

VitForecast: an IoT approach to predict diseases in vineyard

Vinicius Bischoff
Programa de Pós-Graduação em Computação
Aplicada (PPGCA), UNISINOS
Avenida Unisinos, 950
São Leopoldo, RS
viniciusbischof@unisinos.br

Kleinner Farias
Programa de Pós-Graduação em Computação
Aplicada (PPGCA), UNISINOS
Avenida Unisinos, 950
São Leopoldo, RS
kleinnerfarias@unisinos.br

ABSTRACT

Diseases in vines, notably Downy Mildew, cause economic losses in the viticulture sector by affecting the oenological quality of grapes in infected vines and causing plants to die. The identification of these diseases usually happens late, soon after the grapevines present damage in leaf physiology, characterized by dryness of the leaves. Although this is a widely known problem, current research is still limited, particularly with regard to the proactive identification of disease incidence. This paper, therefore, proposes VitForecast, an IoT approach to aid in the prediction of diseases in grapevines. VitForecast uses the Internet of Things (IoT) devices and Artificial Intelligence techniques to collect microclimate data and make predictions about the favorability of grapevine contamination. To this end, a disease prediction workflow is proposed, a component-based architecture to support different prediction strategies, and a layered architecture to facilitate understanding and evolution of the approach. VitForecast was implemented through a mobile application and used IoT devices to collect and transmit microclimate data, including temperature and humidity sensors, Raspberry PI, and others. The case study carried out demonstrated the feasibility of the approach, as well as the effectiveness of predicting the favorability of grapevine contamination by Downy Mildew.

Keywords

Precision Agriculture; Vineyard Diseases; IoT, Artificial Intelligence

1. INTRODUÇÃO

A videira (*Vitis spp.*), quando cultivada em condições climáticas favoráveis ao desenvolvimento de patógenos, está sujeita a uma série de doenças [9, 7, 8], destacando-se o *Downy Mildew* como a principal doença fúngica. Estas doenças causam perdas econômicas no setor de viticultura, ao afetar a qualidade enológica da uva em videiras infectadas, e

ao levar as plantas à morte, necessitando de tecnologias para auxiliar no seu controle [1, 7].

Apesar disso, a identificação da doença, na maior parte das propriedades rurais, é realizado de forma tardia, através de inspeções manuais realizadas pelos agricultores, isto é, *ad hoc*, visando a detecção das lesões iniciais de infecção, caracterizadas por manchas cloróticas ou mesmo o ressecamento das folhas, posteriormente ocorrendo pulverizações com defensivos agrícolas.

Dispositivos de *Internet of Things (IoT)* estão sendo cada vez mais incorporados aos processos agrícolas, juntamente com sistemas de informação, impulsionando o progresso para o campo [3, 7]. Porém, a literatura atual ainda carece de estudos que usem dispositivos *IoT* para predição de doenças em vinhedos. Além disso, poucos trabalhos [10, 11] apresentam um fluxo dos processos tecnológicos necessários para o controle de doenças. Este fluxo abrange o uso de novas tecnologias, por exemplo, sensores para coleta de dados climáticos aplicados a modelos de alerta fitossanitários e a modelos que antecipem as condições favoráveis ao desenvolvimento de doenças, para assim reduzir as áreas infectadas [9, 10, 8].

Este trabalho, portanto, propõe o *VitForecast*¹, uma abordagem *IoT* para auxiliar na predição de doenças em videiras. O *VitForecast* utiliza dispositivos (*IoT*) e técnicas de Inteligência Artificial para coletar dados de microclimas e realizar predições da favorabilidade de contaminação das videiras. Para isso, propõem-se um *workflow* de predição de doenças, uma arquitetura baseada em componentes para suportar diferentes estratégias de predição, e uma arquitetura em camadas para facilitar a compreensão e evolução da abordagem.

O *VitForecast* foi implementado através de um aplicativo móvel e utilizou-se de dispositivos *IoT* para coletar e transmitir dados de microclimas, incluindo sensores de temperatura e umidade, *Raspberry PI*, entre outros. O estudo de caso realizado demonstrou a viabilidade da abordagem, bem como mostrou a efetividade da predição da favorabilidade da contaminação de videiras pelo *Downy Mildew*.

O artigo foi estruturado da seguinte maneira. A Seção 2 apresenta a fundamentação teórica, onde os conceitos necessários para o entendimento deste estudo são apresentados. A Seção 3 realiza uma análise dos trabalhos relacionados, bem como estabelece uma comparação conforme os critérios determinados. A Seção 4 introduz a abordagem adotada para realizar o processo de predição fitossanitária. A Seção 5 descreve os aspectos de implementação e avaliação dos resultados obtidos. E, por fim, a Seção 6 apresenta as

Permission to make digital or hard copies of all or part of this work for personal or classroom use is granted without fee provided that copies are not made or distributed for profit or commercial advantage and that copies bear this notice and the full citation on the first page. To copy otherwise, or republish, to post on servers or to redistribute to lists, requires prior specific permission and/or a fee.

SBSI 2020 May 18th – 22th, 2020, São Bernardo do Campo, São Paulo, Brazil

Copyright SBC 2020.

¹Todos os direitos reservados aos autores.

considerações finais deste estudo.

2. FUNDAMENTAÇÃO TEÓRICA

Esta Seção apresenta a fundamentação teórica necessária ao entendimento deste trabalho. Para isso, serão apresentados os conceitos sobre as doenças em vinhedos na Seção 2.1, os aspectos climáticos na Seção 2.2, e sobre diagnóstico e predição de doenças na Seção 2.3.

