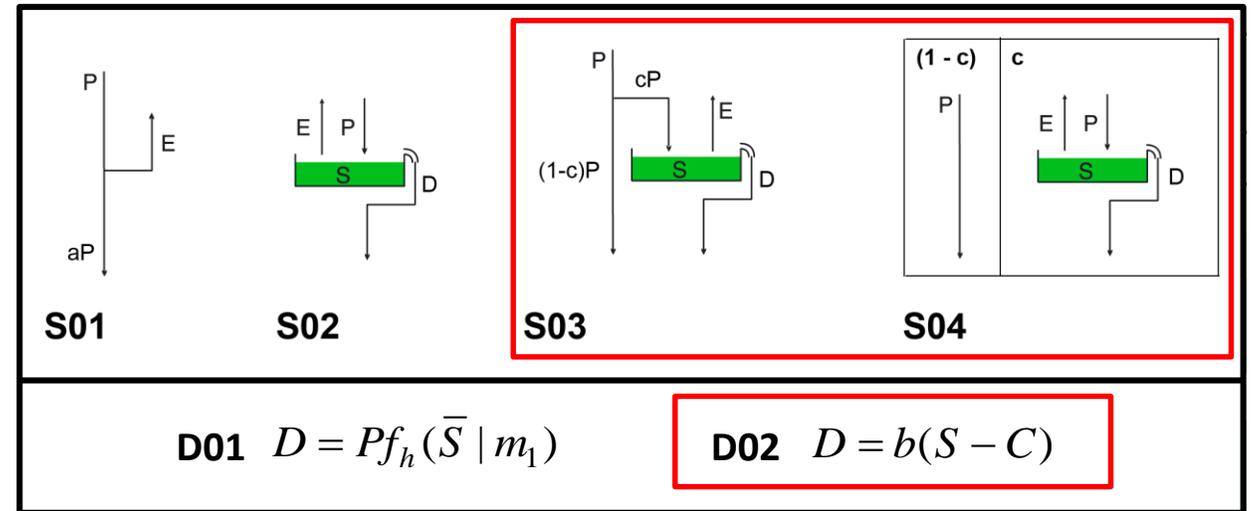
## COMPARAÇÃO ENTRE MODELOS: REFLORESTAMENTO DE PINUS

Calibração

S1	0.57	0.11	0.05	0.07	0.62
S2D1	0.71	0.26	0.03	0.03	0.22
S3D1	0.54	0.05	0.04	0.05	0.19
S4D1	0.52	0.04	0.04	0.05	0.21
S2D2	0.84	0.34	0.06	0.06	0.22
S3D2	0.62	0.19	0.07	0.07	0.13
S4D2	0.61	0.18	0.05	0.06	0.11
	P	B	C	$C^{y<2}$	$C^{y>2}$

Validação

S1	0.48	0.22	0.05	0.02	0.65
S2D1	0.62	0.14	0.05	0.05	0.27
S3D1	0.47	0.03	0.02	0.03	0.25
S4D1	0.46	0.04	0.03	0.04	0.26
S2D2	0.74	0.20	0.05	0.04	0.24
S3D2	0.55	0.09	0.03	0.03	0.14
S4D2	0.54	0.08	0.02	0.03	0.12
	P	B	C	$C^{y<2}$	$C^{y>2}$



L5 na formulação ZI-GL

S1	-865	7	533	19	1749	14	1744
S2D1	-884	8	533	22	1790	16	1784
S3D1	-840	9	533	25	1704	18	1697
S4D1	-839	9	533	25	1703	18	1697
S2D2	-841	8	533	22	1703	16	1697
S3D2	-835	9	533	25	1695	18	1688
S4D2	-836	9	533	25	1696	18	1689

# INTERCEPTAÇÃO

## COMPARAÇÃO ENTRE MODELOS: FLORESTA NATIVA

Calibração

	P	B	C	$C^{y<2}$	$C^{y>2}$
S1	0.38	0.05	0.02	0.05	0.35
S2D1	0.57	0.28	0.04	0.04	0.37
S3D1	0.44	0.18	0.04	0.03	0.32
S4D1	0.45	0.20	0.06	0.04	0.34
S2D2	0.49	0.29	0.05	0.02	0.45
S3D2	0.42	0.22	0.06	0.04	0.44
S4D2	0.42	0.22	0.06	0.03	0.44

Validação

	P	B	C	$C^{y<2}$	$C^{y>2}$
S1	0.34	0.11	0.07	0.04	0.52
S2D1	0.53	0.21	0.06	0.07	0.30
S3D1	0.39	0.09	0.05	0.05	0.17
S4D1	0.40	0.11	0.05	0.06	0.20
S2D2	0.46	0.20	0.02	0.03	0.31
S3D2	0.38	0.13	0.03	0.05	0.24
S4D2	0.38	0.13	0.02	0.03	0.25

Formulação	$\ln L$	$k$	$n$	BIC		AIC	
				$\psi(k \ln n)$	$I_k$	$\psi(2k)$	$I_k$
<b>L1 na formulação GL</b>							
S1	-2233	3	669	8	4475	6	4472
S2D1							
S3D1	-2188	5	669	14	4390	10	4385
S4D1	-2462	5	669	14	4938	10	4934
S2D2	-2502	4	669	11	5015	8	5012
S3D2	-2191	5	669	14	4397	10	4393
S4D2	-2255	5	669	14	4525	10	4521
<b>L5 na formulação ZI-GL</b>							
S1	-1145	7	669	20	2310	14	2304
S2D1	-1130	8	669	23	2282	16	2275
S3D1	-1091	9	669	25	2207	18	2199
S4D1	-1090	9	669	25	2206	18	2199
S2D2	-1006	8	669	23	2034	16	2028
S3D2	-1021	9	669	25	2067	18	2060
S4D2	-1021	9	669	25	2068	18	2060

# INTERCEPTAÇÃO

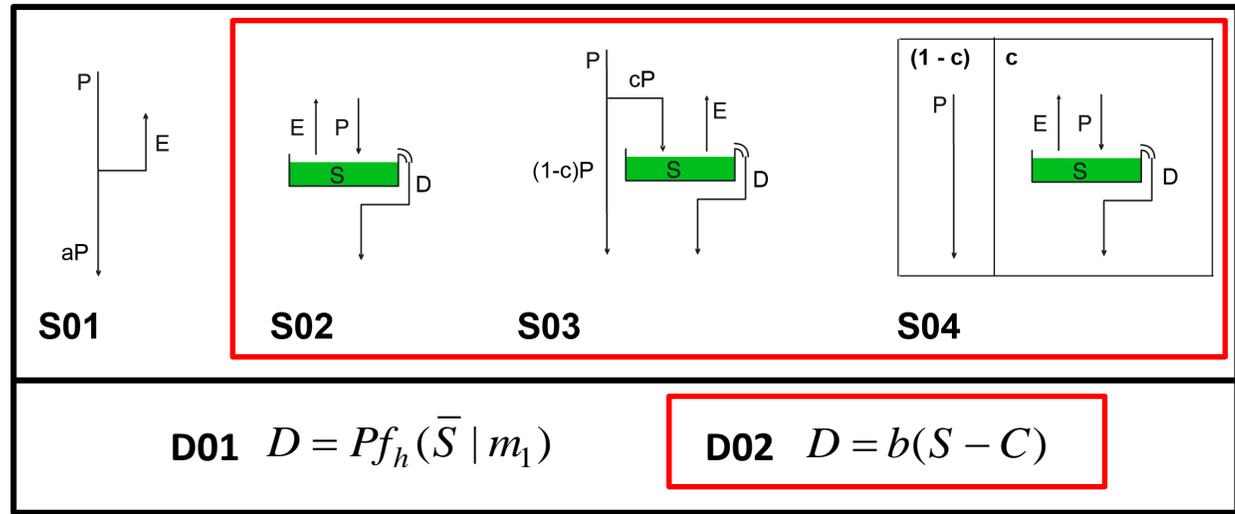
## COMPARAÇÃO ENTRE MODELOS: FLORESTA NATIVA

Calibração

S1	0.38	0.05	0.02	0.05	0.35
S2D1	0.57	0.28	0.04	0.04	0.37
S3D1	0.44	0.18	0.04	0.03	0.32
S4D1	0.45	0.20	0.06	0.04	0.34
S2D2	0.49	0.29	0.05	0.02	0.45
S3D2	0.42	0.22	0.06	0.04	0.44
S4D2	0.42	0.22	0.06	0.03	0.44
	P	B	C	$C^{y<2}$	$C^{y>2}$

Validação

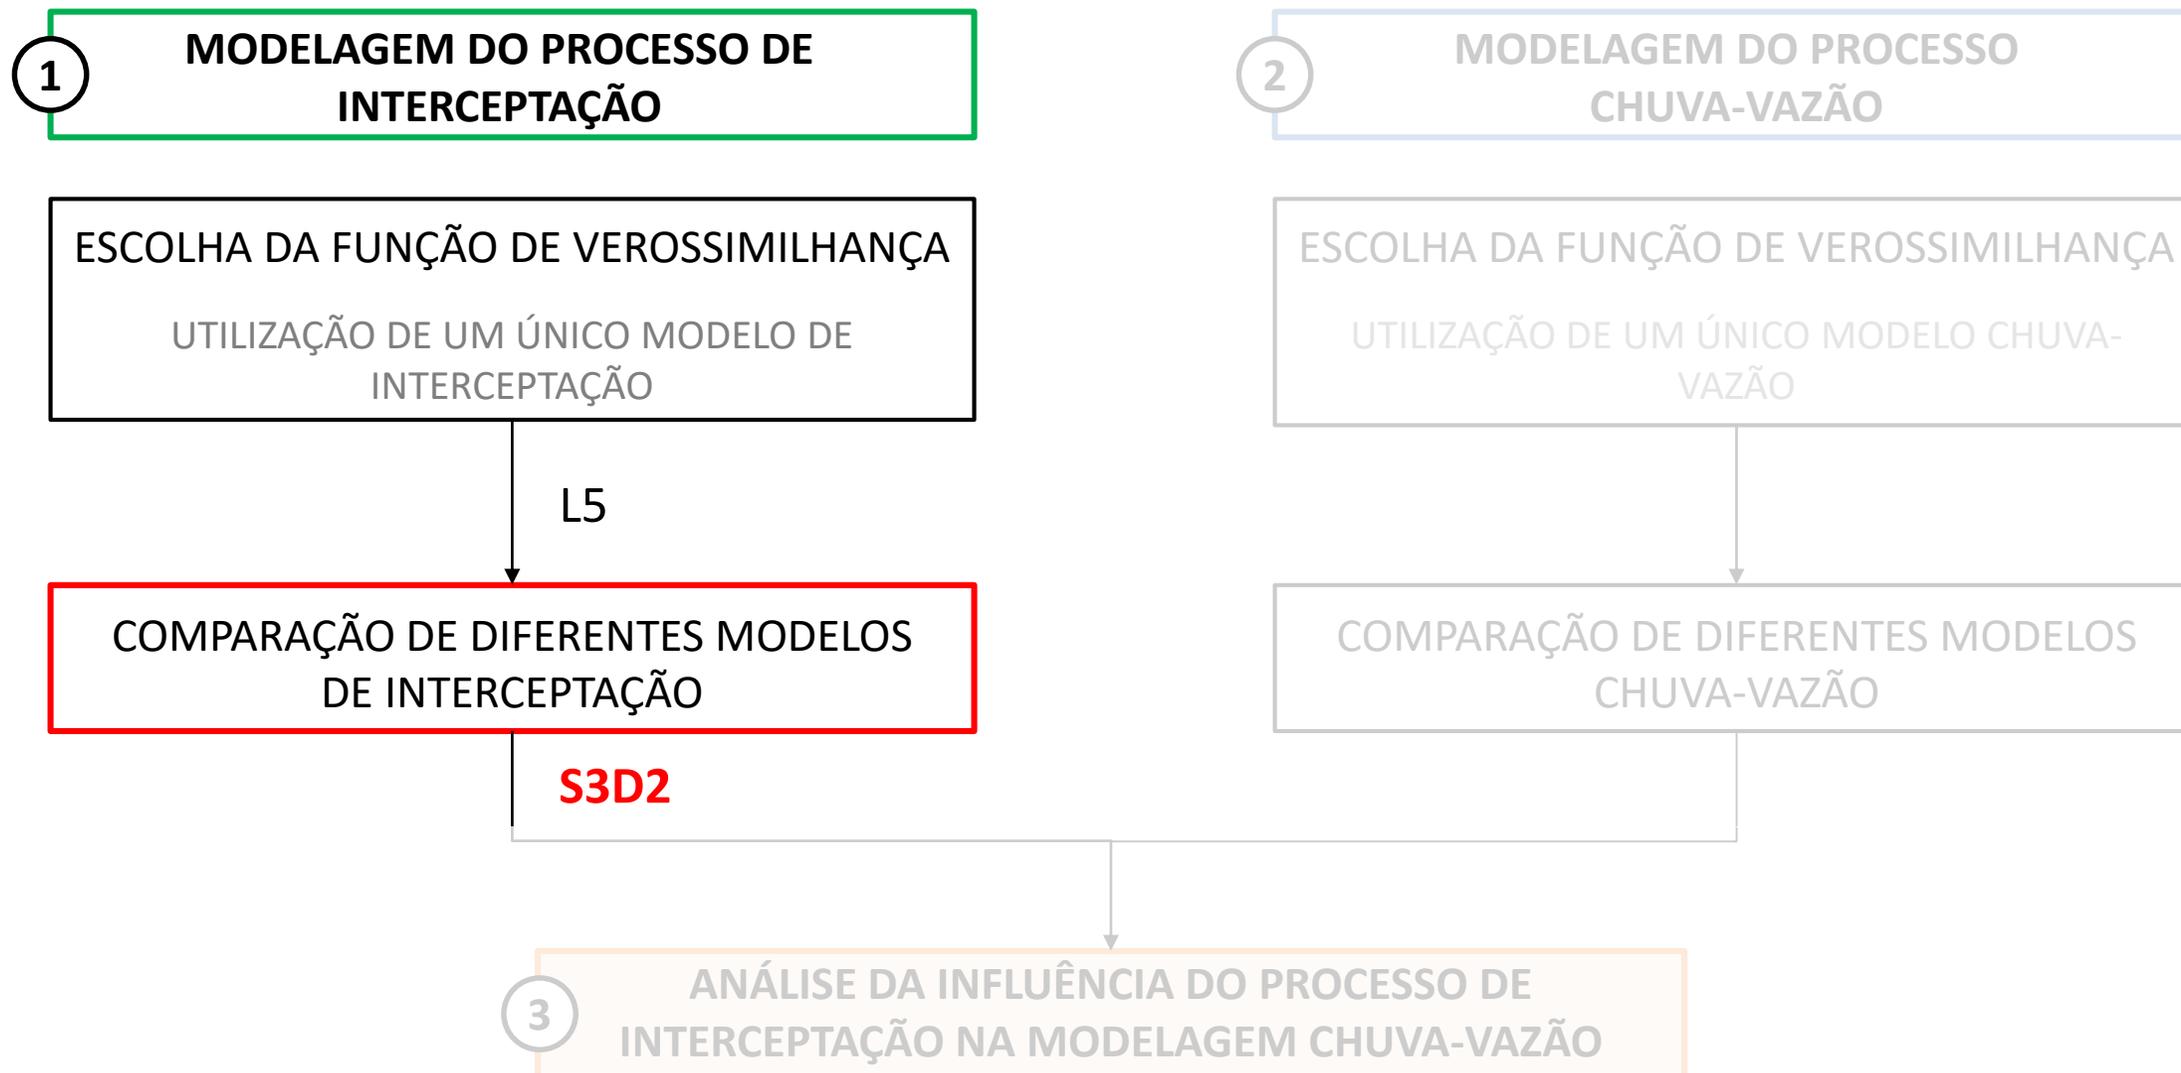
S1	0.34	0.11	0.07	0.04	0.52
S2D1	0.53	0.21	0.06	0.07	0.30
S3D1	0.39	0.09	0.05	0.05	0.17
S4D1	0.40	0.11	0.05	0.06	0.20
S2D2	0.46	0.20	0.02	0.03	0.31
S3D2	0.38	0.13	0.03	0.05	0.24
S4D2	0.38	0.13	0.02	0.03	0.25
	P	B	C	$C^{y<2}$	$C^{y>2}$



