

Aula 2

2. PRINCÍPIOS DE MODELAGEM DE SISTEMAS AGRÍCOLAS

2.1. 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 da 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.

Pode-se definir um modelo como uma caracterização de um sistema real, 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. Como exemplo, um modelo mecanístico de crescimento vegetal realiza simulações pela estimativa do crescimento dos componentes vegetais como folhas, raízes e caule. Assim, um modelo de crescimento de cultura não somente estima a biomassa total, mas também inclui 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 apoio 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 agronômicos 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 preenchem 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 incerteza¹ 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

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

interessante dos trabalhos foi que nenhum dos modelos mostrou-se superior para todos os locais testados e que a média das predições 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.

2.2. Tipos de modelos

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

Os modelos mecanísticos são estruturalmente mais complexos que os modelos empíricos. Entretanto, seu conteúdo normalmente aplica-se a uma maior gama de fenômenos. Baseiam-se nos processos envolvidos e, por este motivo, oferecem respostas mais consistentes. Os modelos mecanísticos tornaram-se 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 (Dourado-Neto et al., 1998a; Wallach et al., 2001).

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 & Luyten, 1998). Essa interação não linear deve-se, em última instância a organização hierárquica dos sistemas (que dá origem aos subsistemas, como exemplifica a Figura 1.

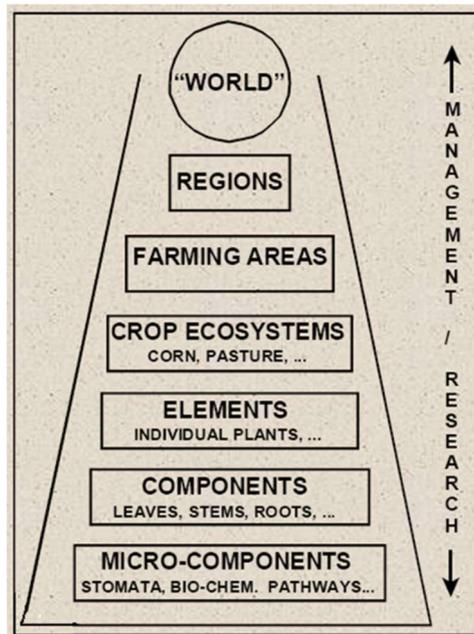


Figura 1. Representação esquemática dos sistemas biológicos ilustrando sua dependência em relação aos processos biofísicos que atuam em escalas inferiores. (Extraído de Jones & Luyten, 1998).

Os modelos empíricos procedem 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 (Figura 2). 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 mais variáveis para a descrição 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.

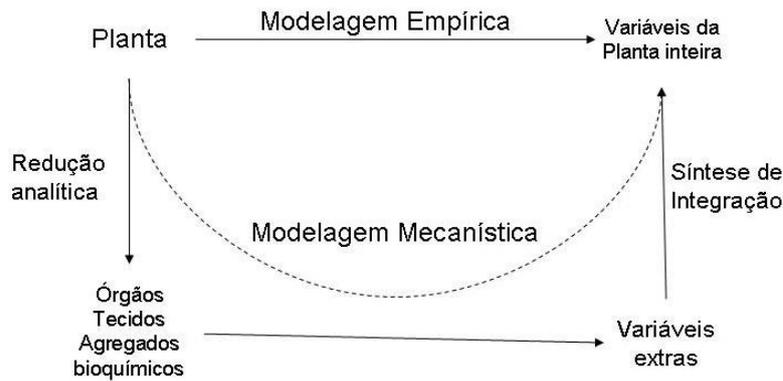


Figura 2 Representação esquemática da relação entre modelagem empírica e mecanística (Adaptado de Thornley e Johnson, 2000)

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 1). Os modelos aplicados em pesquisa, por serem mais detalhados, baseados em processos e possuírem um maior número de parâmetros, tendem a apresentar respostas mais próximas da realidade. Por sua vez, os modelos de aplicação prática, 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, modelos de simulação inicialmente classificados como “pesquisa” tem sido utilizado os em aplicações práticas, elevando a qualidade das predições e da tomada de decisão.

Tabela 1 - Modelos de pesquisa e modelos aplicados: comparação das principais diferenças (Adaptado de Thornley & Johnson, 2000)

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

Uma outra classificação de modelos se baseia no modo pela qual as variáveis de estado de um modelo são simuladas. Neste contexto, os modelos se distinguem 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 oferecem as mesmas respostas dadas 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.