2.1 Doença em Vinhedos

A viticultura no Brasil segue o modelo convencional agrícola. O *Downy Mildew* da videira (*Vitis vinifera*) é causado pelo fungo *Plasmopara viticola*, sendo a principal doença ocorrida no país [1]. Os danos de necrose irreversível e o desfolhamento provocados pela ocorrência do *Downy Mildew* causam diminuição da produção de carboidratos e queda na produtividade, afetando inclusive os ciclos seguintes da cultura. O *Downy Mildew* da videira pode causar a perda da produção de até 100% do vinhedo, principalmente se o ataque do patógeno ocorrer no período da floração [6]. O *Plasmopara viticola* possui uma complexa interação com o ambiente, sendo que as condições ambientais exercem influência sobre todos os seus processos vitais. Os fatores climáticos de maior importância para a ocorrência do *Downy Mildew* da videira são a umidade do ar e a temperatura [5, 6, 1].

2.2 Aspectos Climáticos

Nesta Seção, são abordados os aspectos climáticos para as regiões que possuem uma colheita por ano, seguida de repouso vegetativo. Assim, três conceitos são considerados para diferenciar escalas climáticas de interesse da viticultura [2]:

- **Macroclima** (ou clima regional): corresponde ao clima médio ocorrente em um território relativamente vasto, exigindo, para sua caracterização, dados de um conjunto de estações meteorológicas.
- **Mesoclima** (ou clima local): corresponde a uma situação particular do macroclima. Normalmente, é possível caracterizar um mesoclima através dos dados de uma estação meteorológica.
- **Microclima**: corresponde às condições climáticas de uma superfície pequena, registra aspectos climáticos específicos de um vinhedo.

2.3 Predição de Doenças

A predição de doenças da videira é acompanhada da geração de alertas por ferramentas, as quais reportam aspectos fitossanitários e climáticos que darão suporte à decisão. De posse destas informações, os agricultores determinarão quando e como aplicar medidas de controle das doenças, incluindo a pulverização de defensivos agrícolas [9, 1]. Os modelos fitossanitários [5, 11] avaliam através das condições climáticas o nível de favorabilidade de contaminação dos vinhedos. As principais variáveis climáticas utilizadas para determinar a favorabilidade de doenças fúngicas, em especial o *Downy Mildew*, são: temperatura, umidade e precipitação [5, 9, 11, 7]. A previsão dos fatores climáticos associados à dispersão de doenças é fundamental para o setor agrícola, uma vez que permite melhorar o planejamento de medidas preventivas e o tratamento da doença em plantas. Neste contexto, técnicas de inteligência artificial [9, 10], tais como

*ARIMA*² [4], mostram-se promissoras para realizar predições de favorabilidade, considerando dados climáticos. Porém, trabalhos neste sentido ainda são incipientes.

3. TRABALHOS RELACIONADOS

No meio acadêmico, estudos focados em inteligência artificial aplicados em dispositivos através da IoT têm ganhado espaço. Porém, quando se trata de predições pouco se tem relatado na literatura. Sendo assim, foram realizadas pesquisas com o objetivo de localizar trabalhos publicados em bibliotecas digitais, tais como Google Acadêmico³, ACM⁴, Computadores e Eletrônicos na Agricultura⁵.

3.1 Seleção e Análise dos Trabalhos

No total, seis trabalhos foram selecionados, os quais são descritos e analisados a seguir.

Cruz et al. (2015) [3] descrevem a utilização de técnicas de inteligência artificial baseadas em visão computacional para realizar a detecção precoce da requeima no tomateiro. Os fatores geográficos e climáticos são explorados sem profundidade neste estudo. O sistema proposto faz o reconhecimento das lesões sofridas, através do envio de imagem. Entretanto, não identifica a doença em tempo real, ou seja, a planta já apresenta alguma lesão. Apesar de aplicar técnicas IA, o trabalho não realiza predições, neste contexto retorna a gravidade da lesão. Por fim, os autores concluem que o uso de dispositivos móveis aplicados às redes neurais mostrou-se eficaz no reconhecimento de doenças através do uso de imagens.

Patil et al. (2016) [9] descrevem um modelo de monitoramento para identificar seis doenças (*Bacterial Stain*, *Powdery Mildew*, *Downy Mildew*, *Anthraxnose*, *Bacterial Cancer*, e *Rust*) nos estágios iniciais e fornecer alertas por SMS aos agricultores. O estudo leva em consideração os fatores climáticos, ignorando o relevo da região analisada. Entretanto, há uma preocupação em calcular a distância entre as estações que se encontram distribuídas pela vinha. Neste estudo, os autores utilizam o modelo de Markov Oculto em comparação com os modelos estatísticos, para realizar suas previsões. Os resultados finais indicaram que a aplicação utilizando técnicas de aprendizado de máquina obteve elevado desempenho em relação aos modelos estatísticos.

Santos et al. (2019) [10] reportam um modelo que combina um sistema de rede sem fio aplicados a *IoT* em conjunto com um mecanismo de previsão para antecipar proativamente possíveis problemas na lavoura, através de alertas para notificar os agricultores. O estudo não considera fatores geográficos. O projeto utilizou sensores para realizar a extração de dados. O modelo de previsão, adotado no estudo foi o *ARIMA*. Os resultados demonstraram a viabilidade do uso de *LoRa* em áreas rurais, além de fornecer um sistema de previsão para observação de problemas relacionados à umidade e temperatura do solo.

Trilles et al. (2019) [11] descrevem uma abordagem para de detecção do *Downy Mildew* em videiras. Desenvolveram estações de baixo custo para monitorar fenômenos climáticos em tempo real. Contudo, não analisam a geografia da

² *Autoregressive Integrated Moving Average (ARIMA)*

³ <https://scholar.google.com.br>

⁴ <https://acm.org>

⁵ <https://www.journals.elsevier.com/computers-and-electronics-in-agriculture>

região. Por exemplo, alteração de umidade do ar devido à radiação solar, produzindo um falso-positivo em determinada área de propriedade rural. Propõem também o uso de um modelo fitossanitário (*Goidanich*) inflexível, não permite interação entre agricultor-máquina. Além disso, não há recomendações de uma possível infecção futura da doença. Os autores concluíram que o sistema proposto detecta o melhor momento para aplicar os tratamentos de controle ao *Downy Mildew* e reduz o uso produtos químicos.