L5 na formulação ZI-GL

S1	-1145	7	669	20	2310	14	2304
S2D1	-1130	8	669	23	2282	16	2275
S3D1	-1091	9	669	25	2207	18	2199
S4D1	-1090	9	669	25	2206	18	2199
S2D2	-1006	8	669	23	2034	16	2028
S3D2	-1021	9	669	25	2067	18	2060
S4D2	-1021	9	669	25	2068	18	2060

# FLUXOGRAMA



# INTERCEPTAÇÃO

---

## ESCOLHA DA FUNÇÃO DE VEROSSIMILHANÇA

- Necessidade da consideração de heteroscedasticidade, curtose, autocorrelação e inflação da distribuição por zeros

## COMPARAÇÃO ENTRE MODELOS

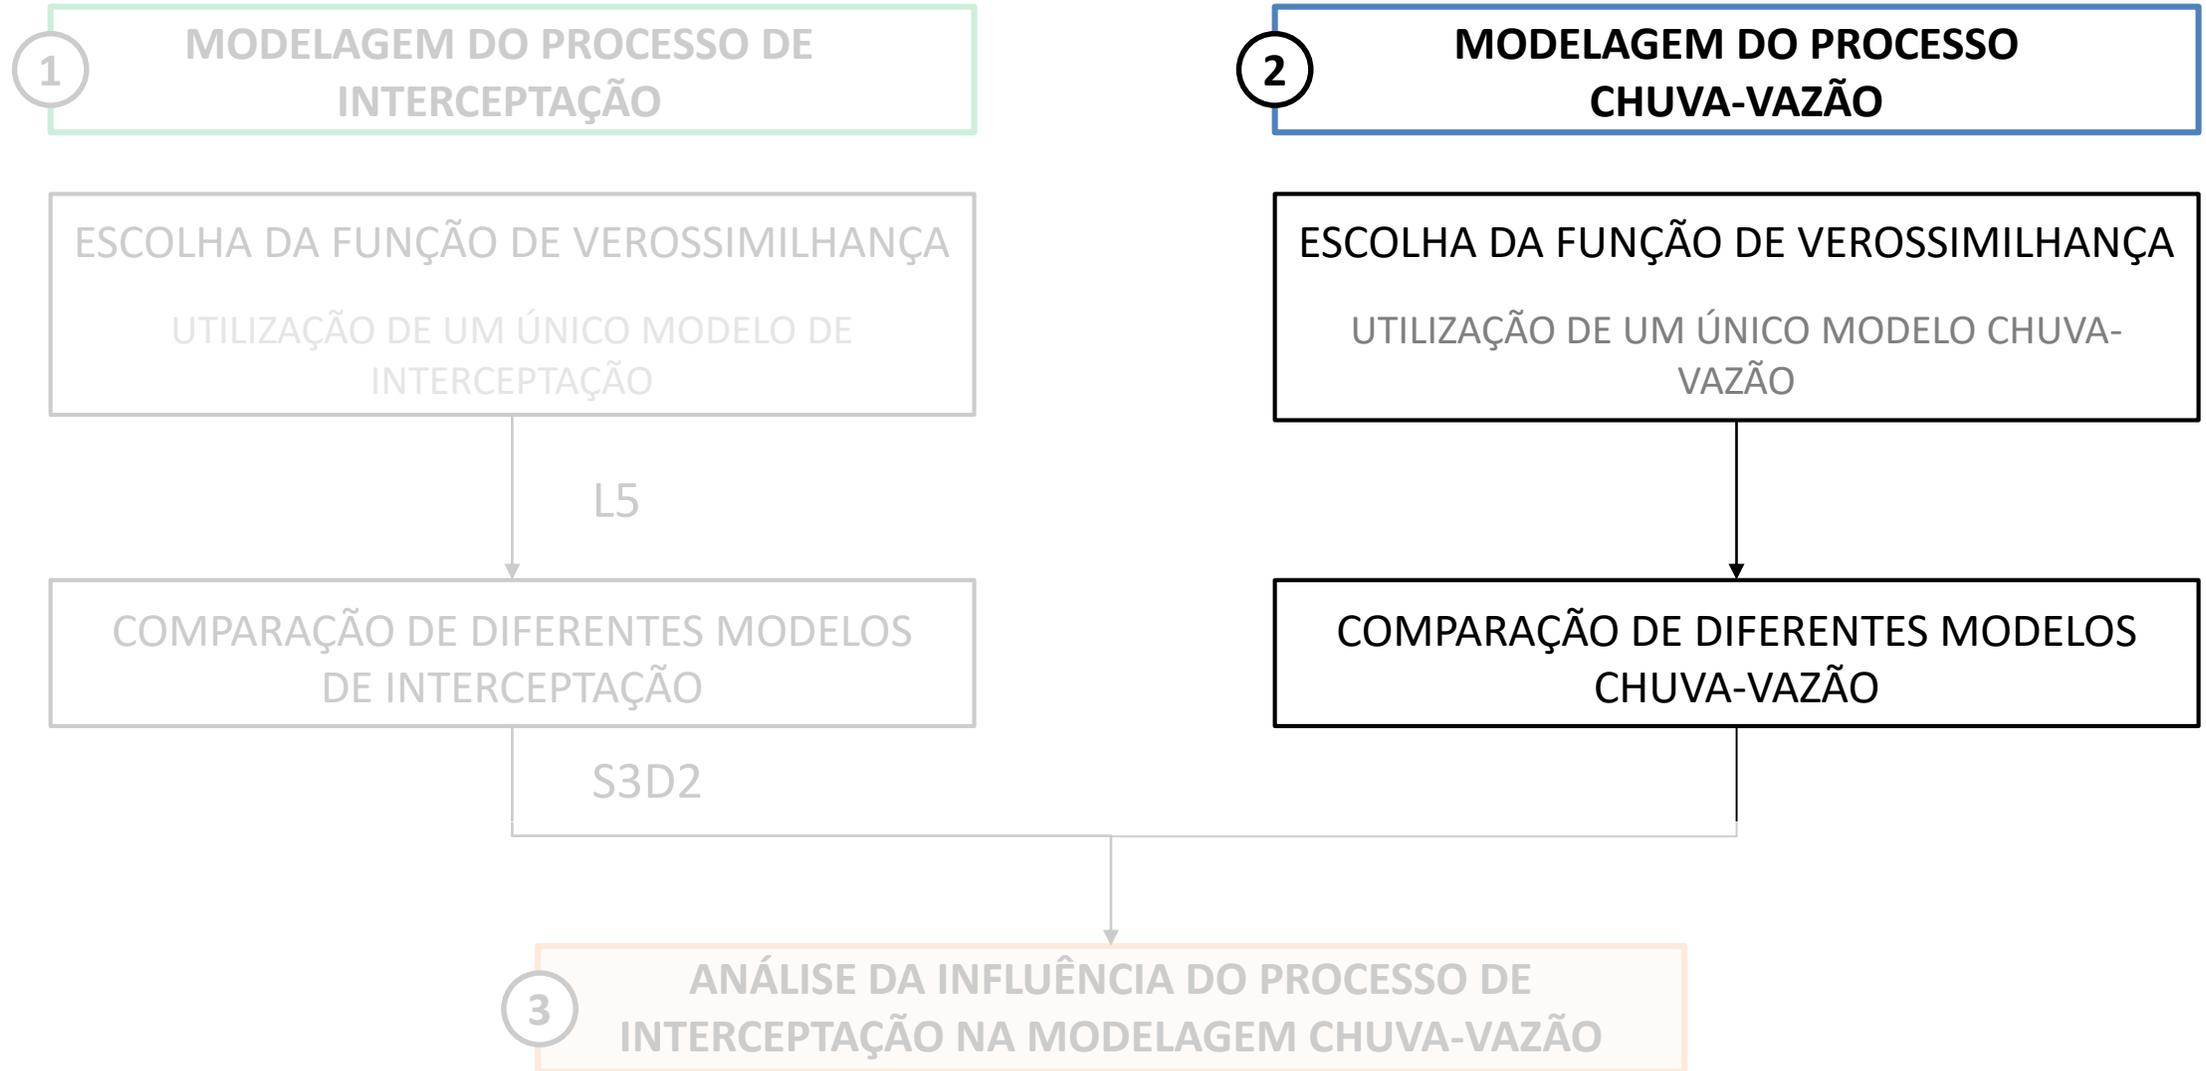
- Função de drenagem D02 produziu um melhor ajuste da série simulada à série observada
- Estruturas que consideram o armazenamento na vegetação promoveram melhor resultado do que considerar que a chuva líquida é uma proporção constante da chuva total
- Pequena diferença entre as estruturas S03 e S04 → elevado fator de cobertura

