



Programa de Pós-Graduação em

**Computação Aplicada**

Mestrado/Doutorado Acadêmico

Bruno Guilherme Martini

INDOORPLANT: UM MODELO COMPUTACIONAL DE  
SERVIÇOS INTELIGENTES BASEADOS EM HISTÓRICOS DE  
CONTEXTOS VOLTADOS À AGRICULTURA INDOOR

São Leopoldo, 2020

Bruno Guilherme Martini

**INDOORPLANT: UM MODELO COMPUTACIONAL DE SERVIÇOS  
INTELIGENTES BASEADOS EM HISTÓRICOS DE CONTEXTOS VOLTADOS À  
AGRICULTURA INDOOR**

Dissertação apresentada como requisito parcial  
para a obtenção do título de Mestre pelo  
Programa de Pós-Graduação em Computação  
Aplicada da Universidade do Vale do Rio dos  
Sinos — UNISINOS

Orientador:  
Prof. Dr. Jorge Luis Victória Barbosa

Coorientador:  
Prof. Dr. Márcio Rosa da Silva

São Leopoldo  
2020

M386i

Martini, Bruno Guilherme.

Indoorplant : um modelo computacional de serviços inteligentes baseados em históricos de contextos voltados à agricultura indoor / Bruno Guilherme Martini. – 2020.

108 f. : il. ; 30 cm.

Dissertação (mestrado) – Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Computação Aplicada, 2020.

“Orientador: Prof. Dr. Jorge Luis Victória Barbosa ;  
coorientador: Prof. Dr. Márcio Rosa da Silva”.

1. Computação na agricultura. 2. Agricultura indoor. 3. Produção na agricultura. 4. Sensibilidade ao contexto na agricultura.  
I. Título.

CDU 004:63

"O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior Brasil (CAPES) - Código de Financiamento 001 /"This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) – Finance Code 001

(Esta folha serve somente para guardar o lugar da verdadeira folha de aprovação, que é obtida após a defesa do trabalho. Este item é obrigatório, exceto no caso de TCCs.)



Aos meus pais.

*Se eu vi além dos outros,  
é porque eu estava nos ombros de gigantes.*  
— SIR ISAAC NEWTON





## AGRADECIMENTOS

Agradeço primeiramente aos meus pais, Sandra Luzia Martini e José Henrique Martini, que apesar de todas as dificuldades me incentivaram e me proporcionaram a possibilidade de me tornar engenheiro e agora mestre em computação aplicada. Vocês são os causadores de tudo isso!

A minha namorada, Carolina Cravo Saft pela paciência e compreensão durante a minha ausência e também por sempre me motivar a fazer o melhor possível todas às vezes durante o curso, desenvolvimento e escrita dessa dissertação. Te amo!

A minha irmã, Milene Martini Petry e ao meu cunhado, Fábio Petry que se colocaram a disposição para qualquer problema encontrado e que sempre se interessaram em ajudar nas dificuldades encontradas nos trabalhos do curso e na dissertação.

Ao professor Jorge Barbosa, pela orientação, motivação, disponibilidade e principalmente paciência ao longo não só de todo esse trabalho, mas também dos oito anos como meu orientador desde a iniciação científica até o final do mestrado. Sempre exigindo nada menos que a excelência acadêmica.

Ao professor Márcio Silva que acompanha minha caminhada desde 2010 na UNISINOS e hoje atua como meu coorientador. Sempre disposto a solucionar meus problemas, dar dicas e ajudar no que for preciso.

Aos amigos e colegas Jorge Aranda, Robson Lima, Márcio Garcia Martins e Gilson Helfer pela ajuda em momentos de dificuldade, auxílio em inúmeras ocasiões e parcerias durante o mestrado.

À UNISINOS, e todos os professores que lá atuam. Graças a UNISINOS tive a oportunidade de me tornar o que sou hoje, e expandir meus horizontes.

Fica o agradecimento especial a CAPES - PROSUP pelo apoio financeiro, sem o qual, este curso de pós-graduação não seria possível.

Por fim, agradeço a todos aqueles que diretamente e indiretamente me auxiliaram no desenvolvimento deste trabalho, que não é a etapa de um sonho, e sim a base de algo muito maior que almejo.



*“Para se ter sucesso, é necessário amar de verdade o que se faz. Caso contrário, levando em conta apenas o lado racional, você simplesmente desiste. É o que acontece com a maioria das pessoas”.*  
(Steve Jobs)



## RESUMO

A aplicação de computação ubíqua tem aumentado nos últimos anos, especialmente devido ao desenvolvimento de tecnologias como computação móvel, sensores mais precisos e protocolos específicos para a IoT. Uma das tendências nesta área de pesquisa é o uso da sensibilidade de contexto. Na agricultura, o contexto pode estar relacionado ao ambiente, por exemplo, as condições encontradas dentro de uma estufa. Recentemente, uma série de estudos propôs o uso de sensores para monitorar a produção e/ou o uso de câmeras para obter informações sobre o cultivo, fornecendo dados, lembretes e alertas aos agricultores. Esta dissertação propõe um modelo computacional para Agricultura *Indoor* denominado IndoorPlant, que utiliza a análise dos históricos de contextos para fornecer serviços inteligentes, como prever a produtividade, indicar os problemas que o cultivo pode sofrer, dar sugestões de melhorias nos parâmetros da estufa, entre outros. O IndoorPlant foi testado em 3 cenários do cotidiano de agricultores com dados de produção hidropônica que foram obtidos durante 7 meses de cultivo de radite, alface e rúcula. Esses 3 cenários mostraram a capacidade do modelo proposto juntamente de um *bot* desenvolvido no Telegram Messenger para que o agricultor consiga se comunicar e receber as informações do modelo. Por fim, são apresentados os resultados obtidos através dos serviços inteligentes que utilizam os históricos de contextos. Os cenários utilizaram serviços de recomendações de melhorias no cultivo, perfis e por fim, ocorreu a predição do tempo de cultivo do radite, alface e rúcula através da utilização da técnica de PLS. Os resultados das predições foram relevantes, visto que o radite obteve os valores ( $R^2$ ) de 0.964, (RMSE) de 1.06 e (RMSECV) de 1.94. O alface obteve os valores ( $R^2$ ) de 0.947, (RMSE) de 1.37 e (RMSECV) de 3.31 e a rúcula obteve os valores ( $R^2$ ) de 0.932, (RMSE) de 1.10 e (RMSECV) de 1.89. Por fim, foi aplicado um formulário TAM para analisar a utilidade e a facilidade percebida pelos agricultores, obtendo aprovação de 92% quanto a utilidade do modelo e 98% quanto a facilidade de uso do modelo proposto.

**Palavras-chave:** computação na agricultura. agricultura indoor. produção na agricultura. sensibilidade ao contexto na agricultura.



## ABSTRACT

The application of ubiquitous computing has increased in recent years, especially due to the development of technologies such as mobile furniture, more accurate sensors and applicable protocols for IoT. One of the trends in this area of research is the use of context sensitivity. In agriculture, the context can be related to the environment, for example, as conditions found inside a greenhouse. Recently, a series of studies has proposed the use of sensors to monitor production and/or the use of cameras to obtain information on cultivation, providing data, reminders and alerts to farmers. This dissertation applies a computational model for Agriculture indoor called IndoorPlant, which uses an analysis of historical contexts to provide intelligent services, such as previewing, indicating the problems that cultivation may suffer, giving suggestions for performance in greenhouse tests , among others. IndoorPlant was tested in 3 scenarios of the daily life of farmers with hydroponic production data that were used during 7 months of cultivation of radite, surface and arugula. These 3 display modes allow the ability of the defined model of a bot developed in Telegram Messenger for those who are farmers, communicate and receive it as model information. Finally, the results obtained through intelligent services using context histories are presented. The scenarios used services to recommend improvements in cultivation, profiles and finally, the prediction of the cultivation time of radite, lettuce and arugula occurred through the use of the PLS technique. The results of the predictions were relevant, since the radite obtained the values ( $R^2$ ) of 0.964, (RMSE) of 1.06 and (RMSECV) of 1.94. Lettuce obtained values of ( $R^2$ ) of 0.947, (RMSE) of 1.37 and (RMSECV) of 3.31 and arugula obtained values of ( $R^2$ ) of 0.932, (RMSE) of 1.10 and (RMSECV) of 1.89. Finally, a TAM form was applied to analyze the utility and ease perceived by farmers, obtaining approval of 92% for the utility of the model and 98% for the ease of use of the proposed model.

**Keywords:** computing in agriculture. indoor agriculture. prediction in agriculture. context awareness in agriculture.





## LISTA DE FIGURAS

Figura 1 – Evolução dos Sistemas Distribuídos até a Computação Ubíqua . . . . .	30
Figura 2 – Filtragem Completa do Mapeamento Sistemático . . . . .	39
Figura 3 – Relação entre os Dispositivos para Obtenção das Informações e as Áreas de Aplicação . . . . .	44
Figura 4 – Estudos de Predição na Agricultura no decorrer dos Anos . . . . .	46
Figura 5 – Quantidade de Publicações de 2009 até 2019 . . . . .	47
Figura 6 – Atores do IndoorPlant . . . . .	55
Figura 7 – Casos de Uso do RT . . . . .	56
Figura 8 – Casos de Uso do Funcionário . . . . .	56
Figura 9 – Casos de Uso do Dispositivo . . . . .	57
Figura 10 – Casos de Uso dos Dados Externos . . . . .	58
Figura 11 – Arquitetura do IndoorPlant . . . . .	59
Figura 12 – Funcionamento do Módulo de Similaridade de Contexto . . . . .	63
Figura 13 – Fluxograma do Funcionamento do Módulo de Similaridade de Contexto . . . . .	64
Figura 14 – Perfis Considerados Diferentes Devido a ID da Estufa ser Diferente . . . . .	65
Figura 15 – Amostra de Contexto do Cultivo de Morango com a Produtividade Informada . . . . .	66
Figura 16 – Contexto Atual da Estufa para Predizer a Produtividade de Morango . . . . .	66
Figura 17 – Ontologia Agrindoor e suas Classes e Exemplos de Instâncias . . . . .	67
Figura 18 – Localização da Empresa onde o IndoorPlant foi Instalado . . . . .	70
Figura 19 – Imagem Aérea das Estufas em que o Protótipo foi Instalado . . . . .	70
Figura 20 – Imagem dos Cultivos Hidropônicos Dentro das Estufas . . . . .	71
Figura 21 – Amostra dos Dados Recebidos do Controlador de Estufas . . . . .	72
Figura 22 – Amostra dos Dados Enviados para a Base de Históricos de Contextos . . . . .	73
Figura 23 – Comparação entre o Contexto Atual e os Melhores Contextos das Estufas 2 e 3 . . . . .	73
Figura 24 – Menu do Bot Telegram Após Selecionar o Botão Estufas (a), Contextos Atuais das Estufas (b), Seleção de Melhorias (c) . . . . .	74
Figura 25 – Melhorias Indicadas pelo Bot para as Estufas . . . . .	75
Figura 26 – Perfis das Plantas do Cultivo Hidropônico . . . . .	75
Figura 27 – Perfis Existentes de Radite Hidropônico no IndoorPlant . . . . .	76
Figura 28 – Menu do Bot com a Seleção de Perfis (a), Seleção da Espécie Radite (b) . . . . .	77
Figura 29 – Perfis Existentes de Radite (a) e Perfil de Radite Escolhido (b) . . . . .	77
Figura 30 – Amostra de Contextos Relacionados com o Tempo de Cultivo . . . . .	78
Figura 31 – Exemplo de Matriz com Dados Multivariados . . . . .	78
Figura 32 – Menu do Bot para Solicitar a Predição de Produtividade (a) Indicação da Predição de Produtividade para as 3 Espécies de Plantas . . . . .	80
Figura 33 – Utilidade percebida pelos usuários ao acessar os índices em tempo real (a) e conexão com a Internet (b) . . . . .	82

Figura 34 – Utilidade percebida pelos usuários ao utilizar a predição para o tempo de cultivo (a) e para a indicação de melhorias (b) . . . . .	83
Figura 35 – Utilidade percebida pelos usuários ao poder avaliar a colheita (a) e para a utilização de perfis existentes (b) . . . . .	83
Figura 36 – Facilidade percebida dos usuários pelo aplicativo ser via chat (a) e compreensão dos índices das estufas (b) . . . . .	84
Figura 37 – Facilidade percebida pelos usuários para compreender a predição do tempo de colheita (a) e compreensão das melhorias indicadas pelo modelo (b) . . . .	84
Figura 38 – Facilidade percebida pelos usuários para avaliar a colheita (a) e escolher e compreender os perfis existentes (b) . . . . .	85
Figura 39 – Utilidade Total Percebida pelos Usuários . . . . .	85
Figura 40 – Facilidade Total Percebida pelos Usuários . . . . .	86

## LISTA DE TABELAS

Tabela 1 – Questões de Pesquisa . . . . .	36
Tabela 2 – Termos da String de Pesquisa . . . . .	37
Tabela 3 – Relação dos Microcontroladores Utilizados . . . . .	40
Tabela 4 – Relação dos Sensores Utilizados . . . . .	41
Tabela 5 – Tipo de Comunicação dos Protótipos . . . . .	42
Tabela 6 – Áreas da Agricultura que os Estudos Foram Aplicados . . . . .	43
Tabela 7 – Técnicas de Predição Utilizadas na Agricultura . . . . .	45
Tabela 8 – Comparativo dos Trabalhos Relacionados com o IndoorPlant . . . . .	51
Tabela 9 – Históricos de Contextos das Informações Obtidas . . . . .	60
Tabela 10 – Dias de Cultivo para Cada Planta . . . . .	79
Tabela 11 – Itens relacionados à avaliação da utilidade percebida do IndoorPlant . . . . .	81
Tabela 12 – Itens relacionados à avaliação da facilidade de uso percebida no IndoorPlant . . . . .	81
Tabela 13 – Perfil dos Usuários que Utilizaram e Avaliaram o IndoorPlant . . . . .	82
Tabela 14 – Relação de Produtividade Real e Prevista . . . . .	87
Tabela 15 – Relação dos Estudos Seleccionados no Mapeamento Sistemático . . . . .	101