Morais et al. (2019) [7] desenvolveram uma plataforma de *hardware* e *software* para auxiliar na viticultura de precisão de código aberto. Aplicam conceitos de tecnologia emergente como: *IoT*, computação nuvem, névoa e o uso de sensores atrelados a tecnologia sem fio. Por fim, disponibilizam o uso de uma plataforma *web*, através de uma *API* para monitoramento e compartilhamento de dados extraído da estações climáticas.

Mouakher et al. (2019) [8] apresentam um sistema de monitoramento baseado em ontologia, aplicado a um conjunto de sensores sem fio instalados na vinha para obtenção de dados climáticos. As informações coletadas são cruzadas e convertidas em regras de associação. Essas regras são automaticamente transformadas em regras de SWRL (*Semantic Web Rule Language*) de inferência e introduzidas no mecanismo de raciocínio. O sistema emite alertas e avisos de risco de doenças e pragas, assim como fornece uma visão geral do ciclo de vida da videira.

3.2 Análise Comparativa

Nesta seção, uma comparação dos trabalhos relacionados é apresentada. Esta comparação serve para identificar as similaridades e diferenças entre o trabalho proposto e a literatura selecionada. Os critérios de comparação (C) são apresentados a seguir:

- **Fatores geográficos e climáticos (C1):** Experimentos que consideram em seus estudos o relevo do terreno de plantio, no contexto em que diferentes condições climáticas podem ocorrer na mesma propriedade rural.
- **Implementação de hardware e software em tempo real (C2):** Estudos que desenvolveram protótipos com sensores e software para auxiliar no monitoramento agrícola em tempo real.
- **Técnicas de predição e modelos fitopatológicos (C3):** Estudos que empregam técnica de inteligência artificial para fornecer informações preditivas na detecção de doenças fitossanitárias, relacionadas ao contexto climático e utilizam-se de modelos flexíveis, os quais permitem criar uma interação agricultor-máquina.
- **Arquitetura de software (C4):** Estudos cuja contribuição é desenvolver e avaliar a aplicação de uma arquitetura de *software*, para auxiliar na detecção de doenças em plantas.

A Tabela 1 apresenta a comparação considerando tais critérios. Apenas o *VitForecast* atende plenamente os critérios definidos, destacando a contribuição e o diferencial deste trabalho. Os trabalhos que atendem parcialmente os critérios, por exemplo, o C1 em [8, 9, 10, 11] considera apenas as condições climáticas das áreas investigadas sem analisar a inferência do relevo (montanhoso) em relação à posição solar que incidem sobre as folhas da videira alterando a umidade

relativa. No C2 em [7, 10, 11] atende plenamente, isto é, em ambos os trabalhos desenvolveu-se um *software* para análise dos dados assim como projetaram as estações climáticas, os demais trabalhos atendem parcialmente, projetando modelos através de *software* ou *hardware*, e/ou processam os dados isoladamente. Em [10], não aplicam um modelo fitossanitário no C3, entretanto utiliza técnica de inteligência artificial, assim como em [3, 9], em [11] utiliza-se o modelo fitossanitário, e por fim em [8] aplicam regras de associação. Finalmente, o C4 os trabalhos apresentam uma arquitetura mais abrangente (genérica) em [3, 8, 9]. Os trabalhos [7, 10, 11] aplicam arquitetura de referência, onde os artefatos fazem parte da base de ativos reutilizáveis para uso em domínio específico.

Tabela 1: Análise comparativa.

Trabalho Relacionado	Critérios de Comparação			
	C1	C2	C3	C4
Cruz et al. (2015) [3]	○	●	●	●
Patil et al. (2016) [9]	●	●	●	●
Santos et al. (2019) [10]	●	●	●	●
Trilles et al. (2019) [11]	●	●	●	●
Morais et al. (2019) [7]	●	●	○	●
Mouakher et al. (2019) [8]	●	●	●	●
VitForecast (2019)	●	●	●	●

Legenda:

● Atende totalmente
● Atende parcialmente

○ Não atende
○ Não aplicável

4. ABORDAGEM PROPOSTA

Esta seção apresenta o *VitForecast*, uma abordagem *IoT* para auxiliar agricultores na predição de doenças em videiras. Para isso, a Seção 4.1 introduz o contexto de aplicação do *VitForecast*. A Seção 4.2 descreve o *workflow* de predição de doenças. A Seção 4.3 introduz a arquitetura baseada em componentes do *VitForecast*. A Seção 4.4 descreve a arquitetura em camadas proposta para facilitar sua compreensão e evolução.

4.1 Contexto de Aplicação

A Figura 1 ilustra o contexto de aplicação da abordagem proposta, o qual apresenta algumas características que são discutidas a seguir:

- **Comunicação (1):** A falta de conectividade, ilustrada na Figura 1.1, é um obstáculo nas áreas rurais, limitando a captura e transmissão de dados. A Figura 1.(a-c) exibe 3 exemplos ilustrativos de área rural de cultivo de videiras, nas quais supostamente problemas de comunicação são encontrados: (a) apresenta um microclima com área de cobertura de aproximadamente 80%; (b) mostra um microclima sem conectividade; e (c) microclima, representado por uma elipse, que determina a área de cobertura da rede, com aproximadamente 20%. Sem comunicação, não é possível transmitir os dados coletados, inviabilizando predições utilizando dados de várias micro estações.
- **Favorabilidade (2):** A abordagem de previsão climática para detectar o *Downy Mildew* é baseada no efeito do ambiente que, por sua vez, ativa o processo infeccioso para gerar as condições de favorabilidade.

