



## PRINCÍPIOS DE MODELAGEM DE SISTEMAS AGRÍCOLAS

### Introdução

A modelagem de sistemas agrícolas baseada em processos biofísicos, isto é, realizada por modelos mecanísticos, apresenta diversas aplicações, sendo algumas delas descritas por Lisson et al. (2005) como: a) impacto do plantio e da colheita sobre a produtividade da cana-de-açúcar, onde os dados podem ser analisados para tomada de decisão mais adequada sobre melhor época de plantio e colheita; b) benchmarking dos limites de produção, potenciais e atingíveis, onde o conhecimento dos limites de produção permite o estudo da produtividade potencial em diferentes regiões; c) melhoria da eficiência do uso da água; d) previsão de produtividade.

Em resumo, pode-se definir um modelo como uma caracterização de um sistema real, que pode ser representado com um simples desenho do sistema analisado, como uma simples descrição verbal escrita, ou ainda como um complexo conjunto de equações para ser utilizada na descrição numérica de um dado sistema. No contexto deste trabalho, pode-se definir modelos de culturas como um simulador dinâmico do crescimento de um cultivo por meio de integração numérica de seus processos biofísicos constituintes com a ajuda de computadores, sendo, portanto, uma técnica para a construção de uma “cópia” relativamente transparente da cultura no campo (Sinclair & Seligman, 1996).

Modelo pode, também, ser definido como um conjunto de algoritmos organizados que descrevem um sistema. Segundo Soler (2004), um modelo simula uma cultura pela estimativa do crescimento de seus componentes como folhas, raízes e caule. Assim, um modelo de crescimento de cultura não somente estima a biomassa total, mas também inclui mais informações quantitativas sobre a maioria dos processos envolvidos no crescimento e desenvolvimento vegetal. Monteith (1996) definiu que modelos de simulação de cultura são como um conjunto de equações relacionadas a processos biofísicos para estimar o crescimento, desenvolvimento e produção de uma cultura a partir de coeficientes genéticos e de variáveis ambientais, permitindo analisar diversos componentes da produção.

O entendimento básico e a consideração dos processos biofísicos-chave para a cultura, e as interações com outros processos no sistema de produção agrícola são os fundamentos para a modelagem de culturas agrícolas. Baseado nesses princípios vários sistemas de suporte à decisão podem ser construídos como ferramenta de suporte a gestão de um setor da agricultura. Exemplos de aplicações são: a seleção de genótipos ou locais para instalação de novas áreas produtivas; avaliação estratégica das melhores formas de manejo de cultivos; investimentos em infraestrutura e decisões de marketing (Lisson et al., 2005).

A necessidade por sistemas dessa natureza emergiu principalmente no início da década de 1990 como uma consequência da aplicação da análise sistêmica ao setor agrícola. Isso, por sua vez, foi viabilizado principalmente pelo aumento na necessidade de informações para a tomada de decisão no setor agrícola, o que por sua vez, decorreu principalmente pelo aumento nas pressões sociais e políticas envolvendo o uso da terra, da água e outros recursos naturais (Jones et al., 2003). Com isso, a geração de novos dados através do pensamento tradicional da pesquisa agrícola e sua publicação não eram suficientes para atender essa nova demanda. Experimentos agrônômicos tradicionais são conduzidos em parcelas experimentais definidas no espaço e no tempo, tornando, portanto, os resultados derivados específicos no espaço e no tempo, demandantes de tempo e de grande montante de recursos financeiros. Neste sentido, McCown et al. (1996) afirmam que entre as muitas mudanças que se observaram na agricultura e nas instituições de pesquisa do mundo ocidental, destaca-se um aumento considerável no reconhecimento de que a análise sistêmica é necessária para atingir os ousados objetivos trazidos pela complexidades, incertezas e conflitos dos sistemas de produção agrícola contemporâneos.

