

Verificação, Validação e Experimentação com Modelos de Simulação

Prof. Luís César da Silva

Email: silvalc@cca.ufes.br - Website: www.agais.com

A estruturação de modelos para a simulação de sistemas leva a organização de estruturas matemáticas que podem ser visualizadas como sendo uma função f que produz uma saída y a partir de entradas de x e parâmetros do sistema p , Figura 1, assim $y = f(x, p)$. Os fatores y , x e p podem ser uma única variável, ou um vetor, ou ainda uma matriz.

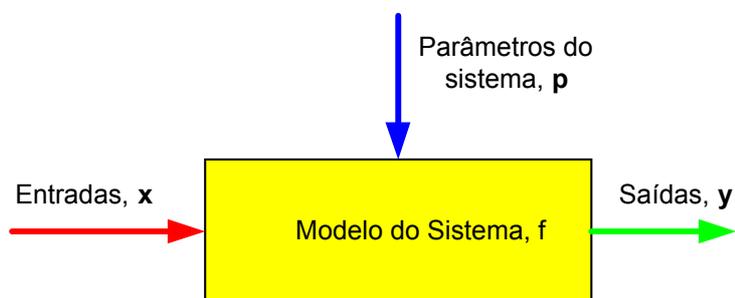


Figura 1 – Visualização de modelos de simulação, $y = f(x, p)$ (MENNEN, 1995).

Quando da elaboração de modelos de simulação o objetivo é utilizá-los como ferramenta de suporte ao processo de tomada de decisão. O que normalmente, requer a condução de experimentos, tais como: (i) análise de sensibilidade, (ii) comparação de cenários, (iii) otimização, e (iv) simulação de Monte Carlo. No entanto, para que os resultados dessas experimentações possam realmente ser utilizados, o modelo de simulação empregado deve passar pelos procedimentos de verificação e validação.

Conforme representado na Figura 2, quando da implementação de modelos de simulação três tipos de erros podem ocorrer: (i) Erro do Tipo I – os dados gerados pelo modelo são confiáveis, mas mesmo assim são rejeitados; (ii) Erro do Tipo II – os resultados apresentados pelo modelo não são apropriados, no entanto são aceitos como válidos; e (iii) Erro do Tipo III – o modelo foi mal estruturado conseqüentemente é inadequado para o uso.

Para evitar a ocorrência desses erros é recomendado conduzir os procedimentos de verificação e validação. E estes procedimentos constituem nas atividades mais árduas no desenvolvimento de modelos; e visam responder se o modelo representa com fidelidade os aspectos em estudo associados a um dado sistema.

O procedimento de verificação consiste em um conjunto de ações cuja meta é certificar se o modelo conceitual foi transcrito de forma adequada quando do uso da linguagem de

simulação ou de programação. Para a execução da verificação é recomendado: (i) envolver outras pessoas além dos idealizadores do modelo, (ii) rodar o modelo e proceder à comparação dos resultados gerados com os obtidos do sistema real, (iii) rastrear o programa e verificar a execução de cada rotina computacional, (iv) observar a animação e (v) analisar estatisticamente os valores gerados para as variáveis aleatórias, quer estas associadas as variáveis de entrada, parâmetros do sistema, ou variáveis de saída, Figura 1 (BALCI, 1997; MARIA, 1997).

