

# Revisão sobre modelagem da avaliação do rendimento considerando a influência da variabilidade temporal em espécies frutíferas perenes

*Review on yield evaluation modeling considering the influence of temporal variability in perennial fruit crops*

Luciano Gebler<sup>1</sup>, Renata Bulling Magro<sup>2</sup>, Eduardo Antonio Speranza<sup>3</sup>

<sup>1</sup> Pesquisador, Embrapa Uva e Vinho, Vacaria (RS), Brasil, [luciano.gebler@embrapa.br](mailto:luciano.gebler@embrapa.br)

<sup>2</sup> Doutoranda, Universidade de São Paulo, São Carlos (SP), Brasil, [renatamagro4@gmail.com](mailto:renatamagro4@gmail.com)

<sup>3</sup> Analista, Embrapa Agricultura Digital, Unicamp, Barão Geraldo, Campinas (SP), [eduardo.speranza@embrapa.br](mailto:eduardo.speranza@embrapa.br)

## RESUMO

Um objetivo importante da fruticultura de precisão é compreender e gerenciar os padrões de variações espaciais e temporais do rendimento. A adoção de tecnologias para coleta e avaliação de dados obtidos em campo ao longo de períodos produtivos pode contribuir para o estabelecimento de padrões que auxiliem no manejo da área agrícola. O objetivo deste trabalho foi realizar uma revisão narrativa da literatura sobre os métodos utilizados para a avaliação do rendimento de culturas frutíferas perenes, destacando as atuais limitações metodológicas e as perspectivas de desenvolvimento. A partir dos trabalhos revisados, foi possível estabelecer distinções entre estratégias de avaliação, tipos de variáveis, classes de modelagem e modelos utilizados. Por fim, são apresentados possíveis caminhos para pesquisas futuras no âmbito da avaliação do rendimento de culturas perenes, que podem permitir maior eficiência no processo de tomada de decisão e no manejo das culturas visando ao aumento da produtividade.

**Palavras-chave:** fruticultura de precisão; previsão agrícola; modelagem estocástica; suporte à decisão; banco de dados.

## ABSTRACT

An important objective of precision fruit growing is to understand and manage the patterns of spatial and temporal variations in yield. The adoption of technologies for collecting and evaluating data obtained in the field over productive periods can contribute to the establishment of standards that aid in the management of the agricultural area. The objective of this work was to carry out a narrative review of the literature on the methods used to evaluate the yield of perennial fruit crops, highlighting the current methodological limitations and development prospects. From the work reviewed, it was possible to establish distinctions between evaluation strategies, types of variables, modelling classes and models used. Finally, possible paths for future research in the field of the perennial crop yield evaluation are presented, which can allow for greater efficiency in the decision-making process and in crop management aiming at increasing yield.

**Keywords:** precision fruit growing; agricultural forecasting; stochastic modelling; decision support; database.

<https://doi.org/10.4322/978-65-86819-38-0.1000045>

 Este é um capítulo publicado em acesso aberto (Open Access) sob a licença Creative Commons Attribution-NonCommercial-NoDerivatives, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que sem fins comerciais, sem alterações e que o trabalho original seja corretamente citado.

## 1 INTRODUÇÃO

O rendimento é uma variável de final do ciclo de produção agrícola que integra os efeitos cumulativos do clima e das práticas de manejo ao longo desse período, podendo ser influenciado por fatores endógenos ou exógenos à planta (Fisher, 2000). No entanto, no que se refere ao cultivo de espécies frutíferas perenes, o resultado final da produção não é influenciado apenas pelas interferências anuais desses fatores, mas pelo somatório de interferências ocorridas ao longo do período de vida completo da espécie vegetal, o qual, a exemplo da macieira, pode variar entre 20 e 25 anos (Lordan et al., 2018). Algumas ações, como as práticas de poda e de raleio, podem afetar o desenvolvimento produtivo por períodos maiores do que uma safra, visto que o impacto produzido sobre a planta em um ciclo de produção pode se estender pelo menos até o ciclo seguinte.