## LISTA DE SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
AP	Agricultura de Precisão
CAPES	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
CE	Critérios de Exclusão
CI	Critérios de Inclusão
FAPERGS	Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul
GPRS	<i>General Packet Radio Services</i> (Serviços Gerais de Pacote por Rádio)
GPS	<i>Global Positioning System</i> (Sistema de Posicionamento Global)
HCA	<i>Hierarchical Cluster Analysis</i>
ICT	<i>Information and Communication Technology</i> (Tecnologia de Informação e Comunicação)
OWL	<i>Ontology Web Language</i>
PLS	<i>Partial Least Squares</i>
QEP	Questões Específicas
QET	Questões Estatísticas
QG	Questões Gerais
RDF	<i>Resource Description Framework</i>
RMSE	Erro Médio de Calibração
RMSECV	Erro Médio de Validação Cruzada
SFT	<i>Smart Farming Technology</i> (Tecnologias da Agricultura Inteligente)
TAM	<i>Technical Architecture Modeling</i> (Arquitetura de Modelagem Técnica)
TAM	<i>Technology Acceptance Model</i> (Modelo de Aceitação de Tecnologia)
UML	<i>(Unified Modeling Language)</i> (Linguagem de Modelagem Unificada)
UNISINOS	Universidade do Vale do Rio dos Sinos
WiLDNet	<i>Wi-Fi Long Distance Network</i>



## LISTA DE SÍMBOLOS

°C Graus Celsius

lm lumens

qtd quantidade

un unidade





## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>25</b>
1.1	Motivação	25
1.2	Definição do Problema e Questão de Pesquisa	27
1.3	Objetivos	27
1.4	Metodologia	28
1.5	Organização do Trabalho	28
<b>2</b>	<b>CONCEITOS BÁSICOS</b>	<b>29</b>
2.1	Computação Ubíqua	29
2.2	<i>Internet of Things</i>	31
2.3	Agricultura Inteligente	32
2.4	Ontologias	33
2.5	Considerações sobre o Capítulo	33
<b>3</b>	<b>TRABALHOS RELACIONADOS</b>	<b>35</b>
3.1	Mapeamento Sistemático	35
3.2	Planejamento do Mapeamento Sistemático	35
3.2.1	Elaboração das Questões de Pesquisa	36
3.2.2	Elaboração do Processo de Busca	36
3.2.3	Definição dos Critérios de Filtragem dos Resultados	38
3.3	Resultados do Mapeamento Sistemático	39
3.3.1	QG 1: Quais as tecnologias de computação sensível ao contexto estão sendo usadas na agricultura?	39
3.3.2	QG 2: As informações são enviadas via cabo ou por qual tipo de rede sem fio?	40
3.3.3	QG 3: Que áreas da agricultura a sensibilidade ao contexto e/ou predição estão sendo aplicadas?	42
3.3.4	QEP 1: Quais trabalhos utilizam câmeras para obtenção de informações na agricultura?	43
3.3.5	QEP 2: Quais técnicas de predição são utilizadas na agricultura?	44
3.3.6	QET 1: Onde as pesquisas foram publicadas?	45
3.3.7	QET 2: Quantas publicações ocorreram por ano?	46
3.4	Discussão do Mapeamento Sistemático	46
3.4.1	Ameaças à Validade	47
3.4.2	Discussão	48
3.5	Conclusões do Mapeamento Sistemático	49
3.6	Comparação do IndoorPlant com Trabalhos Relacionados	50
<b>4</b>	<b>MODELO INDOORPLANT</b>	<b>53</b>
4.1	Visão Geral do Modelo	53
4.2	Requisitos do Modelo	54
4.2.1	Casos de Uso	54
4.3	Arquitetura do IndoorPlant	58
4.3.1	Módulo de Similaridade de Contexto	62
4.3.2	Módulo de Perfil	65
4.3.3	Módulo de Predição	65
4.4	Ontologia Proposta para o Modelo - Agrindoor	66
4.5	Considerações Sobre o Capítulo	67

<b>5</b>	<b>ASPECTOS DE IMPLEMENTAÇÃO E VALIDAÇÃO</b>	<b>69</b>
<b>5.1</b>	<b>Desenvolvimento do Protótipo</b>	<b>69</b>
<b>5.2</b>	<b>Avaliação do Modelo</b>	<b>72</b>
5.2.1	Cenário 1: Módulo de Similaridade de Contexto	72
5.2.2	Cenário 2: Módulo de Perfis	74
5.2.3	Cenário 3: Módulo de Predição	76
5.2.4	Avaliação TAM	81
<b>5.3</b>	<b>Considerações sobre o capítulo</b>	<b>86</b>
<b>6</b>	<b>CONSIDERAÇÕES FINAIS</b>	<b>89</b>
<b>6.1</b>	<b>Conclusão e Contribuições</b>	<b>89</b>
<b>6.2</b>	<b>Trabalhos Futuros</b>	<b>90</b>
<b>6.3</b>	<b>Trabalhos Publicados e Submetidos</b>	<b>91</b>
	<b>REFERÊNCIAS</b>	<b>93</b>
	<b>APÊNDICE A – RELAÇÃO DOS ARTIGOS SELECIONADOS NO MAPEAMENTO SISTEMÁTICO</b>	<b>101</b>

## 1 INTRODUÇÃO

O avanço da tecnologia vem ampliando a modernização da agricultura. Essa modernização vem ocorrendo principalmente através do uso de computadores embarcados, do surgimento de sensores para as mais diversas finalidades relacionadas a agricultura e do aumento da eficácia e confiabilidade na comunicação entre os dispositivos eletrônicos. Com isso a agricultura está adotando recursos tecnológicos projetados para aumento do rendimento desde o plantio até a colheita através de monitoramento, recomendações (RODRÍGUEZ; GUALOTUÑA; GRILO, 2017) e suporte (SISYANTO; SUHARDI; KURNIAWAN, 2017).

Oferecer monitoramento, recomendações e suporte para a agricultura como um todo pode ser uma tarefa inviável, mas fornecer esses recursos em ambientes dotados de tecnologias, tais como rede de sensores, informações de cultivo, geolocalização, mapeamento de recursos, e sinal de internet, torna-se possível, desde que um modelo voltado para estes ambientes seja proposto e avaliado. O aproveitamento das informações geradas durante o monitoramento de uma plantação, por exemplo, passa a ser um aspecto importante para oferecer indicações para outros cultivos.

Os trabalhos apresentados no capítulo 3, tais como Santos et al. (2018), Goap et al. (2018), Mehra et al. (2018), não aproveitaram por completo as informações obtidas de seus sistemas, não possibilitaram a troca de informações com outros sistemas, não suportaram todos os tipos de cultivo, e não atenderam a aplicações em cultivos de grande produção. Essas lacunas percebidas ajudam a identificar quais funcionalidades devem ser criadas e propostas. Com essas informações o presente trabalho apresenta no capítulo 4 um modelo para a agricultura *indoor* contemplando as lacunas encontradas.

### 1.1 Motivação

Os avanços tecnológicos ocasionaram o aumento na produtividade e na imunidade das culturas plantadas. Um fator que gera a busca pelo aumento da produtividade agrícola é que aproximadamente 70% da água doce disponível é consumida pelo setor agrícola (PIMENTEL et al., 2004). Assim, o aumento da eficiência da agricultura torna-se estratégica, fomentando investimentos públicos e privados neste setor. Existem estudos indicando que devido ao crescimento da população mundial e conseqüentemente maior consumo de comida, a produção de alimentos deverá aumentar em 60% até o ano de 2050 (NAÇÕES UNIDAS BRASIL, 2015). Isso mostra a necessidade do aumento da eficiência da agricultura como um todo, por isso está ocorrendo um crescimento de investimentos público e privados na área.

Como as informações relativas às lavouras estão cada vez mais acessíveis, estudos sobre a sensibilidade ao contexto (DEY; ABOWD; SALBER, 2001) e também sobre predição (FI-EHN et al., 2018), (NAGINI; KANTH; KIRANMAYEE, 2016), (VADIVEL et al., 2019) estão sendo elaborados com maior frequência pela comunidade científica. Contexto tem como signi-

ficado qualquer informação que caracterize os objetos, ambiente ou pessoas. A obtenção dessas informações deve ocorrer sem que o usuário necessite tomar alguma ação, ou seja, ocorre automaticamente. A sensibilidade ao contexto refere-se aos sistemas computacionais que induzem ações ou efetuam operações para aprimorar a usabilidade em ambientes e sistemas. A predição pode ser definida como o ato ou efeito de afirmar algo que irá ocorrer no futuro, assim como trata o estudo de Nagini, Kanth e Kiranmayee (2016).

Além da utilização de sensores para obter informações relativas à produtividade, estudos estão utilizando câmeras dispostas ao longo do cultivo (JOSHI et al., 2017), (TAN, 2016) para viabilizar o processamento de imagens para monitoramento da produção. Esse processamento normalmente ocorre junto a um computador com capacidade de processamento e não diretamente nos módulos que capturam as imagens.

A agricultura também está sofrendo mudanças, cultivos de espécies que normalmente ocorriam em lavouras a céu aberto cada vez mais estão sendo cultivadas em ambientes fechados como estufas e/ou pavilhões. Devido a essas mudanças foi criada uma ramificação do termo agricultura que é a agricultura *indoor*. Essa mudança ocorre porque dentro de estufas pode-se criar um microclima mais favorável para a espécie e com isso obter melhores resultados na diminuição de pragas, menor colocação de pesticidas, maior produção, entre outros aspectos.

As aplicações com foco na agricultura *indoor* (SANTOS et al., 2018), (ALIPIO et al., 2017) não trocam informações com outros sistemas, não aproveitam por completo as informações de sistemas já existentes e também não atendem aos diferentes tipos de cultivo que se pode ter dentro de uma estufa como hidroponia, fertirrigação e cultivo no solo. Ao aproveitar as informações de sistemas externos, as aplicações conseguem estender sua área de atuação, comparando os contextos que cada cultivo possui para poder fazer sugestões de melhorias e alertas de algum problema que pode afetar a plantação.

Neste trabalho utiliza-se o conceito de *Smart Farming* (Agricultura Inteligente) (DOSHI; PATEL; BHARTI, 2019) que representa a utilização dos sistemas de tecnologia da informação e comunicação (ICT do inglês *Information and Communication Technology*) aplicados na agricultura, levando ao que pode ser chamado de Terceira Revolução Verde (SMART AKIS, 2017). Neste cenário é proposto o modelo IndoorPlant que fornece serviços inteligentes baseados em históricos de contextos para os seus usuários. O IndoorPlant é destinado aos usuários que possuem cultivos em estufas e segmentos relacionados, tais como agricultores e fornecedores de insumos agrícolas. Na computação ubíqua os temas IoT, predição e similaridade de históricos de contextos são estratégicos porque proporcionam a base tecnológica do modelo.

O IndoorPlant suporta diferentes tipos de cultivo dentro de estufas como hidroponias, go-tejamentos e cultivo no solo. O modelo também gerencia contextos (COSTA, 2009), perfil (WAGNER, 2013) dos usuários, armazena histórico (MARTINS, 2011) formando os históricos de contextos (BARBOSA et al., 2018). Os históricos de contextos além de possuírem informações relacionadas as plantas, também são formados por ações e sequências de acionamentos dentro de uma estufa.

## 1.2 Definição do Problema e Questão de Pesquisa

A *Smart Farming* (WOLFERT et al., 2017) também conhecida como Agricultura Inteligente está se tornando mais efetiva devido ao avanço nos padrões de equipamentos e protocolos impulsionados pela Internet das Coisas (IoT do inglês *Internet of Things*). A agricultura inteligente normalmente é aplicada em segmentos/cultivos específicos, a fim de oferecer um melhor resultado para determinada espécie. Porém, não existe um modelo que integre diferentes sistemas e/ou que utilize informações de outros sistemas para analisar as informações e auxiliar na tomada de decisões do sistema. Neste sentido a utilização de informações de sistemas externos para análise e indicações é uma área a ser investigada para auxiliar os cultivos e também poder comparar se as situações encontradas em diferentes cultivos não são parecidas ou até mesmo iguais.

Além disso, o estado da arte possibilita a concepção de um modelo que faça uso dessas informações de sistemas já existentes para a utilização em novos serviços inteligentes, podendo fornecer indicações aos usuários de melhorias no plantio, de alertas de algum problema na estufa, de prever quando a produção estará pronta, entre outros serviços.

O problema de pesquisa investigado nesse trabalho consiste em criar um modelo computacional que utilize os históricos de contextos para fornecer serviços inteligentes e de fácil usabilidade aos agricultores. Assim surge a seguinte questão de pesquisa: “Como um modelo computacional para a Agricultura *Indoor* pode utilizar a computação ubíqua e a análise de históricos de contextos para fornecer serviços inteligentes que auxiliem os agricultores?”.

Para resolver este problema foi desenvolvido um *web service*, aplicativo em forma de *bot* e coleta dos contextos de cultivo, com o objetivo de oferecer serviços inteligentes através dos históricos de contextos. Para avaliar a utilidade e a facilidade de uso do modelo proposto, foi elaborado e aplicado um questionário com 8 agricultores de diferentes funções dentro do cultivo.

## 1.3 Objetivos

Este trabalho de pesquisa tem como objetivo principal criar um modelo de computação para a agricultura *indoor* que utilize os históricos de contextos dos cultivos e forneça serviços inteligentes para os agricultores em diferentes tipos de cultivo. Para atingir esse objetivo principal seguem os objetivos específicos:

- Explorar os conceitos relacionados ao assunto proposto, ou seja, conceitos relevantes sobre agricultura inteligente, computação ubíqua e IoT.
- Caracterizar o estado da arte de obras selecionadas à agricultura indoor e seus cultivos, para identificar funcionalidades já existentes e demandas não preenchidas.
- Especificar o modelo IndoorPlant para a agricultura *indoor*.

- Implementar um protótipo do modelo visando atender demandas identificadas no estudos dos trabalhos relacionados.
- Validar o modelo IndoorPlant através de protótipo.

## 1.4 Metodologia

Para elaborar este trabalho de pesquisa inicialmente foi realizada uma pesquisa preliminar para identificar as tecnologias, conceitos e técnicas que oferecem uma base teórica para conceituar um modelo para a agricultura *indoor* que atenda aos objetivos propostos. Esta pesquisa resultou em alguns projetos de agricultura inteligente que ajudam a resolver problemas identificados.

O fundo teórico presente nas pesquisas que implementam esses projetos foi importante para incorporar conhecimento também no desenvolvimento do modelo ontológico. Uma vez que o modelo ontológico foi projetado, uma especificação inicial sobre a aplicação foi criada, fornecendo uma visão detalhada sobre seus requisitos funcionais.

Como a pesquisa preliminar resultou em apenas algumas pesquisas que atendem aos critérios necessários para este trabalho, foi realizado um estudo de mapeamento sistemático para obter uma visão estruturada do estado da arte no campo dos modelos da agricultura inteligente com foco na agricultura *indoor*. Isso direcionou oportunidades presentes no campo da agricultura *indoor*, resultando em um melhor refinamento do modelo.