A agricultura tradicional propõe falsos-positivos aos agricultores. Nesse sentido, é necessário realizar as previsões de dados extraídos de estações distribuídas pela vinha, para obtenção de dados pontuais. A Figura 1.2 ilustra o fungo *Downy Mildew* localizado no microclima (c).

- **Predição (3):** Realizar previsões de contaminação é fundamental para a execução antecipada de medidas preventivas, visando evitar a infecção, e de tratamentos das plantas, buscando evitar a morte das plantas. Porém, tais previsões acabam, ou não sendo realizadas, ou são realizadas de forma imprecisa, devido aos seguintes motivos: (1) heterogeneidade dos microclimas causada pela instabilidade de fatores climáticos e pela formação sinuosa do relevo onde as videiras tipicamente são plantadas, como ilustrado na Figura 1.3, dificulta a coleta precisa de dados dos microclimas; (2) os agricultores, por sua vez, fazem uso de dados climáticos da região (genéricos) ao invés de dados de microclima (específicos); e, por fim, (3) o desconhecimento de técnicas de inteligência artificial capazes de realizar previsões. Outro fator a ser considerado é que, após o alerta de favorabilidade, o tempo entre os processos de execução para aplicação de produtos químicos sejam insuficientes. Considerando a variável vento, a infecção pode se espalhar pelo vinhedo sem ter ocorrido as aplicações fungicidas.
- **Notificação (4):** O agricultor precisa ser notificado de forma antecipada da possibilidade de contaminação das videiras. Dessa forma, ele poderá tomar as medidas preventivas necessárias, evitando danos às plantas. A Figura 1.4 ilustra um agricultor em um trator recebendo notificações de previsão de contaminação através de um aplicativo do seu *smartphone*. Aplicativos para *smartphones* já é uma realidade no campo. Além da mobilidade, o *smartphone* viabiliza a notificação de forma prática, em qualquer momento e lugar. Porém, atualmente as notificações não são formuladas, muito menos enviadas aos agricultores.




Figura 1: Contexto da aplicação.

Para atender as demandas de contexto, propõe-se a realização de um fluxo das atividades inerentes ao processo de predição.

4.2 Processo de Predição

A Figura 2 ilustra o processo de predição da abordagem proposta. Ele é representado como um *workflow* compreensível, permitindo o entendimento das atividades inerentes ao processo de predição em termos de etapas, seus artefatos, atividades e o fluxo entre si.

1) Etapa de coleta e transmissão: Tem como objetivo principal coletar dados oriundos dos sensores e posteriormente realizar sua transferência em tempo real. O primeiro passo de entrada ocorre na configuração dos sensores na rede, para que os dados brutos sejam empacotados, recebidos e anexados ao endereço de transmissão, no segundo passo. O terceiro passo verifica a autenticação de acesso aos dados, liberando estes para a transmissão. Por fim, o quarto passo transfere os dados para a etapa de análise.

2) Etapa de análise: É responsável por gerenciar a formatação dos dados brutos de coleta recebidos na Etapa 1. Realiza a análise dos dados coletados. Verificando a normalização e classificação dos dados em informações de contexto. Caso os dados não estejam normalizados, por exemplo, apresente valores muito acima da média das variáveis são considerados inválidos. Os dados válidos são classificados em: (i) contexto de planta contém informações da cultura, (ii) contexto hidrológico exhibe informações dos sensores de pluviômetro, (iii) contexto de solo exhibe informações de temperatura e umidade do solo, (iv) contexto climático exhibe informações de temperatura e umidade do ar, (v) contexto espacial-temporal exhibe informações referente a data, hora e localização dos dados extraídos, e contexto de energia apresenta as informações de carga de bateria. A etapa seguinte consiste no cálculo da favorabilidade de contaminação.

3) Etapa de favorabilidade: Esta etapa consiste na aplicação do modelos fitossanitários desenvolvidos para detectar o estágio de infecção primária de doenças fúngica em plantas. O primeiro passo consiste na definição da estratégia abordada. A estratégia utilizada segue modelo Australiano 10:24 adaptado [5, 6] no qual são necessários pelo menos 10 mm de chuva durante um período de 24 horas. O passo seguinte é repassada as informações de geolocalização das estações e o limites superiores e inferiores de temperatura e umidade para calcular a favorabilidade da doença. Retornando como saída a descrição e o índice de favorabilidade.

4) Etapa de predição: Esta etapa é responsável por anteceder o ciclo de contaminação. Executando predições oriundas de dados de contexto em conjunto com o cálculo de favorabilidade, caso os índices de contaminação estejam desfavoráveis o mesmo é desconsiderado. Ocorrendo a descrição de propensão o mesmo gera o alerta de contaminação.

5) Etapa de notificação: Esta etapa gera o alerta de contaminação para que os usuários do sistema executem as ações necessárias para evitar a dispersão da doença. Após definir os processos de predição, descreve-se o projeto arquitetural, para fornecer uma visão geral das camadas e componentes de *software* aplicados ao sistema.