A influência de ciclos anteriores no rendimento atual de frutíferas perenes é um fator que aumenta a complexidade do sistema, conforme pode ser observado pela produção irregular entre os anos de cultivo (Dambreville et al., 2013). Ainda, aspectos de variabilidade espacial e temporal relacionados à produção apresentam forte correlação com um processo estocástico, no qual pelo menos uma variável do sistema se comporta de forma aleatória no decorrer do tempo. Esses fatores podem contribuir para que a modelagem de avaliação do rendimento com razoável tempo de antecedência da colheita seja uma tarefa desafiadora.

Contudo, no escopo da fruticultura de precisão, diferentes métodos computacionais constituem ferramentas valiosas para a avaliação do rendimento (Laurent et al., 2021). Atualmente, existe uma grande procura por modelos matemáticos capazes de fornecer quantificações antecipadas do rendimento, os quais podem auxiliar na definição de zonas de manejo temporalmente variáveis quanto à produtividade, visando aumentar a eficiência das áreas cultivadas

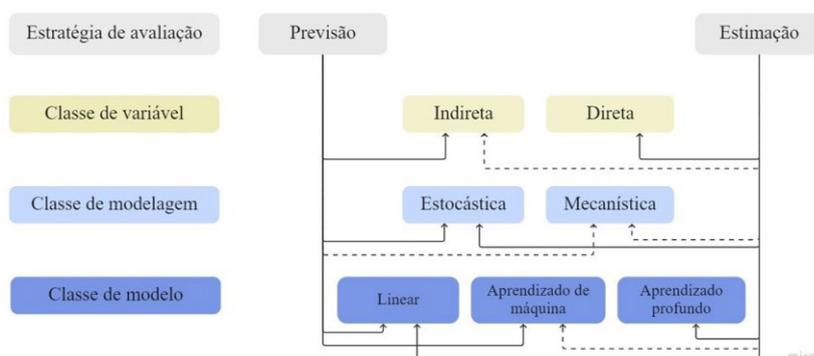
(Sirsat et al., 2019). Dessa forma, o objetivo desta revisão foi realizar uma análise exploratória dos principais métodos de avaliação do rendimento abordados na literatura, além de propor recomendações em termos de desafios científicos com relação à modelagem preditiva em sistemas de cultivo perenes, considerando a inclusão do aspecto temporal.

## 2 ESTRATÉGIAS DE AVALIAÇÃO DO RENDIMENTO DE ÁRVORES FRUTÍFERAS PERENES

A partir dos trabalhos revisados, diferentes abordagens metodológicas de avaliação do rendimento foram identificadas e categorizadas de acordo com a estratégia de avaliação (estimativa ou previsão), a classe de variável (direta ou indireta), a classe de modelagem (estocástica ou mecanística) e, por fim, com o modelo utilizado (linear, aprendizado de máquina ou aprendizado profundo) (Figura 1).

Em geral, o processo de modelagem produzirá ou uma estimativa ou uma previsão do rendimento agrícola. Assim, considerando essas duas estratégias de avaliação, realizou-se uma análise das principais palavras e expressões de indexação dos trabalhos (Figura 2). Além de “rendimento”, as expressões “redes neurais” e “sensoriamento remoto” destacaram-se como tópicos de maior interesse. As expressões “processamento de imagens” e “aprendizado profundo”, e as palavras “floração” e “detecção” foram encontradas em trabalhos relacionados à estimativa do rendimento. A expressão “longo prazo” apareceu em um trabalho com o objetivo de previsão.

A estimativa do rendimento é uma forma mais simples de avaliação, a qual é realizada na mesma unidade de medida, de tempo e de espaço que a medição e a amostragem dos parâmetros de entrada. Dessa forma, na modelagem de estimativa, são preferencialmente utilizadas variáveis diretas obtidas por meio de amostragem em campo para quantificar objetivamente os



**Figura 1.** Fluxograma das principais estratégias utilizadas para a avaliação do rendimento em culturas perenes. \*Linha contínua significa maior frequência de utilização; linha tracejada significa menor frequência de utilização.