O modelo teve seu protótipo desenvolvido e foram coletados dados reais através de um sistema denominado Cultiva Fácil Hidroponia que é de propriedade da empresa BGM Sistemas de São Leopoldo/RS. O local de onde esses dados foram coletados é da Hortinova Agrícola, uma empresa que cultiva hortifruti e também está situada na cidade de São Leopoldo/RS. Foram criados 3 cenários para validação e testes do modelo com os dados coletados, juntamente da criação do servidor proposto para o modelo e criação de um *bot* no Telegram para comunicação do servidor com o agricultor.

## 1.5 Organização do Trabalho

Esta dissertação está organizada em 6 capítulos. O segundo capítulo discute o contexto e conceitos básicos que são relevantes para este trabalho. O terceiro capítulo detalha o estudo do mapeamento sistemático utilizado para identificar estudos relacionados a esta pesquisa e oportunidades de melhoria na área da agricultura *indoor*.

O modelo IndoorPlant, sua arquitetura, seus requisitos, casos de uso e sua ontologia são apresentados no quarto capítulo. O quinto capítulo descreve a metodologia utilizada para realizar a criação do protótipo, avalia as funcionalidades do modelo através de cenários e por fim, foi aplicado um questionário para avaliar a percepção dos agricultores. O sexto e último capítulo apresenta as considerações, conclusão e trabalhos futuros.

## 2 CONCEITOS BÁSICOS

Para construir um modelo de serviços inteligentes voltada à agricultura *indoor* é necessária a exploração das tecnologias envolvidas. Desta forma o presente capítulo busca descrever conceitos de tecnologias para o desenvolvimento do IndoorPlant.

### 2.1 Computação Ubíqua

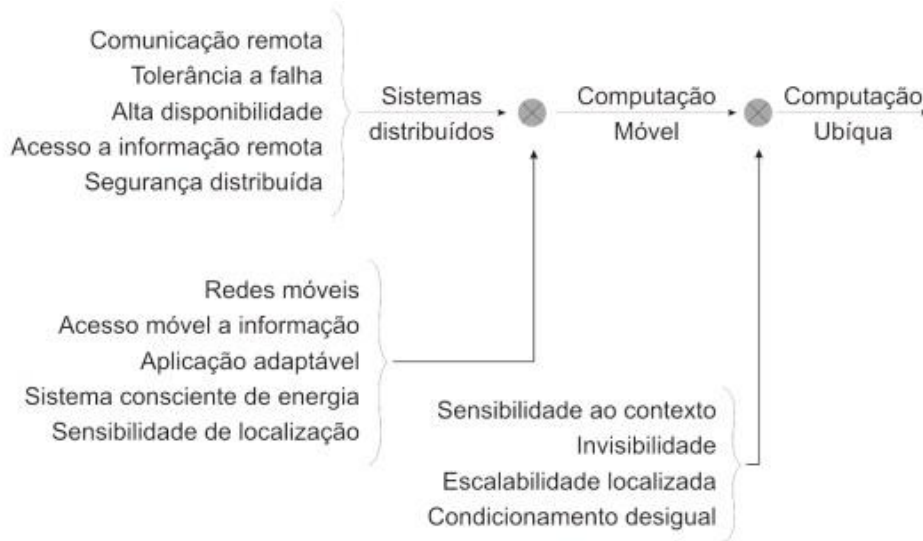
Mark Weiser escreveu em 1991 sobre a computação ubíqua (WEISER, 1991). Ele relatou que os equipamentos e dispositivos da época continham limitações, mas que com o passar dos anos seria possível tornar a computação imperceptível e os recursos dos computadores seriam utilizados sem a percepção do usuário (WEISER, 1991). O avanço tecnológico cresceu exponencialmente fazendo com que em pouco tempo a computação ubíqua se tornasse parte da nossa realidade. Weiser tinha como intuição que os recursos que a computação disponibilizaria, estariam conectados para fornecer as informações necessárias em qualquer lugar e a qualquer momento e que os mesmos não seriam notados pelos usuários.

Com essa visão, os dispositivos e computadores que estivessem localizados em um ambiente se comunicariam entre eles, por exemplo, os móveis em uma sala que poderiam estar interligados com as roupas dos usuários, interagindo entre eles sem que fossem notados pelas pessoas. A esta visão foi dado o nome de Computação Ubíqua (WEISER, 1991), porém alguns autores utilizam o termo computação pervasiva. O uso de recursos ou conjunto de recursos a serem utilizados imperceptivelmente pelas pessoas é um dos principais conceitos da computação ubíqua.

Em 2001, Satyanarayanan apresentou cenários de aplicação do conceito (SATYANARAYANAN, 2001) e também informou os problemas que ainda precisavam ser solucionados para tornar reais os mesmos. A Computação Ubíqua de acordo com Satyanarayanan (2001) é considerada uma extensão da computação móvel, já que herdou algumas características como a invisibilidade e a sensibilidade ao contexto. Do mesmo modo que os sistemas distribuídos juntamente com a adição de características como a localização e redes móveis deu origem à computação móvel (SATYANARAYANAN, 2001). A evolução que Satyanarayanan (2001) explica desde os sistemas distribuídos até a computação ubíqua é demonstrada na Figura 1 a seguir.

O estabelecimento dos recursos na computação ubíqua contém um aspecto importante, chamado de sensibilidade ao contexto (DEY; ABOARD; SALBER, 2001). Contexto tem como significado qualquer informação importante que caracterize os objetos, lugares ou pessoas. A obtenção dessas informações deve ocorrer sem que o usuário necessite tomar alguma ação, ou seja, ocorre automaticamente. Já a sensibilidade ao contexto é quando os sistemas computacionais induzem ações ou efetuam operações para aprimorar a utilização dos usuários em ambientes e sistemas.

Figura 1 – Evolução dos Sistemas Distribuídos até a Computação Ubíqua



Fonte: Feltes e Barbosa (2013) traduzido de Satyanarayanan (2001)

A crescente utilização de dispositivos móveis e a evolução das mais variadas espécies de sensores, são duas características principais que ampliaram o âmbito de possíveis enfoques que apresentam a sensibilidade ao contexto. Porém devido a grande variedade de tipo das informações e a dificuldade de obtenção e gerenciamento das mesmas, criam-se grandes desafios (LOKE, 2006).

Muitos serviços chegaram ao alcance dos usuários devido a computação ubíqua e entre os principais fatores que contribuíram para isso pode-se citar a facilidade no uso e benefícios, baixo custo dos equipamentos, e uma ampla diversificação de desenvolvedores (TELLES, 2015).

Os registros históricos de uma entidade também podem ser destacados quando se fala em sensibilidade ao contexto. Os registros do percurso dos inúmeros contextos são chamados de Trilhas por Barbosa et al. (2018). A interação do usuário com o sistema ubíquo resume o que é uma trilha, também classificada como uma coleção de lugares frequentados com informações de contexto e que segue uma ordem cronológica. Porém o IndoorPlant utiliza a nomenclatura de histórico de contexto ao invés de trilhas. Isso se deve ao fato de que o histórico de contexto não refere-se apenas ao percurso e sim uma grande variedade de informações que são obtidas do local.

Uma trilha no caso dos transportes pode mostrar toda a rota que um usuário fez desde sair de casa, atravessar uma rua, pegar um ônibus e com isso é possível ter todo o deslocamento da pessoa. Com a trilha do usuário é possível auxiliar outros usuários que desejam chegar ao mesmo destino, pois já se sabe como é possível chegar até o determinado local.

Os sensores na computação ubíqua são importantíssimos para Ye, Dobson e McKeever (2012). Pois com a utilização deles pode-se capturar diversas informações sobre o ambiente (temperatura, umidade, entre outros), usuário (localização, velocidade, entre outros) e interação (sensores de presença, sensores de distância, entre outros). Com o armazenamento dessas infor-



mações do contexto atual é possível gerar um histórico de contextos. Os históricos de contextos quando relacionados com os contextos atuais podem auxiliar na tomada de decisão devido as informações e situações que os mesmos já armazenadas anteriormente.

## 2.2 *Internet of Things*

IoT é uma combinação de Internet do futuro com a computação ubíqua. Ela demanda interações com sensores heterogêneos, agregadores, atuadores e um diversificado domínio no contexto de aplicações conscientes, preservando a segurança (BANDYOPADHYAY; SEN, 2011). A computação ubíqua como já falado anteriormente, se tornou uma realidade, e é definida como a capacidade de conexão e comunicação entre os dispositivos a qualquer momento.

Essa comunicação em qualquer lugar e a qualquer hora que se tem hoje em dia proporciona aos usuários a possibilidade de utilizar ou acessar os recursos computacionais a qualquer momento. A IoT aumenta ainda mais a gama de dispositivos que podem se interconectar, englobando objetos do dia a dia para que troquem informações de forma que ajude as pessoas nas tarefas mais corriqueiras, ao mesmo tempo em que transforma os computadores/objetos em algo invisível.

São vários os setores hoje na sociedade que mostram o funcionamento da IoT, entre os principais, podemos citar: transportes, energia e assistência médica. No caso do transporte, pode-se falar na cobrança automática em praças de pedágios, onde o veículo não necessita parar nas cancelas para que ocorra o pagamento da tarifa. Na área de assistência médica pode-se citar o monitoramento remoto do paciente, em que ocorre o recolhimento de informações como pressão arterial, níveis de glicose e frequência cardíaca do usuário.

A medição inteligente na área de energia é outra aplicação que utiliza a IoT. Com a medição inteligente é possível coletar automaticamente as informações de nível de consumo, status e diagnósticos de medições de energia elétrica. Esse controle de consumo além de ocorrer na energia elétrica pode ocorrer em recursos naturais como a água. Um exemplo de aplicação de controle na água é a medição dos níveis de consumo de água em uma residência/condomínio, que notifica os usuários quando os níveis de consumo ficam anormais ou altos. Com isso ajuda na prevenção dos desperdícios de recursos e prejuízos financeiros.

Ultimamente a IoT também está sendo aplicada na agricultura em cultivos de solo (GOAP et al., 2018) e em hidroponias (MEHRA et al., 2018). O estudo de Goap et al. (2018) propõe um sistema inteligente que possui sensores para a irrigação do solo, já o estudo de Mehra et al. (2018) propõe o desenvolvimento de um sistema hidropônico que consegue controlar as ações do ambiente. O que mostra que a IoT pode ser aplicada na agricultura indoor como na agricultura *outdoor*.

### 2.3 Agricultura Inteligente

A Agricultura Inteligente, também conhecida por *Smart Farming* (WOLFERT et al., 2017), representa a aplicação das modernas Tecnologias de Comunicação e Informação na agricultura. Após as revoluções dos melhoramentos de plantas e a revolução das mudanças genéticas, essa nova revolução na agricultura está sendo denominada de Terceira Revolução Verde. A Terceira Revolução Verde está tomando conta do mundo agrícola com a aplicação de soluções de ICT juntamente com a IoT, equipamentos de precisão, sensores, atuadores, robótica e outras tecnologias que incrementam o poder tecnológico da agricultura.

Um dos grandes focos da Agricultura Inteligente (KALE; SONAVANE, 2019) é gerar uma produção agrícola de maior rendimento e sustentável, com foco em eficiência e precisão na utilização dos recursos. No entanto ainda existe grande desparelhamento na utilização das Tecnologias da Agricultura Inteligente (STF do inglês *Smart Farming Technology*), em que nos Estados Unidos 80% dos agricultores utilizam algum tipo de STF, enquanto que na Europa menos de 24% dos agricultores utilizam (SMART AKIS, 2017).

A Agricultura Inteligente pode proporcionar ao agricultor um auxílio na tomada de decisões, nas operações do cultivo (SANTOS et al., 2018) e na gestão da agricultura como um todo. Para que isso ocorra a agricultura necessita estar interligada a três áreas tecnológicas, que são: automação agrícola e robótica, Agricultura de Precisão (AP) e sistemas de informação gerencial para a agricultura.

A automação agrícola pode automatizar o processo de técnicas de cultivo, controle automático dos cultivos e aplicar inteligência artificial em qualquer nível de produção agrícola. Já os sistemas de informação gerencial são desenvolvidos para coletar, armazenar, processar e enviar os dados necessários para realizar as operações na fazenda.

A Agricultura de Precisão (C. BERNARDI et al., 2014) busca melhorar os retornos econômicos com a utilização de insumos, reduzir o impacto ambiental e aplicar recursos disponíveis nas fazendas de forma otimizada. Esse conceito consiste em utilizar as informações geradas por outros cultivos para construir uma base de dados históricos, oferecendo suporte em tempo integral com uso da IoT atendendo os agricultores nas suas atividades cotidianas.

Um dos grandes diferenciais da *Smart Farming* é que a mesma não possui foco apenas em fazendas de grande porte e aumento da exploração agrícola, a Agricultura Inteligente também busca impulsionar novas tendências como a agricultura familiar. A agricultura familiar não possui um foco apenas, possui alguns focos e entre eles pode-se citar os pequenos cultivos, cultivos de culturas específicas, alta qualidade nas plantas cultivadas, entre outros aspectos.

A cultura dos alimentos orgânicos também sofre a influência da Agricultura Inteligente, pois a mesma gera uma confiabilidade nos dados das plantações, o que torna o cultivo mais respeitado e transparente com os compradores. Deixando evidente que as plantas não sofrerem adição de agrotóxicos, insumos e nutrientes que prejudiquem à saúde. Esse fator mostra outro benefício da Agricultura Inteligente em que a mesma fornece grades benefícios ambientais para

a população em geral como, por exemplo, o uso mais eficiente de insumos, otimização de tratamentos e uso eficiente da água (NAÇÕES UNIDAS BRASIL, 2015).

## 2.4 Ontologias

Guarino (1998) apresenta a classificação das ontologias conforme sua função, que segmenta as ontologias em nível superior, domínio, tarefa e aplicação. As ontologias têm suas aplicações em sistemas de recomendações (BOBADILLA et al., 2013) e em inferências (MIDDLETON; SHADBOLT; ROURE, 2004) e (QIN; SHI; SUO, 2007). As maiores motivações para o emprego de ontologias são a representação do conhecimento, compartilhamento de informações e a padronização de termos de um certo domínio (GUARINO, 1997).

Existem basicamente 3 grupos de linguagens utilizadas para composição das ontologias, que são: linguagens tradicionais, linguagens padrão *Web* e linguagens padrão *Web-based*. Entre elas as mais comuns encontradas são *Ontology Web Language* (OWL) que é padrão *Web-based* e a *Resource Description Framework* (RDF) que é padrão *Web*.