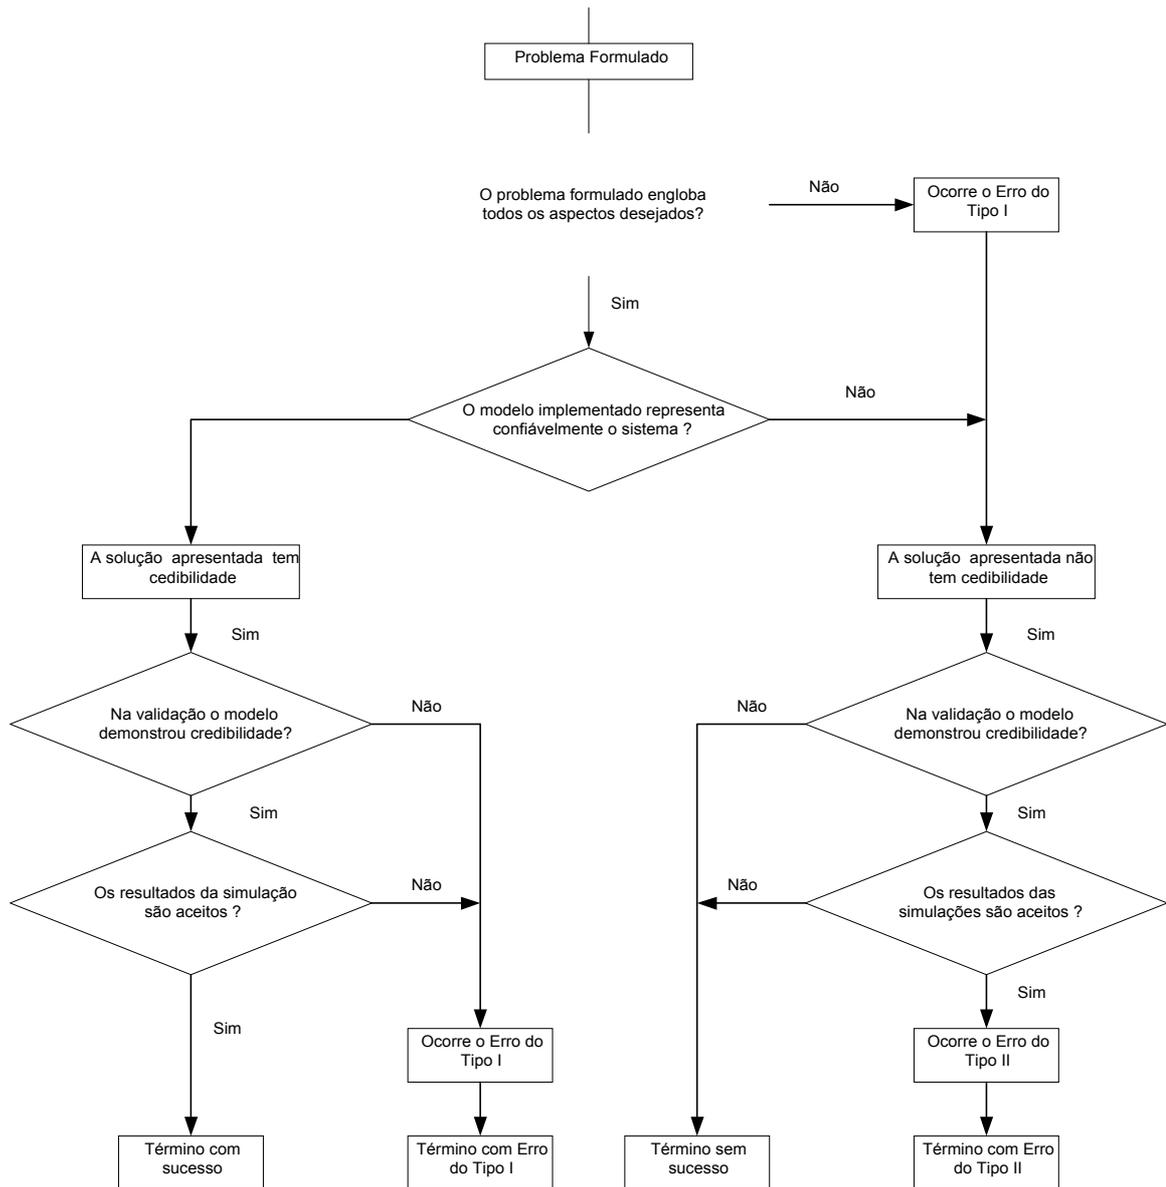


Figura 2 – Ocorrência de erros em estudos de simulação (BALCI, 1997).

É importante ressaltar que as tarefas associadas ao procedimento de verificação devem ser conduzidas durante as diferentes fases de implementação do modelo, e não somente ao final.

Quanto ao procedimento de validação, este objetiva certificar se a transformação entrada-saída (input-output) realizada pelo modelo tem precisão para representar a mesma ocorrência procedida no sistema real. Para condução desse procedimento deve-se: (i) rodar o modelo considerando mesmas condições impostas ao sistema e (ii) comparar os dados gerados pelo modelo e o sistema (BALCI, 1997). A validação pode ser realizada de forma subjetiva ou estatística (MENNER 1995).

A validação subjetiva é realizada quando não é possível conduzir incursões apropriadas sobre o sistema em estudo. Neste caso pode ser empregado, por exemplo, o Teste de Turing. Este consiste em: (i) obter os dados gerados pelo modelo e os do sistema, (ii) formatar os dados obtidos para um mesmo padrão e (iii) submeter os dois conjuntos de dados a equipe de especialistas. Caso estes profissionais não percebam diferenças entre os dois conjuntos de dados isto indica que o modelo está validado. Outra forma de proceder validação subjetiva é submeter a análise dos dados gerados pelo modelo a uma equipe de especialistas. Estes profissionais com base em suas experiências farão julgamento quanto a confiabilidade dos dados gerados (LAW e KELTON, 1991; WINSTON, 1994).