2.3. Modelagem aplicada a agricultura

Uma etapa que antecede ao processo de modelagem propriamente dita é a definição das condições de contorno dos modelos agrícolas a serem contruídos. Para tanto, é comum se estabelecer níveis de produtividade para facilitar esta definição. Por exemplo, em ambiente tropical, durante os dias com céu claro, alta temperatura e suprimento adequado de água no solo, a utilização da energia solar para a atividade fotossintética pode ser limitada pelo teor de dióxido de carbono na atmosfera, pela estrutura não eficiente do dossel (com sombreamento mútuo das folhas, por exemplo) e pela deficiência nutricional às plantas. Quando estes fatores são favoráveis, contudo, a taxa de produção de matéria seca é denominada de potencial (Y_p), por atingir um nível teórico máximo. Outros dois termos relacionados à interação da vegetação com o ambiente são a produtividade atingível e produtividade real (Figura 2). De modo geral, a produtividade real é o termo mais familiar àqueles que estão envolvidos com o setor produtivo, uma vez que os dados comerciais ou mesmo as estatísticas oficiais de produtividade da cana-de-açúcar são valores que informam sobre a produtividade real (ou atual) de um talhão ou de

uma região produtora. Por definição, produtividade real (Y_r) é a produtividade alcançada de fato em condições operacionais de uma usina, no caso da cana-de-açúcar em talhões agrícolas comerciais. Para representar a variabilidade espaço-temporal observada em uma dada região, utiliza-se um valor médio (no tempo e no espaço), que representaria o padrão tecnológico adotado. A Y_p é definida com a aquela obtida por um genótipo adaptado sob condições ótimas de cultivo, sem qualquer fator limitante (água) ou redutores, (pragas, doenças, nutrientes) ao seu crescimento. Por fim, tem-se que a produtividade atingível (Y_w) é aquela obtida por um genótipo adaptado sob condições reais de cultivo, sob influência desfavorável de um ou mais fatores limitantes (água) ou redutores, (pragas, doenças, nutrientes) ao seu crescimento.

Segundo van Ittersum et al. (2013), o termo produtividade potencial (Y_p) refere-se à produtividade de uma cultivar crescendo sem limitação quanto ao suprimento hídrico ou nutricional e sem qualquer limitação quanto ao estresse biótico causado por pragas e doenças (Evans, 1993; van Ittersum & Rabbinge, 1997). Quando este mesmo cultivo cresce sob condições em que pode atingir Y_p , a taxa de crescimento da cultura é determinada apenas pela radiação solar, a temperatura, a concentração de CO_2 na atmosfera ($[CO_2]$) e as características genéticas que controlam a duração do ciclo do cultivo e a interceptação de radiação pela copa da planta (i.e. arquitetura da copa). Portanto, Y_p é específico de cada local por causa do clima, mas não do solo, porque em teoria o solo pode ter suas propriedades corrigidas por técnicas adequadas de manejo. Assim, em áreas com boas condições de solo, Y_p é mais relevante como referência para sistemas irrigados ou sob condições climáticas de adequado suprimento hídrico durante a estação de cultivo. Para cultivos de sequeiro, contudo, a produtividade limitada por água (Y_w), equivalente à produtividade potencial decrescida apenas pelo estresse hídrico, parece mais adequada como indicador de referência de produtividade (ou como *benchmark* regional). Nos cultivos parcialmente irrigados, tanto Y_p como Y_w podem servir como úteis valores de referência. Portanto, a definição de Y_w é similar à de Y_p , porém em Y_w a cultura sofre algum estresse por falta d'água e, portanto, é dependente do tipo de solo que afeta a sua capacidade de retenção de água, a profundidade do sistema radicular e da topografia do terreno, que influencia o *runoff*. Tanto Y_p como Y_w são calculados para as melhores datas de plantio/semeadura, densidade populacional e variedades.

A produtividade média comercial (Y_a) é definida como aquela de fato obtida pelos produtores, representando a variabilidade no espaço e no tempo numa dada região geográfica. Ela é definida pela média das produtividades obtidas pelos produtores da região envolvendo as mais variadas práticas de manejo (datas de plantio/semeadura e colheita, variedades,

densidade populacionais, manejo nutricional e proteção da cultura contra pragas e doenças). O número de anos utilizado para estimar Y_a precisa levar em conta um período suficientemente longo para considerar a variabilidade climática sem, contudo, confundir efeitos temporais associados às tendências de produtividade decorrentes da melhoria tecnológica ou mudança no clima (van Ittersum et al., 2013).