O RDF tem por objetivo possibilitar a realização de consultas e organizar os dados de forma semântica. As ontologias são compostas por relacionamentos, atributos e classes, sendo que todas as classes possuem um relacionamento inicial com a classe “coisa” (GUARINO, 1998). Existem regras que são utilizadas nas ontologias para possibilitam descrever as relações lógicas existentes entre as classes de um domínio. Essas regras possibilitam adicionar novos fatos a partir dos conceitos que foram definidos durante a modelagem do sistema.

Após essas regras serem definidas, as inferências são realizadas por motores de raciocínio (do inglês *reasoner*). Dentre os *reasoners* disponíveis existem o HerMiT (MOTIK; SHEARER; HORROCKS, 2009), RACER (HAARSLEV; MÖLLER, 2001), entre outros. Esses raciocinadores fazem parte dos elementos da camada lógica da *Web Semântica*, embora a *Web Semântica* não seja exclusiva à *web* e sim a qualquer domínio de conhecimento.

Após a elaboração e definição de uma ontologia, a mesma deve passar por um processo de avaliação (USCHOLD; GRUNINGER, 1996). Nesta avaliação é verificado se a ontologia atende aos requisitos que foram definidos na sua construção. Para auxiliar o processo de avaliação da ontologia, é criado um conjunto de critérios para guiar o desenvolvimento e a avaliação da qualidade da ontologia. Os critérios avaliados da ontologia são: verificação da especificação de requisitos, coerência, clareza, extensibilidade, compromissos ontológicos mínimos, comparação com o mundo real, validação das questões de competência, relações e relação inversas.

## 2.5 Considerações sobre o Capítulo

O presente capítulo abordou as tecnologias de computação ubíqua (WEISER, 1991), sensibilidade ao contexto (DEY; ABOWD; SALBER, 2001) e IoT (BANDYOPADHYAY; SEN, 2011) que são fundamentais para o IndoorPlant. Alguns aspectos práticos sobre o funciona-

mento das tecnologias apresentadas foram discutidos, pois foram necessários para o modelo e protótipo.

As áreas de aplicação da IoT estão cada vez mais abrangentes e ficam evidentes nos exemplos de utilização da mesma no setor de transporte, energia, área médica e exemplos de estudos na agricultura. Assim mostrando sua forte influência e benefícios proporcionados para as questões e desafios da agricultura. O tema Agricultura Inteligente (WOLFERT et al., 2017) foi apresentado de uma maneira mais aprofundada, a fim de relacionar a agricultura com ICT, agricultura de precisão e robótica.

Assim como o estudo dos conceitos apresentados neste capítulo, também é necessária uma pesquisa sobre os trabalhos já realizados, a fim da compreensão dos esforços já desenvolvidos. Diante desta necessidade o próximo capítulo apresenta os trabalhos relacionados com o IndoorPlant.

### 3 TRABALHOS RELACIONADOS

Neste capítulo é apresentado o processo de pesquisa utilizada para mapear os trabalhos do campo da agricultura *indoor* que utilizem alguma técnica de predição e/ou sensibilidade ao contexto. Um total de 51 artigos resultaram desse mapeamento. Este capítulo está organizado em 6 seções, As seções 1 a 5 apresentam as informações relacionadas com o mapeamento sistemático. A seção 6 apresenta as considerações sobre o capítulo que compara as características dos trabalhos relacionados com o IndoorPlant, descrevendo mais afundo os trabalhos relacionados e destacando as diferenças entre eles.

#### 3.1 Mapeamento Sistemático

Com o objetivo de obter na literatura existente os sistemas e modelos de agricultura *indoor* que suportam serviços inteligentes relacionadas às ideias apresentadas no primeiro capítulo deste trabalho, foi realizado um mapeamento sistemático. Portanto, este estudo permite mostrar as técnicas e tecnologias mais utilizadas para a predição e sensibilidade ao contexto aplicados na agricultura. O trabalho visa também, com base na literatura analisada, apresentar possíveis lacunas e desafios de pesquisa. Deste modo, o mapeamento propõe apresentar o estado da arte suportando futuras pesquisas.

O mapeamento sistemático de acordo com Petersen, Vakkalanka e Kuzniarz (2015), elimina ou reduz as divergências que possam existir quando comparado com revisões que não possuam um método determinado e com resultados expressivos. Sendo possível assim, a obtenção de resultados mais confiáveis e de maior impacto. As próximas seções são estruturadas da seguinte maneira: a seção 2 apresenta como foi planejado o mapeamento sistemático, na seção 3 são apresentados os resultados obtidos durante o estudo. A seção 4 discute os resultados obtidos no estudo e a seção 5 apresenta as conclusões do mapeamento com indicações de trabalhos futuros.

#### 3.2 Planejamento do Mapeamento Sistemático

Com a utilização da metodologia do mapeamento sistemático não é discutido apenas uma conclusão final, mas sim todas as atividades relacionadas às descobertas durante todo o processo do mapeamento. Assim, o mapeamento sistemático é capaz de fazer a ligação entre a coleta de dados, os locais em que a mídia foi publicada, qual a área de aplicação na agricultura, qual o ano de publicação dos estudos, tecnologias que foram utilizadas, qual metodologia empregada no desenvolvimento, entre outras informações. O mapeamento se concentra em artigos publicados, podendo os mesmos estarem publicados em jornais, conferências, livros e workshops. As etapas para o mapeamento são:

- Elaboração das questões de pesquisa.

Tabela 1 – Questões de Pesquisa

<b>Tipo</b>	<b>Detalhes</b>
<b>Questões Gerais</b>	
QG 1	Quais as tecnologias de computação sensíveis ao contexto estão sendo usadas na agricultura?
QG 2	As informações são enviadas via cabo ou por qual tipo de rede sem fio?
QG 3	Quais áreas da agricultura estão aplicando sensibilidade ao contexto e/ou predição?
<b>Questões Específicas</b>	
QEP 1	Quais trabalhos utilizam câmeras para obtenção de informações na agricultura?
QEP 2	Quais técnicas de predição são utilizadas na agricultura?
<b>Questões Estatísticas</b>	
QET 1	Onde as pesquisas foram publicadas?
QET 2	Quantas publicações ocorreram por ano?

Fonte: Elaborado pelo autor.

- Elaboração do processo de busca.
- Definição dos critérios de filtragem.

### 3.2.1 Elaboração das Questões de Pesquisa

Para este trabalho foram definidas sete questões, sendo organizadas em três questões gerais (QG), duas questões específicas (QEP) e duas questões estatísticas (QET). O objetivo das questões gerais é entender em que áreas da agricultura a sensibilidade ao contexto e/ou a predição são aplicadas, quais as tecnologias utilizadas atualmente e como é feita a comunicação das informações entre os sensores e os servidores. O objetivo das questões específicas é identificar os estudos que utilizam câmeras para obtenção de informações, quais sistemas utilizam predição aplicada na agricultura e qual a técnica utilizada em cada um deles. Por fim, o objetivo das questões estatísticas é reunir dados sobre a área em estudo e mostrar o comportamento das publicações ao longo dos últimos 12 anos. As tecnologias utilizadas de sensibilidade ao contexto e predição na agricultura dificilmente eram aplicadas antes de 2008, por isso o ano de 2008 serviu como marco. As questões de pesquisa são detalhadas na Tabela 1.

### 3.2.2 Elaboração do Processo de Busca

O processo de busca foi organizado em três etapas: especificar a string de busca, selecionar as bases de dados e entender o método de pesquisa de cada uma delas, e por fim, obter os resultados das mesmas. Para a primeira etapa, foi adotado o processo de pesquisa proposto por Petersen, Vakkalanka e Kuzniarz (2015). A primeira etapa identifica os principais termos e seus sinônimos mais relevantes. Neste estudo foi selecionado o termo “Agricultura” como termo primário e como secundários os termos “Predição de Contexto”, “Sensibilidade ao Contexto”,

Tabela 2 – Termos da String de Pesquisa

<b>Termos Principais</b>	<b>Sinônimos</b>
Agricultura	"agriculture" OR "hydroponics" OR "aquaponics"
Predição de Contexto	"context prediction" OR "prediction of context"
Sistema Cyber Físico	"cyber physical system" OR "cps"
Internet das Coisas	"Internet of Things" OR "IoT"
Sensibilidade ao Contexto	"context awareness" OR "context aware"

Fonte: Elaborado pelo autor.

“Sistema Cyber Físico” e “Internet das Coisas”. Estes termos foram escolhidos porque o mapeamento busca qualquer relação que o termo “Agricultura” tenha com os termos secundários. Os sinônimos para Agricultura foram palavras que se referem a métodos de plantio da agricultura indoor (hidroponia e aquaponia), para garantir que também seriam obtidos estudos aplicados em estufas ou pavilhões, pois existem métodos específicos para o plantio interno. Para os termos secundários foram utilizadas siglas dos termos originais ou sinônimos conforme mostra a Tabela 2.

Uma vez definidos os termos e sinônimos, foi elaborada a seguinte *string* de busca:

((*"agriculture"*OR *"hydroponics"*OR *"aquaponics"*) AND (“*context prediction*” OR *"prediction of context"*OR *"cyber physical system"*OR *"cps"*OR *"context awareness"*OR *"context aware"*OR *"IoT"*OR *"Internet of Things"*))

Uma vez definida a *string* de busca, a segunda etapa foi selecionar bases de dados relevantes para a área de estudo para aplicar a *string* de pesquisa. Por cada base ter seu método de pesquisa, após a escolha delas foi necessário determinar os parâmetros de pesquisa a serem usados em cada uma. Deste modo, quatro bases de dados de pesquisa foram utilizadas, incluindo a ACM Digital Library, IEEE Xplore, Science Direct e a Springer Link.

As bases de dados selecionadas são as que priorizam estudos de pesquisa na área ciência da computação, pois o mapeamento possui como ênfase a sensibilidade ao contexto e a predição aplicadas na agricultura. Assim, artigos da área da agricultura poderiam entrar na seleção, porém ao passar pelos critérios de filtragem seriam retirados por não terem vínculo com a sensibilidade ao contexto e nem com a predição.

A pesquisa na base de dados ACM Digital Library exigiu o uso de recursos de pesquisa avançada, na qual a *string* foi inserida no campo de edição da própria base. Para pesquisar na base de dados da IEEE Xplore, também foi utilizado o recurso de pesquisa avançada. O processo de busca no repositório da Science Direct envolveu a aplicação da *string* de consulta ao título, resumo e palavras-chave. Por fim, na Springer Library, além de usar a *string* de pesquisa como a consulta, também foi necessária a remoção dos documentos categorizados como *Preview Only*. Após a exclusão desses documentos foi selecionado o filtro de pesquisa intitulado "*Computer Science*" primeiramente, efetuou-se a pesquisa e posteriormente selecionado o filtro "*Life Science*" para obter resultados que também possa ter ligação com o tema pesquisado.

### 3.2.3 Definição dos Critérios de Filtragem dos Resultados

Foram elencados critérios para incluir e para excluir os trabalhos obtidos nas bases de dados. Para tanto, Critérios de Inclusão (CI) e Critérios de Exclusão (CE) foram definidos. A seguir são apresentados os CIs.

- CI 1: O estudo deverá estar publicado em *journal*, conferência ou *workshop*.
- CI 2: O estudo deverá ser um *full paper*.
- CI 3: O estudo deve estar relacionado com as áreas de ciência da computação (*computer science*) ou ciências da natureza (*life science*).

Os Critérios de Exclusão (CE) são os seguintes:

- CE 1: Os estudos que forem publicados antes de 2008.
- CIE2: Os estudos que não forem escritos em inglês.
- CE 3: Os estudos que foram publicados em teses e revistas.
- CE 4: Os estudos que não apresentam conexão da agricultura com a ciência da computação (*computer science*).
- CE 5: Os estudos que não estão relacionados com as questões de pesquisa.

Os critérios de inclusão e exclusão auxiliam durante o processo de filtragem a fim de obter os estudos mais aderentes ao estudo e eliminar discrepâncias geradas na pesquisa. Com a filtragem foram removidas impurezas que não estavam de acordo com os critérios de inclusão, sendo essa a primeira filtragem. A quantidade de estudos obtidos em cada passo da filtragem e também as porcentagens de trabalhos retirados em cada etapa pode ser visto na Figura 2.

Após os artigos terem sido filtrados na busca inicial através da *string* e depois de terem passado pelos 2 primeiros CIs, os mesmos foram para a terceira filtragem. O terceiro filtro do mapeamento foi a retirada dos estudos devido aos três primeiros critérios de exclusão. Na sequência foram filtrados por título e palavras-chave. Na quinta etapa de filtragem removeram-se os estudos após a leitura do *abstract*. Em seguida, os artigos duplicados foram removidos.

No final do processo de filtragem, foi realizada uma leitura completa de cada artigo, observando os dois últimos critérios de exclusão (CE 4 e CE 5). A Figura 2 apresenta o processo de filtragem, com os Critérios de Inclusão e Critérios de Exclusão aplicados em cada etapa. As bases de dados IEEE Xplore e ACM trouxeram menos trabalhos. Entretanto, essas bases foram mais assertivas, considerando-se a porcentagem entre o número de artigos encontrados na pesquisa inicial até a junção deles após a leitura por *abstract*. Considerando que as bases de dados Springer Library e Science Direct tiveram mais de 99% dos resultados filtrados ao longo



Figura 2 – Filtragem Completa do Mapeamento Sistemático

	Initial Search	Impurity Removal (IC1, IC2, IC3)	Impurity Removal (EC1, EC2, EC3)	Filter By Title and Keywords	Filter By Abstract	Combination	Duplicate Removal	Filter by Full Text (EC4, EC5)
IEEE Xplore	5,05% filtered 951	0,001% filtered 903	91,7% filtered 902	38,7% filtered 75	46	1,81% filtered 110	52,77% filtered 108	51
ACM Digital Library	18,4% filtered 120	2,05% filtered 98	67,7% filtered 96	38,7% filtered 31	19			
Springer Library	65,8% filtered 4276	43,03% filtered 1464	94,5% filtered 834	58,7% filtered 46	19			
Science Direct	31,6% filtered 7057	36,6% filtered 4895	98,1% filtered 3104	55,9% filtered 59	26			
<b>TOTAL</b>	40,7% filtered 12404	32,9% filtered 7360	95,7% filtered 4936	47,8% filtered 211	1,81% filtered 110			

Fonte: Elaborado pelo autor.

do processo, conclui-se que embora as mesmas tenham trazido mais resultados, quando comparadas com as demais bases de dados, as buscas originaram artigos menos aderentes ao tema proposto. O Apêndice A apresenta a relação dos 51 estudos selecionados no mapeamento que estão dispostos em ordem cronológica, juntamente com os autores, o título do artigo, o objetivo de cada um deles e seus IDs. Os IDs dos artigos servem de base para as tabelas e figuras apresentadas na seção a seguir. Essa disposição do Apêndice A facilita a compreensão da evolução dos trabalhos até o ano de 2019.