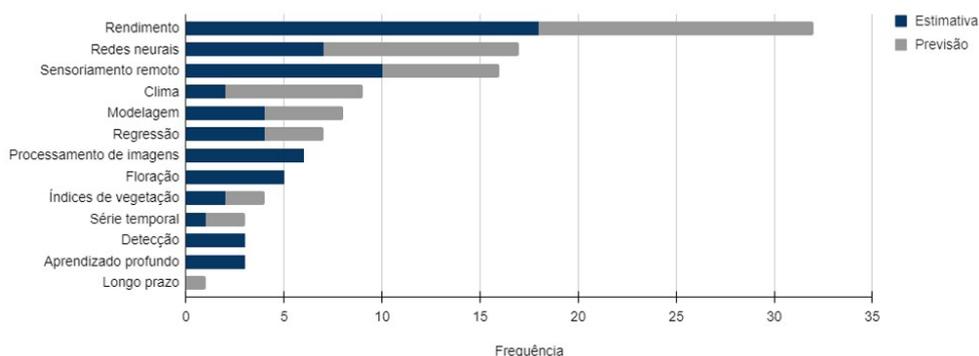


Figura 2. Frequência de ocorrência das palavras-chave nas publicações.

componentes de produção (Laurent et al., 2021). Por definição, variáveis diretas são variáveis diretamente associadas ao rendimento em qualquer estágio do desenvolvimento da cultura, sendo comumente utilizadas as variáveis relativas ao número de flores e frutos, o peso médio dos frutos e o diâmetro da seção transversal do tronco (He et al., 2022).

A aquisição de variáveis diretas por meio de processamento de imagens é uma alternativa rápida e não invasiva comparando-se à amostragem manual. As imagens possibilitam a identificação e a contabilização do número de flores ou de frutos e, em seguida, a utilização de modelos de aprendizado profundo, como redes neurais convolucionais (CNN) e suas derivações, para estimar o rendimento final (Chen et al., 2019; Tian et al., 2019). Outra possibilidade é a utilização de modelos capazes de reconhecer traços fenotípicos das culturas, os quais são relacionados com a produção (Stajnko; Cmelik, 2005; Sarron et al., 2018).

Uma solução também explorada para estimar a produção é por meio de modelos lineares, considerando que pode ser estabelecida uma relação linear e conhecida, pelo menos parcialmente, entre os dados de entrada e de saída (Aggelopoulou et al., 2009). Além do método baseado em variável de entrada única, são utilizados métodos de regressão linear múltipla que incluem mais de um parâmetro de entrada como variável explicativa (Jimenez; Diaz, 2004; Salvo et al., 2012). Nesses casos, diferentes abordagens, como a contagem do número de flores (Dorj et al., 2017), o uso de imagens RGB para aquisição de dados (Črtomir et al., 2012) e a utilização de índices de vegetação (IVs) (Anastasiou et al., 2018), são alternativas.

De forma resumida e em razão do tipo de variável preferencialmente utilizada para estimar o rendimento, essa estratégia considera apenas a janela temporal anual da produção. Assim, os modelos têm como objetivo principal fornecer uma estimativa de rendimento no decorrer da safra (n) sobre a produção de frutos esperada para aquele respectivo ano. Entretanto, essa

estratégia de avaliação pode se tornar mais complexa quando se deseja extrapolar os resultados de rendimento de um ano para o outro.

Mesmo com a relação entre o número de flores e o número de frutos previamente estabelecida, esta pode não ser útil em extrapolações para além do ano de coleta de dados, principalmente em regiões que apresentam intensa variabilidade de produção ano a ano, como é o caso de regiões ambientalmente limítrofes para uma determinada cultura. Nesse caso, a alternância de produção interanual e a variabilidade dos indicadores tornam difícil, senão impossível, produzir um modelo global que forneça resultados precisos para qualquer ano, quando calibrado com base em dados diretamente relacionados à produção de uma safra (Ballesteros et al., 2020). Ademais, considerando que o rendimento apresenta forte correlação com parâmetros de resposta temporal, pode não ser estratégico considerar apenas indicadores anuais para uma avaliação precisa do rendimento de árvores frutíferas perenes.