Em geral, modelos de culturas agrícolas podem ser classificados com base no modo como eles descrevem dados observados em termos das leis biofísicas ou apenas utilizando relações matemáticas sem qualquer relação com leis da física (Dourado-Neto et al., 1998b), como as leis termodinâmicas de conservação da energia, com o conhecimento fisiológico sobre a cultura, ou mesmo por qualquer outro conhecimento disponível sobre a estrutura do sistema. Estes últimos são chamados modelos empíricos, enquanto que aqueles em que os modeladores tentam reconstruir uma descrição do comportamento do sistema baseado em submodelos descrevendo os processos biofísicos da cultura e se possível até os níveis hierárquicos mais baixos de organização. Modelagem de culturas baseada em processos é chamada de “*hard science*” na língua inglesa e segue a tradicional abordagem reducionista que tem sido bem sucedida nas ciências físicas, fisiologia vegetal e bioquímica (Thornley & Johnson, 1990). Nas ciências agrícolas é comum denominar-se os modelos de culturas como uma abreviação para os modelos mecanísticos de culturas baseados em processos biofísicos, para enfatizar que essa abordagem da modelagem considera processos fisiológicos e físicos controlando o desenvolvimento da espécie e sua relação com o ambiente e fatores de manejo da cultura.



Sistemas de suporte à decisão são compostos por vários programas de computador tendo como um componente central os modelos de culturas descrevendo relações entre a cultura, a atmosfera, o solo e componentes bióticos do sistema.

Utilizando modelos de cultura, por exemplo, pode-se analisar e manipular um dado sistema produtivo com muito mais facilidade e rapidez do que seria possível considerando toda a complexidade do sistema real. Ao longo do século 20, houve um desenvolvimento científico sem precedentes em decorrência de uma mistura dos métodos de indução e dedução. A indução parte das observações específicas para leis gerais, enquanto que a dedução parte de princípios gerais para realizar previsões específicas. Desde a década de 1960, modelos baseados em processos têm sido desenvolvidos e refinados passo a passo guiados por resultados experimentais que preenchiam pouco a pouco pequenas lacunas no conhecimento em oposição aos grandes e onerosos experimentos (Overman & Scholtz III, 2002).

Uma das formas cientificamente aceitas para a análise de impactos das mudanças climáticas na agricultura é o uso de modelos de crescimento de plantas (MCP), baseados em processos biofísicos que ocorrem em culturas (do inglês, *process based crop model*) (Rosenzweig et al., 2013), que são ferramentas consagradas na literatura científica para testes de hipóteses acadêmicas, bem como de avaliação de cenários e de impacto de mudanças climáticas na agricultura em escalas mundial (Rosenzweig & Parry, 1994), nacional (Adams et al., 1990) e regional (Marin et al., 2012). No entanto, apesar da importância desses modelos, uma das incertezas nas projeções agrícolas decorre, também, dos próprios modelos.

A comunidade de modeladores do clima tem atacado o problema da incerteza<sup>1</sup> utilizando agrupamentos (do inglês, *ensembles*) de modelos de circulação geral da atmosfera (Semenov & Stratonovitch, 2010). Os MCP's, contudo, são ainda utilizados com uma abordagem determinística, sem contar com uma análise probabilística adequada a despeito das incertezas associadas em seus algoritmos, dados de entrada e parâmetros (Rötter et al., 2011). A opção para enfrentar essa limitação, é o uso de um conjunto de MCP's em paralelo, adequadamente calibrados, em analogia aos *ensembles* dos modelos climáticos. Por exemplo, em trigo (Rötter et al., 2012) e cevada (Palosuo et al., 2011), foram utilizados nove diferentes MCP's para as simulações de efeitos da mudança no clima nessas culturas na Europa. Uma conclusão interessante dos trabalhos foi que nenhum dos modelos mostrou-se superior para todos os locais testados e que a média das previsões de todos os modelos mostrou-se a mais adequada para as simulações de produtividade. Asseng et al. (2013) encontraram resultados similares utilizando 27 modelos de trigo, mas verificaram que apenas três modelos escolhidos aleatoriamente seriam suficientes para reduzir a incerteza a nível suficientemente baixo.

Merece destaque o fato de o trabalho de Asseng et al. (2013) ter sido publicado em periódico de altíssimo impacto (Nature Climate Change) por se revelar uma verdadeira ruptura nas limitações previamente atribuídas ao uso dos MCP's em larga escala. Até poucos anos atrás, por tratarem de processos biofísicos relativamente detalhados do sistema de produção agrícola, tais modelos eram considerados como dedicados à simulação de pequenas parcelas, sem possibilidade de extrapolação para grandes áreas. O trabalho de Asseng et al. (2013), por verificar que uso de múltiplos modelos em paralelo foi capaz de reduzir a incerteza para níveis similares aos obtidos nos sítios experimentais, demonstrou a capacidade dessa ferramenta para aplicações operacionais em larga escala.