# 2. CHUVA-VAZÃO

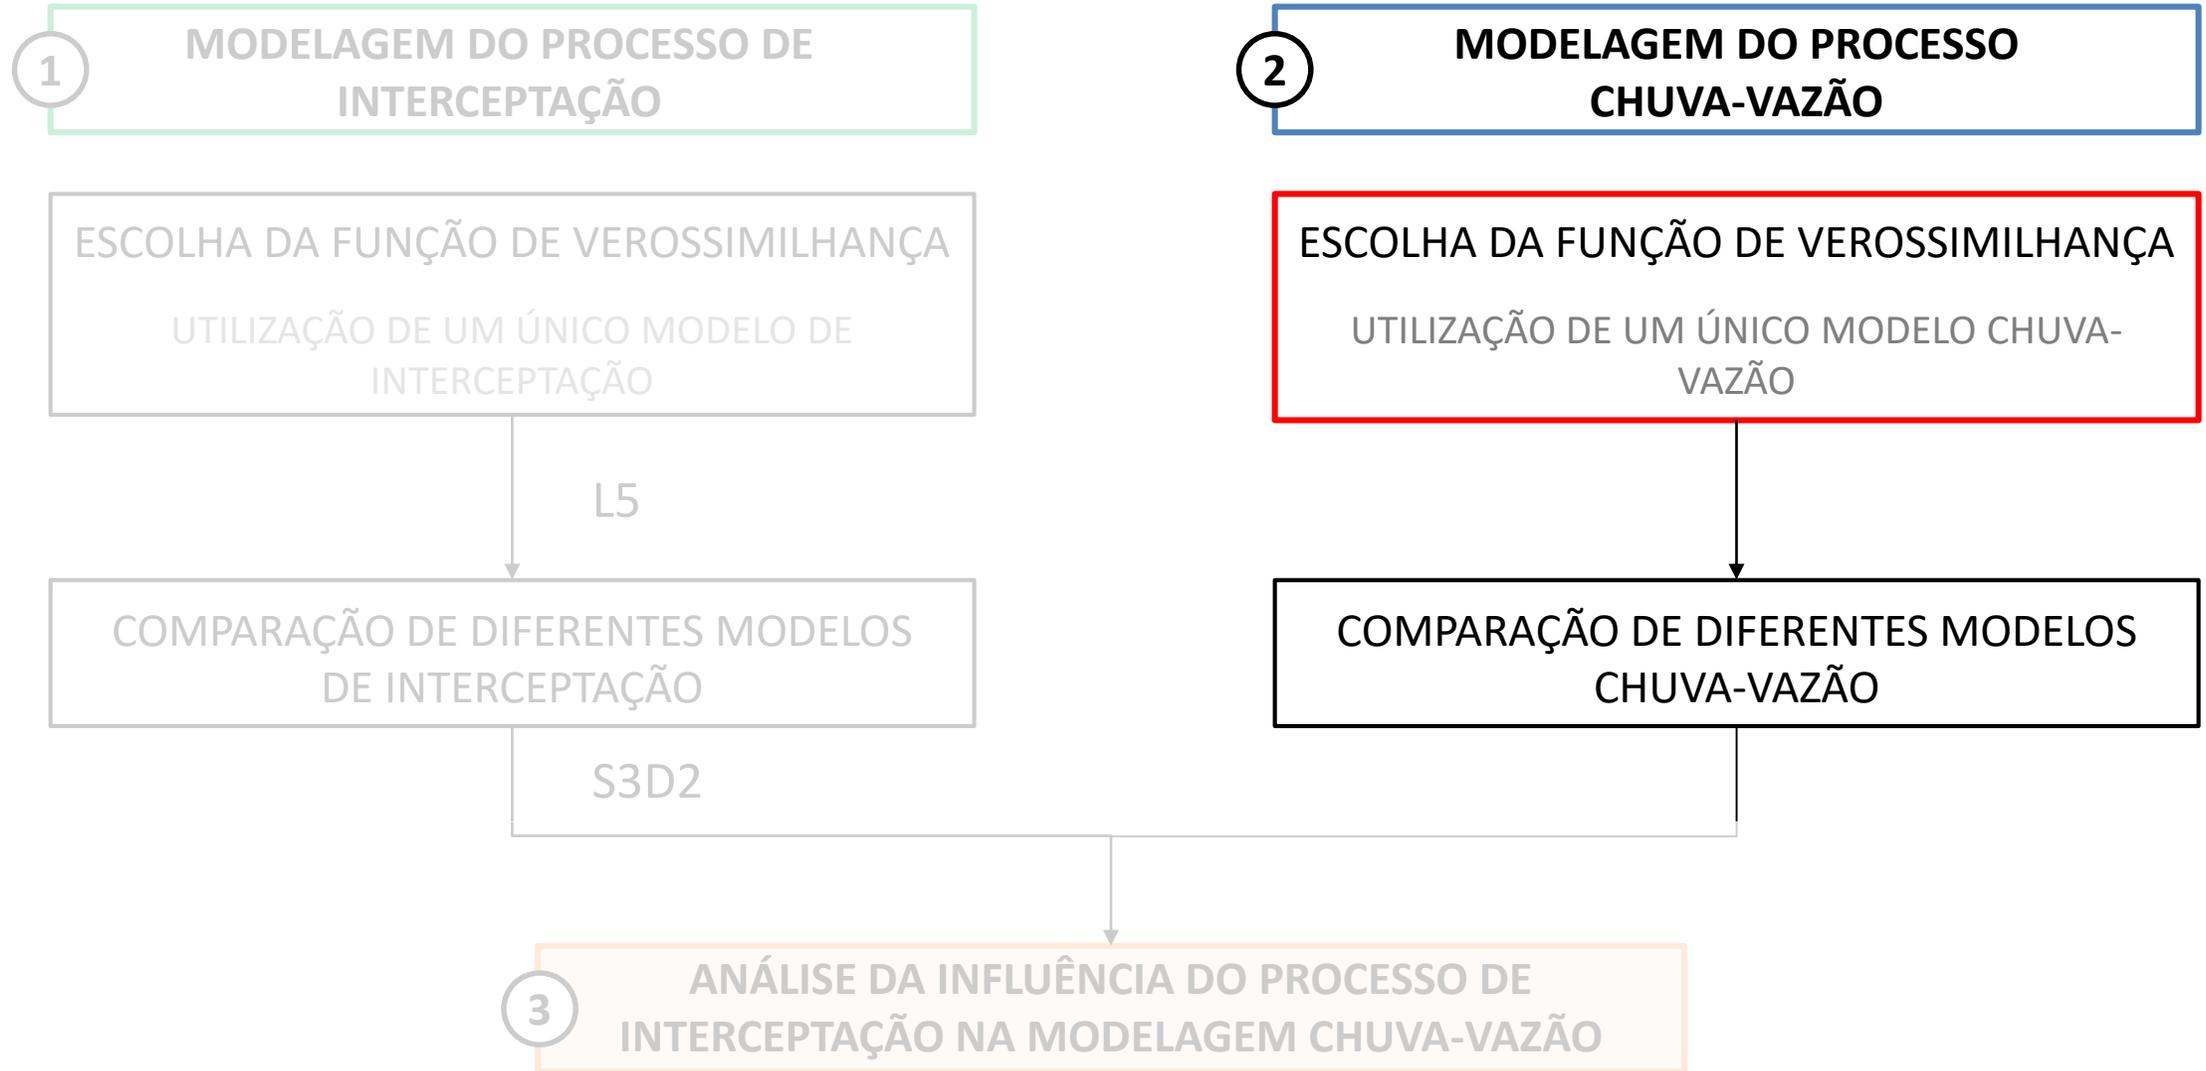
---

RESULTADOS E DISCUSSÃO

# FLUXOGRAMA

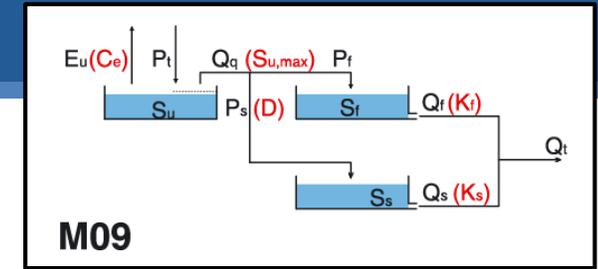


# FLUXOGRAMA

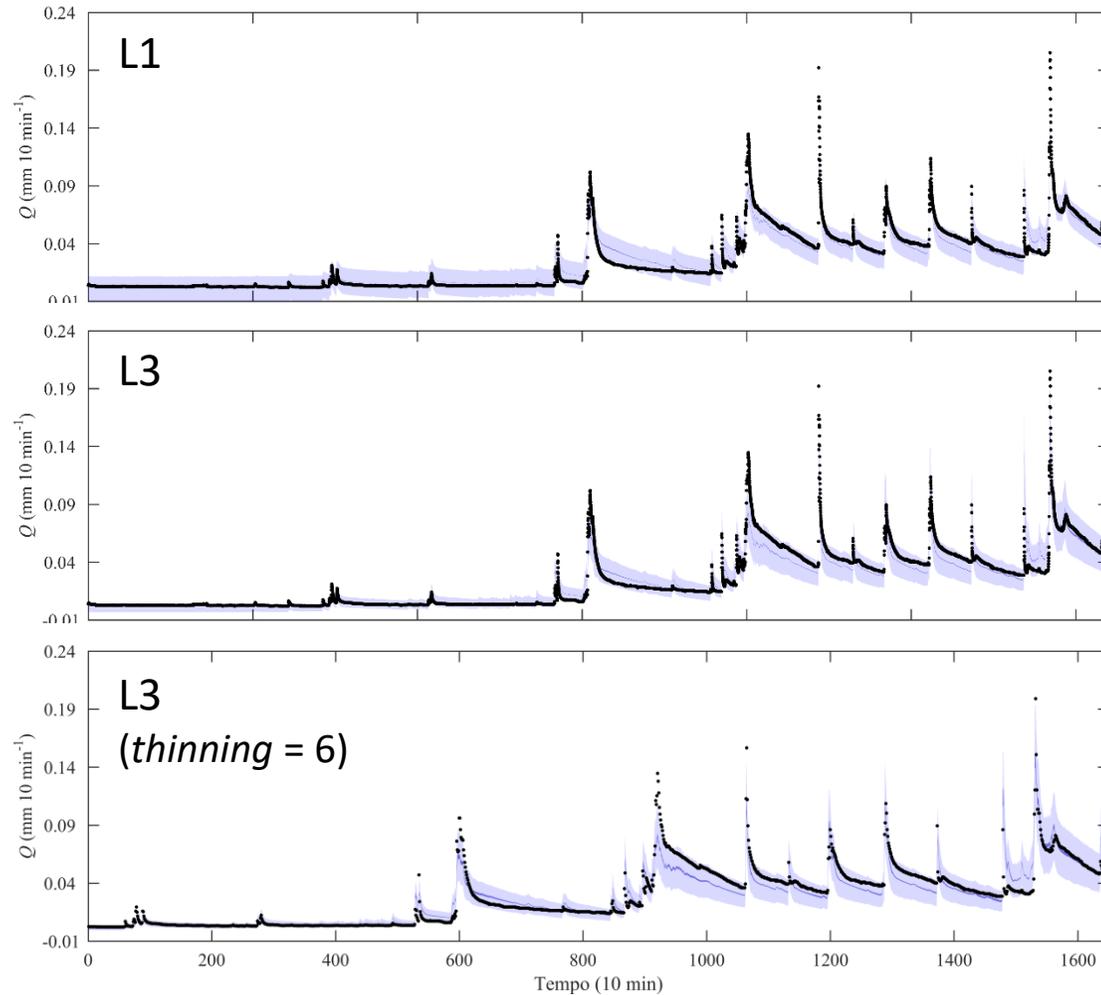


# CHUVA-VAZÃO

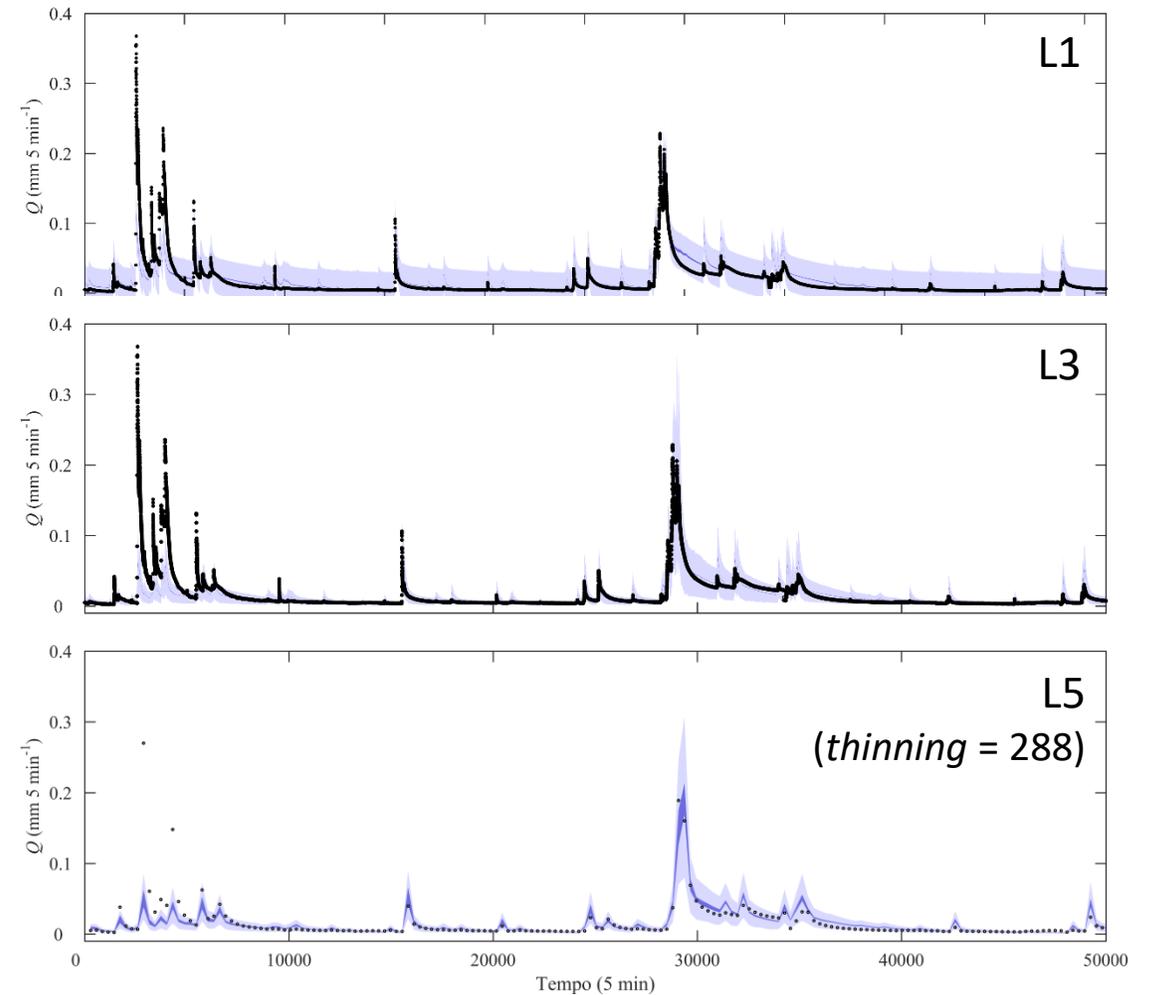
## ESCOLHA DA FUNÇÃO DE VEROSSIMILHANÇA



BACIA DO RIO SACI

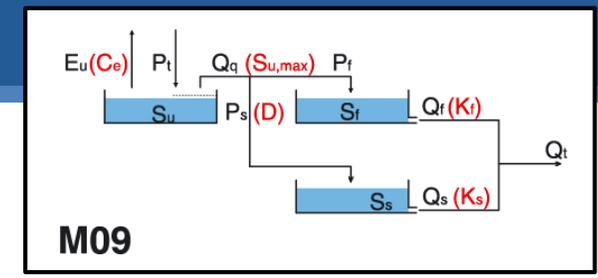


BACIA DO RIO ARAPONGA

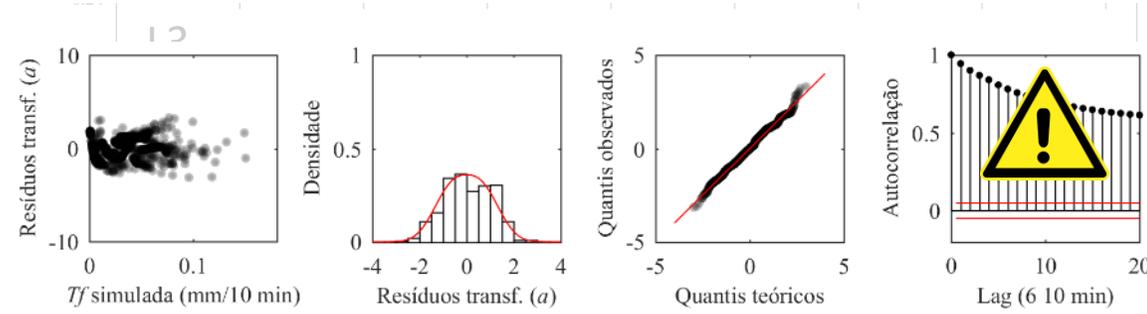
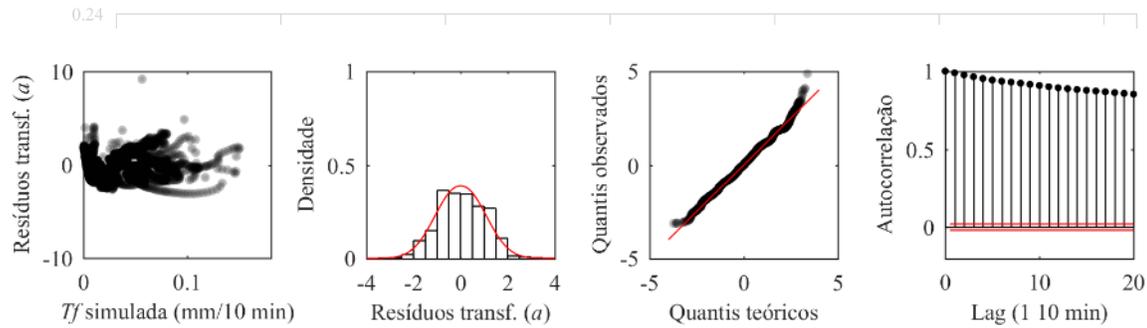
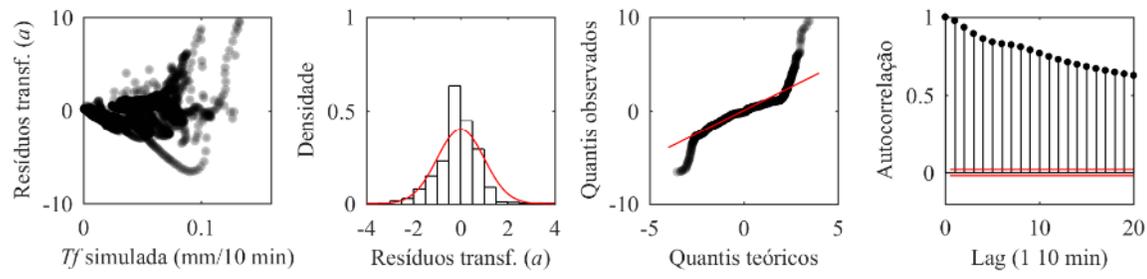