Em contrapartida, os modelos de previsão do rendimento (modelos preditivos) são desenvolvidos a partir de dados de safras anteriores (n-1) ou de períodos pré-desenvolvimento da safra atual (n) (Laurent et al., 2021). A previsão envolve, na maioria dos casos, a caracterização de fatores relacionados ao clima, à fisiologia das plantas e à gestão dos pomares. Para isso, normalmente são utilizadas variáveis indiretas, ou seja, variáveis que não são diretamente associadas ao rendimento, mas que influenciam ou interagem com os componentes do rendimento em algum nível, com o objetivo de estabelecer relações quantitativas de causa-efeito entre indicadores fisiológicos e climatológicos, e o rendimento das culturas.

As variáveis indiretas identificadas na literatura como as utilizadas com maior frequência para a previsão do rendimento foram as climáticas (temperatura do ar, precipitação, fotoperíodo, intensidade de radiação solar) (Molitor; Keller, 2017), as fisiológicas

(idade do pomar, densidade de plantio, espaçamento entre árvores) (Jin et al., 2020) e os índices de vegetação (IVs) (Ye et al., 2005; Birkhoff; Robson, 2021). Alguns estudos incluíram indicadores de localização geográfica (latitude, longitude) (Brinkhoff; Robson, 2021; Jin et al., 2020) e de propriedades físicas e químicas do solo (condutividade elétrica, conteúdo de matéria orgânica) (Papageorgiou et al., 2013). Com isso, foi possível identificar potenciais opções de ação no âmbito da modelagem para a previsão na fruticultura de precisão, sendo que indicadores climatofisiológicos tendem a ser mais representativos que indicadores relacionados às propriedades do solo.

Com relação à classe de modelo utilizada para a previsão do rendimento, modelos lineares e modelos de aprendizado de máquina, como as florestas randômicas (*Random Forest Model*), apareceram com destaque (Ye et al., 2005; Sirsat et al., 2019; Bai et al., 2021), os quais podem ser classificados como modelos estocásticos. Uma alternativa é a modelagem mecânica, a qual pode ser útil com a finalidade de previsão do rendimento da cultura perene devido à sua capacidade de hierarquizar fatores relevantes no desenvolvimento dos frutos e quantificar seus efeitos para a produção final (Maselli et al., 2012; Guilpart et al., 2014).

Na modelagem de previsão, os fatores temporais são incluídos, pelo menos parcialmente, pois os modelos preditivos consideram que as condições da cultura serão alteradas entre a coleta de dados, a modelagem e o relatório de avaliação de rendimento em função do horizonte de previsão. No entanto, uma quantidade mínima de estudos se interessou por realizar uma previsão de rendimento de longo prazo, isto é, quando a previsão da safra  $n$  é realizada sem depender de nenhuma variável proveniente do ano  $n$  (Beattie; Folley, 1978; Sakai; Noguchi; Asada, 2008; Brinhoff; Robson, 2021).

A utilização de dados da safra atual ( $n$ ), mesmo que relativos a variáveis indiretas, pode limitar o alcance da previsão, pois reduz a janela temporal disponível para ações de manejo da cultura e de tomada de decisão a fim de aumentar a produtividade, visto que a produção do ano ( $n$ ) já está estabelecida. Logo, o conjunto ideal de dados para obter uma previsão de rendimento de longo prazo contém, basicamente, variáveis agregadas de anos anteriores ( $n-1, n-2, n-3, \dots$ ).

### 3 CONSIDERAÇÕES ACERCA DA ESCALA TEMPORAL PARA O DESENVOLVIMENTO DE MODELOS DE PREVISÃO DE RENDIMENTO

Os efeitos de trajetória no escopo da previsão de rendimento de frutíferas perenes, como implicações de

influências acumuladas ao longo do período de vida útil da planta, são aspectos complexos de investigação, mas foram sugeridos por estudos que avaliaram o comportamento do rendimento ao longo de múltiplos anos (Sakai et al., 2008; Lordan et al., 2018). Assim, as informações contidas em séries temporais longas de dados podem ser explicativas do desenvolvimento do rendimento da cultura por registrarem os efeitos da sua trajetória.