O estado da arte no estudo dos MCP's, contudo, aponta que a próxima fronteira nessa linha de pesquisa é a incorporação da simulação estocástica nesse contexto, permitindo assim conhecer como a incerteza dos dados de entrada se propaga nas variáveis de saída do modelo. Além disso, uma necessidade importante no âmbito da abordagem estocástica é considerar a correlação entre as variáveis consideradas aleatórias durante o processo de simulação, permitindo assim projetar as incertezas dos parâmetros e/ou dados de entrada no resultado final das simulações de modo biofísicamente coerente e evitando incluir incertezas não pertencentes a condição de contorno do sistema simulado (Baigorria & Jones, 2010). Neste sentido, considerando o argumento de Sinclair & Seligman (1996) sobre a importância do desenvolvimento dos próprios modelos para grupos de cientistas, permitindo aprofundar o conhecimento sobre os mecanismos envolvidos no processo de simulação e sobre as incertezas inerentes ao uso de modelos, essa abordagem estocástica seria uma oportunidade para o Brasil.

## 11.2 Conceitos e Definições

Um modelo é um padrão, um plano, uma representação ou descrição feita para demonstrar o funcionamento de um objeto, um sistema, ou conceito. Do latim a palavra modelo tem origem em *modulus*, que significa uma pequena proporção ou redução de um padrão. Modelos de simulação são representações relativamente simples do mundo real a nossa volta.

Modelos podem ser classificados de várias formas e, didaticamente, são normalmente divididos em modelos empíricos e mecanísticos (Thornley & Johnson, 2000). Modelos empíricos são fundamentalmente

<sup>1</sup> Qualquer desvio em relação a um valor ideal obtido a partir de um conhecimento determinístico supostamente completo sobre um sistema.

relações matemáticas descritas a partir da observação do sistema, por informações biológicas ou por qualquer conhecimento da estrutura do sistema estudado. Consistem em uma ou mais equações, e normalmente estão associados a características locais, com dificuldade para sua extrapolação.

Os modelos mecanísticos são relativamente mais complexos que os modelos empíricos. Entretanto, seu conteúdo normalmente aplica-se a uma maior gama de fenômenos. Baseiam-se na física e nos processos fisiológicos envolvidos no crescimento da cultura e, por este motivo, oferecem mais respostas mais consistentes. Wallach et al. (2001) afirmaram, os modelos mecanísticos tornaram-se cada vez mais importantes nos últimos anos como ferramentas de ensino e pesquisa, bem como ferramentas de auxílio a tomada de decisão sobre o manejo de culturas.

Quando aplicados a sistemas biológicos, a simulação mecanística é altamente recomendada, uma vez que sistemas vivos são compostos por subsistemas e componentes e cada um deles interage simultaneamente com os demais de modo não-linear e caótico, por natureza. Por causa dessa complexidade, métodos clássicos (matemáticos-estatísticos) aplicados a sistemas vivos têm se mostrado inadequados para sistemas vivos (Jones & Lyuten, 1998). Essa interação não linear deve-se, em última instância a organização hierárquica dos sistemas (que dá origem aos subsistemas, como exemplifica a Figura 11.1.

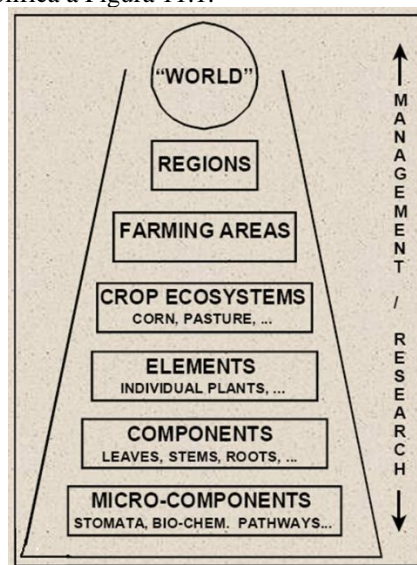


Figura 11.1. Representação esquemática dos sistemas biológicos ilustrando sua dependência em relação aos processos biofísicos que atuam em escalas inferiores. (Extraído de Jones & Luiten, 1998).

Conforme apresentado na Figura 11.2, o modelo empírico procede diretamente para as variáveis de interesse sobre a cultura, conectando as variáveis de entrada e saída em qualquer caminho que apresente um bom ajuste dos dados. Os modelos mecanísticos, no entanto, têm uma rota relativamente mais longa, já que em seus componentes precisam respeitar a ordem dos processos e suas respectivas propriedades, introduzindo variáveis extras no nível de órgãos, tecidos e agregados bioquímicos onde dados de observações adicionais geralmente também são disponíveis. Pela síntese e integração do conjunto de equações que definem o sistema, chega-se então às variáveis de interesse da cultura, como massa de colmos e teor de sacarose, por exemplo.




