



Proposta de uma Plataforma para o Desenvolvimento e Análise Visual de Modelos Preditivos para Doenças da Soja *

Cristiano C. Kemmer¹, Luana P. Reis¹, João G. Rodrigues-Silva¹,
Luigi B. Scolin², Marcelo G. Canteri², Daniel S. Kaster¹

¹Departamento de Computação - Universidade Estadual de Londrina (UEL)
Londrina, PR – Brazil

²Departamento de Agronomia - Universidade Estadual de Londrina (UEL)
Londrina, PR – Brazil

{criskemmer, reispereiraluana, luigibertolaccini}@gmail.com

{joaogabriel.rl, canteri, dskaster}@uel.br

Abstract. *Models for predicting behavior in the agronomic field have an essential role in helping producers make decisions. Models enable predictions of unfavorable situations and management improvements to reduce costs and increase productivity. In this work, we propose a software architecture to support the development of models and related applications, offering functions to capture, prepare and process agrometeorological data. We also present a sample application built on top of the architecture for simulating soybean rust development under different control actions.*

Resumo. *Modelos de previsão de comportamento na área agrônômica têm sido essenciais para auxiliar os produtores na tomada de decisões. Os modelos permitem prever situações desfavoráveis e melhorar a gestão para reduzir custos e aumentar a produtividade. Este trabalho propõe uma arquitetura de software para apoiar o desenvolvimento de modelos e aplicações, oferecendo funções para capturar, preparar e processar dados agrometeorológicos. Também é mostrada uma aplicação de exemplo construída sobre a arquitetura para simular a evolução da ferrugem da soja sob diferentes manejos.*

1. Introdução

O desenvolvimento e evolução das doenças nas diferentes culturas é dado pela interação entre hospedeiro, patógeno e ambiente, sendo denominado de *triângulo da doença*. O

*Este trabalho foi desenvolvido com suporte da Fundação Araucária, do CNPq e da CAPES.

entendimento dessa interação é fundamental para a implementação de estratégias de manejo eficientes, visando reduzir os seus impactos [Munir 2018]. Conseqüentemente, há um esforço em construir modelos para representar e evolução das doenças, que possam permitir identificar antecipadamente condições favoráveis ao seu desenvolvimento.

Na cultura da soja, ferrugem-asiática (*Phakopsora pachyrhizi*) e mofo branco (*Sclerotinia sclerotiorum*) são reconhecidas como algumas das principais doenças que afetam a lavoura, por causarem reduções de produtividade de até 90% e 70%, respectivamente [Yorinori et al. 2005, Meyer et al. 2019]. Em razão da dificuldade da detecção dos sintomas das doenças e das perdas ocasionadas por elas, o manejo destas doenças é normalmente feito através da aplicação calendarizada de fungicidas, em intervalos de tempo regulares, baseados no estágio fenológico da cultura. Vários trabalhos têm se concentrado no desenvolvimento de modelos para o monitoramento dessas doenças, para subsidiar o produtor na realização de um controle mais efetivo da doença.

Contudo, os diversos modelos existentes na literatura são limitados, tanto na diversidade de dados utilizados, quanto na escala considerada. Em geral, os resultados das análises dos modelos são obtidos em ambientes controlados ou pré-definidos, com conjuntos de dados limitados e trabalhados individualmente em ferramentas não integradas. Assim, o desenvolvimento de novos modelos, bem como sua execução em dados continuamente atualizados requer reimplementar tarefas comuns, que poderiam ser embutidas em uma plataforma de software e compartilhadas entre os diferentes modelos e aplicações.

Este trabalho propõe uma arquitetura para suporte ao desenvolvimento de modelos preditivos para agricultura, com recursos de coleta e preparação de dados, além da execução e análise de modelos em uma camada de aplicações. A arquitetura visa facilitar o processamento e uso de diversos tipos de dados agrometeorológicos para a construção de soluções baseadas em modelos, desde a coleta de dados até a apresentação e interação em uma interface web. Este artigo reporta o estado atual da arquitetura e uma aplicação de exemplo de simulações da evolução da severidade da ferrugem asiática da soja construída sobre a arquitetura, com mapas detalhados customizados por parâmetros fornecidos pelo usuário.