# CHUVA-VAZÃO

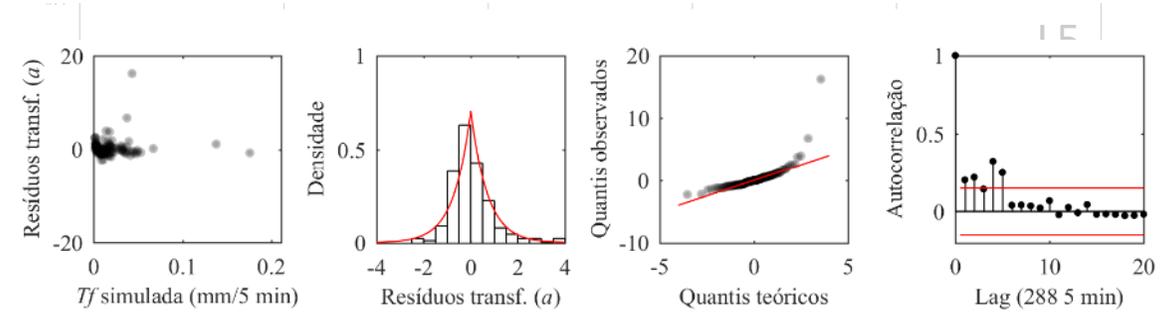
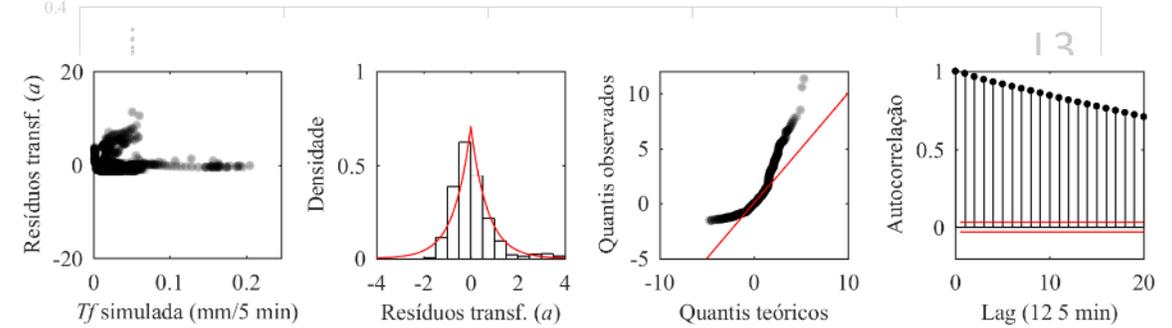
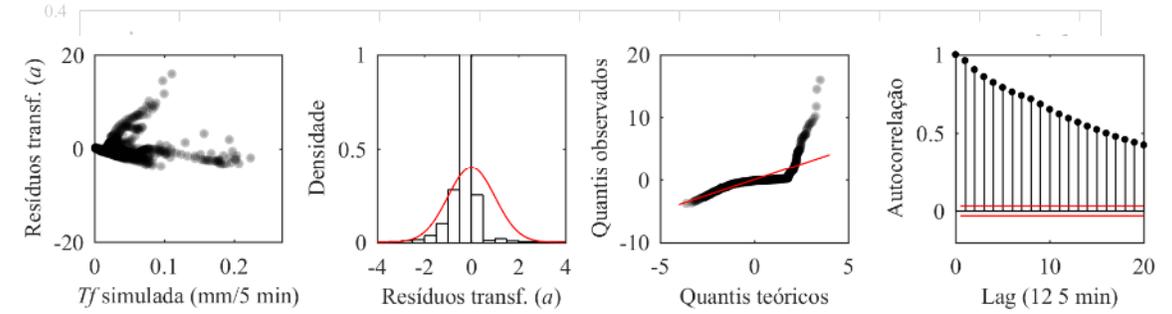
## ESCOLHA DA FUNÇÃO DE VEROSSIMILHANÇA