4.3 Arquitetura Proposta

A Figura 3 apresenta a arquitetura baseada em componentes do *VitForecast*. Esta arquitetura foi proposta devido às seguintes razões, as quais foram identificadas como lacunas em trabalhos anteriores [9, 10, 7, 8]: (1) propor uma arquitetura reutilizável para apoiar e orientar o desenvolvimento de novas estratégias de predição; (2) apresentar uma visão estática de como o sistema será implementado e quais os componentes serão utilizados; (3) identificar os arquivos que

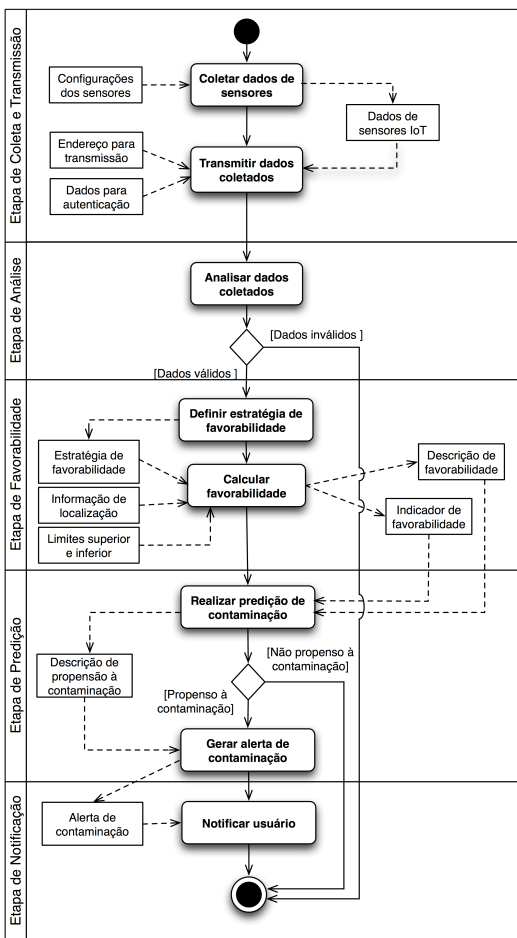


Figura 2: Processo de predição proposto.

irão compor o aplicativo em termos de módulos, bibliotecas, além de identificar os relacionamentos destes; e, por fim, (4) modelar os componentes, destacando às responsabilidades de cada componente (isto é, suas características (do inglês, *features*)) facilitando a sua reutilização em outros sistemas.

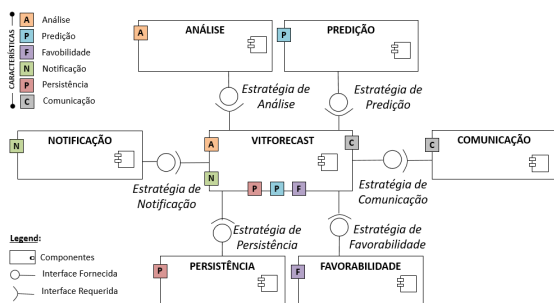


Figura 3: Arquitetura de componentes *VitForecast*.

A arquitetura proposta possui 7 componentes arquiteturais, cada um sendo responsável por implementar uma característica, ou responsabilidade, específica. Cada componente é descrito a seguir:

- **Análise:** É responsável por implementar a Etapa de

Análise do *workflow* de predição proposto. Implica em autenticar a estrutura dos dados de entrada, separado os dados de acordo com suas estratégias.

- **Predição:** É responsável por implementar a Etapa de Predição do *workflow*. Realiza as predições climáticas para verificar se há propensão a contaminação.
- **Notificação:** É responsável por implementar a Etapa de Notificação do *workflow*. Envia os métodos de alerta para que os usuários do sistema sejam notificados do período de infecção.
- **VitForecast:** É responsável por implementar o conjunto dos processos aderentes à execução das etapas de predição do *workflow*. Define o motor central da aplicação, concentrando todos os componentes, suas atividades e execuções de métodos.
- **Comunicação:** É responsável por implementar a Etapa de coleta e transmissão dos dados do *workflow*.
- **Persistência:** Carrega os dados através do componente de análise responsável pelo envio dos dados aos componentes de favorabilidade e predição. Os arquivos gerados ficam armazenados no Banco de dados.
- **Favorabilidade:** É responsável por implementar a Etapa de favorabilidade do *workflow*. Define as estratégias empregadas através dos modelos fitossanitários, seus limites e calcula a favorabilidade da doença.

4.4 Arquitetura em Camadas

A arquitetura lógica e multicamada permite suportar sistemas de aplicação flexíveis, colocando assim as preocupações heterogêneas e transversais, descritas anteriormente na Figura 1. A arquitetura é composta por 5 camadas:

- **Camada de apresentação:** Representa a camada mais alta do aplicativo, reunindo os dados de entrada necessários para executar as funcionalidades e divulgar as notificações de alerta.
- **Camada de aplicação:** Abrange o mecanismo do *VitForecast* e seus operadores. É responsável por orquestrar, junto com seus operadores, o processo de predição como um todo. Desempenha o papel central, fornecendo os fluxos de entrada e saída dos dados de contexto, coordenando solicitações de favorabilidade recebidas, transformando as solicitações em previsões.

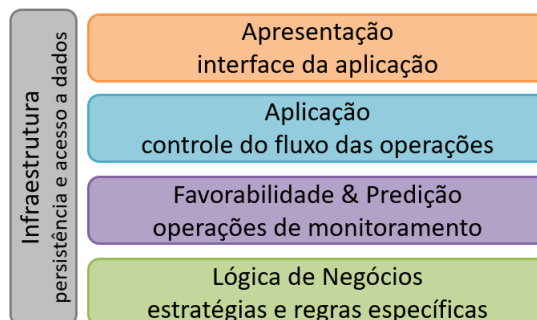


Figura 4: Arquitetura em camadas *VitForecast*.