2. Conceitos e Trabalhos Relacionados

2.1. Sistemas para a Construção e Execução de Modelos na Agricultura

Existem diversos trabalhos na literatura que utilizam modelos para o desenvolvimento de aplicações diversas na agronomia, com intuito de fornecer suporte ao produtor. Por exemplo, em [Pavan et al. 2011], é proposto um sistema de previsão de doenças em morangos, tendo em vista a redução de aplicações de fungicidas, detectando antecipadamente as doenças *Anthracoze* e *Botrytis fruit rot*, por meio de modelos da literatura. Outros sistemas semelhantes baseados em modelos podem ser encontrados no portal Agro-climate, como o para doenças em melancias¹ e citrus [Perondi et al. 2020].

Existem também soluções mais abrangentes, que permitem combinar diversas fontes de dados climáticos. Um exemplo de destaque é o trabalho [Perondi et al. 2019], que visa auxiliar na determinação da melhor época de fazer o plantio. Os autores argumentam que soluções com auxílio de Ciência de Dados tornam viáveis a análise, em

¹<http://agroclimate.org/tools/watermelon-wilt/>

tempo real, de modelos complexos e com muitas fontes de dados. Outro exemplo é o trabalho [Han et al. 2019], que propõe uma ferramenta que analisa condições climáticas e apresenta visualmente a favorabilidade do desenvolvimento das culturas de milho, soja e trigo. Esse sistema tem a intenção de ajudar o produtor a tomar decisões de plantio e de quais culturas, tendo em vista reduzir o risco na safra.

Nota-se que os trabalhos existentes baseados em modelos preditivos na agricultura têm seu enfoque em produzir bons resultados, para propósitos específicos. Contudo, não é o foco destes trabalhos propor maneiras de apresentação e interação com os usuários desse modelo, tampouco de automatizar seu desenvolvimento e uso. Desta forma, cada novo modelo ou aplicação requer reimplementar uma série de funcionalidades ou etapas de processamento, aumentando o tempo e esforço de desenvolvimento. Este trabalho, por outro lado, propõe uma arquitetura computacional que agrega um conjunto de funcionalidades úteis para suportar o desenvolvimento de modelos preditivos e de aplicações sobre esses modelos. O trabalho também descreve uma aplicação de simulação de manejos para a ferrugem asiática da soja sobre a arquitetura proposta, para ilustrar o seu potencial.

2.2. Manejo da Ferrugem da Soja com Modelos de Detecção da Doença

No controle de ferrugem asiática da soja, as empresas fabricantes de fungicidas recomendam aplicações dos produtos em intervalos pré-determinados, de acordo com o estágio fenológico da cultura, conhecida como aplicação calendarizada. Entretanto, à medida que os estudos sobre a evolução das doenças e as condições para o seu desenvolvimento avançam, diversos autores sugerem que a aplicação de medidas de controle pode ser condicionada pelo efeito do ambiente sobre o processo infeccioso [Reis et al. 2004, Beruski et al. 2020, Megeto et al. 2014, Yang et al. 1991].

Tendo em vista esse aperfeiçoamento, os pesquisadores têm buscado desenvolver modelos para determinar o surgimento de doenças a partir de condições climáticas e meteorológicas. O modelo mais eficaz proposto até o momento é o modelo baseado em precipitação proposto em [Beruski et al. 2020]. Este modelo baseia-se na precipitação acumulada dos últimos 30 dias, produzindo como resultado um valor denominado *severidade*. A Severidade é uma métrica que aponta a gravidade da ocorrência de ferrugem asiática, representada pelo *número de lesões por cm²* e determina a estimativa para uma data selecionada. O objetivo de se calcular a severidade é guiar as aplicações de fungicidas utilizando limiares de ação.

3. Proposta de Arquitetura para Construção e Uso de Modelos Preditivos

3.1. Visão Geral da Arquitetura

A arquitetura proposta é composta por um conjunto de camadas, ou módulos, que trabalham de forma integrada, conforme ilustra a Figura 1. Primeiramente, a *Camada de Entrada de Dados* é responsável por conectar-se a provedores de dados e coletar conjuntos de dados que atendam a critérios de filtragem indicados. Cada conector é adaptado à natureza e funcionamento do provedor de dados, utilizando interfaces padronizadas. Os dados coletados são armazenados em um Repositório de Dados Brutos, para manter a linhagem completa dos dados. A versão atual possui um conector que interage com os servidores do CPTEC/INPE² para coletar dados meteorológicos e utiliza o sistema de