### 3.3 Resultados do Mapeamento Sistemático

Nesta seção são apresentados os resultados obtidos através da leitura e análise dos 51 estudos do mapeamento. As questões de pesquisa foram respondidas e considerações e análises adicionais sobre os estudos foram apresentadas.

#### 3.3.1 QG 1: Quais as tecnologias de computação sensível ao contexto estão sendo usadas na agricultura?

Os artigos foram classificados de acordo com o tipo de microcontroladores que utilizam em seus sistemas e também os tipos de sensores que estão sendo utilizados para obtenção das informações de contextos das plantações. Nos estudos os dois microcontroladores mais utilizados são Raspberry e Arduino. A Tabela 3 mostra que os mesmos são utilizados em 52,9% (27/51) dos trabalhos. Nem todos os artigos utilizados no mapeamento sistemático utilizaram microcontroladores. Por outro lado alguns estudos utilizavam dois microcontroladores (KUMAR et al., 2016), (POPOVIC et al., 2017), (GOAP et al., 2018), e (MEHRA et al., 2018).

A Tabela 4 apresenta os sensores utilizados para obtenção de informações do plantio. Os

Tabela 3 – Relação dos Microcontroladores Utilizados

Microcontrolador	Qtd. de Artigos	Porcentagem	ID dos Artigos
ARM	1	1,9%	[4]
Arduino	14	27,5%	[5], [14], [15], [20], [24], [25], [27], [29], [36], [37], [38], [43], [47], [49]
Intel Galileo Gen2	1	2,4%	[18]
Raspberry	16	31,4%	[7], [15], [19], [21], [24], [28], [30], [32], [33], [34], [35], [37], [38], [42], [45], [49]
Zigbee	6	11,8%	[2], [6], [14], [23], [29], [31]
NodeMCU	2	3,9%	[44], [51]

Fonte: Elaborado pelo autor.

tipos de sensores encontrados foram das mais diversas funcionalidades, totalizando 23 tipos. O sensor mais utilizado foi o sensor de umidade do solo aplicado em 52,9% (27/51) dos estudos, e o segundo mais utilizado foi o sensor de temperatura do ambiente aplicado em 45,1% (23/51) dos trabalhos. O sensor de umidade do ambiente foi empregue em 21 estudos dos 51, totalizando 41,2%.

### 3.3.2 QG 2: As informações são enviadas via cabo ou por qual tipo de rede sem fio?

O envio das informações envolve basicamente três tipos de comunicação, sendo eles Wi-Fi, dados móveis (3G/4G) e via cabos. Nesse mapeamento sistemático a comunicação Wi-Fi foi considerada toda aquela comunicação sem fio que não comunique dados através de módulos GPRS/GSM. Essa comunicação Wi-Fi pode ser entre os micros controladores dispersos no plantio e um servidor e na comunicação entre os micros controladores, entre outros. A Tabela 5 exhibe os tipos de comunicação, quais estudos utilizam cada tipo e quantos estudos utilizam cada uma das comunicações.

A comunicação 3G normalmente foi utilizada com módulos GSM/GPRS, em alguns casos a comunicação utiliza o 4G, mas sempre utilizando os dados móveis através desses módulos. Devido a isso essa comunicação foi nomeada de dados móveis. Em alguns protótipos foram utilizados mais que um tipo de comunicação. A Tabela 5 mostra que os estudos que utilizaram dois tipos de comunicação foram Luimula et al. (2009), Zhou et al. (2012), Kubicek et al. (2013), Divya et al. (2014), Rodríguez, Gualotuña e Grilo (2017), Alipio et al. (2017), Joshi et al. (2017), Zhou e Li (2017). Apenas um estudo utilizou os três tipos de comunicação (Zhang et al., 2017). Alguns estudos não utilizaram a comunicação Wi-Fi e aplicaram seu próprio tipo de conexão sem fio. Os trabalhos de Santos et al. (2018) e de Ji et al. (2019) aplicaram LoRa. Por sua vez, Fiehn et al. (2018) utilizou o WiLDNet, que é a sigla de *Wi-Fi Long Distance Network*, uma Wi-Fi criada para longas distâncias.

Tabela 4 – Relação dos Sensores Utilizados

Sensores	Número de Artigos	Porcentagem	ID dos Artigos
Umidade do Solo	27	52,4%	[2], [3], [6], [7], [13], [14], [17], [18], [20], [23], [24], [25], [26], [27], [29], [30], [31], [32], [34], [35], [37], [40], [43], [44], [46], [47], [51]
Temperatura da Água	8	15,6%	[8], [9], [19], [21], [33], [36], [47], [49]
Temperatura do Ambiente	23	45,1%	[2], [3], [4], [12], [14], [15], [17], [18], [20], [21], [24], [25], [29], [30], [31], [34], [37], [39], [44], [46], [47], [49], [51],
Luminosidade	14	27,4%	[2], [3], [12], [17], [18], [19], [21], [29], [31], [34], [35], [39], [46], [49]
CO2	4	7,9%	[2], [3], [31], [35]
Componentes Químicos do Solo	7	13,7%	[3], [4], [6], [12], [15], [24], [35]
Temperatura do Solo	10	19,6%	[2], [3], [4], [6], [7], [12], [26], [37] [43], [51]
Umidade do Ambiente	21	41,2%	[2], [3], [4], [12], [14], [15], [17], [19], [20], [21], [25], [29], [30], [31], [36], [37], [39], [44], [47], [49], [51]
Pressão Atmosférica	2	3,9%	[24], [39]
Velocidade do Vento	2	3,9%	[24], [39]
Chuva	2	3,9%	[8], [24]
RFID	2	3,9%	[4]
pH do Solo	2	3,9%	[2], [6]
Salinidade	2	3,9%	[8], [9]
Oxigênio Dissolvido	1	1,95%	[9]
Condutividade da Água	4	7,9%	[17], [19], [21], [49]
UV	3	5,9%	[37], [39], [51]
Solenóide	1	1,95%	[32]
Termohigrômetro	1	1,95%	[39]
Nível de Água	5	9,8%	[8], [17], [30], [33], [38]
pH da Água	10	19,6%	[9], [17], [19], [20], [21], [25], [27], [38], [47], [49]
Ultrassônico	2	3,9%	[28], [49]

Fonte: Elaborado pelo autor.

Tabela 5 – Tipo de Comunicação dos Protótipos

Tipo de Comunicação	Número de Artigos	Porcentagem	ID dos Artigos
Cabo	5	9,8%	[23], [34], [38], [47], [49]
Dados Móveis (3G/4G)	14	27,45%	[1], [3], [4], [6], [7], [9], [17], [18], [23], [24], [25], [31], [32], [39]
Wi-Fi	28	54,9%	[1], [2], [3], [4], [5], [6], [7], [10], [12], [15], [18], [20], [21], [23], [27], [29], [30], [31], [33], [34], [35], [36], [37], [42], [43], [44], [45], [51]

Fonte: Elaborado pelo autor.

### 3.3.3 QG 3: Que áreas da agricultura a sensibilidade ao contexto e/ou predição estão sendo aplicadas?

Agricultura *indoor* é a agricultura realizada em um local fechado, como uma plantação dentro de uma estufa ou pavilhão. Nesse tipo de cultivo foram encontrados 15 estudos. A agricultura *outdoor* é aplicada em ambientes abertos, onde é reduzida a possibilidade de controle do ambiente. Para esse tipo de cultivo foram encontrados 23 estudos, os quais estão distribuídos durante todo o período do mapeamento, pois existem estudos desde 2009 até 2019.

O termo agricultura foi utilizado para os estudos que podem ser aplicados tanto na agricultura *indoor* como na agricultura *outdoor*. A Tabela 6 apresenta as áreas de atuação em que os estudos foram aplicados. Como na agricultura *indoor* existem diferentes métodos de cultivo, a Tabela 6 apresenta a área agricultura *indoor* e também os 2 tipos de plantios diferentes do método tradicional da agricultura.

O primeiro deles foi a hidroponia, que é um modelo de cultivo da agricultura que funciona através da recirculação de água que possui os nutrientes necessários para as plantas, sendo a mesma empregada em locais fechados, como estufas ou pavilhões. Estudos de predição e sensibilidade ao contexto na hidroponia são recentes tendo início em 2017 com os estudos de Alipio et al. (2017) e Eko et al (2017) e o estudo de Mehra et al. (2018) que foi publicado em 2018.

O segundo cultivo diferente do método tradicional foi a aquaponia, que possui o mesmo princípio que a hidroponia, porém, ao invés de serem adicionados nutrientes na água de circulação existe uma criação de peixes que trabalham em conjunto com o cultivo das plantas. Os peixes ficam localizados em um tanque separado e geram os nutrientes para as plantas através de seus excrementos. Esse tipo de cultivo foi encontrado nos trabalhos de Jacob (2017) e de Ong, Ng e Kyaw (2019). Também foram encontrados dois trabalhos sobre aquacultura, que é a criação de peixes e que ambos possuem um controle sobre a qualidade da água (SHAHRIAR;

Tabela 6 – Áreas da Agricultura que os Estudos Foram Aplicados

Área da Agricultura	Número de Artigos	Porcentagem	ID dos Artigos
Agricultura	11	21,5%	[6], [16], [20], [22], [23], [24], [31], [40], [43], [48], [50]
Agricultura Outdoor	23	45,1%	[34], [13], [1], [2], [4], [5], [7], [10], [12], [14], [15], [18], [25], [26], [28], [30], [32], [37], [39], [41], [42], [45], [46]
Agricultura Indoor	10	19,6%	[3], [11], [17], [27], [29], [35], [36], [44], [47], [51]
Aquacultura	2	3,9%	[8], [9]
Hidroponia	3	5,9%	[19], [21], [38]
Aquaponia	2	3,9%	[33], [49]

Fonte: Elaborado pelo autor.


MCCULLUCH, 2014) e (XU et al., 2014).

A Figura 3 mostra a relação entre o tipo de dispositivo que obtém as informações e a área de aplicação ao decorrer dos anos. A Figura 2 mostra que os sensores são os dispositivos mais utilizados para fornecer informações sobre o cultivo desde 2012, mas que a partir do ano de 2014 a câmera foi agregada aos sensores ou até mesmo utilizada de forma independente para informar dados sobre a produção. Entre as áreas de aplicação destacam-se os estudos sobre agricultura *outdoor*, sempre em maior número durante os anos. No entanto, a quantidade de estudos aplicados na agricultura *indoor* teve um crescimento de 400% (8/2) nos anos de 2017 e 2018 em relação aos anos de 2015 e 2016. Já a agricultura *outdoor* teve seu crescimento de 220% (11/5) relacionados com o mesmo período. Esse crescimento da agricultura *indoor* gerou um equilíbrio entre as áreas nos últimos três anos. Os dois estudos encontrados sobre a aquacultura foram publicados no ano de 2014.

### 3.3.4 QEP 1: Quais trabalhos utilizam câmeras para obtenção de informações na agricultura?

O mapeamento encontrou 23 estudos que utilizam câmeras para obter informações do processo produtivo. Entre eles, os estudos de Zhou e Li (2017) e de Jacob (2017) utilizam as câmeras para visualizar a plantação, ou seja, não são obtidas informações da produção além da visualização do cultivo. Outros 17 estudos (LUIMULA et al., 2009), (ZHOU et al., 2012), (KUBICEK et al., 2013), (FUKATSU; HIRAFUJI, 2014), (RUPANAGUDI et al., 2015), (MA et al., 2015), (TAN, 2016), (KUMAR et al., 2016), (WINICZENKO et al., 2016), (RODRÍGUEZ; GUALOTUÑA; GRILO, 2017), (YAHATA et al., 2017), (ZHANG et al., 2017), (ARAKERI et al., 2017), (SARANGDHAR; PAWAR, 2017), (JOSHI et al., 2017), (TREBOUX; GENOUD, 2018), (FIEHN et al., 2018), (JI et al., 2019), (TIWARI et al., 2019), (ONG; NG; KYAW, 2019), (KALE; SONAVANE, 2019) obtêm informações para diversas funcionalidades, entre elas, de-

Figura 3 – Relação entre os Dispositivos para Obtenção das Informações e as Áreas de Aplicação



Fonte: Elaborado pelo autor.

teccção de pragas na plantação, identificação de frutos com problema na sua formação, contagem de insetos, crescimento das plantas, entre outros.

O processamento de imagens está obtendo resultados cada vez mais expressivos, isso fica evidente nos estudos desse mapeamento. As imagens do plantio foram analisadas de diferentes maneiras nos estudos e forneceram informações como detectar a indicação da espécie da planta (KUMAR et al., 2016), o tamanho das plantas (JOSHI et al., 2017) e (FUKATSU; HIRAFUJI, 2014), praga nos frutos (TAN, 2016), indicação da espécie de pássaro (FIEHN et al., 2018), contagem de insetos (FUKATSU; HIRAFUJI, 2014), a cor do fruto (TAN, 2016), entre outros aspectos.

### 3.3.5 QEP 2: Quais técnicas de predição são utilizadas na agricultura?

Sistemas preditivos evitam perdas, pois evitam a zona não ideal de execução do sistema, mas em contrapartida, é necessário maior acompanhamento das informações e também do modelo de predição. Deste modo, um software de predição depende da geração de um modelo preditivo baseado na análise de dados, como o contexto que o mesmo está incluso.

A Tabela 7 mostra os 20 trabalhos que utilizam a predição na agricultura, destacando a técnica aplicada em cada um deles. Alguns artigos utilizam mais de uma técnica e por esse motivo ao se somar as técnicas utilizadas, o seu valor é maior que o número de estudos.

A Tabela 7 mostra que existem estudos que aplicaram duas ou até mesmo três técnicas

Tabela 7 – Técnicas de Predição Utilizadas na Agricultura

Técnica Aplicada	Qtd. de Artigos	Porcentagem	ID dos Artigos
Regras de Especialista	1	1,95%	[8]
Séries Temporais	1	1,95%	[8]
Regressão Linear/Vetorial	5	9,8%	[29], [30], [37], [47], [49]
Redes Neurais	6	11,8%	[27], [29], [35], [38], [39], [48]
Método Estatístico	1	1,95%	[14]
Modelo Markov	2	3,9%	[14], [40]
Redes Bayesianas	1	1,95%	[19], [34]
ARIMA	3	5,9%	[35], [36], [40]
Árvore de Decisão	1	3,9%	[41]
Algoritmo Genético	2	3,9%	[16], [50]
Superfície de Resposta	1	1,95%	[16]
BirdNet	1	1,95%	[42]
Regressão Lasso	1	1,95%	[35]

Fonte: Elaborado pelo autor.

de predição. O estudo de Park et al. (2017) aplica três técnicas e depois relata qual obteve o melhor resultado. Os trabalhos de Shahriar e McCulluch (2014), Winiczenko et al. (2016), Patil e Thorat (2016) e Rodríguez, Gualotuña e Grilo (2017) aplicaram duas técnicas de predição.