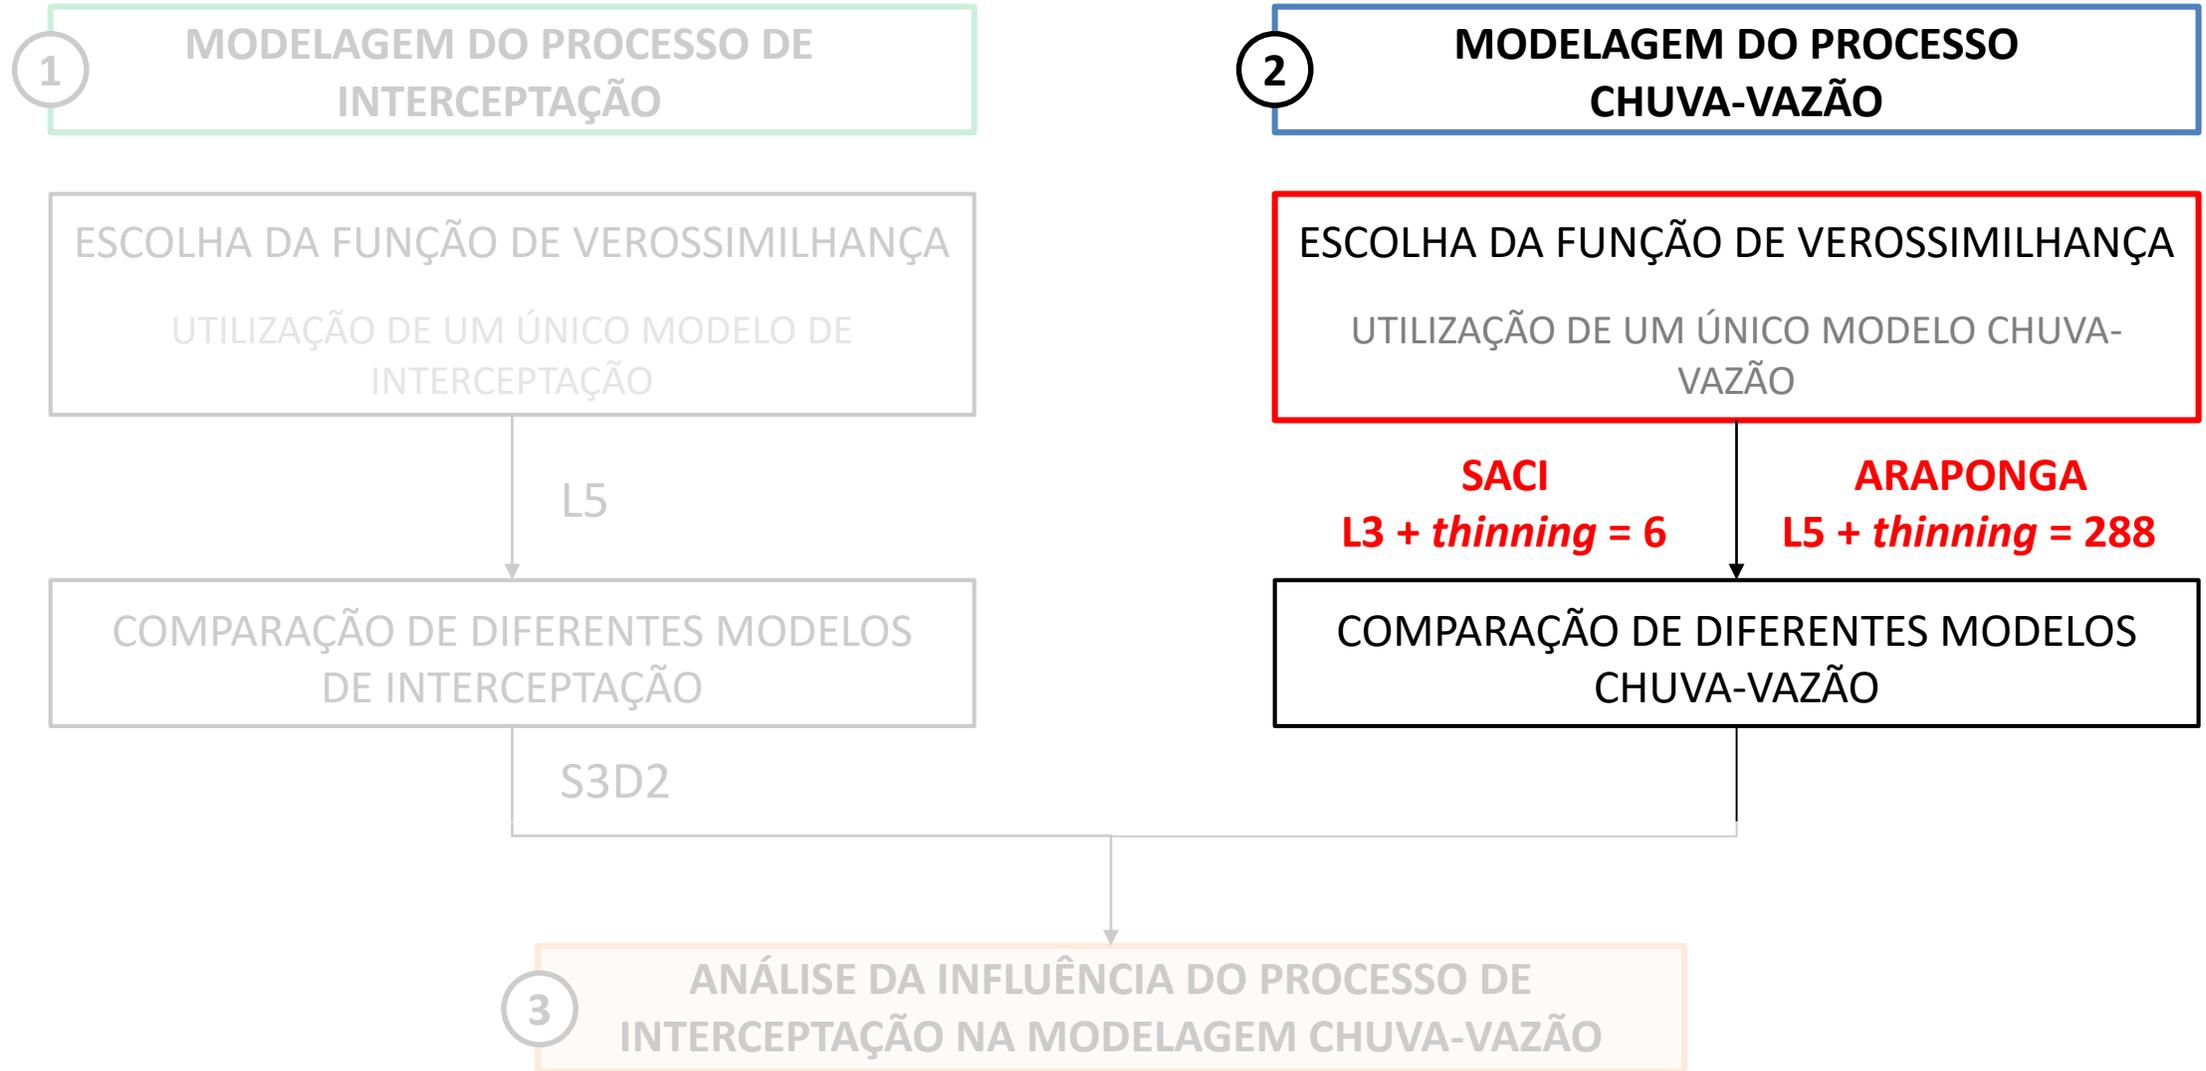
### BACIA DO RIO SACI



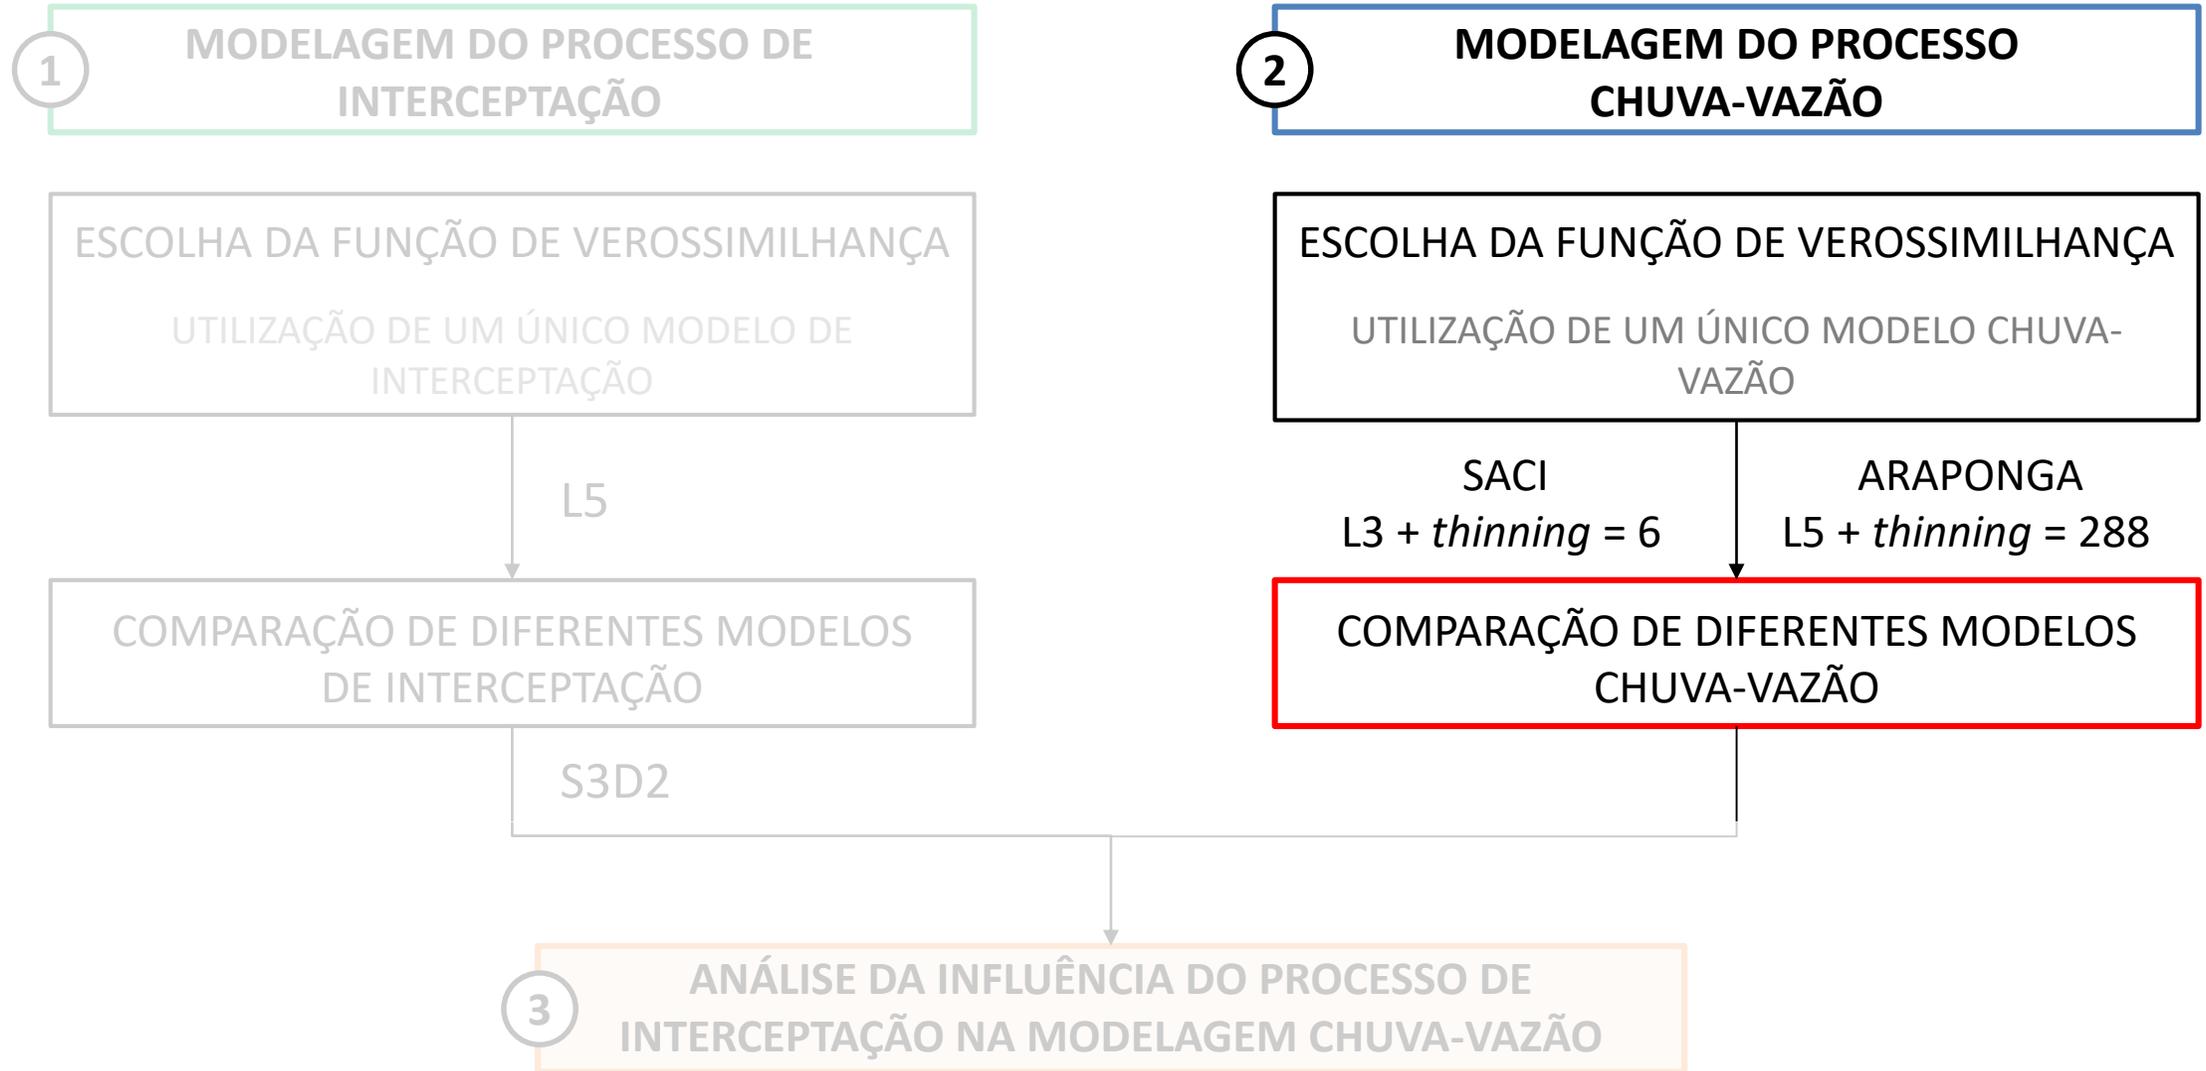
### BACIA DO RIO ARAPONGA



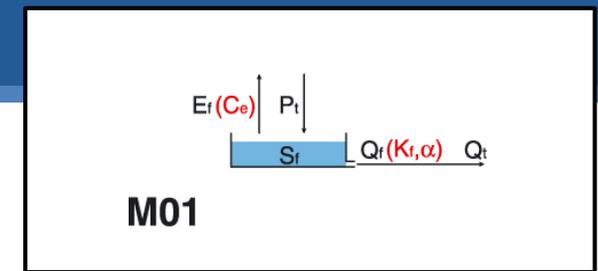
# FLUXOGRAMA



# FLUXOGRAMA

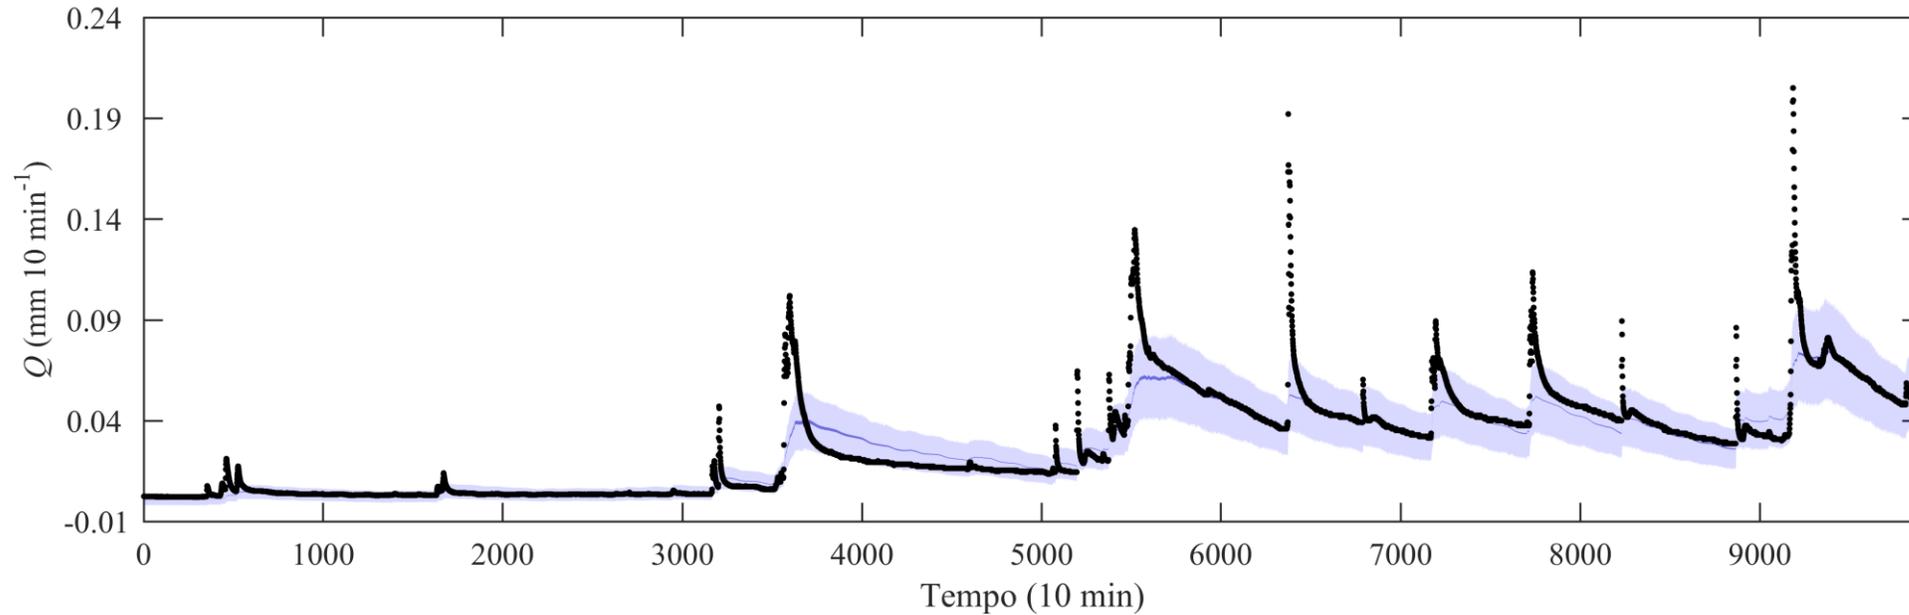


## COMPARAÇÃO ENTRE MODELOS

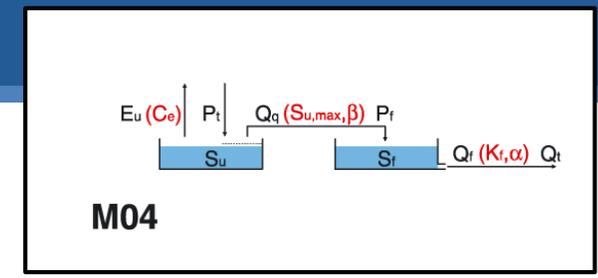


BACIA DO RIO SACI

ÚNICO RESERVATÓRIO

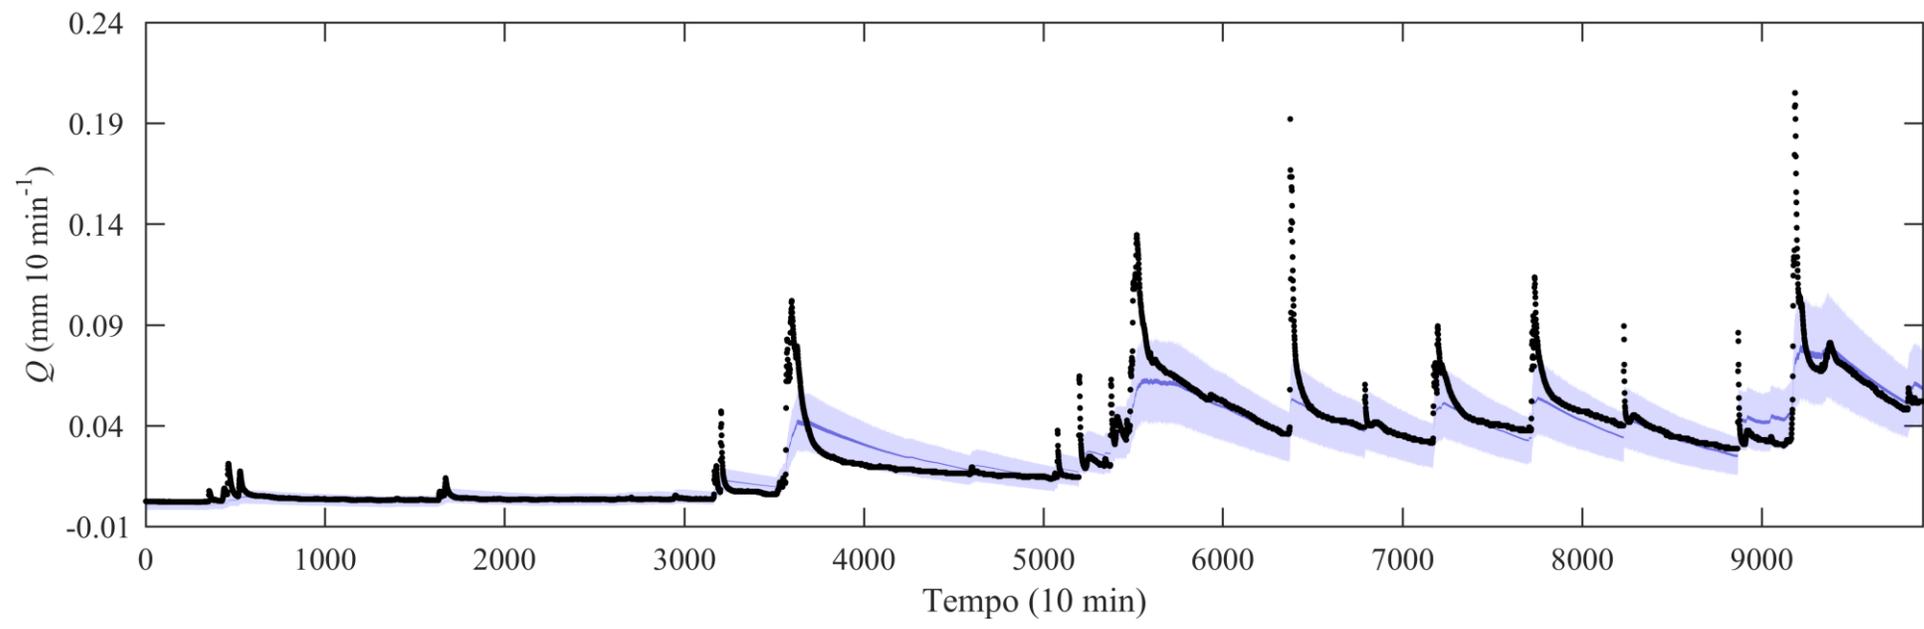


## COMPARAÇÃO ENTRE MODELOS

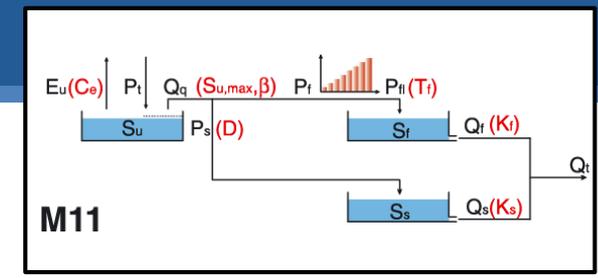


BACIA DO RIO SACI

EM SÉRIE

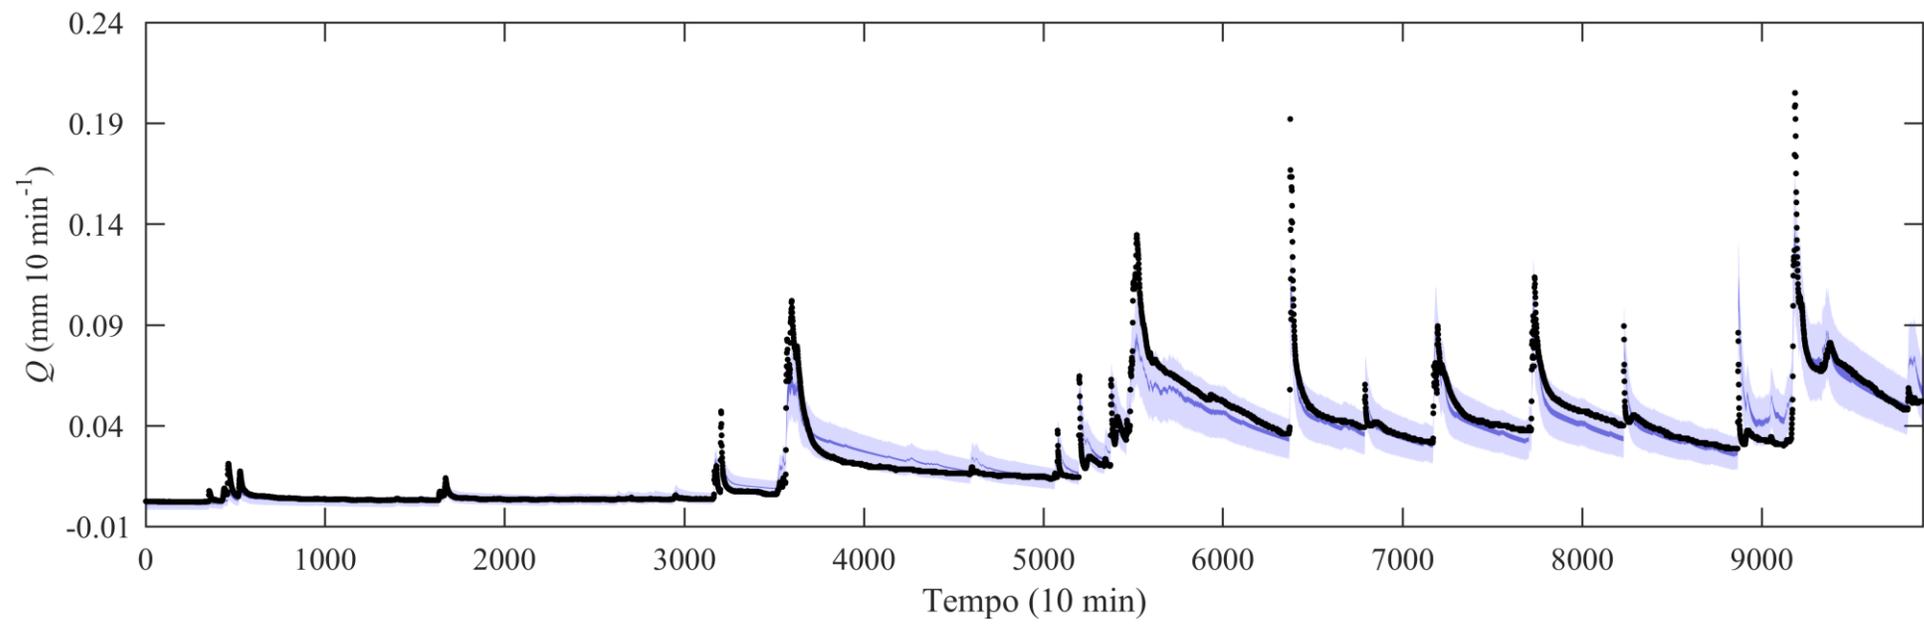


## COMPARAÇÃO ENTRE MODELOS

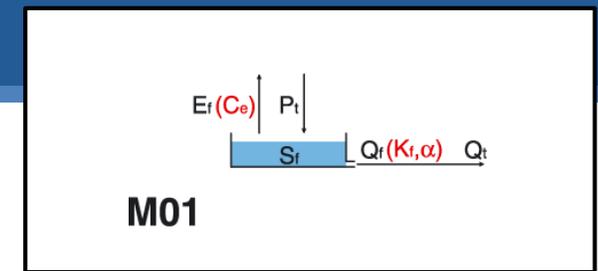


BACIA DO RIO SACI

EM PARALELO

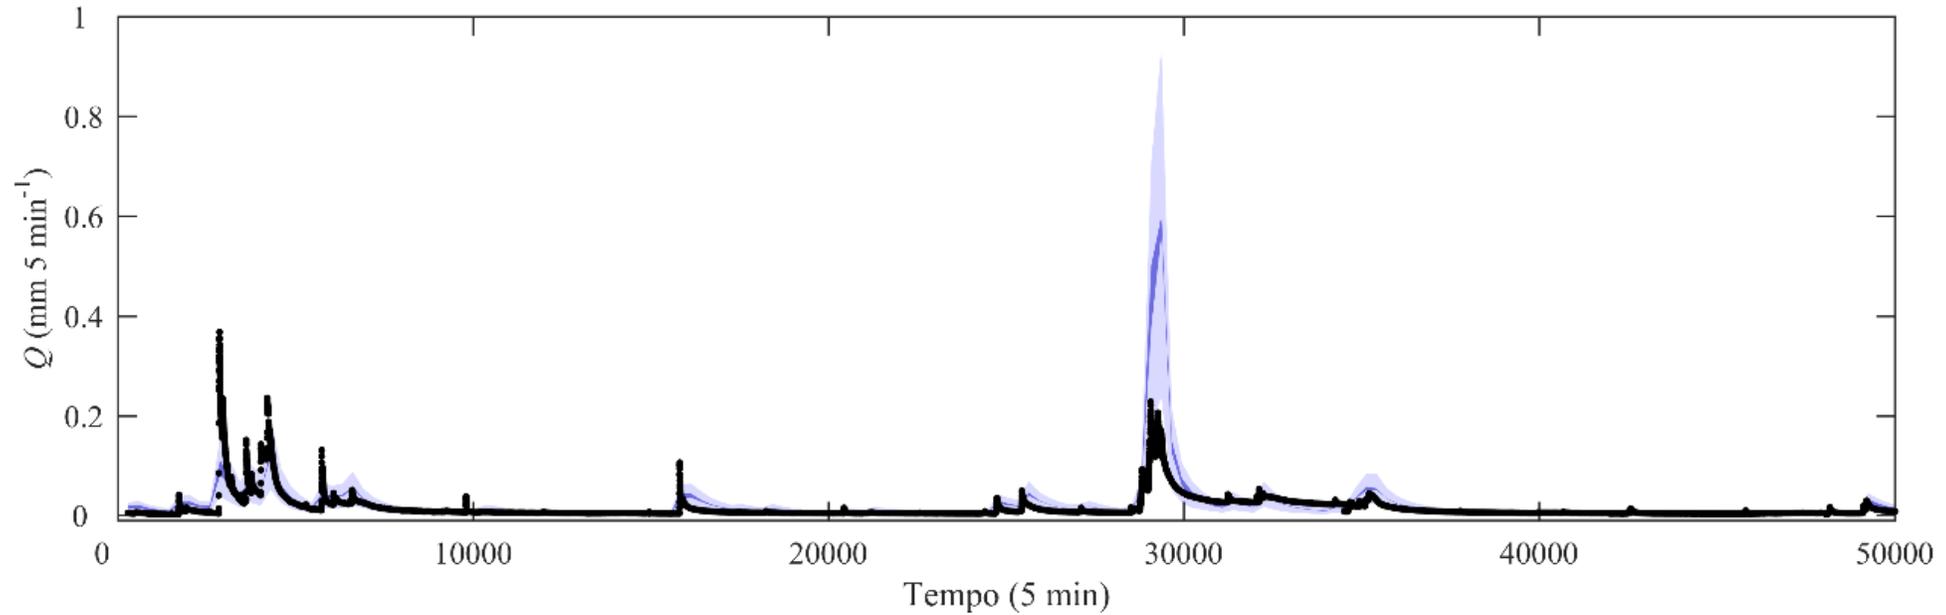


## COMPARAÇÃO ENTRE MODELOS

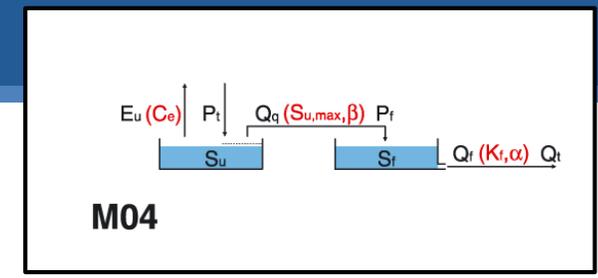


BACIA DO RIO ARAPONGA

ÚNICO RESERVATÓRIO