²<https://www.cptec.inpe.br/>

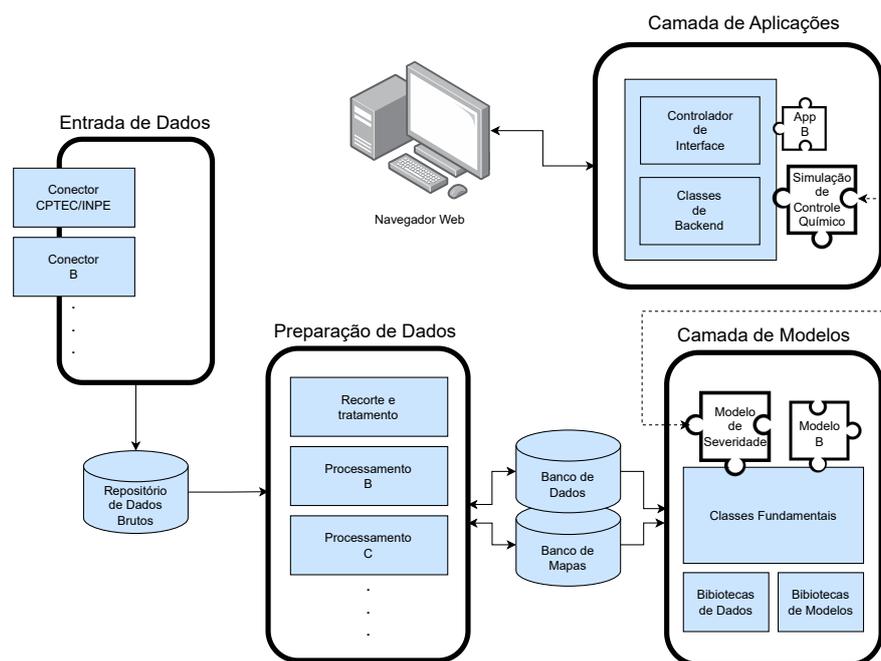


Figura 1. Arquitetura proposta, com suas camadas e fluxos de dados e de interação entre camadas.

arquivos do servidor para armazenar os dados brutos.

Em seguida, a *Camada de Preparação de Dados* aglutina conjuntos de funções diversas de tratamento de dados. Esta camada contém funcionalidades para extrair propriedades e formatar dados obtidos pela camada de coleta de dados conforme a necessidade dos modelos da plataforma. As camadas de entrada e preparação de dados são utilizadas periodicamente em conjunto de forma a armazenar previamente os dados necessários para a camada de modelos, diminuindo o tempo de processamento para suas funcionalidades. Exemplos de funções úteis são para tratamento de mapas agrometeorológicos, que cobrem grandes regiões e podem ser recortados em regiões de interesse menores, reduzindo o custo de processamentos posteriores. Os dados processados são armazenados logicamente em um banco de dados e em um banco de mapas, conforme o tipo de dado.

A *Camada de Modelos* utiliza padrões de projeto para o desenvolvimento de modelos diversos de forma homogênea. Para isto, a camada contém um conjunto de classes fundamentais, fazendo uso de bibliotecas de manipulação de dados tradicionais, geográficos e outros, conforme a necessidade, e bibliotecas de modelos, particularmente para prototipação e execução de modelos de aprendizado de máquina. O foco inicial da arquitetura é a implementação de modelos analíticos, mas a meta é concentrar-se em modelos baseados em aprendizado de máquina. Atualmente, a camada de modelos conta com o modelo de estimativa de severidade da ferrugem da soja baseado em precipitação, adaptado para estimar a *severidade acumulada* no decorrer da safra (vide Seção 3.2).

Por fim, a *Camada de Aplicações* oferece recursos para desenvolver aplicações na arquitetura. Fundamentalmente, são oferecidas classes de *backend* e de controle de interface, para implementação do fluxo de requisições, classes com as regras de negócio da aplicação e interação com o usuário. Cada aplicação possui um módulo específico

que define a rota de ativação dos modelos utilizados e os dados retornados, permitindo a adição de novas funcionalidades e modelos sem a necessidade de alteração do que já está em funcionamento. A interação do usuário com as aplicações desenvolvidas é feita por meio de um navegador *web* com *JavaScript*.

Na versão atual, foi incluída uma aplicação para simulação da evolução da severidade da ferrugem da soja, mediante simulações de diferentes métodos de controle por meio de fungicidas. A aplicação oferece uma visualização interativa, com mapas resultantes da aplicação dos métodos simulados. A visualização dos mapas possibilita uma análise comparativa de diferentes métodos.