A validação estatística é realizada pelo emprego de procedimentos estatísticos como os apresentados na Tabela 1.

Tabela 1 - Estatísticas para análises aplicadas em verificação e validação de modelos

Categoria	Procedimento estatístico	
Estatística Descritiva	Medidas de posição (amostral)	Média
		Mediana
		Moda
	Medidas de dispersão (amostral)	Variância
		Desvio padrão
		Coeficiente de variação
		Erro padrão da média
		Amplitude total
Coeficiente de correlação amostral		
Hipóteses Estatísticas	Hipótese de Nulidade	
	Hipótese alternativa	
	Teste de Z	
		Teste de Aderência
	Teste do Qui-Quadrado (χ^2)	Teste de Independência
		Teste de homogeneidade
	Teste de F	
	Teste de t	
Teste de hipótese para dados emparelhados		

Para a aplicação dos processos destacados na Tabela 1 faz-se necessário a observância de fundamentos estatísticos, no que concerne ao tipo de variável, aleatória ou discreta, e se estas são independentes ou não.

No caso de variáveis aleatórias, por exemplo, a variável X_i que corresponde ao tempo de espera em um sistema de fila, gerada pelo modelo na simulação na roda de número, tem-se que após n rodadas será constituído o conjunto $\{X_1, X_2, \dots, X_n\}$. Esses valores serão independentes se as sementes dos geradores de números aleatórios foram escolhidas aleatoriamente. Desta forma, pode ser utilizado ferramentas disponibilizadas pela estatística clássica (Tabela 1) como: a média (equação 1), a variância amostral (equação 2), e o intervalo de variação da variável a um dado nível de probabilidade (equação 3).

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \quad (1)$$

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 \quad (2)$$

$$\bar{X} \pm t_{\alpha/2, n-1} \sqrt{\frac{s^2}{n}} \quad (3)$$

em que

$t_{\alpha/2, n-1}$ - representa um valor da distribuição t para $n-1$ graus de liberdade ao nível de probabilidade de $\alpha/2$.

Um exemplo de emprego da equação 3 é apresentado na Tabela 2. Neste caso são calculados os Limites Inferior e Superior tomando como ponto de referência a média dos dados obtidos do sistema real, assim:

$$\text{Limite superior} \rightarrow LS = M_s + t.Dp/\sqrt{n}$$

$$\text{Limite inferior} \rightarrow LS = M_s - t.Dp/\sqrt{n}$$

em que

M_s = média dos dados obtidos do sistema real;

D_p = desvio padrão dos dados gerados pelo modelo.

Calculados os limites é testado para cada nível de probabilidade se os valores máximos e mínimos estão contidos no intervalo de confiança. Se os valores estão contidos o teste é aceito caso contrário é rejeitado.

Tabela 2 – Uso do teste de t na determinação de intervalo de confiança quando praticado cinco rodadas de simulação

Rodada n°	Consumo de Energia Elétrica			Demanda de Energia Elétrica	
	MWh – FP	MWh – HP	Total kWh	kW -FP	kW-HP
1	160,20	19,17	179,37	233,46	204,02
2	152,53	19,39	171,92	247,63	204,02
3	159,06	19,44	178,50	233,46	204,02
4	158,59	19,21	177,80	247,63	218,19
5	166,90	20,15	187,05	247,63	196,94
Valor Máximo	152,53	19,17	171,92	233,46	196,94
Valor Mínimo	166,90	20,15	187,05	247,63	218,19
Desvio Padrão	5,108	0,387	5,389	6,986	7,720
Média Sistema Real	159,46	19,47	178,93	241,96	205,434
Intervalo de confiança segundo o teste t					
Confiança 99% t =	4,604	4,604	4,604	4,604	4,604
Limite Inferior	148,94	18,68	167,83	227,58	189,54
Limite Superior	169,97	20,27	190,02	256,35	221,33
Intervalo de confiança segundo o teste t					
Confiança 95% t =	2,776	2,776	2,776	2,776	2,776
Limite Inferior	153,12	18,99	172,24	233,29	195,85
Limite Superior	165,80	19,95	185,62	250,64	215,02
Intervalo de confiança segundo o teste t					
Confiança 90% t =	2,132	2,132	2,132	2,132	2,132
Limite Inferior	154,59	19,10	173,79	235,30	198,08
Limite Superior	164,33	19,84	184,07	248,62	212,80
Testes					
99%	Aceito	Aceito	Aceito	Aceito	Aceito
95%	Rejeitado	Rejeitado	Rejeitado	Aceito	Rejeitado
90%	Rejeitado	Rejeitado	Rejeitado	Rejeitado	Rejeitado

Obs: FP – fora do horário de pico; HP – horário de pico.