No entanto, poucas foram as tentativas de representar a variabilidade temporal do sistema de produção perene por meio de um inventário abrangente de gestão de safras ao longo de múltiplos anos. Os resultados da análise do banco de dados temporal utilizado para condução das pesquisas de previsão de rendimento, considerando a amostra de 19 trabalhos nessa categoria, indicaram que a modelagem foi realizada com base em registros históricos de mais de 10 anos em 11% dos casos, enquanto a maioria dos trabalhos (47%) utilizou dados de no máximo três safras anteriores (Figura 3), o que pode significar um período insuficiente para avaliação da variabilidade temporal da produção de variedades perenes e, consequentemente, dos efeitos que influências passadas têm na produção atual (Sakai et al., 2008).

Além disso, poucos estudos abordaram a importância da temporalidade em suas avaliações, o que pode ser realizado por meio de variáveis intrassazonais. Variáveis climáticas e IVs são capazes de fornecer dados cronológicos do desenvolvimento da cultura. Entretanto, a maioria dos trabalhos disponíveis na literatura tem focado em indicadores pontuais, os quais se fundamentam em alguns estádios fenológicos ou em algumas etapas temporais específicas, como, por exemplo, a temperatura média do ar em torno do período de floração (Keller; Molitor, 2017), o que muitas vezes é considerado independente quando analisado com métodos clássicos, como a regressão linear (Guilpart et al., 2014).

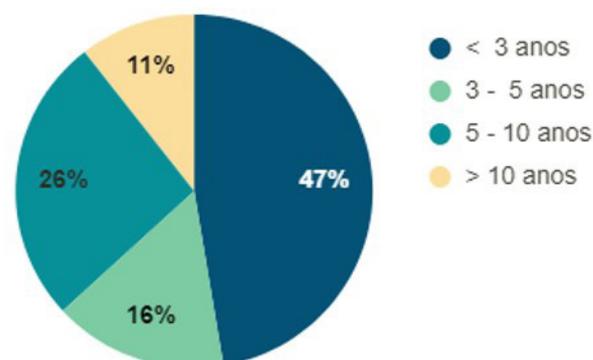


Figura 3. Distribuição percentual do período temporal de dados utilizado para previsão do rendimento.

Visto que a produtividade de culturas perenes pode apresentar alta variabilidade ano a ano, nota-se que a definição de métodos precisos para avaliação ou redução da alternância de produção ainda não ocorreu. Portanto, essa tarefa exige a coleta de dados de alta qualidade acerca do rendimento dos pomares ao longo uma série temporal extensa para que seja possível estabelecer relações causais entre o rendimento e os fatores ambientais ou de gestão das áreas plantadas (Logan et al., 2016; Brinkhoff; Robson, 2021). Assim, podem-se desenvolver modelos de previsão capazes de identificar e relacionar padrões temporais e espaciais de rendimento em áreas produtivas.

O uso de novos ou mais avançados métodos de avaliação que incluam análise de séries temporais pode auxiliar na obtenção de melhores informações e contribuir para o desenvolvimento de modelos de previsão mais robustos e com maior vantagem operacional, capazes de fornecer respostas precisas com tempo de antecedência suficiente para permitir ajustes de manejo antes do estabelecimento da produção e, conseqüentemente, da colheita. Ainda, o desenvolvimento de um banco de dados consistente a respeito do histórico de produção e do manejo de pomares é um aspecto crítico para estudos futuros. Assim, a abordagem temporal para previsão do rendimento pode ser consistente, favorecendo a tomada de decisão para a definição de zonas de manejo e o aumento da produtividade.