3.2. Aplicação: Modelagem da Evolução de Severidade da Ferrugem

Este trabalho introduz, para utilização na aplicação proposta, o conceito de *severidade acumulada*. A severidade acumulada é definida de forma semelhante à severidade diária, porém acumulando os valores diários de precipitação em intervalos de tamanho variável. Esse indicador foi utilizado para representar o funcionamento do modelo dentro do contexto de um período de interesse (e.g. uma safra), onde a evolução da doença é cumulativa. A severidade acumulada é monotonicamente não decrescente em um período de análise, o que corresponde intuitivamente ao comportamento esperado de simulações de manejo, em contraponto à severidade diária, cujos valores variam para cima ou para baixo dependendo do volume de chuva nos 30 dias anteriores. O modelo de severidade acumulada foi implementado com os mesmos parâmetros do modelo de [Beruski et al. 2020], porém sem a ponderação maior do acumulado de chuva dos 15 dias imediatamente anteriores do que o acumulado dos outros 15 dias de análise. Tal ponderação foi removida para suavizar o comportamento da função e porque a severidade acumulada não é limitada a 30 dias de análise.

Tratamentos com fungicidas têm o efeito de retardar a evolução deste indicador, proporcionalmente ao potencial de eficácia do produto utilizado. Com base nesta premissa, extraída de indicações de especialistas do campo agrônômico, torna-se possível realizar simulações de manejo, possibilitando fazer análises interativas de custo-benefício de diferentes estratégias de aplicação. A previsão de severidade acumulada mediante diferentes estratégias de aplicação é realizada sobre um *intervalo de interesse*, que vai do fechamento de linha até o último dia do ciclo que a ferrugem impacta a produtividade, próximo à maturação. A data de início, a cultivar utilizada e a região de interesse são fornecidas pelo usuário, para gerar a simulação. Os dados das cultivares utilizados nos modelos são do Ministério da Agricultura e Pecuária (MAPA)³ e Sistema de Zoneamento Agrícola de Risco Climático (SISZARC)⁴. As estratégias de aplicação são modeladas são as seguintes.

Estratégia Sem Aplicações: Esta estratégia representa a evolução da severidade acumulada no intervalo de interesse. O nome *sem aplicações* remete ao fato de não considerar nenhuma aplicação de fungicida para reduzir ou interromper o desenvolvimento da doença. É usada como linha base para a evolução da doença.

³<https://www.gov.br/agricultura/pt-br/assuntos/riscos-seguro/programa-nacional-de-zoneamento-agricola-de-risco-climatico/portarias/safra-vigente/parana/word/MacrorregiesSojcolasPR.xlsx/view>

⁴<https://sistemasweb.agricultura.gov.br/siszarc/consultarCultivares.action>

Estratégia de Aplicação Calendarizada: Esta estratégia é a primeira que simula aplicações de fungicidas, que interrompem o desenvolvimento da doença. O cálculo da severidade acumulada é realizado considerando-se que cada aplicação interrompe o acúmulo da severidade por 14 dias, adotado como número médio de dias de efeito da proteção do fungicida, conforme indicado por especialistas de campo. Um ajuste especial é realizado nesta estratégia, determinado pela última data de aplicação, a fim de reduzir uma aplicação excedente, mas evitando que a produção fique desprotegida.

Estratégia de Aplicação Guiada por Modelo Preditivo: Uma variação da estratégia de aplicação calendarizada foi implementada, onde as datas das aplicações são guiadas por um *limiar de severidade*. Em paralelo à determinação das datas de aplicação, um cálculo extra do valor diário da severidade é realizado. A data de aplicação determinada pelo calendário é postergada enquanto a severidade diária não atinge o limiar indicado. Esta estratégia pode ser subdividida em diferentes “graus de risco”, de mais arrojada (maiores limiares) a mais conservadora (menores limiares).

Estratégia de Aplicação Definida pelo Especialista ou Produtor: Esta última estratégia de aplicação corresponde à evolução da severidade acumulada mediante aplicações nas datas fornecidas pelo usuário da simulação. Isto é, as datas não são mais calculadas automaticamente, mas informadas manualmente. Esta estratégia tem como objetivo permitir que o usuário (pretendendo ser um produtor) compare as estimativas de severidade das demais estratégias com uma específica, definida pelas datas informadas, que podem refletir datas reais de aplicação de uma safra anterior ou datas de sua conveniência.