A Figura 4 mostra como o número de estudos sobre predição na agricultura aumentou no decorrer dos anos. No ano de 2018 a porcentagem de publicações que utilizam predição na agricultura aumentou significativamente em relação ao número de trabalhos publicados, era de 33,33% (6/18) no ano de 2017 para 100% (7/7) no ano de 2018. É possível constatar que todos os sete estudos (GOAP et al., 2018), (MEHRA et al., 2018), (PLAZAS; GAONA-GARCÍA; MARIN, 2018), (HUONG et al., 2018), (TREBOUX; GENOUD, 2018), (FIEHN et al., 2018) e (SANTOS et al., 2018), do ano de 2018 utilizaram predição na sua elaboração. No mapeamento sistemático, o trabalho mais antigo relacionado com alguma técnica de predição aplicada na agricultura foi o de Shahriar e McCulluch (2014).

Os trabalhos de 2019 que utilizaram técnicas de predição foram os de Kale e Sonavane (2019), Ong, Ng e Kyaw (2019), Tiwari et al. (2019) e Vadivel et al. (2019). Também é possível notar que houve uma queda do ano de 2018 para o ano de 2019 em relação a quantidade de trabalhos que utilizaram técnicas de predição, porém é importante ressaltar que alguns artigos que utilizavam técnicas de predição foram retirados durante o processo de filtragem por não indicarem como obtiveram as informações que estavam utilizando.

### 3.3.6 QET 1: Onde as pesquisas foram publicadas?

Os artigos foram agrupados de acordo com as quatro bases utilizadas na pesquisa. A base de dados que obteve o maior número de trabalhos foi a IEEE Xplore com 21 artigos de um total

Figura 4 – Estudos de Predição na Agricultura no decorrer dos Anos



Fonte: Elaborado pelo autor.

de 51, ou seja, 41,2%. Em segundo lugar ficou a base Science Direct com 14 artigos, resultando em 27,5%. A base de dados ACM Digital Library retornou 10 estudos (19,6%) e por fim, a Springer Library retornou 6 artigos que são equivalentes a 11,8%.

### 3.3.7 QET 2: Quantas publicações ocorreram por ano?

A Figura 5 mostra os 51 artigos distribuídos por ano de publicação e base de dados. Nos últimos três anos, o número de publicações sobre predição e/ou sensibilidade ao contexto aumentou significativamente. Este crescimento mostra o interesse de pesquisadores em aplicar predição e contextos para aperfeiçoar o cultivo da agricultura, melhorar a qualidade dos produtos, ter um maior acompanhamento da produção, entre outros aspectos.

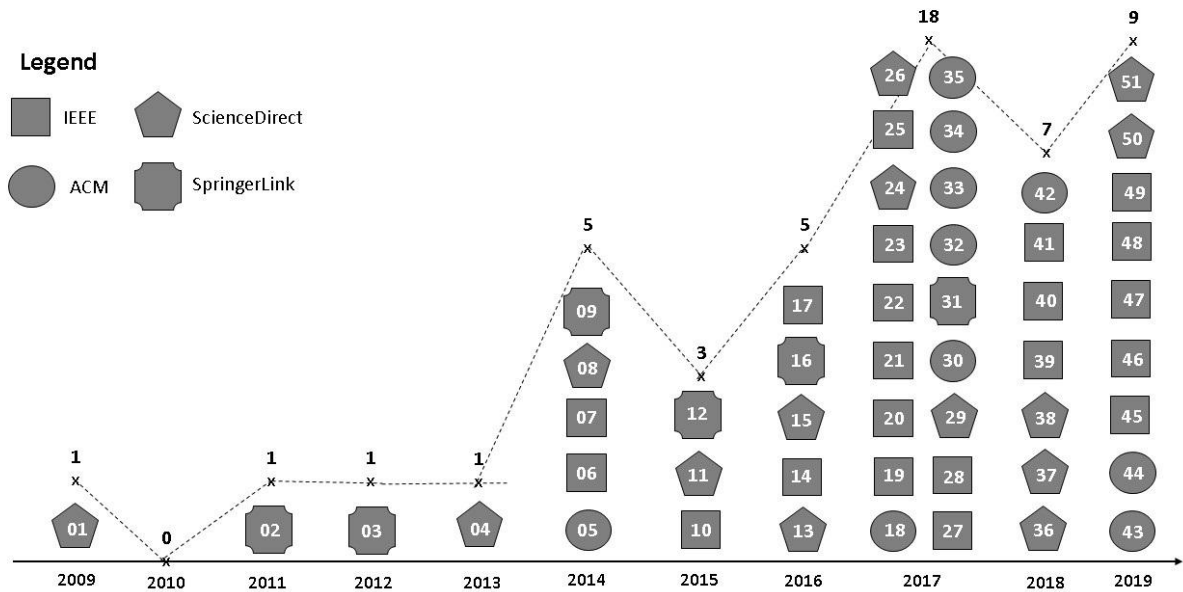
É possível também constatar que base de dados que esteve mais presente nesses 12 anos de estudos foi a base da Science Direct, pois em 8 dos 12 anos a mesma teve artigos selecionados. A partir do ano de 2014 houve uma maior diversidade das bases de dados até o ano de 2017. Nos anos de 2018 e 2019 a base da Springer Library foi a única que não teve nenhum artigo selecionado para o mapeamento.

## 3.4 Discussão do Mapeamento Sistemático

Nesta seção são discutidos os resultados obtidos e as ameaças à validade do mapeamento.



Figura 5 – Quantidade de Publicações de 2009 até 2019



Fonte: Elaborado pelo autor.

### 3.4.1 Ameaças à Validade

Os trabalhos de mapeamento sistemático estão expostos a riscos que podem invalidar o estudo. Esses riscos podem ter origem em decisões tomadas equivocadamente durante o mapeamento sistemático. Com o objetivo de garantir melhores resultados, foram selecionadas quatro bases de dados, conhecidas na área acadêmica por sua relevância na área de ciência da computação e afins. Portanto, procurou-se mitigar a possibilidade das bases de dados impactarem nos resultados.

Foram utilizados cinco termos principais classificados como um termo primário e quatro secundários. Foram utilizados seus sinônimos para construir a *string* de pesquisa. Como resultado da *string* buscou-se obter estudos que tivessem relação com um dos quatro termos secundários relacionados com o termo primário “Agricultura” e suas áreas específicas “Hidroponia” e “Aquaponia”. Assim, procurou-se a obtenção do maior número de estudos nos resultados de busca.

O mapeamento não considerou aspectos conceituais da área de Agricultura, como estudos aplicados somente na área de ciências da natureza, atendo-se exclusivamente na aplicação da Agricultura envolvendo os termos secundários “Predição”, “Sensibilidade ao Contexto”, “Sistemas Cyber Físicos” e “Internet das Coisas”. Esta decisão contribui com a filtragem, direcionando a busca apenas a um contexto específico dentro da área da “Agricultura e Ciência da Computação”, uma disciplina que concentra uma ampla quantidade de trabalhos acadêmicos.

O processo de filtragem pode ter restringido os trabalhos de forma que algum estudo relevante possa ter sido removido. Para mitigar esse risco, o processo de filtragem foi baseado em uma técnica amplamente adotada em trabalhos acadêmicos de mapeamento sistemático (PE-

TERSEN; VAKKALANKA; KUZNIARZ, 2015). Foram utilizados processos de revisão já utilizados por outros autores (GONÇALES et al., 2018), (DIAS; BARBOSA; VIANNA, 2014), (BISCHOFF et al., 2019) e (DALMINA; BARBOSA; VIANNA, 2019).

Alguns estudos podem não ter sido citados especificamente nas respostas das questões, porém foram citados nas tabelas e figuras através de seus IDs que são indicados no Apêndice A. Esses trabalhos são de Zhou, Liu e Dong (2011), Shahriar e McCulluch (2014), Concepcion, Stefanelli e Trincherro (2014), Tan, Zhao e Wu (2015), Batista, Rodríguez e Quintana (2016), Ivanov e Tsvetkov (2017), Rajendrakumar et al. (2017), Saha et al. (2017), López-Riquelme et al. (2017) e Kokkonis, Kontogiannis e Tomtsis (2017).

### 3.4.2 Discussão

Apenas 20 trabalhos utilizaram predição na agricultura, ou seja, 39,2% dos artigos. Entre eles, a técnica mais utilizada foi Redes Neurais em seis artigos (ATHANI et al., 2017), (RODRÍGUEZ; GUALOTUÑA; GRILO, 2017), (PARK et al., 2017), (MEHRA et al., 2018), (PLAZAS; GAONA-GARCÍA; MARIN, 2018) e (TIWARI et al., 2019). A técnica de Regressão Linear/Vetorial foi utilizada nos estudos de Rodríguez, Gualotuña e Grilo (2017), Sarangdhar e Pawar (2017) e Goap et al. (2018), Vadivel et al. (2019) e Ong, Ng e Kyaw (2019). Por sua vez, ARIMA foi utilizada nos estudos de Park et al. (2017), Santos et al. (2018) e Huong et al. (2018).

A utilização de câmeras para obter informações aumentou nos últimos anos e com isso mais sistemas e softwares estão podendo utilizá-las. As informações podem ter diferentes finalidades como detectar as espécies de plantas (KUMAR et al., 2016), espécies de pássaros (FIEHN et al., 2018), o tamanho das plantas (JOSHI et al., 2017), (FUKATSU; HIRAFUJI, 2014), a cor de frutos (TAN, 2016), as pragas nos frutos (TAN, 2016) e também contar insetos (FUKATSU; HIRAFUJI, 2014). Essas aplicações mostram o potencial na área devido a diversidade de informações que podem ser obtidas com o mesmo equipamento.

Analisando todo o processo de filtragem apresentado na Figura 2, e a Questão Estatística 1 (QET1) que apresenta em quais bases de dados os artigos foram publicados, é possível constatar que as bases de dados mais precisas que processaram a string de consulta foram a ACM Library e a IEEE Xplore, por terem um número de artigos pequeno na pesquisa inicial, mas terem um número relativamente alto quando comparado ao total de artigos utilizados no mapeamento. O banco de dados menos preciso foi o Springer Libray, pois dos 4276 trabalhos resultantes na pesquisa inicial, apenas 6 estudos foram utilizados após a última filtragem.

Outro dado estatístico foi que, até 2013 a quantidade de trabalhos anual sobre predição e sensibilidade ao contexto na agricultura se manteve estável, com até uma publicação por ano. A partir do ano de 2014 houve um aumento progressivo até 2018. Em 2014 foram apresentados 5 trabalhos, valor que no ano de 2015 teve uma queda (3 trabalhos) e no ano de 2016 novamente 5 publicações. No entanto, houve um aumento maior de publicações nos últimos dois anos,

mostrando o interesse crescente de pesquisadores nesta área.

### 3.5 Conclusões do Mapeamento Sistemático

Nesta seção são apresentadas as conclusões sobre o mapeamento sistemático e a identificação das lacunas e oportunidades para futuras pesquisas. O estudo de mapeamento sistemático apresentou o estado da arte no uso da predição e/ou sensibilidade ao contexto na Agricultura. Este mapeamento também apresentou as principais tecnologias utilizadas para obter informações, tais como os microcontroladores, e também constatou que são utilizados os diversos sensores para obtenção de informações do plantio. Além dos sensores utilizados também foi informado qual o modo de envio das informações obtidas nos cultivos até os servidores dos artigos estudados. Além de apresentar quais trabalhos utilizavam câmeras para obter informações do cultivo, também foi possível gerar dados estatísticos das publicações referentes aos temas pesquisados na última década.

Observou-se que a maior parte dos estudos aplicam a mesma metodologia, ou seja, a instalação de sensores, a obtenção e análise dos dados. Destaca-se que 20 deles apresentam o desenvolvimento de um sistema preditivo. Com isso alguns estudos se tornam um pouco repetitivos em relação a metodologia, porém existe uma grande diversidade de técnicas de predição aplicadas em cada um deles, como mostra a Tabela 7. Um desafio para trabalhos futuros é aprofundar os estudos e classificá-los em projetos semelhantes, o que pode tornar a utilização da predição mais rápida e buscando sempre melhores resultados.

O uso de algoritmos matemáticos e estatísticos para comprovar a eficácia dos trabalhos, mostra-se presente nos trabalhos que utilizaram predição na Agricultura (SHAHRIAR; MCCULLUCH, 2014), (PATIL; THORAT, 2016), (WINICZENKO et al., 2016), (JOSHI et al., 2017), (ALIPIO et al., 2017), (ATHANI et al., 2017), (RODRÍGUEZ; GUALOTUÑA; GRILO, 2017), (SARANGDHAR; PAWAR, 2017), (PARK et al., 2017), (SANTOS et al., 2018), (GOAP et al., 2018), (MEHRA et al., 2018), (PLAZAS; GAONA-GARCÍA; MARIN, 2018), (HUONG et al., 2018), (TREBOUX; GENOUD, 2018), (FIEHN et al., 2018), (VADIVEL et al., 2019), (ONG; NG; KYAW, 2019) e (KALE; SONAVANE, 2019), (TIWARI et al., 2019). Esses estudos buscaram mostrar o resultado e a incerteza quando se trabalha com predição, não podendo garantir a ocorrência de certo evento, mas dando indicações de situações que podem melhorar a produção devido aos dados analisados.

A revisão dos trabalhos publicados nos últimos 12 anos pode fornecer *insights* iniciais para novos estudos baseados em predição ou, mais especificamente, predição baseada na sensibilidade ao contexto. Como trabalhos futuros pode-se citar a comparação entre os resultados obtidos nos estudos que utilizam predição para determinar qual técnica está sendo mais efetiva na Agricultura. Essa efetividade na Agricultura pode ser obtida através de um maior rendimento de produção no mesmo espaço de cultivo, utilização de menos mão de obra, mais sistemas automatizados, entre outras melhorias.

Outro ponto a ser estudado é a análise de tipos de sensores que tornam a predição mais efetiva, por exemplo, a utilização de sensores de umidade do solo, de pH da água, buscando determinar quais informações seriam mais relevantes para a predição. Com isso a predição poderá fornecer inferências com maior precisão visando sistemas de suporte à decisão, entre outros auxílios que a predição pode proporcionar.