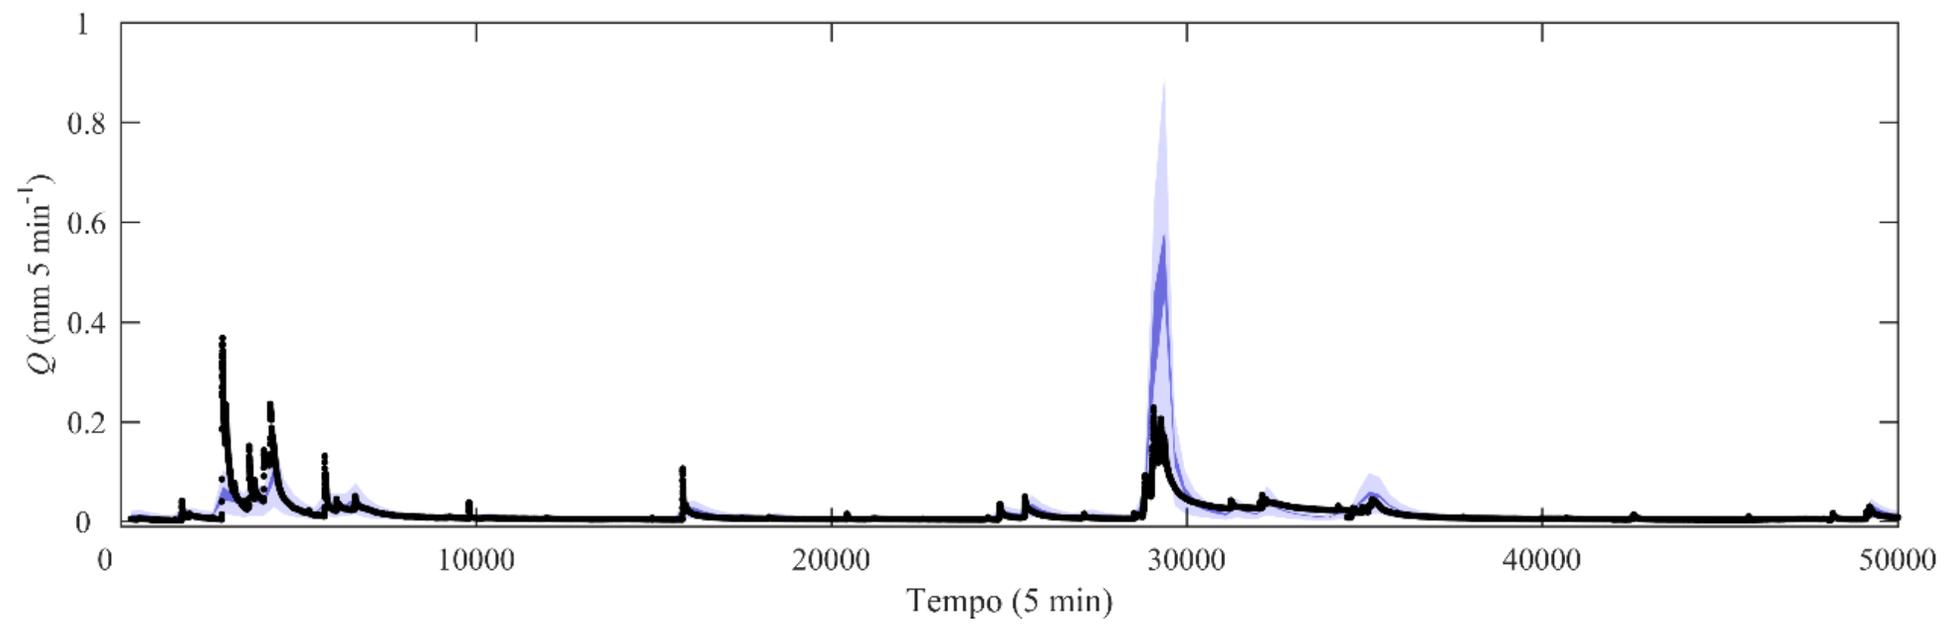
## COMPARAÇÃO ENTRE MODELOS



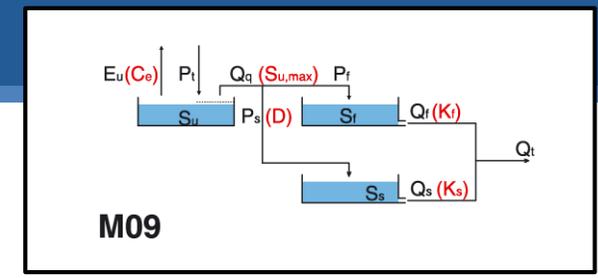
M04

BACIA DO RIO ARAPONGA

EM SÉRIE

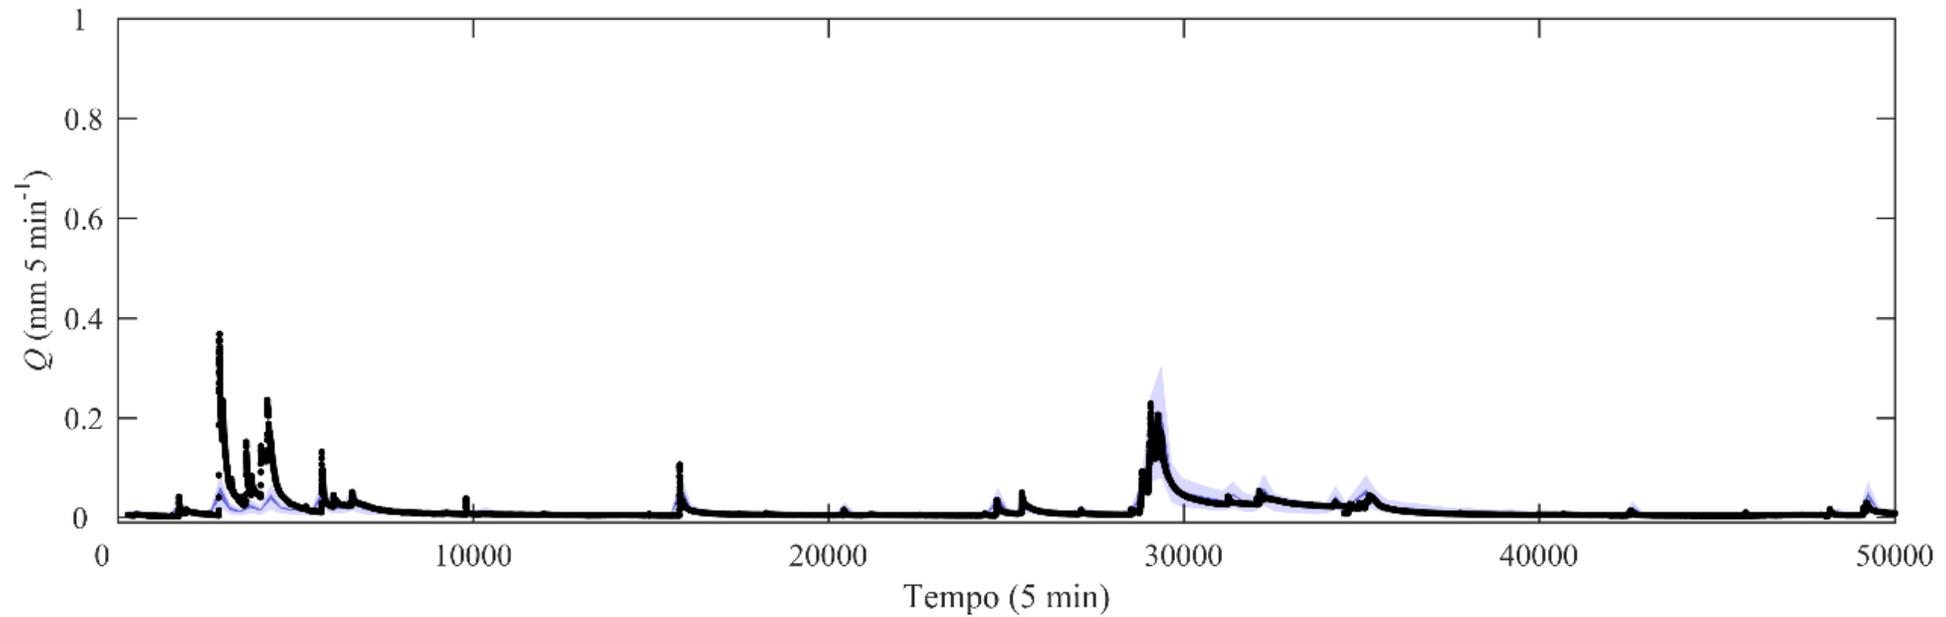


## COMPARAÇÃO ENTRE MODELOS



BACIA DO RIO ARAPONGA

EM PARALELO

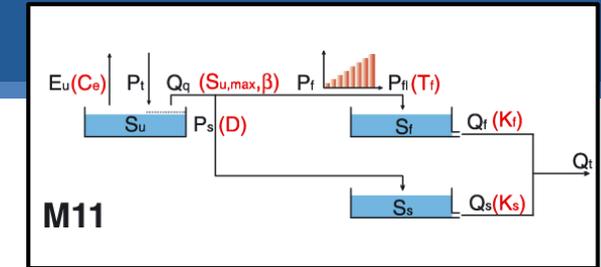


## COMPARAÇÃO ENTRE MODELOS

### BACIA DO RIO SACI

Modelo	$\ln L$	$k$	$n$	BIC $\psi(k \ln n)$	$I_k$	AIC $\psi(2k)$	$I_k$
Estrutura com único reservatório							
M01	3617	6	1650	44	-7190	12	-7223
Estruturas em série							
M03	3419	7	1650	52	-6787	14	-6825
M04	3625	8	1650	59	-7191	16	-7234
Estruturas em paralelo							
M07	3896	11	1650	81	-7710	22	-7769
M08	3022	7	1650	52	-5991	14	-6029
M09	3687	8	1650	59	-7315	16	-7358
M10	3691	9	1650	67	-7314	18	-7363
M11	3835	10	1650	74	-7596	20	-7650