3.3. Aspectos de Implementação

A arquitetura está sendo desenvolvida em ambiente web, separando o projeto em *backend* e *frontend*. O *backend* consiste em um servidor responsável pelo armazenamento e processamento dos dados, enquanto que o *frontend* é responsável pelas interfaces que exibem os dados para o usuário final. O *backend* é desenvolvido em Python utilizando o Framework Flask para a definição de uma API REST. Diversas bibliotecas auxiliares foram utilizadas, podendo-se destacar: SQLAlchemy e GeoAlchemy2, para acesso ao banco de dados; Pandas, GeoPandas e NumPy, para o processamento dos dados; Cartopy e Matplotlib, para geração de mapas; e APScheduler, para a execução de rotinas periodicamente. O gerenciamento das bibliotecas no *backend* foi feito utilizando Poetry, de forma a facilitar o controle de dependências em um ambiente com múltiplos desenvolvedores. Já o *frontend* tem sua base desenvolvida a partir da biblioteca React, com diversas bibliotecas auxiliares como: React Router, para navegação de páginas; Axios, para a realização de requisições HTTP para o servidor *backend*; e bibliotecas que auxiliam no projeto e controle visual das interfaces.

4. Exemplo de uso

A aplicação desenvolvida permite visualizar os modelos de previsão de doenças de duas maneiras diferentes. A primeira é a forma analítica e global, para uma região maior, no caso o Paraná (Figura 2). Nesta visualização, os resultados são apresentados em forma de mapa com uma escala de severidade, onde as cores mais escuras representam um valor maior da severidade, permitindo navegar pela data. É possível adicionar máscaras que delimitam as macrorregiões do estado ou seus municípios.

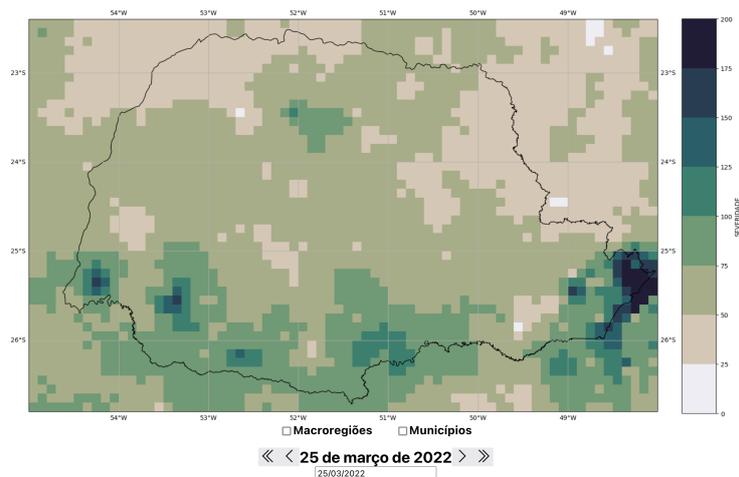


Figura 2. Modelo baseado em precipitação, com resultados para o Paraná.

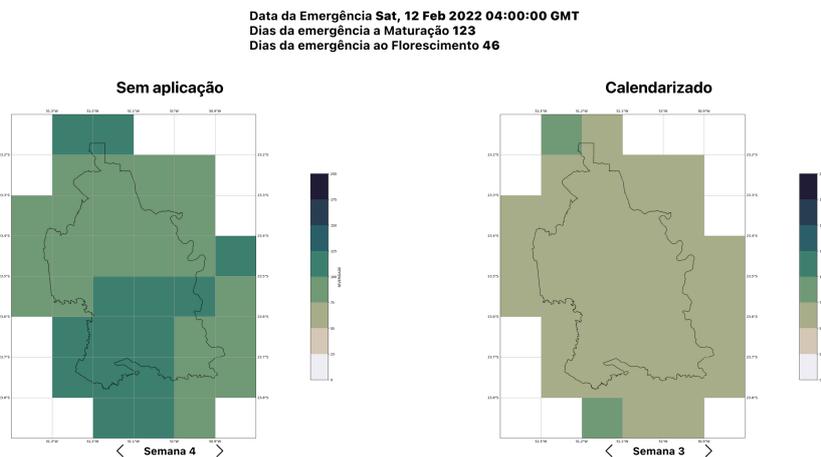


Figura 3. Comparativo de modelos: sem aplicação (esq.) vs. calendarizada (dir.).