- **Camada de favorabilidade:** Implementa o comportamento das operações fitossanitárias responsáveis por gerar os alertas de contaminação. Para isso, os componentes e elementos oriundos de outras camadas proporcionam comportamentos adicionais ou alternativos, ou seja, estratégias e regras que inferem no limiar da doença.
- **Camada lógica de negócios:** Define uma família de algoritmos que implementam os recursos do *VitForecast*. Esses algoritmos coletam e analisam dados de entrada em tempo real, processam informações para auxiliar nas previsões.
- **Camada Infraestrutura:** Modela as preocupações relacionadas ao tratamento de exceção, acesso a dados, persistência e registro, que são as principais funcionalidades transversais para colocar em prática o processo de previsão.

5. ASPECTOS DE IMPLEMENTAÇÃO E AVALIAÇÃO

A Seção 5.1 apresenta os aspectos de implementação do protótipo desenvolvido. A Seção 5.2 exibe o estudo de caso realizado para demonstrar a viabilidade da abordagem e uma breve discussão dos resultados.

Micro estações climáticas de baixo custo foram desenvolvidas, juntamente com um aplicativo (*App*) de suporte, o qual implementou o mecanismo de previsão do modelo fitossanitário (Regra 3-10-24), adaptado de [6, 5]. Este modelo foi utilizado como referência-base dos valores aplicados para gerar os alertas de favorabilidade do *Downy Mildew* em videiras.

A Figura 5 apresenta as três camadas físicas da abordagem, incluindo camada de nuvem, nevoeiro e de borda, bem como os componentes de hardware usados em cada uma delas: (1) sensor de temperatura e umidade AM2302/DHT22; (2) *NodeMcu* módulo 4 *Mbytes ESP-12E ESP8266 Wi-Fi*; (3) *Raspberry PI* e *GSM GPRS V2.3*; (4) módulos de geração de energia; (5) Servidor, processador Intel Core i5 3.2ghz, Hd 500gb, 6gb *ram*.




Figura 5: Distribuição do hardware em camadas físicas

5.1 Implementação do Protótipo

A camada da nuvem oferece uma infraestrutura para processamento de alto desempenho, possibilitando analisar os dados e realizar os cálculos de previsão em curto período de tempo. Além de disponibilizar uma arquitetura baseada em *software* com serviço, fornecendo o aplicativo para os agricultores de forma transparente, inexistindo a necessidade de infraestrutura tecnológica na propriedade rural.

A camada de nevoeiro executa o pré-processamento dos dados recebidos das estações climáticas (sensores) antes de os encaminhar para a nuvem. Este pré-processamento permite reduzir a quantidade de dados que necessitam ser transportados à nuvem, para análise, processamento ou armazenamento. Esta camada realiza a comunicação entre os sensores e a transferência dos dados pertinentes à nuvem. Ou seja, promovendo o uso de serviços de conexão com a *internet*. Além disso, realiza a interface com outras redes que usam protocolos de comunicações distintos, por exemplo, *wi-fi*.

A borda da rede é a camada cujo os dados de *IoT* são coletados, através de sensores. A coleta destes dados acontece em tempo real permitindo seu processamento de forma instantânea. Este processamento possibilita alertar outros sensores sobre a mudança de *status* e tomar medidas apropriadas. Enfim, a camada da borda é utilizada para controlar os sensores que estão sendo monitorados.

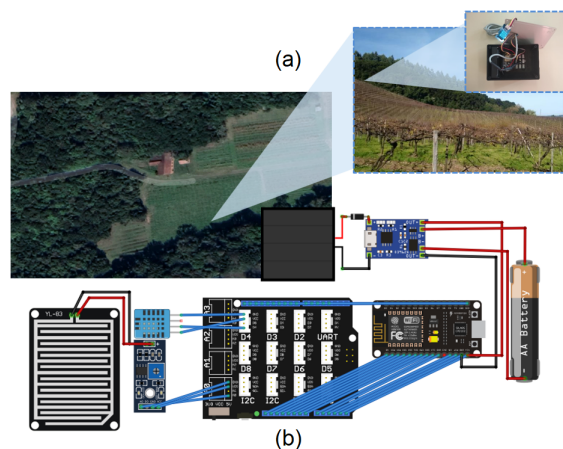


Figura 6: Vista parcial do vinhedo exibindo o sombreamento da copa das árvores e micro estações meteorológicas desenvolvidas (a), esquema de micro estações projetadas (b).

A região analisada apresenta diferentes condições climáticas, em virtude de possuir um relevo montanhoso. Esta diferença climática é devido ao sombreamento da copa das árvores e a posição da montanha onde concentram-se as videiras, uma vez que está poderá receber insolação diária, influenciando diretamente na variável de umidade relativa, como mostra a Figura 6 (a). Para obter-se valores climáticos mais assertivos nos lotes de plantação das videiras, propõe-se o uso de múltiplas estações climáticas distribuídas pela vinha. Assim, projetou-se o desenvolvimento de estações climáticas de baixo custo, conforme ilustrado no projeto de componentes de *hardware* (b).

A próxima etapa consiste em exibir os dados coletados através das estações climáticas aos agricultores. Assim, projeta-se a construção de um protótipo para auxiliar na previsão de

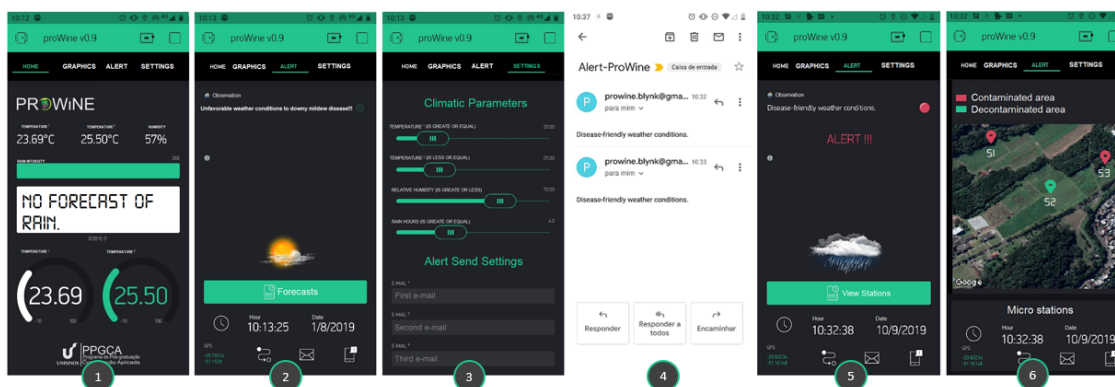


Figura 7: Telas do aplicativo desenvolvido.