BARLAS (1989) sugere as seguintes práticas na execução de perdimentos quando da validação de modelo:

- Avaliar de tendências: consiste em proceder análise de regressão tendo por dados os gerados pelo modelo e os coletados do sistema real;
- Conduzir teste de autocorrelação (*autocorrelation function test*): é extensivamente utilizado em estimativas de modelos de séries temporais;

- Conduzir do o teste da correlação cruzada (*cross-correlation function test*): que consiste em determinar como duas séries temporais se assemelham. O que pode aplicado as séries correspondentes aos dados gerados pelo modelo e os coletados;
- Realizar o cálculo do erro percentual (equação 4);

$$E_1 = \frac{|\bar{S} - \bar{A}|}{|\bar{A}|} \cdot 100 \quad (4)$$

em que

\bar{S} - é a média dos dados simulados; e

\bar{A} - é a média dos dados observados no sistema.

- Avaliar a amplitude das variâncias (equação 5)

$$E_2 = \frac{|s_s - s_a|}{s_a} \quad (5)$$

em que

s_s - variância dos dados simulados; e

s_A - variância dos dados observados no sistema.

- Determinar o coeficiente de discrepância: este procedimento é recomendado somente para se ter um apanhado da performance do modelo. Portanto, deve ser aplicado após ter-se utilizado de outros procedimentos mais eficientes. Como forma de cálculo tem-se as proposta por Henry Theils (equação 6) e por Griner (equação 7):

$$U_o = \frac{\sqrt{\sum (S_i - A_i)^2}}{\sqrt{\sum S_i^2} + \sqrt{\sum A_i^2}} \quad (6)$$

$$U_o = \frac{\sqrt{\sum (S_i - \bar{S} - A_i + \bar{A})^2}}{\sqrt{\sum (S_i - \bar{S})^2} + \sqrt{\sum (A_i - \bar{A})^2}} \quad (7)$$

em que:

A_i - valor observado no sistema

S_i - valor simulado

Experimentação com modelos

Uma vez o modelo verificado, validado e especificado as condições de uso, este pode ser utilizado para conduzir experimentações tipo: (a) análise de sensibilidade, (b) comparação de cenários, (c) otimização, e (d) simulação de Monte Carlo.

1. Análise de sensibilidade: consiste em alterar o valor de um ou mais parâmetros do modelo e certificar o impacto sobre os valores das variáveis de saída. Por exemplo, no caso uma unidade industrial poderia ser verificado o impacto sobre a performance do sistema ao ser aumentada ou reduzida a produtividade em uma dada operação unitária.
2. Comparação de cenários: é aplicado quando o objetivo é fazer a comparação das diversas possíveis configurações. Nestas comparações é certificado a que melhor atende os anseios do tomador de decisão.
3. Otimização: tem por objetivo por meio do modelo buscar a configuração e/ou a forma operação do sistema que trás melhor desempenho. O que pode ser em termos técnicos e/ou econômicos.
4. Simulação de Monte Carlo: é aplicada a modelos do tipo estocástico. Para tanto, é necessário proceder a várias rodadas com o modelo, e em seqüência realizar análises estatisticamente dos resultados gerados. Deste modo, para uma dada variável será possível determinar as probabilidades de ocorrência de valores, bem como, o intervalo de confiança.

Referências

KRAHL, A. The Extend Simulation Environment. In: The 2000 Winter Simulation Conference. Piscataway: NJ, IEEE, **Proceedings**. 2000. p. 280-289.

LAW, A. M., KELTON, W. D. **Simulation modeling & analysis**, 2nd Edition, McGraw Hill, Inc: New York. 1991.

MARIA, A. Introduction to Modeling and Simulation. In: The 1997 Winter Simulation Conference. Piscataway: NJ, IEEE, **Proceedings**. 1997. p. 7-13.

Menner, W. A. Introduction to modeling and simulation. **Johns Hopkins APL Technical Digest** 16(1): 6:17. 1995

Neelamkavil, F. **Computer simulation and modeling**. Great Britain: John Wiley & Sons Ltd. 1987.

RIVERA, J. Modeling with Extend. In: The 1997 Winter Simulation Conference. Association of

Computer: New York, **Proceedings**. 1997. p. 674-676

SILVA, L. C. **Stochastic simulation of the dynamic behavior of grain storage facility**. 2002. Tese (Doutorado em Engenharia Agrícola.) Universidade Federal de Viçosa. Viçosa: MG.

WINSTON, W. L. **Operations research - applications and algorithms**. In. International Thomson Publishing. Belmont, California. 1994. 1312p.