## COMPARAÇÃO ENTRE MODELOS



BACIA DO RIO SACI

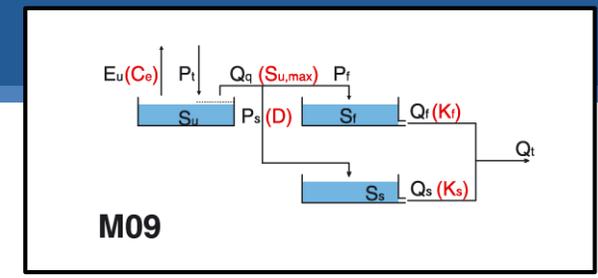
Modelo	$\ln L$	$k$	$n$	BIC $\psi(k \ln n)$	$I_k$	AIC $\psi(2k)$	$I_k$
Estrutura com único reservatório							
M01	3617	6	1650	44	-7190	12	-7223
Estruturas em série							
M03	3419	7	1650	52	-6787	14	-6825
M04	3625	8	1650	59	-7191	16	-7234
Estruturas em paralelo							
M07	3896	11	1650	81	-7710	22	-7769
M08	3022	7	1650	52	-5991	14	-6029
M09	3687	8	1650	59	-7315	16	-7358
M10	3691	9	1650	67	-7314	18	-7363
M11	3835	10	1650	74	-7596	20	-7650

## COMPARAÇÃO ENTRE MODELOS

### BACIA DO RIO ARAPONGA

Modelo	$\ln L$	$k$	$n$	BIC $\psi(k \ln n)$	$I_k$	AIC $\psi(2k)$	$I_k$
Estrutura com um único reservatório							
M01	291	6	178	31	-551	12	-570
Estruturas em série							
M03	303	7	178	36	-569	14	-591
M04	317	8	178	41	-592	16	-618
Estruturas em paralelo							
M07	342	11	178	57	-627	22	-662
M08	289	7	178	36	-542	14	-564
M09	342	8	178	41	-642	16	-668
M10	342	9	178	47	-637	18	-665
M11	347	10	178	52	-643	20	-675

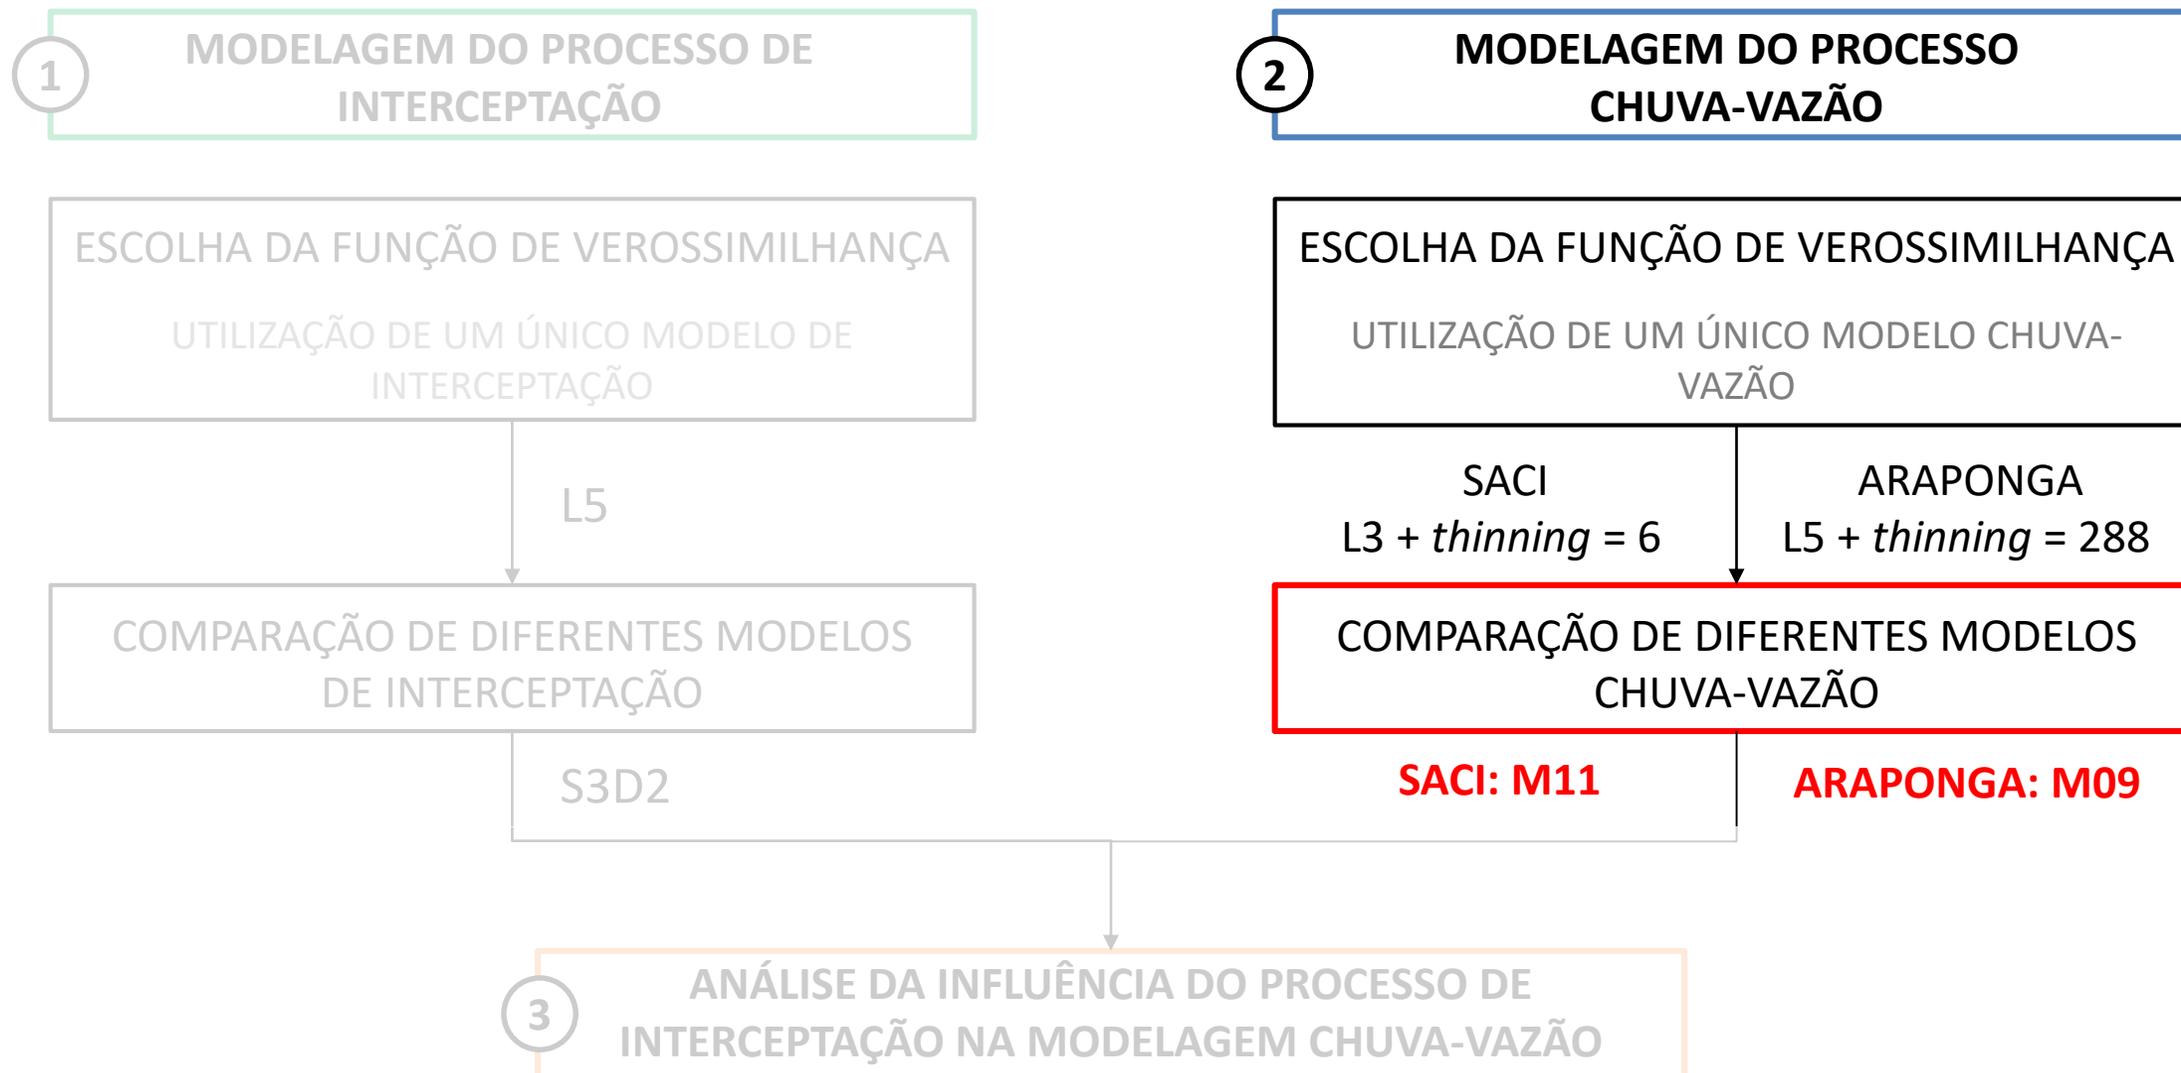
## COMPARAÇÃO ENTRE MODELOS



### BACIA DO RIO ARAPONGA

Modelo	$\ln L$	$k$	$n$	BIC		AIC		
				$\psi(k \ln n)$	$I_k$	$\psi(2k)$	$I_k$	
Estrutura com um único reservatório								
M01	291	6	178	31	-551	12	-570	
Estruturas em série								
M03	303	7	178	36	-569	14	-591	
M04	317	8	178	41	-592	16	-618	
Estruturas em paralelo								
M07	342	11	178	57	-627	22	-662	
M08	289	7	178	36	-542	14	-564	
M09	342	8	178	41	-642	16	-668	
M10	342	9	178	47	-637	18	-665	
M11	347	10	178	52	-643	20	-675	

# FLUXOGRAMA



# CHUVA-VAZÃO

---

## ESCOLHA DA FUNÇÃO DE VEROSSIMILHANÇA

- Necessidade da consideração de heteroscedasticidade, curtose e autocorrelação

## COMPARAÇÃO ENTRE MODELOS

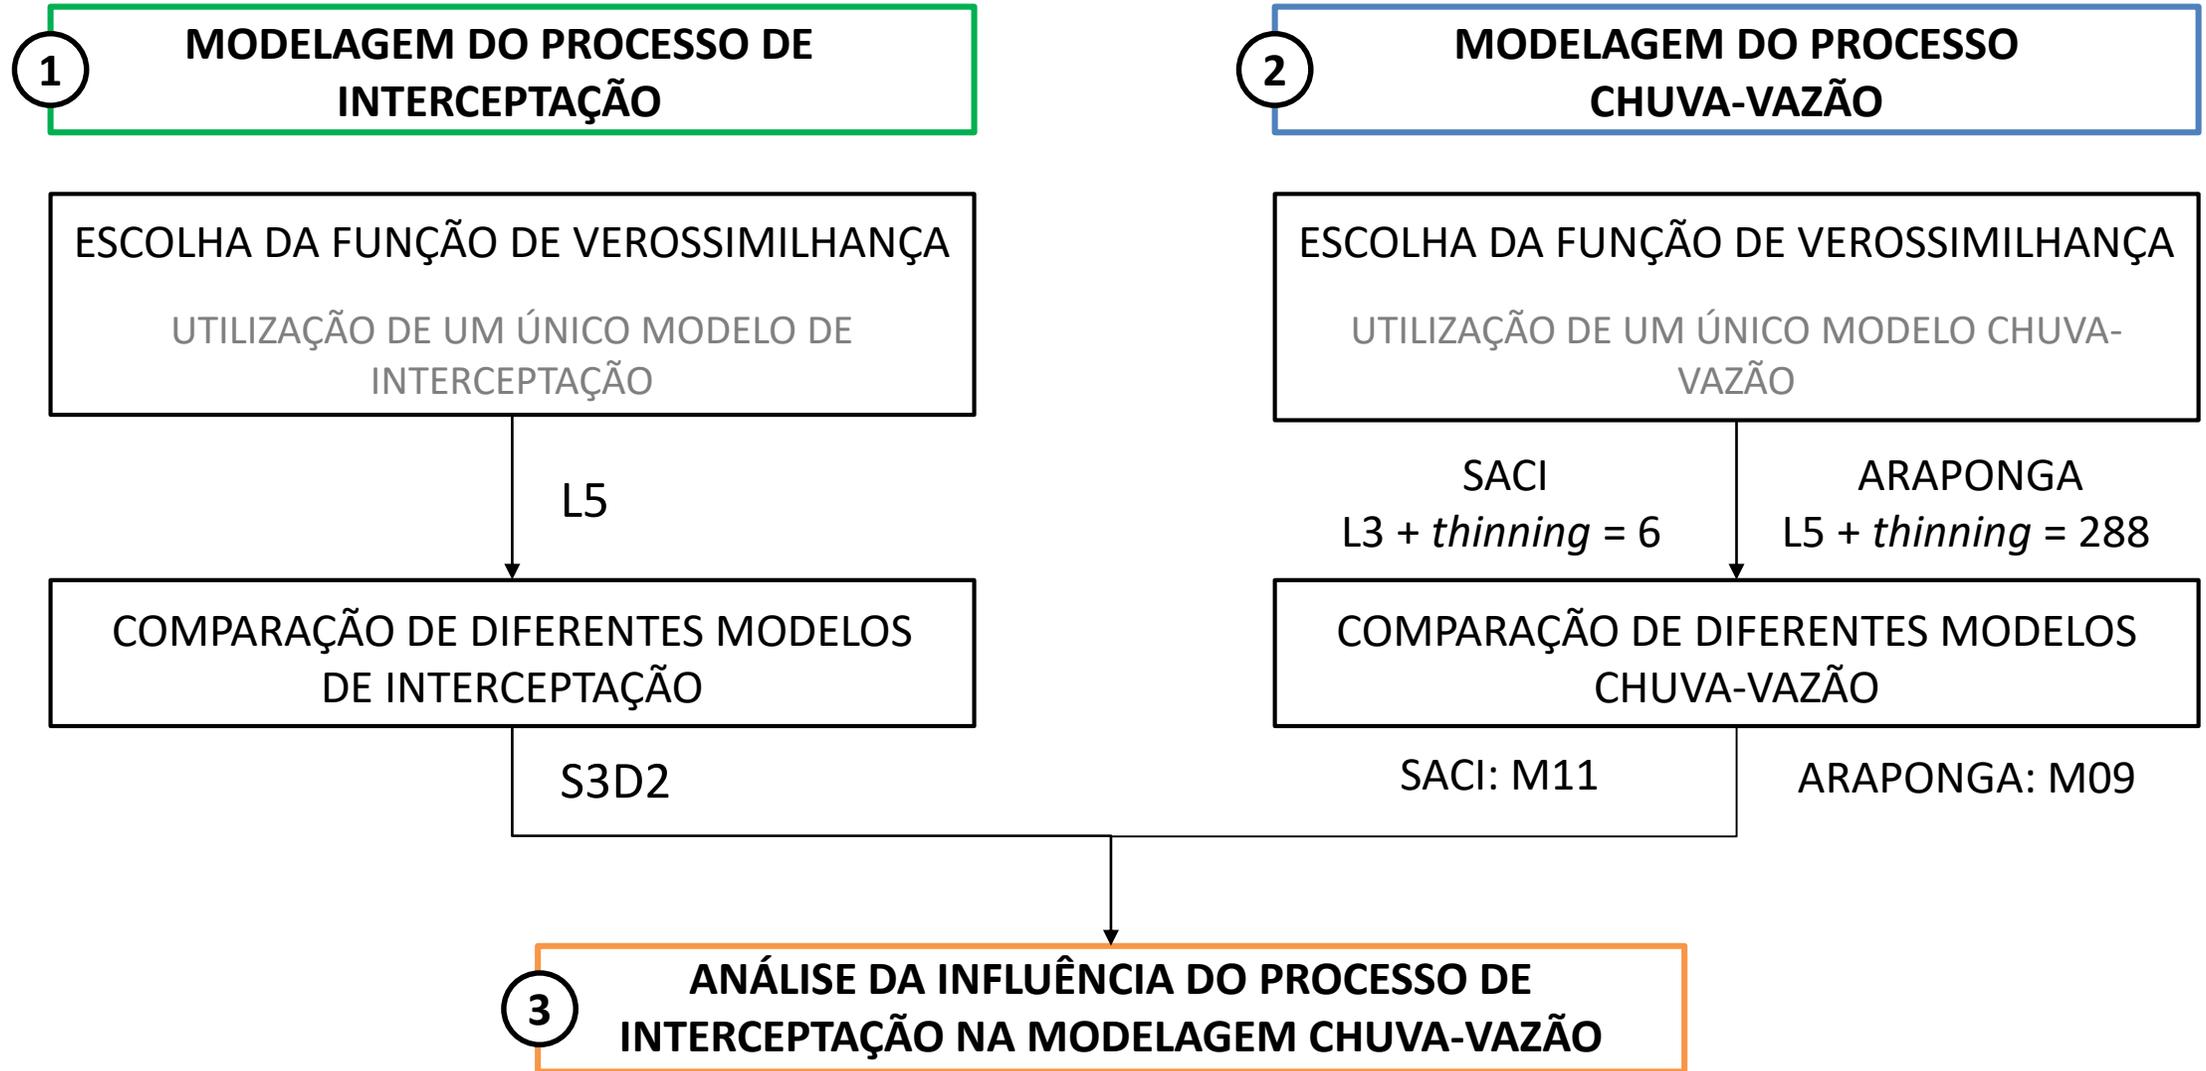
- Estruturas em paralelo representam melhor o processo chuva-vazão nas duas bacias: movimento vertical da água → bacias florestais
- Necessidade da consideração de um reservatório para a zona não-saturada: importância do armazenamento da água no solo