## REFERÊNCIAS

- AGGELOPOULOU, K. D.; WULFSOHN, D.; FOUNTAS, S.; GEMTOS, T. A.; NANOS, G. D.; BLACKMORE. Spatial variation in yield and quality in a small apple orchard. **Precision Agriculture**, v. 11, n. 5, p. 538-556, 2009.
- ANASTASIOU, E.; BALAFOUTIS, A.; DARRA, N.; PSIROUKIS, V.; BINIARI, A.; XANTHOPOULOS, G.; FOUNTAS, S. Satellite and proximal sensing to estimate the yield and quality of table grapes. **Agriculture**, v. 8, n. 7, p. 94, 2018.
- BAI, X.; LI, Z.; LI, W.; ZHAO, Y.; LI, M.; CHEN, H.; WEI, S.; JIANG, Y.; YANG, G.; ZHU, X. Comparison of machine-learning and CASA models for predicting apple fruit yields from time-series planet imageries. **Remote Sensing**, v. 13, n. 16, p. 3073, 2021.
- BALLESTEROS, R.; INTRIGLIOLO, D. S.; ORTEGA, J. F.; RAMÍREZ-CUESTA, J. M.; BUESA, I.; MORENO, M. A. Vineyard yield estimation by combining remote sensing, computer vision and artificial neural network techniques. **Precision Agriculture**, v. 21, n. 6, p. 1242-1262, 2020.
- BEATTIE, B. B.; FOLLEY, R. R. W. Production variability in apple crops. II. The long-term behaviour of the English crop. **Scientia Horticulturae**, v. 8, n. 4, p. 325-332, 1978.
- BRINKHOFF, J.; ROBSON, A. J. Block-level macadamia yield forecasting using spatio-temporal datasets. **Agricultural and Forest Meteorology**, v. 303, pp. 108369, 2021. DOI: <https://doi.org/10.1016/j.agrformet.2021.108369>.
- CHEN, Y.; LEE, W. S.; GAN, H.; PERES, N.; FRAISSE, C.; ZHANG, Y.; HE, Y. Strawberry yield prediction based on a deep neural network using high-resolution aerial orthoimages. **Remote Sensing**, v. 11, n. 13, p. 1584, 2019.
- ČRTOMIR, R.; URŠKA, C.; STANISLAV, T.; DENIS, S.; KARMEN, P.; PAVLOVIČ, M.; MARJAN, V. Application of neural networks and image visualization for early forecast of apple yield. **Erwerbs-Obstbau**, v. 54, n. 2, p. 69-76, 2012.
- DAMBREVILLE, A.; LAURI, P.-E.; TROTTIER, C.; GUÉDON, Y.; NORMAND, F. Deciphering structural and temporal interplays during the architectural development of mango trees. **Journal of Experimental Botany**, v. 64, n. 8, p. 2467-80, 2013. DOI: <https://doi.org/10.1093/jxb/ert105>.
- DORJ, U.-O.; LEE, M.; YUN, S. An yield estimation in citrus orchards via fruit detection and counting using image processing. **Computers and Electronics in Agriculture**, v. 140, p. 103-112, 2017.
- FISHER, D. Understanding technology adoption through system dynamics modeling: Implications for agribusiness management. **The International Food and Agribusiness Management Review**, v. 3, n. 3, p. 281-296, 2000.
- GUILPART, N.; METAY, A.; GARY, C. Grapevine bud fertility and number of berries per bunch are determined by water and nitrogen stress around flowering in the previous year. **European Journal of Agronomy**, v. 54, p. 9-20, 2014.
- HE, L.; FANG, W.; ZHAO, G.; WU, Z.; FU, L.; LI, R.; MAJEED, Y.; DHUPIA, J. Fruit yield prediction and estimation in orchards: A state-of-the-art comprehensive review for both direct and indirect methods. **Computers and Electronics in Agriculture**, v. 195, p. 106812, 2022.
- JIMÉNEZ, C. M.; DÍAZ, J. B. R. Statistical model estimates potential yields in 'Golden Delicious' and 'Royal Gala' apples before bloom. **Journal of the American Society for Horticultural Science**, v. 129, n. 1, p. 20-25, 2004.
- JIN, Y.; CHEN, B.; LAMPINEN, B. D.; BROWN, P. H. Advancing agricultural production with machine learning analytics: yield determinants for California's almond orchards. **Frontiers in Plant Science**, v. 11, 2020.
- KELLER, M.; MOLITOR, D. Yield of Müller-Thurgau and Riesling grapevines is altered by meteorological conditions in the current and previous growing seasons. **OENO One**, v. 50, n. 4, 2017.
- LAURENT, C.; OGER, B.; TAYLOR, J. A.; SCHOLASCH, T.; METAY, A.; TISSEYRE, B. A review of the issues, methods and perspectives for yield estimation, prediction and forecasting in viticulture. **European Journal of Agronomy**, v. 130, p. 126339, 2021.
- LOGAN, T. M.; MCLEOD, S.; GUIKEMA, S. Predictive models in horticulture: a case study with Royal Gala apples. **Scientia Horticulturae**, v. 209, p. 201-213, 2016.