doenças. As imagens das telas são ilustradas na Figura 7. A tela inicial (1) mostra os dados coletados dos dispositivos em tempo real. As telas de alerta (2) e configurações (3) referem-se à favorabilidade do *Downy Mildew*. As variáveis são configuradas através da guia Parâmetros Climáticos, também é criada uma lista de e-mails que serão notificados sobre as condições ideais da infecção, mostrada na Figura 7 (4) o envio de alerta. Quando ocorre a interação entre o patógeno, ou seja, o agente infeccioso, supondo que ele esteja espalhado por toda a vinha, e as condições do ambiente sejam favoráveis à sua dispersão em tempo real, o sistema envia uma notificação aos e-mails configurados, por meio do aplicativo, como mostrado na Figura 7 (4). No entanto, na aplicação, a guia de alerta (2) modifica o seu status, mostrando a condição favorável ao *Downy Mildew* (5) e permite a visualização das estações climáticas para que seus gestores tomem as ações necessárias. A Figura 7 (2) exhibe o botão de previsão, Forecast. Este botão destina-se a fornecer as previsões climáticas para antecipar a doença nas videiras. Os dados, por sua vez, são analisados e extraídos para que os scripts desenvolvidos calculem as previsões de risco de contaminação. As previsões então são armazenadas e transferidas para o aplicativo exibir os alertas de notificação ao agricultor, antecipando em 10 horas o período de infecção.

5.2 Estudo Caso

Esta seção apresenta as principais decisões subjacentes ao estudo de caso que foi realizado para avaliar a abordagem *VitForecast* e os resultados.

O modelo de previsão *ARIMA* (*autoregressive integrated moving average*) é mais eficiente em situações que envolvem um pequeno número de séries temporais [4]. Na escolha do modelo mais adequado, buscou-se estimar o número possível de parâmetros, entre 50 e 200 registros, para cada variável de contexto analisada. Nesta análise foi utilizado um total de 168 registros para cada variável, referentes ao período de 01/09/2019 a 09/09/2019 distribuído a cada hora. Destes, realizou-se um treinamento dos registros nos dias 6 e 7 de setembro de 2019, totalizando 48 registros por variável. Por fim, executou-se a previsão para 10 horas dos registros em nosso modelo.

O modelo fitossanitário proposto está configurado com os seguintes limites: temperaturas entre 20 °C e 25 °C, umidade relativa em 80% e precipitação acumulada em 10 mm para as últimas 24 horas.

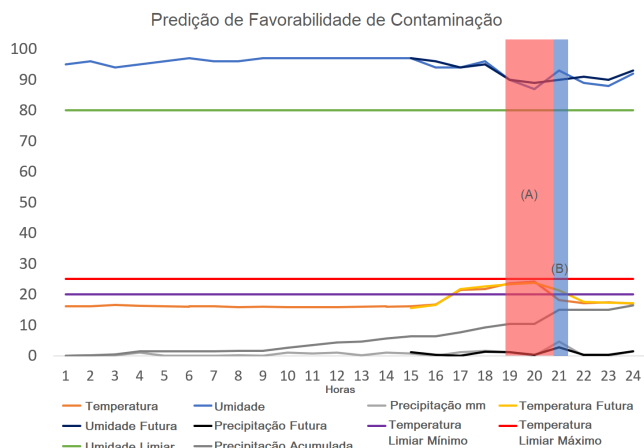


Figura 8: Predição de favorabilidade de contaminação por *Downy Mildew* em videiras. (A) representa a favorabilidade de contaminação, enquanto (B) exhibe uma distorção da predição em relação ao dado real.

A Figura 8 ilustra os resultados da previsão das variáveis para o período do dia 7 de setembro de 2019. Observam-se no gráfico as linhas de previsão representadas através das cores: (i) azul escuro para umidade, (ii) amarelo para temperatura e (iii) preto para precipitação. Estas encontram-se sobrepostas sobre os dados reais, nas cores (iv) laranja para temperatura, (v) azul claro para umidade e cinza claro para precipitação. As linhas que formam uma reta, exibidas nas cores verde (80%), vermelho (25 °C), roxo (20 °C) e cinza (maior que 10 mm), representam o limiar favorável da doença. Entre as 19 horas e 21 horas, pode-se observar que o limite das condições favorabilidade dos valores previstos sobrepostos aos valores realizados atinge o despertar da infecção. Sendo que a barra em vermelho (A) exhibe a favorabilidade crítica de infecção para o *Downy Mildew* da videira, enquanto que a barra em azul (B) ilustra uma leve distorção dos dados gerados. Enfim, a abordagem desenvolvida aplicada ao uso de séries temporais de dados climáticos em conjunto com o modelo fitossanitário demonstrou resultados satisfatório, antecedendo em 10 horas o período de contaminação.

Os fatores climáticos que mais contribuem para a predição do *Downy Mildew* são temperatura, umidade e precipitação.

A precipitação pluvial e umidade relativa (água livre sobre as folha e frutos) são os principais fatores para desencadear o início das infecções fúngicas na videira.




Figura 9: Histograma e densidade estimada.