# 3. INFLUÊNCIA DA INTERCEPTAÇÃO NA MODELAGEM CHUVA-VAZÃO

---

RESULTADOS E DISCUSSÃO

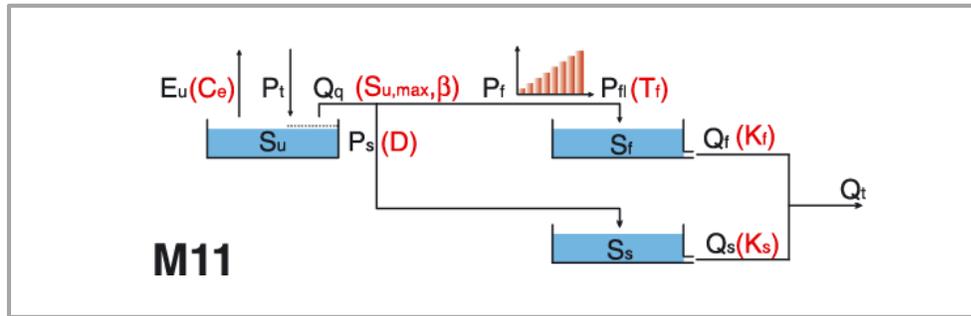
# FLUXOGRAMA



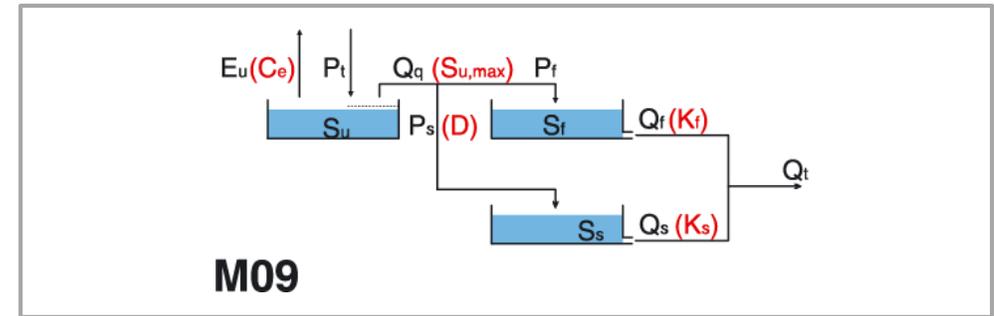
# INTERCEPTAÇÃO E CHUVA-AVAZÃO

## INFLUÊNCIA DO PROCESSO DE INTERCEPTAÇÃO NA MODELAGEM CHUVA-AVAZÃO

BACIA DO RIO SACI



BACIA DO RIO ARAPONGA



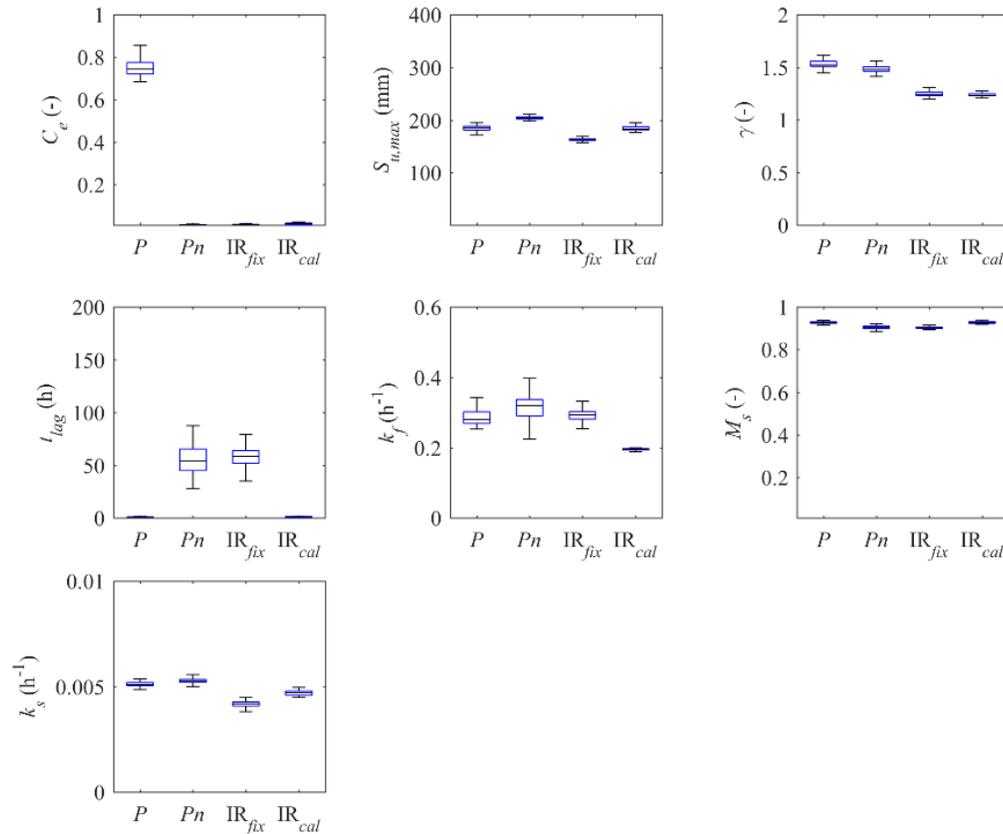
Modelo	ln L	k	n	BIC		AIC	
				$\psi(k \ln n)$	$I_k$	$\psi(2k)$	$I_k$
M11-P	3836	10	1650	74	-7598	20	-7652
M11-Pn	3864	10	1650	74	-7653	20	-7707
M11-IR <sub>fix</sub>	3846	10	2183	77	-7616	20	-7673
M11-IR <sub>cal</sub>	3879	14	1650	104	-7654	28	-7730

Modelo	ln L	k	n	BIC		AIC	
				$\psi(k \ln n)$	$I_k$	$\psi(2k)$	$I_k$
M09-P	342	8	178	41	-642	16	-668
M09-Pn	361	8	178	41	-680	16	-705
M09-IR <sub>fix</sub>	342	10	1011	69	-614	20	-663
M09-IR <sub>cal</sub>	353	14	179	73	-633	28	-677

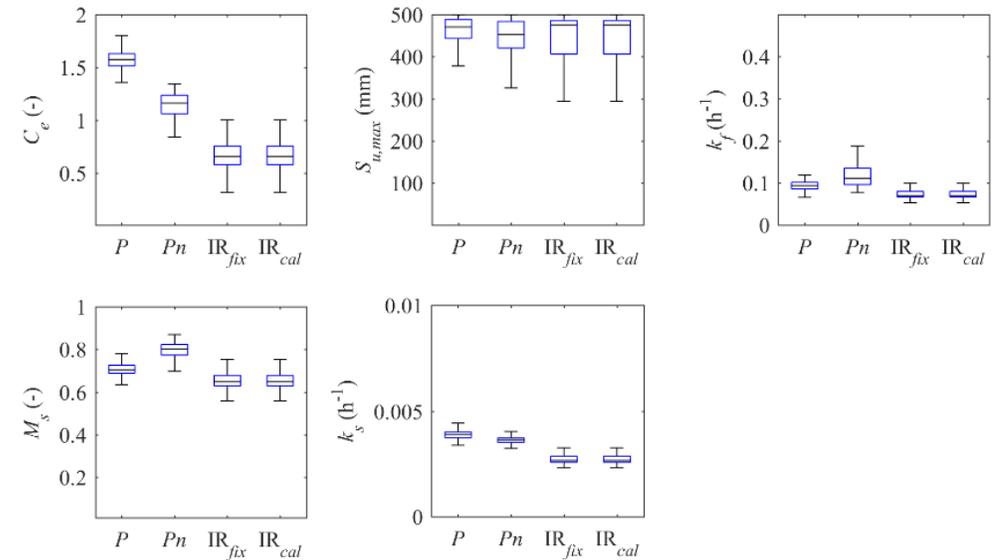
# INTERCEPTAÇÃO E CHUVA-AVAZÃO

## INFLUÊNCIA DO PROCESSO DE INTERCEPTAÇÃO NA MODELAGEM CHUVA-AVAZÃO

BACIA DO RIO SACI



BACIA DO RIO ARAPONGA



# INTERCEPTAÇÃO E CHUVA-VAZÃO

## INFLUÊNCIA DO PROCESSO DE INTERCEPTAÇÃO NA MODELAGEM CHUVA-VAZÃO

- Utilização dos valores de chuva líquida como entrada no modelo chuva-vazão promoveu um melhor ajuste da série observada à série simulada
- Aumento de complexidade do modelo chuva-vazão com a incorporação explícita de uma representação do processo de interceptação pode resultar em compensação de erros através da variação dos valores dos (novos) parâmetros
- Aumento de complexidade visando melhorar a representação do sistema estudado deve ser acompanhada da adição de mais informação ao processo de calibração

# CONCLUSÕES

---

## OBJETIVO ESPECÍFICO 1

*Identificar funções de verossimilhança que representem de maneira adequada os resíduos de modelos de interceptação e chuva-vazão*

- Necessidade de considerar heteroscedasticidade, curtose e autocorrelação dos resíduos
- Para interceptação, necessidade de considerar inflação da distribuição por zeros
- A escolha da função de verossimilhança impactou a qualidade da faixa de incerteza e os valores dos parâmetros obtidos na inferência
- A escolha de uma função de verossimilhança influencia a seleção de modelos

## OBJETIVO ESPECÍFICO 2

*Avaliar o desempenho de diferentes formulações do processo de interceptação*

- Melhor desempenho dos modelos de interceptação comparados à consideração de que a chuva líquida é uma proporção da chuva total: modelos promovem uma melhor representação do processo, apesar de elevada incerteza
- Pequena diferença entre as estruturas S03 e S04: elevado fator de cobertura nas duas bacias
- Os critérios de informação utilizados tenderam a favorecer modelos mais complexos: a inclusão de uma formulação de drenagem mais complexa foi justificada pela melhoria de desempenho promovida

## OBJETIVO ESPECÍFICO 3

*Avaliar o desempenho de diferentes estruturas de modelos chuva-vazão quando aplicados a duas bacias florestais*

- Os critérios de informação utilizados tenderam a favorecer modelos mais complexos
  -  Apenas valor máximo da função de verossimilhança é considerado
- As estruturas em paralelo promoveram uma melhor representação do processo, o que indica que as duas bacias apresentam um movimento vertical relevante
- Necessidade de aprimoramento dos modelos para obtenção de uma melhor representação da vazão observada

## OBJETIVO ESPECÍFICO 4

*Avaliar a influência da interceptação na modelagem do processo chuva-vazão*

- A consideração explícita do processo de interceptação na modelagem chuva-vazão resultou em melhores simulações (quando avaliada em termos do valor máximo da função de verossimilhança)
- Porém, a faixa de incerteza obtida em todos os casos testados foi muito similar
- Calibração dos parâmetros de interceptação junto com os demais parâmetros do modelo chuva-vazão pode levar a compensação de erros

## OBJETIVO GERAL

*Analisar como a inferência Bayesiana pode auxiliar na modelagem dos processos de interceptação e chuva-vazão*

- A análise Bayesiana permitiu que a comparação dos modelos fosse efetuada considerando a existência de diversas fontes de incerteza
- O método empregado agrega todos os erros (de cada passo de tempo) em uma única métrica → função de verossimilhança
  - ✓ Quantificação das incertezas a cada passo de tempo
  - ✗ Porém, pouca informação sobre como reduzir as incertezas

MUITO OBRIGADA!

---

# REFERÊNCIAS

CHAFFE, P.L.B. **Monitoramento e modelagem do processo chuva-vazão de uma pequena bacia florestal com ênfase em interceptação**. 2009. 100 f. Dissertação (Mestrado em Engenharia Ambiental) – Universidade Federal de Santa Catarina, Florianópolis, 2009.

FENICIA, F.; KAVETSKI, D.; SAVENIJE, H. H. G.; CLARK, M. P.; SCHOUUPS, G.; PFISTER, L.; FREER, J. Catchment properties, function, and conceptual model representation: Is there a correspondence? **Hydrological Processes**, v. 28, n. 4, p. 2451–2467, 2014.

MOTA, A. DE A. **Mecanismo de geração de vazão em pequena bacia experimental do bioma Mata Atlântica**. 2017. Tese (Doutorado em Recursos Hídricos e Saneamento) – Universidade Federal do Rio Grande do Sul, 2017.

SÁ, J.H.M. **Monitoramento e modelagem do processo de interceptação da chuva de uma bacia coberta por Floresta Ombrófila Mista**. 2015. 129 f. Dissertação (Mestrado em Engenharia Ambiental) – Universidade Federal de Santa Catarina, Florianópolis, 2015.

SADEGH, M.; VRUGT, J. A. Bridging the gap between GLUE and formal statistical approaches: Approximate Bayesian computation. **Hydrology and Earth System Sciences**, v. 17, n. 12, p. 4831–4850, 2013.

SCHOUUPS, G.; VRUGT, J. A. A formal likelihood function for parameter and predictive inference of hydrologic models with correlated, heteroscedastic, and non-Gaussian errors. **Water Resources Research**, v. 46, p. W10531, 2010.