A segunda é a comparação de resultados de diferentes modelos, para uma região mais específica. Nesta visualização, é possível ver os resultados entre diferentes estratégias de aplicação lado-a-lado. O usuário fornece em um formulário os parâmetros para os modelos invocados pela aplicação: Município, cultivar, data de emergência, modelo de referência (e.g., modelo baseado em precipitação) e aplicações do produtor. A partir destes parâmetros, os resultados dos modelos serão calculados e dispostos como ilustra a Figura 3, que compara a evolução da severidade sem aplicações versus com aplicação calendarizada. A visão lado-a-lado dos modelos, calculados por parâmetros iniciais idênticos, simula a comparação entre diferentes técnicas de manejo para o produtor, permitindo analisar o desenvolvimento da severidade durante a evolução do intervalo de interesse.

5. Conclusão

Este trabalho apresentou uma arquitetura de software para dar suporte ao desenvolvimento de aplicações em modelos preditivos para agricultura. A solução está em constante desenvolvimento, e os resultados apresentados neste trabalho ilustram seu uso e suas fa-

cilidades técnicas para suportar soluções e conjuntos de dados com grande complexidade, tais como a aplicação apresentada de simulação de manejos da ferrugem asiática da Soja. Ainda, a arquitetura permite o compartilhamento de funcionalidades e bases de dados entre múltiplos modelos, com diferentes parâmetros, tornando o desenvolvimento de modelos mais eficaz. A proposta é flexível, baseada em avançadas ferramentas do campo da Ciência de Dados e podendo suportar outros tipos de modelos de previsão no campo agrônomo, particularmente de Aprendizado de Máquina.

Referências

- Beruski, G. C., Del Ponte, E. M., Pereira, A. B., Gleason, M. L., Câmara, G. M., Araujo Junior, I. P., and Sentelhas, P. C. (2020). Performance and profitability of rain-based thresholds for timing fungicide applications in soybean rust control. *Plant disease*, 104(10):2704–2712.
- Han, E., Baethgen, W. E., Ines, A. V., Mer, F., Souza, J. S., Berterretche, M., Atunéz, G., and Barreira, C. (2019). Simagri: An agro-climate decision support tool. *Computers and electronics in agriculture*, 161:241–251.
- Megeto, G. A., Oliveira, S. R. d. M., Ponte, E. M. d., and Meira, C. A. (2014). Decision tree for classification of soybean rust occurrence in commercial crops based on weather variables. *Engenharia Agrícola*, 34:590–599.
- Meyer, M. C., Campos, H. D., Godoy, C. V., Utiamada, C., Dias, A., De Souza, D., et al. (2019). Eficiência de fungicidas para controle de mofo-branco (sclerotinia sclerotiorum) em soja, na safra 2018/19: Resultados sumarizados dos experimentos cooperativos. *Brasília: Brazilian Agricultural Research Corporation*.
- Munir, M. (2018). Plant disease epidemiology: disease triangle and forecasting mechanisms in highlights. *Hosts Virus*, 5(1):7–11.
- Pavan, W., Fraisse, C., and Peres, N. (2011). Development of a web-based disease forecasting system for strawberries. *Computers and electronics in agriculture*, 75(1):169–175.
- Perondi, D., Fraisse, C. W., Dewdney, M. M., Cerbaro, V. A., Andreis, J. H. D., Gama, A. B., Junior, G. J. S., Amorim, L., Pavan, W., and Peres, N. A. (2020). Citrus advisory system: A web-based postbloom fruit drop disease alert system. *Computers and Electronics in Agriculture*, 178:105781.
- Perondi, D., Fraisse, C. W., Staub, C. G., Cerbaro, V. A., Barreto, D. D., Pequeno, D. N., Mulvaney, M. J., Troy, P., and Pavan, W. (2019). Crop season planning tool: Adjusting sowing decisions to reduce the risk of extreme weather events. *Computers and Electronics in Agriculture*, 156:62–70.
- Reis, E., Sartori, A., and Câmara, R. (2004). Modelo climático para a previsão da ferrugem da soja. *Summa Phytopathologica*, 30(2):290–292.
- Yang, X., Dowler, W., and Tschanz, A. (1991). A simulation model for assessing soybean rust epidemics. *Journal of Phytopathology*, 133(3):187–200.
- Yorinori, J., Paiva, W., Frederick, R., Costamilan, L., Bertagnolli, P., Hartman, G., Godoy, C., and Nunes Jr, J. (2005). Epidemics of soybean rust (phakopsora pachyrhizi) in Brazil and Paraguay from 2001 to 2003. *Plant Disease*, 89(6):675–677.