### 3.6 Comparação do IndoorPlant com Trabalhos Relacionados

Nesta seção são apresentados os estudos que possuem relação com o IndoorPlant. Como mencionado anteriormente, busca-se mostrar nesse capítulo o estado da arte e também as lacunas de pesquisa. Nesse sentido foram selecionados 6 trabalhos que possuam relação com a agricultura de precisão, que utilizem os dados obtidos de sensores instalados na plantação e que utilizem alguma técnica de predição com as informações obtidas. A seguir são descritos os trabalhos relacionados e destacadas as diferenças entre eles.

Santos et al. (2018) apresentaram um modelo que combina um sistema de alcance de rede sem fio (LoRa) com um mecanismo de predição que antecipa possíveis disfunções nas culturas proativamente, notificando o agricultor para ações corretivas o mais rápido possível. O modelo proposto foi aplicado em uma estufa de 12 m<sup>2</sup> com cultivo no solo.

Goap et al. (2018) propuseram um sistema inteligente, aplicado na agricultura de solo, programado em código aberto que preve os requisitos de irrigação do campo com utilização de sensores. Mehra et al. (2018) realizaram o desenvolvimento de um sistema hidropônico baseado em IoT inteligente empregando Redes Neurais. O sistema desenvolvido é inteligente o suficiente para controlar as ações do ambiente hidropônico.

Alipio et al. (2017) desenvolveram um sistema de hidroponia inteligente utilizado na automação do processo de crescimento das culturas usando inferência através de Redes Bayesianas. Huang et al. (2018) propuseram um modelo genérico utilizando o Modelo de Decisão de Markov para criar uma irrigação automática e precisa. Com o modelo se busca transformar a agricultura e ser mais eficiente em consumo de energia e água.

Sisyanto, Suhardi e Kurniawan (2017) criaram um sistema que possibilita o agricultor a monitorar sua hidroponia através do Telegram Messenger. A Tabela 8 compara os artigos citados quanto ao tipo de sensores, qual espécie de planta foi cultivada, análise e armazenamento dos dados, técnica de predição e utilização de históricos de contextos.

A análise da Tabela 8 permite constatar que apenas o IndoorPlant utiliza as informações dos cultivos como históricos de contextos, os outros estudos apenas utilizam as informações para treinarem seus serviços. Ou seja, o IndoorPlant pode fazer recomendações para o cultivo com base em contextos anteriores, por exemplo quando nota algum parâmetro do contexto atual de cultivo fora dos padrões dos contextos anteriores, com isso o IndoorPlant indica ao agricultor modificar o parâmetro de cultivo, porém o agricultor necessita aprovar essa modificação.

Outro aspecto é que os estudos relacionados com o IndoorPlant possuem apenas um ser-

Tabela 8 – Comparativo dos Trabalhos Relacionados com o IndoorPlant

Artigo	Sensores	Técnica	Planta	Dados	Hist. de Contextos
(ALIPIO et al., 2017)	Umid. do ar, luminosidade, temp. da água, pH e condutividade	Redes Bayesianas	Repolho	Agendada	Não
(GOAP et al., 2018)	UV, temp. do solo, umid. do solo, temp. do ar, umid. do ar	Regressão Vetorial	Flores	Agendada	Não
(HUONG et al., 2018)	Umid. do solo	Decisão Markov	Tomate	ND	Não
(MEHRA et al., 2018)	pH, nível do tanque, temp. do ar, umid. do ar, luminosidade	Redes Neurais	Tomate	Tempo Real	Não
(SANTOS et al., 2018)	Temp. do ar, temp. do solo, umid. do ar, umid. do solo, luminosidade	ARIMA	Rúcula	Agendada	Não
(SISYANTO et al., 2017)	Umid. do ar, temp. do ar e luminosidade	ND	ND	Tempo Real	Não
IndoorPlant	Temp. do ar, umid. do ar, luminosidade, condutividade, pH, nível do tanque, quantid. de nutrientes, pressão da bomba	Análise de similaridade e previsão PLS	Todas culturas	Tempo Real	Sim

Fonte: Elaborado pelo autor.

viço específico, como predição de temperatura e umidade da estufa (SANTOS et al., 2018) ou a irrigação inteligente (HUONG et al., 2018). Já o IndoorPlant possui capacidade para prover diversos serviços inteligentes para o usuário, como a predição do tempo de colheita, recomendação de melhorias no cultivo, alarmes para algum problema encontrado no cultivo, entre outros.

O tipo de cultivo é outro diferencial entre o IndoorPlant e os demais estudos, o modelo proposto suporta diferentes tipos de cultivo, como hidroponia, fertirrigação (semi-hidroponia) e cultivo no solo. Os demais estudos são focados em apenas um tipo de cultivo como o trabalho de Goap et al. (2018) que é aplicado na agricultura de solo, e a hidroponia que é aplicada nos estudos (ALIPIO et al., 2017) e (SISYANTO; SUHARDI; KURNIAWAN, 2017).

## 4 MODELO INDOORPLANT

Este capítulo descreve o modelo para a agricultura *indoor* que suporta serviços inteligentes genéricos com base nos históricos de contextos, denominado IndoorPlant. A seção 4.1 apresenta uma visão geral sobre o modelo e seus principais conceitos. A seção 4.2 apresenta requisitos e casos de uso. Na seção 4.3 é apresentada a arquitetura com os componentes do modelo, e a seção 4.4 apresenta a ontologia criada. A seção 4.5 apresenta as considerações sobre o capítulo.

### 4.1 Visão Geral do Modelo

Na Agricultura Inteligente deve existir uma infraestrutura capaz de suportar sensores e módulos de diversas funcionalidades, comunicação via cabo, via rádio ou via satélite, entre outros quesitos. Na maioria dos casos a agricultura *indoor* sempre é praticada em locais muito próximos a grandes centros urbanos, já que nesses locais é onde ocorre o maior consumo de alimentos. Com essa distância pequena entre os centros urbanos e as plantações é possível dizer que em grande parte das vezes há acesso à internet e a possibilidade de instalar sensores.

O modelo IndoorPlant concentra-se na área da agricultura *indoor* fornecendo serviços genéricos inteligentes através do armazenamento e análise dos históricos de contextos. O principal objetivo é facilitar o trabalho do agricultor com o uso da tecnologia no seu cotidiano e gerar recomendações para a melhoria do cultivo. Essas recomendações e serviços podem ser diferentes para cada agricultor devido ao motivo da grande variedade de tecnologia embarcada hoje nas estufas hoje no Brasil. Pode-se encontrar estufas totalmente automatizadas que importaram tecnologia de países como Holanda e Israel, como também pode-se encontrar estufas que possuem todo o processo manual, desde a abertura das estufas até a irrigação das plantas.

O IndoorPlant busca gerar recomendações e serviços inteligentes de diferentes aspectos levando em conta o nível de tecnologia que o agricultor possui em sua estufa. O modelo proposto não gera uma indicação para o agricultor de "ligar a ventilação" se a estufa do agricultor não possui essa tecnologia embarcada. Por outro lado, se o agricultor possui uma estufa com os parâmetros sendo monitorado 24 horas por dia, o IndoorPlant possui a capacidade de analisar os históricos de contextos e gerar recomendações como para modificar algum parâmetro na estufa que anteriormente se obteve um resultado melhor ao utilizar um valor diferente do atual.

Outro fato a ser considerado pelo modelo é a grande diversidade na utilização de tecnologia por parte dos próprios agricultores. Existem agricultores que olham seu cultivo e/ou sua propriedade como um negócio promissor e buscam o que existe de mais novo e melhor para sua plantação. Esses agricultores estão acostumados a usarem *smartphones* e afins. Por outro lado também existe uma grande quantidade de agricultores que ainda utilizam de técnicas antigas de plantio e que não possuem uma interação com a tecnologia atual, e ainda possuem celulares antigos que não suportam a instalação de aplicativos. Essa diferente concepção do uso da tecnologia é outro ponto considerado pelo modelo, pois o mesmo deve gerar benefício a maior

parte dos agricultores.

O IndoorPlant suporta o gerenciamento de fertirrigações, semihidroponias, hidroponias e até mesmo a plantação no solo, mas lembrando que isso deve ocorrer sempre dentro de estufas ou pavilhões. O IndoorPlant permite sensores de diferentes finalidades, entre eles: sensores de umidade do ar, temperatura do ar, pH da água, condutividade da água, vazão de nutrientes, temperatura da solução, eletrodos de nível, gás carbônico, umidade do solo, pressão do ambiente, pressão da bomba de circulação e luminosidade.

## 4.2 Requisitos do Modelo

Para atender as especificações do IndoorPlant são definidos os seguintes requisitos:

- Monitorar as entidades (estufas), apresentar informações sobre a situação das mesmas.
- Permitir acesso ao modelo por meio de dispositivos móveis (smartphones e tablets).
- Utilizar os históricos de contextos para gerar serviços inteligentes genéricos e recomendações.
- Suportar serviços inteligentes de diversas finalidades.
- Vincular notas fornecidas pelos agricultores durante a colheita com os contextos atuais.
- Gerar recomendações de melhorias no cultivo baseado nos históricos de contextos e nas notas fornecidas pelos agricultores na colheita.
- Permitir a integração de dados externos ao modelo, como também oferecer dados para outros sistemas por meio de Web Server ou Local Server denominado IndoorServer.
- Realizar a coleta de informações utilizando sensores via cabo e fornecer essas informações para o servidor via Wi-Fi.
- Permitir a inserção de informações no sistema de forma manual ou automática.
- Utilizar perfis para usuários e para as plantas que estão sendo cultivadas.

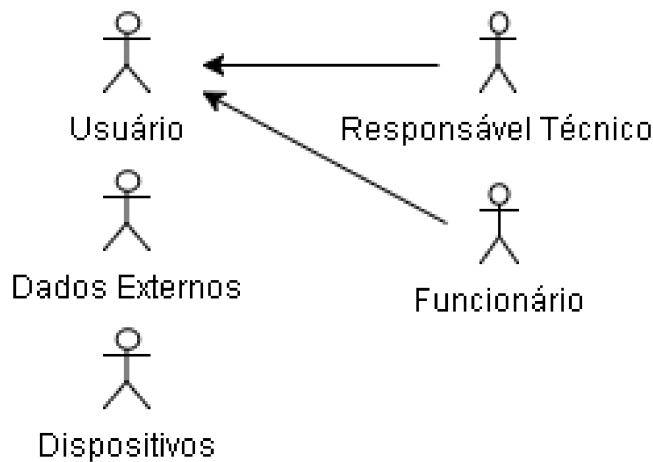
O IndoorPlant também utiliza de permissões para usuários. Através dessa estratégia é possível oferecer níveis de acesso e permissões para cada tipo de usuário (responsável técnico/funcionário).

### 4.2.1 Casos de Uso

Atores em um sistema são os diversos tipos de usuários, não se limitando a pessoas, atores também podem ser aplicações, dispositivos e eventos externos (LEE; TEPFENHARDT, 2000).



Figura 6 – Atores do IndoorPlant



Fonte: Elaborado pelo autor.

O IndoorPlant além dos usuários, que são pessoas, possui também como atores os dispositivos e aplicações.

Os usuários no IndoorPlant podem ser de 2 tipos, funcionário e/ou responsável técnico (RT). O RT é aquele que pode acessar e visualizar as informações do contexto da estufa remotamente, já o funcionário só pode visualizar e atuar o sistema manualmente no local.


Essa diferenciação existe porque o RT possui a responsabilidade da plantação. Com isso ele pode alterar parâmetros no sistema, como por exemplo, ligar bomba de circulação reserva, número de irrigações por dia, temperatura do ambiente na estufa, quantidade de cada nutriente para a planta, entre outros. Já o funcionário pode ser considerado o usuário comum, ou seja, ele apenas recebe informações da estufa, e só consegue atuar o sistema manualmente no local. Por outro lado ambos os usuários (RT e funcionário) recebem alertas de atuações do IndoorPlant e de atuações do sistema e de problemas que foram encontrados no funcionamento.

Os quatro atores do modelo são indicados na Figura 6, são eles usuários (responsável técnico e funcionário), dados externos e dispositivos. O termo “dados externos” representa as aplicações externas e sistemas externos que podem fornecer informações ao IndoorPlant. Os dispositivos são os sensores e atuadores do sistema que também fornecem informações para o modelo. Cada um destes autores interage com o sistema através de componentes específicos e utiliza funcionalidades que são caracterizadas com diagramas de casos de uso.

Os casos de uso do responsável técnico são apresentados na Figura 7, contemplando alguns quesitos citados a seguir:


- **Gerenciar Perfis:** Este é o momento em que o RT pode gerenciar tanto os perfis dos usuários como das plantas que estão sendo cultivadas. Ele pode atribuir mais informações ao controle de produção da planta ou então mudar parâmetros da plantação.
- **Gerenciar Recursos:** Esta funcionalidade se deve ao RT poder saber quais os status dos recursos da plantação estão atuando normal e se algum recurso está com problema. Um

Figura 7 – Casos de Uso do RT



Fonte: Elaborado pelo autor.

Figura 8 – Casos de Uso do Funcionário



Fonte: Elaborado pelo autor.

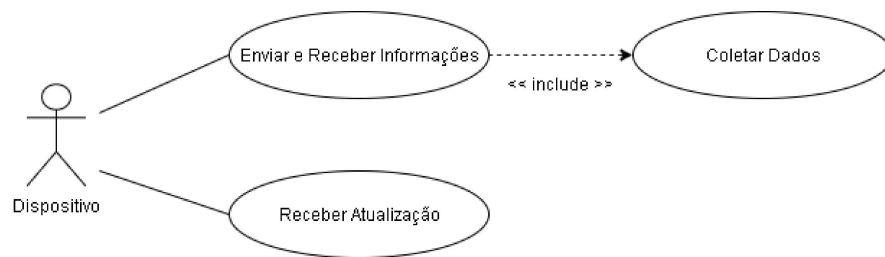
exemplo de recurso pode-se dizer que é a questão das bombas de circulação do cultivo, em que alguma bomba pode estar estragada e o IndoorPlant mostra o status da mesma.

- **Acessar os Dados:** Esta funcionalidade é a responsável por mostrar os dados disponíveis de todo o cultivo e de todos os sensores. Por se tratar do RT, ele possui acesso a todos os dados da plantação, até mesmo para saber se houve algum sinistro que veio a gerar algum problema na produção.
- **Receber Alertas:** Trata-se da funcionalidade que informa o usuário que algo de errado ocorreu ou está ocorrendo dentro da estufa. Entre os alertas pode-se citar a bomba de circulação estragada, o nível do tanque muito baixo, a temperatura da solução muito alta, entre outros.
- **Receber Recomendações:** Esta funcionalidade é a responsável por indicar melhorias nos parâmetros para o RT. O modelo analisa os dados do histórico juntamente com os dados do momento e fornece sugestões para que o RT aprove ou não a modificação nos parâmetros da produção.