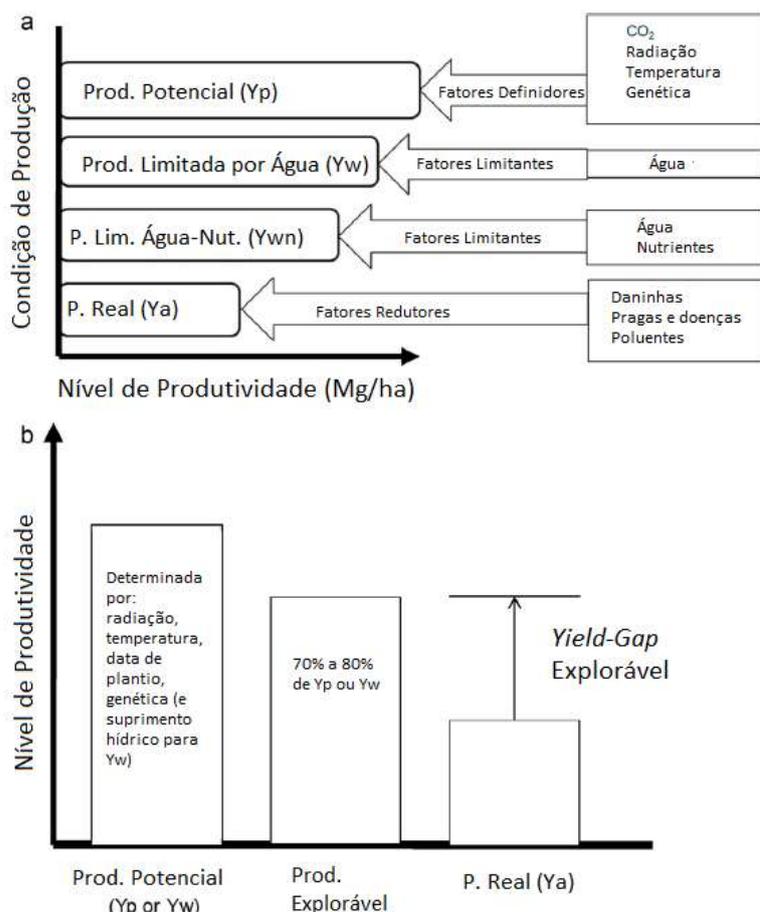


Figura 3 - Níveis de produção e seus respectivos fatores determinantes/limitantes (a). Produtividade potencial (Y_p) de culturas sem limitação hídrica (Y_w para culturas de sequeiro) e seus respectivos fatores determinantes é determinada pela radiação solar, regime térmico e duração do ciclo de cultivo. O yield-gap representa a diferença entre a produtividade explorável (70% a 80% de Y_p ou Y_w) e a produtividade real (Y_a). Adaptado de van Ittersum et al. (2013)

2.4. Linguagens de programação

A implementação de um modelo ocorre normalmente na forma de um software, desenvolvido em alguma linguagem de computador. A melhor linguagem para fazê-lo é aquela

que o desenvolvedor 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.

2.5. Referências

- Asseng, S., F. Ewert, C.F. Rosenzweig, J.W. Jones, J.L. Hatfield, A.C. Ruane, et al. 2013. Uncertainty in simulating wheat yields under climate change. *Nat. Clim. Change* 3:827–832. doi:10.1038/nclimate1916
- Baigorría, G.A., and J.W. Jones. 2010. GiST: A stochastic model for generating spatially and temporally correlated daily rainfall data. *J. Clim.* 23:5990–6008. doi:10.1175/2010JCLI3537.1
- 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.
- 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.
- Evans, L.T. *Crop Evolution, Adaptation, and Yield*. Cambridge, UK: Cambridge University Press, 1993. 345p.
- Jones, J.W. and Luyten, J.C. 1998. Simulation of Biological Processes. In: Peart, R.M. and Curry, R.B. (eds). *Agricultural Systems Modeling and Simulation*. Marcel Dekker Inc. ISBN 0-827-0041-4.
- Keen, R. E. and J. D. Spain. 1992. *Computer Simulation in Biology: A Basic Introduction*. Wiley-Liss Inc. New York.
- 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.
- van Ittersum, M.K., Cassman, K.G., Grassini, P., Wolf, J., Tittonell, P., Hochman, Z., 2013. Yield gap analysis with local to global relevance - A review. *Field Crops Research* 143, 4–17.
- Van Ittersum, M.K.; Cassman, K.G.; Grassini, P.; Wolf, J.; Tittonell, P.; Hochman, Z. Yield gap analysis with local to global relevance—a review. *Field Crop Research*. 2013. <http://dx.doi.org/10.1016/j.fcr.2012.09.009>.
- Van Ittersum, M.K.; Rabbinge, R. Concepts in production ecology for analysis and quantification of agricultural input-output combinations. *Field Crops Research*, Amsterdam, v.52, p.197–208, 1997.
- Wallach, D., D. Makowski, and J. W. Jones (eds.). 2006. *Working with Dynamic Crop Models: Evaluation, Analysis, Parameterization, and Applications*. Elsevier. New York. ISBN 0-444-52135-6.
- 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* 93:757-766.