A Figura 9 histograma ilustra a distribuição dos dados selecionados da amostra coletada (temperatura, umidade e precipitação), e a estimativa de densidade, KDE (*Kernel Density Estimation*). Observa-se que a densidade estimada, linha laranja segue de perto a linha amarela $N(0,1)$ para as variáveis temperatura, umidade, e precipitação, onde $N(0,1)$ é a notação padrão para uma distribuição normal com média 0 e desvio padrão de 1. Indicando que os resíduos são normalmente distribuídos ao longo do tempo em conjunto com o correlograma não apresentam tendência ou sazonalidade. Desta forma, o modelo não apresenta nenhum comportamento fora do esperado. O intervalo de confiança das variáveis analisadas ficou em 95%.

6. CONCLUSÕES, LIMITAÇÕES E TRABALHOS FUTUROS

Este artigo propôs o *VitForecast*, uma abordagem *IoT* para auxiliar na predição de doenças em videiras. O estudo de caso analisou o período climático de nove dias, contendo um total de 504 registros. A predição temporal sobre os registros de dispersão da doença ocorreu cerca de 10 horas antes do estágio inicial de infecção. Os resultados demonstraram que as estações climáticas desenvolvidas possibilitaram uma apuração dos dados mais assertivos nas propriedades rurais (microclima) e o uso de técnica de inteligência artificial aplicada em conjunto com modelos fitossanitários flexíveis ajudam no monitoramento e alerta de doenças em plantas.

Quanto às limitações deste trabalho, identifica-se as seguintes ameaças. A coleta dos dados de pesquisa foram selecionadas a partir de uma única fonte. Isto é, uma propriedade rural, com características específicas de relevo e clima. Outro fator refere-se ao modelo fitossanitário flexível, uma vez que as configurações dos limiares de alerta são definidos conforme o conhecimento dos agricultores, e este possa ter reações diferente com o passar do tempo. Os dados foram analisados a partir de uma janela temporal, o que pode significar, que apenas uma determinada amostra da população foi utilizada. Dados específicos desta janela temporal escolhida podem influenciar nos resultados.

Após os testes nas provas de conceito, a próxima fase deste trabalho consiste em aplicar na prática o uso da abordagem proposta e assim responder as seguintes perguntas no futuro: (1) Qual o desempenho do sistema? (2) Quantos sensores ele suporta? (3) Quantas medições são necessárias para atingir determinada previsão? (4) Qual a densidade necessária para as estações climáticas? Quantos por hectare?

Finalmente, espera-se que as descobertas discutidas ao longo deste trabalho possam incentivar pesquisadores a explorá-las. Além disso, este estudo pode ser visto como um primeiro passo para uma agenda mais ambiciosa sobre como caracterizar e aprimorar técnicas de predição de doenças em plantas.

7. AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, e Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul (FAPERGS), e o Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

8. REFERÊNCIAS

- [1] F. Angelotti, E. Hamada, E. E. Magalhães, R. Ghini, L. d. R. Garrido, P. Júnior, and M. José. Climate change and the occurrence of downy mildew in brazilian grapevines. *Pesquisa Agropecuária Brasileira*, 52(6):426–434, 2017.
- [2] B. Bois, S. Zito, and A. Calonnec. Climate vs grapevine pests and diseases worldwide: the first results of a global survey. *OENO One*, 51(2):133–139, 2017.
- [3] S. da Cruz, D. Nunes, C. Werly, P. Cruz, A. Vieira, and M. Marques. Manejo tecnológico de lavouras através de dispositivos móveis e agricultura de precisão. In *Anais do XI Simpósio Brasileiro de Sistemas de Informação*, pages 379–386. SBC, 2015.
- [4] M. Fernández-González, F. J. Rodríguez-Rajo, V. Jato, M. J. Aira, H. Ribeiro, M. Oliveira, and I. Abreu. Forecasting arima models for atmospheric vineyard pathogens in galicia and northern portugal: Botrytis cinerea spores. *Annals of Agricultural and Environmental Medicine*, 19(2), 2012.
- [5] G. Goidanich. Perisporiales in: *Manuale di patologia vegetale. Vol. II. Edizioni agricole, Bologna*, pages 497–559, 1964.
- [6] R. Magarey and T. Sutton. How to create and deploy infection models for plant pathogens. In *General concepts in integrated pest and disease management*, pages 3–25. Springer, 2007.
- [7] R. Moraes, N. Silva, J. Mendes, T. Adão, L. Pádua, J. López-Riquelme, N. Pavón-Pulido, J. J. Sousa, and E. Peres. mysense: A comprehensive data management environment to improve precision agriculture practices. *Computers and Electronics in Agriculture*, 162:882–894, 2019.
- [8] A. Mouakher, R. Belkaroui, A. Bertaux, O. Labbani, C. Hugol-Gential, and C. Nicolle. An ontology-based monitoring system in vineyards of the burgundy region. In *2019 IEEE 28th International Conference on Enabling Technologies: Infrastructure for Collaborative Enterprises (WETICE)*, pages 307–312. IEEE, 2019.
- [9] S. S. Patil and S. A. Thorat. Early detection of grapes diseases using machine learning and iot. In *2016 Second International Conference on Cognitive Computing and Information Processing (CCIP)*, pages 1–5. IEEE, 2016.
- [10] U. L. Santos, G. Pessin, C. da Costa, and R. Righi. Agriprediction: A proactive internet of things model to anticipate problems and improve production in agricultural crops. *Computers and electronics in agriculture*, 161:202–213, 2019.
- [11] S. Trilles, J. Torres-Sospedra, Ó. Belmonte, F. J. Zarazaga-Soria, A. González-Pérez, and J. Huerta. Development of an open sensorized platform in a smart agriculture context: A vineyard support system for monitoring mildew disease. *Sustainable Computing: Informatics and Systems*, 2019.