Figura 11.2 Representação esquemática da relação entre modelagem empírica e mecanística (Adaptado de THORNLEY e JOHNSON, 2000)



Boote et al. (1996) classificaram três níveis de uso dos modelos de simulação de culturas: modelos utilizados em pesquisas, modelos para uso em análises tecnológicas sobre o manejo dos cultivos e modelos para suporte à política de planejamento agrícola. Cada um deles envolve uma escala espaço-temporal, um nível de detalhamento dos processos modelados e um nível de compromisso com a aplicação operacional.

Thornley & Johnson (2000), por sua vez, classificam os modelos em dois grupos principais: os de aplicação em pesquisas e os de aplicação prática (Tabela 11.1). Os modelos aplicados em pesquisa, por serem mais detalhados, baseados em processos e possuem um maior número de parâmetros, tendem a apresentar respostas mais próximas da realidade. Já os modelos de aplicação prática, por serem mais simples e baseados em equações empíricas, resultam em aproximações mais superficiais, tendo aplicações específicas para os pontos nos quais foram calibrados e maior dificuldade para extrapolação e condições de contorno mais limitadas. Atualmente, dada a boa disponibilidade de dados de entrada e mesmo o domínio relativamente avançado nas técnicas de simulação, tem-se cada vez mais utilizado os modelos de simulação inicialmente classificados como "pesquisa" em aplicações práticas, elevando a qualidade das predições e da tomada de decisão.

Tabela 11.1 - Modelos de pesquisa e modelos aplicados: comparação das principais diferenças (Adaptado de THORNLEY e JOHNSON, 2000)

Características	Pesquisa	Aplicação Prática
Hipóteses	Especulativa	Bem aceito
Conexões com dados observados	Tênue (geralmente)	Bom
Precisão das previsões	Variável	Bom
Escopo/Alcance	Amplio	Limitado
Complexidade	Complexo	Simple
Modelo	Mecânico	Empírico

Outra classificação possível envolve o modo pela qual as variáveis de estado de um modelo são simuladas. Neste contexto, pode-se dividir modelos em determinísticos e estocásticos. Os modelos determinísticos têm suas variáveis de estado determinadas unicamente por seus parâmetros e pelos valores prévios das variáveis de estado. Portanto, eles do mesmo modo dado as mesmas condições iniciais. Nos modelos estocásticos, um componente aleatório está presente e as variáveis de estado não são descritas por um único valor. Ao contrário, elas são descritas por distribuições de probabilidade. Normalmente utiliza-se o método de Monte Carlo para a geração de parâmetros aleatórios.

Em modelagem de sistemas biológicos, há uma terminologia convencionada pela comunidade científica que contribui para a comunicação. Os principais termos utilizados são os seguintes:

- **Sistema:** coleção de componentes e suas inter-relações, agrupadas com o propósito de estudar alguma parte do mundo real. Dependente da visão do modelador sobre a realidade e do propósito da modelagem.
- **Ambiente e condições de contorno:** na definição do escopo de um sistema, é necessário definir seus limites e seu conteúdo. O ambiente inclui tudo, com exceção dos componentes do sistema. Ambiente afeta o sistema, mas o sistema não afeta o ambiente.
- **Modelo:** Representação matemática de um sistema. Conjunto de equações na forma de códigos de programação que quantifica o conhecimento sobre o sistema. Em agricultura, por exemplo, **sistema** pode ser uma cultura; seus **elementos** podem ser as folhas, raízes, colmos, flores e frutos, e seus **processos**, a transpiração, fotossíntese, respiração, crescimento radicular, particionamento.
- **Entradas e saídas:** variáveis de entrada (variáveis exógenas) são grandezas do ambiente que afetam o comportamento do sistema, mas não são influenciados por ele. Variáveis de saída representam numericamente o comportamento do sistema que é de interesse para o modelador. Na modelagem agrometeorológica, há especial interesse em analisar variáveis meteorológicas e sua repercussão nos modelos.
- **Parâmetros e Constantes:** são características dos componentes do sistema que permanecem inalteradas ao longo de uma simulação. **Constantes** são grandezas com valores suficientemente confiáveis que permanecem fixos ainda que as condições experimentais sejam modificadas. **Parâmetros** são grandezas com maior incerteza e que podem ser alterados para configurar o modelo a uma situação específica de simulação.
- **Variáveis de Estado:** são grandezas que descrevem os componentes do sistema, mudando com o tempo conforme os componentes interagem entre si e com o ambiente.
- **Calibração:** consiste em ajustar parâmetros para aproximar as simulações dos dados observados experimentalmente. A estrutura do modelo, portanto, permanece a mesma. Em alguns casos, a calibração é o único meio prático de estimar o valor de alguns parâmetros considerados em processos biológicos.