- LORDAN, J.; FRANCESCATTO, P.; DOMINGUEZ, L. I.; ROBINSON, T. L. Long-term effects of tree density and tree shape on apple orchard performance, a 20 year study—Part 1, agronomic analysis. **Scientia Horticulturae**, v. 238, p. 303-317, 2018.
- MASELLI, F.; CHIESI, M.; BRILLI, L.; MORIONDO, M. Simulation of olive fruit yield in Tuscany through the integration of remote sensing and ground data. **Ecological Modelling**, v. 244, p. 1-12, 2012.
- MOLITOR, D., KELLER, M. Yield of Müller-Thurgau and Riesling grapevines is altered by meteorological conditions in the current and previous growing seasons. **OENO One**, v. 51, n. 2, 2017. DOI: <https://doi.org/10.20870/oen-no-one.2017.51.2.1647>.
- PAPAGEORGIOU, E. I.; AGGELOPOULOU, K. D.; GEMTOS, T. A.; NANOS, G. D. Yield prediction in apples using Fuzzy Cognitive Map learning approach. **Computers and Electronics in Agriculture**, v. 91, p. 19-29, 2013.
- SAKAI, K.; NOGUCHI, Y.; ASADA, S. Detecting chaos in a citrus orchard: reconstruction of nonlinear dynamics from very short ecological time series. **Chaos, Solitons & Fractals**, v. 38, n. 5, p. 1274-1282, 2008.
- SALVO, S.; MUÑOZ, C.; ÁVILA, J.; BUSTOS, J.; RAMÍREZ-VALDIVIA, M.; SILVA, C.; VIVALLO, G. An estimate of potential blueberry yield using regression models that relate the number of fruits to the number of flower buds and to climatic variables. **Scientia Horticulturae**, v. 133, p. 56-63, 2012.
- SARRON, J.; MALÉZIEUX, E.; SANÉ, C. A. B.; FAYE, E. Mango yield mapping at the orchard scale based on tree structure and land cover assessed by UAV. **Remote Sensing**, v. 10, n. 12, pp. 1900, 2018. DOI: <https://doi.org/10.3390/rs10121900>.
- SIRSAT, M. S.; MENDES-MOREIRA, J.; FERREIRA, C.; CUNHA, M. Machine Learning predictive model of grapevine yield based on agroclimatic patterns. **Engineering in Agriculture, Environment and Food**, v. 12, n. 4, p. 443-450, 2019.
- STAJNKO, D.; CMELIK, Z. Modelling of apple fruit growth by application of image analysis. **Agriculae Conspectus Scientificus**, v. 70, n. 2, 2005.
- TIAN, Y.; YANG, G.; WANG, Z.; WANG, H.; LI, E.; LIANG, Z. Apple detection during different growth stages in orchards using the improved YOLO-V3 model. **Computers and Electronics in Agriculture**, v. 157, p. 417-426, 2019.
- YE, X.; SAKAI, K.; SASAO, A.; ASADA, S. Airborne hyperspectral imaging for investigating the dynamics of alternate bearing in citrus. **Agricultural Information Research**, v. 14, n. 4, p. 261-272, 2005.