- **Validação:** é o processo de comparação das variáveis de saída com dados experimentais que não foram utilizados na calibração.
- **Análise de Sensibilidade:** consiste na exploração do desempenho de um modelo pela variação nos valores dos parâmetros. A finalidade dessa análise é quantificar quanto a variação em um parâmetro influencia nas variáveis de saída de um modelo. Pode-se agrupá-las grosseiramente em dois modos de análise: local e global.

Esses termos normalmente precisam ser representados esquematicamente com vistas a esclarecer sobre o sistema a ser tratado, mantendo igualmente um padrão de comunicação visual entre os interessados no modelo. Uma das opções neste sentido é o diagrama de Forrester (Figura 10.3), desenvolvido para aplicações industriais e que foi adotado por modelagem de sistemas biológicos.




Figura 10.3 Representação esquemática da simbologia utilizada nos diagramas de Forrester.

### 10.3 Linguagens de programação

Quando se necessita implementar um modelo em um computador, é válido relembrar que a melhor linguagem para fazê-lo é aquela que você conhece bem. Para aqueles que ainda não dominam nenhuma linguagem de programação, vale lembrar que uma das principais e mais antigas linguagens de programação em modelagem de sistemas biológicos é o Fortran. Ele foi desenvolvido a partir da década de 1950 e continua a ser usada hoje em dia e seu nome é um acrônimo da expressão "IBM Mathematical **FOR**mula **TRAN**slation System". A linguagem Fortran é principalmente usada em Análise Numérica. Apesar de ter sido inicialmente uma linguagem de programação procedural, versões recentes de Fortran possuem características que permitem suportar programação orientada por objetos. O Fortran permite a criação de programas que primam pela velocidade de execução. Daí reside seu uso em aplicações científicas computacionalmente intensivas como meteorologia, oceanografia, física, astronomia, geofísica, economia e modelagem agrícola.

### REFERÊNCIAS

Dourado-Neto, D.; Teruel, K.; Reichardt, D.R.; Nielsen, J.A.; Frizzone; Bacchi, O.O.S. Principles of Crop Modeling and Simulation: I. Uses of Mathematical Models in Agricultural Science. Scientia Agricola, Piracicaba, v.55, p.46–50, 1998.



UNIVERSIDADE DE SÃO PAULO  
ESCOLA SUPERIOR DE AGRICULTURA "LUIZ DE QUEIROZ"  
DEPARTAMENTO DE ENGENHARIA DE BIODIVERSIDADE  
FÁBIO R MARIN; QUIRJN DE JONG VAN LIER



Dourado-Neto, D.; Teruel, D.A.; Reichardt, K.; Nielsen, D.R.; Frizzone, J.A.; Bacchi, O.O.S. Principles of Crop Modelling and Simulation: II. The Implications of the Objective in Model Development. *Scientia Agricola*, Piracicaba, v.55, p.51–57, 1998.

McCown, R.L., Hammer, G.L., Hargreaves, J.N.G., Holzworth, D.P., Freebairn, D.M., 1996. APSIM: a novel software system for model development, model testing and simulation in agricultural systems research. *Agricultural Systems* 50, 255–271. doi:10.1016/0308-521X(94)00055-V

Sinclair, T.R.; Seligman, N.G. Crop Modeling: From Infancy to Maturity. *Agronomy Journal*, Madison, v.88, p. 698–704, 1996.

Thornley, J.H.M., Johnson, I.R., 1990. Plant and crop modelling: a mathematical approach to plant and crop physiology. Clarendon Press.

Wallach, D., Goffinet, B., Bergez, J.E., Debaeke, P., Leenhardt, D., Aubertot, J.N., 2001. Parameter estimation for crop models: a new approach and application to a corn model. *Agronomy Journal* 93, 757.