A Figura 8 apresenta os casos de uso do usuário funcionário. Todos os casos de uso são detalhados na sequência:

- **Acessar os Dados:** Esta funcionalidade é a responsável por mostrar os dados disponíveis de todo o cultivo e de todos os sensores. Por se tratar do funcionário, ele não possui acesso a todos os dados da plantação, ele possui acesso aos dados em tempo real. Não

Figura 9 – Casos de Uso do Dispositivo



Fonte: Elaborado pelo autor.


conseguindo assim saber as condições que a estufa se encontrava há 3 horas atrás, por exemplo.

- **Receber Alertas:** Trata-se da funcionalidade que informa o usuário que algo de errado ocorreu ou está ocorrendo dentro da estufa. Entre os alertas pode-se citar a bomba de circulação estragada, o nível do tanque muito baixo, a temperatura da solução muito alta, entre outros.
- **Receber Informações:** Esta funcionalidade é a responsável por manter o Funcionário atualizado do que está acontecendo no cultivo. Se o sistema fez as medições dos parâmetros e tudo está dentro do esperado o IndoorPlant envia uma mensagem para o usuário avisando que tudo está certo. Ou então se o nível da solução nutritiva baixou, o próprio sistema automaticamente já enche o tanque novamente, após o nível voltar a estar correto, o sistema envia uma mensagem de que o nível da solução estava baixo, mas que após encher o tanque o nível já está correto.

A Figura 9 apresenta os casos de uso do dispositivo, que são comentados na sequência:

- **Enviar e Receber Informações:** Os sensores presentes no IndoorPlant participam desta ação. As informações obtidas por eles são enviadas para o servidor. Quanto ao processo de recebimento de informações, trata-se de uma funcionalidade mais voltada para os acionamentos do sistema, para que os mesmos entrem em operação quando necessários, saindo do seu modo de espera.
- **Coletar Dados:** Os dados coletados pelos sensores do IndoorPlant são obtidos por essa funcionalidade. Esta ação é realizada pelo Dispositivo conforme sua configuração. As informações dos sensores normalmente são obtidas automaticamente, ficando apenas algumas informações sendo obtidas manualmente. Entre as informações automáticas pode-se citar: temperatura do ambiente, condutividade da solução, e todas as informações dos sensores. Como informação manual temos a questão de tamanho da planta caso a câmera do IndoorPlant não seja capaz de obter o tamanho, presença de pragas no cultivo.

Figura 10 – Casos de Uso dos Dados Externos



Fonte: Elaborado pelo autor.

- **Receber Informações:** São recebidas instruções para atualizar parâmetros de configuração do middleware do microcontrolador que controla os sensores, a fim de modificar o período de leitura dos sensores ou o tempo de trabalho dos sensores. Essas atualizações podem alterar o modo de funcionamento, por exemplo, fazendo algum sensor obter as informações necessárias dele mais vezes durante o dia que outros sensores.

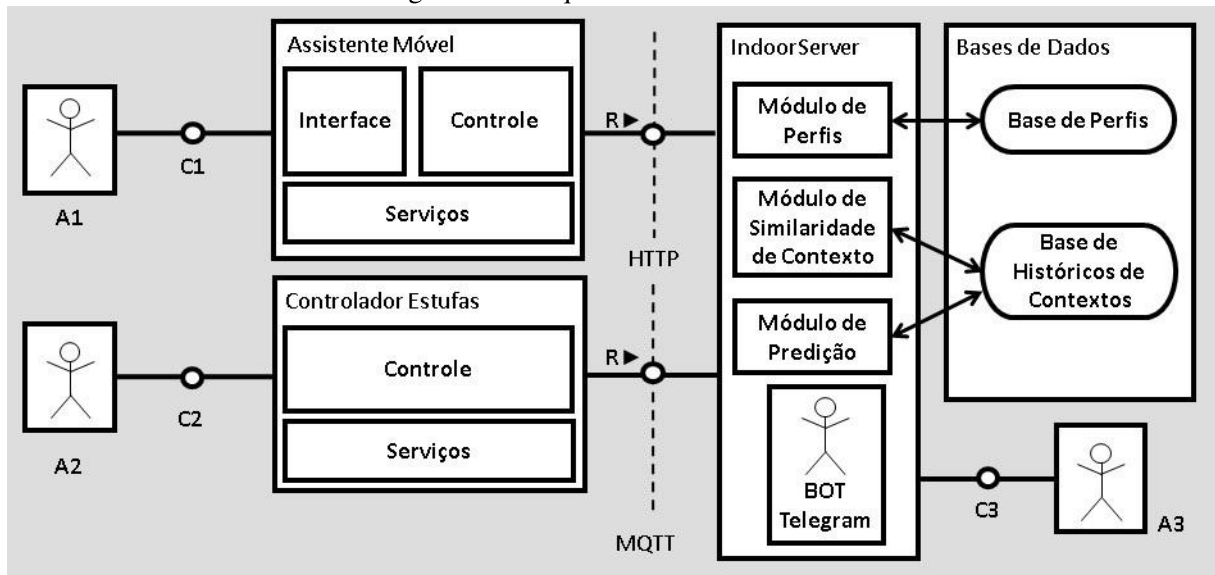
A Figura 10 apresenta o caso de uso do ator Dados Externos. Este ator tem apenas um caso de uso que inclui uma ação, tal caso de uso é mostrado na Figura 10. O caso de uso e sua ação são comentados a seguir:

- **Enviar ou Receber Informações:** Esta funcionalidade é responsável por incorporar ao IndoorPlant, dados de outros sistemas, tais como informações de outros cultivos de outras partes do mundo. Essa função é acessada pelo Responsável Técnico para ele poder comparar com outras plantações e até poder mudar algum parâmetro da sua plantação que pode estar diminuindo sua produção.
- **Integrar Dados:** A integração de dados faz parte do recebimento de informações. Antes de estas serem disponibilizadas aos usuários do modelo, estas devem passar por um processo de validação manual de algum RT, e que por fim passam a integrar os dados oficiais do IndoorPlant.

### 4.3 Arquitetura do IndoorPlant

A arquitetura do IndoorPlant foi projetada utilizando a linguagem unificada de modelagem (UML do inglês (*Unified Modeling Language*)) com definições adicionais propostas na padronização para modelagem técnica de arquitetura (TAM, do inglês *Technical Architecture Modeling*) (SAP AG, 2007). Na Figura 11 é apresentada a arquitetura composta por atores (A1, A2, A3) e seus acessos, os blocos (Assistente Móvel e seus componentes, Controlador Estufas e seus componentes, IndoorServer com seus módulos, e a Base de Dados com suas bases). Os canais de comunicação são apresentados pelos símbolos C1, C2 e C3. Os componentes aparecem na parte interna dos blocos Assistente Móvel (interface, controle e serviços) e Controlador Estufas (controle e serviços) e servem para que os atores (A1 e A2) interajam com o IndoorServer.

Figura 11 – Arquitetura do IndoorPlant



Fonte: Elaborado pelo autor.

O IndoorPlant organiza as informações de forma a obter os dados gerados pelos 3 atores, e após tratar os dados disponibiliza algumas informações contextuais de acordo com a requisição feita. Para isso o IndoorPlant contempla quatro blocos: o servidor denominado IndoorServer, o Assistente Móvel, o Controlador de Estufas e as Bases de Dados.

O Assistente Móvel recebe as ações do cliente móvel (A1) por meio do canal de comunicação (C1) e realiza comunicação com o servidor utilizando webservices a partir de métodos RESTful afim de demonstrar as condições do cultivo dentro de cada estufa. O Assistente Móvel também é responsável por atender os casos de uso dos atores funcionário e RT, pelo canal C1. O módulo do IndoorServer responsável por se comunicar com esse assistente é o módulo do *bot* Telegram, módulo esse criado para facilitar o entendimento e manuseio da maioria dos agricultores por ser em forma de texto.

O Controlador de Estufas se comunica com o servidor através do protocolo MQTT (MQTT, 2017), criado propriamente para a utilização da IoT, e o mesmo também possui métodos de comunicação para envio e recebimento de atualizações e novos parâmetros. O Controlador Estufas também coleta os dados da estufa e do cultivo da estufa e envia para o IndoorServer. O próprio controlador atua em aspectos como manter nível dos reservatórios, irrigar nos horários determinados, entre outros serviços. Essas informações do cultivo são processadas pelo módulo de similaridade de contexto no IndoorServer e posteriormente enviadas para a base de dados denominada Base de Históricos de Contextos. O módulo de similaridade de contexto processa as informações e insere marcações nos históricos de contextos conforme seu processamento. Para gerenciamento dos históricos de contextos são armazenadas as informações conforme apresentadas na Tabela 9.

O componente IndoorServer realiza a comunicação com os demais componentes por canais internos e com o ator Dados Externos (A3), pelo canal C3. O IndoorServer contempla

Tabela 9 – Históricos de Contextos das Informações Obtidas

Propriedade	Formato	Descrição
Temperatura Ambiente	Decimal	Valor referente a temperatura relativa na estufa
Umidade Ambiente	Decimal	Valor referente a umidade relativa na estufa
Umidade Solo	Decimal	Valor referente a umidade do solo cultivado
Temperatura da Água	Decimal	Valor referente a temperatura da água de circulação
pH da Água	Decimal	Valor referente ao pH da água de circulação
Condutividade da Água	Decimal	Valor referente a condutividade da água de circulação
Luminosidade	Decimal	Valor referente a quantidade de luz na estufa
Pressão do Ambiente	Decimal	Valor referente a pressão atmosférica dentro da estufa
Nível do Tanque	Decimal	Valor referente ao nível de água dentro do tanque
Nutrientes	Decimal	Valor referente aos nutrientes que foram adicionados na água
Gás Carbônico	Decimal	Valor referente a porcentagem de gás carbônico dentro da estufa
Pressão da Bomba	Boolean	Valor referente ao estado que se encontra a tubulação de circulação
Evento	Decimal	Armazena Data e Hora Atual
ID	Decimal	Armazena o ID da estufa que enviou os dados

Fonte: Elaborado pelo autor.

mecanismos para tratamento, análise de similaridade e predição dos dados referente às condições das estufas como um todo. Essa análise e possível indicação de melhorias nos parâmetros das estufas ocorrem de acordo com as informações que o controlador de estufas passa para o servidor.

Dentro do IndoorServer o módulo de similaridade de contexto é o responsável por processar e guardar os dados em sua base de dados. A função do módulo de similaridade é gerar a sua base de dados através da análise dos históricos de contextos recebidos. Com essa análise o módulo de similaridade gera uma base que não contém históricos de contextos repetidos e salvos em sequência. O módulo compara os dados recebidos no último recebimento com os dados recebidos na última atualização de contexto, e com isso ele é capaz de indicar se os mesmos são similares ou não. Os dados recebidos na última atualização só serão adicionados a base de dados caso os mesmos não sejam similares ao contexto da última atualização.

O módulo de similaridade de contexto processa os dados recebidos e através de sua regra sempre obtém como resposta um valor entre [0, 1]. Caso a resposta seja um valor próximo de 0, isso mostra que os dados recebidos são diferentes dos dados anteriores, e caso a resposta seja próxima de 1 indica que os dados são parecidos ou idênticos aos dados anteriores. Junto dessa regra há uma configuração que considera que se os valores calculados forem maiores ou iguais a 0.8, os contextos são similares.

Os periféricos que o IndoorPlant utiliza no Controlador de Estufas são: módulo GSM/GPRS para enviar informações e alertas para os usuários, módulo Wi-Fi para se comunicar com o servidor sem a utilização de cabos, módulo Ethernet para se comunicar com o servidor via cabos, câmeras para fotografar e poder analisar a plantação com algoritmo de processamento de imagens e um display para mostrar as informações do cultivo no local. Alguns dos acionamentos que o modelo pode atuar são: repor o nível dos tanques de circulação, irrigar em horários agendados, ligar bomba de circulação, ligar/desligar iluminação, abrir/fechar o sombrite, ligar/desligar os exaustores, aumentar ou diminuir a quantidade de insumos para as plantas, ligar os aspersores e ligar a refrigeração da solução nutritiva.

Além dessas indicações de melhorias, o IndoorPlant possui o módulo de predição que tem como objetivo prever a produção para o mês com base no seu histórico de contextos, prever alertas antes que os memos sejam acionados pelo sistema de controle das estufas. O modelo não suporta apenas esses dois serviços de predição, o IndoorPlant é capaz de aceitar outros serviços de predição e também utilizar dados externos ao modelo. Esses dados externos estão sendo mostrados na Figura 11 como o ator 3 (A3). O IndoorPlant também pode comparar a produção real do mês e calcular qual seria a produção máxima de acordo com os dados já existentes e informar para o agricultor via aplicativo se houve algum erro de controle na estufa como um todo, entre outros serviços.

#### 4.3.1 Módulo de Similaridade de Contexto

O valor de similaridade é obtido através de funções matemáticas de similaridade, e possuem o objetivo de definir o grau de similaridade entre dois objetos, efetuando uma medição e representado por um escore de similaridade (HEMMATI; ARCURI; BRIAND, 2013). Portanto, através de um valor a similaridade mostra computacionalmente quanto dois objetos são semelhantes. Os objetos podem ser de alguns aspectos: estruturas de dados complexas (árvores e grafos), texto simples (tuplas de uma tabela de banco de dados), textos longos (documentos não estruturados como códigos de programa e estruturados como arquivos XML), imagens, sons e vídeos (MARTINS, 2019). O módulo de similaridade de contexto possui como objetivo a análise da similaridade entre históricos de contextos recebidos e armazenados no IndoorPlant.

Segundo Cha (2007) o escore de similaridade ou coeficiente de similaridade é o valor que expressa a distância que se encontram dois objetos. Considera-se que, dados dois objetos A e B, a função de similaridade,  $sim(A,B) \rightarrow [0,1]$ , indica que o objeto A tem um grau de semelhança entre 0 e 1 com o objeto B. Esse valor obtido, que pode estar em qualquer intervalo, é o escore de similaridade e caso o escore seja igual a zero significa que os objetos são completamente diferentes, e se o escore for igual a 1, significa que são completamente iguais. Para cada um dos tipos de objetos (texto simples, tuplas e estruturas de dados complexas) existem funções de similaridade específicas.

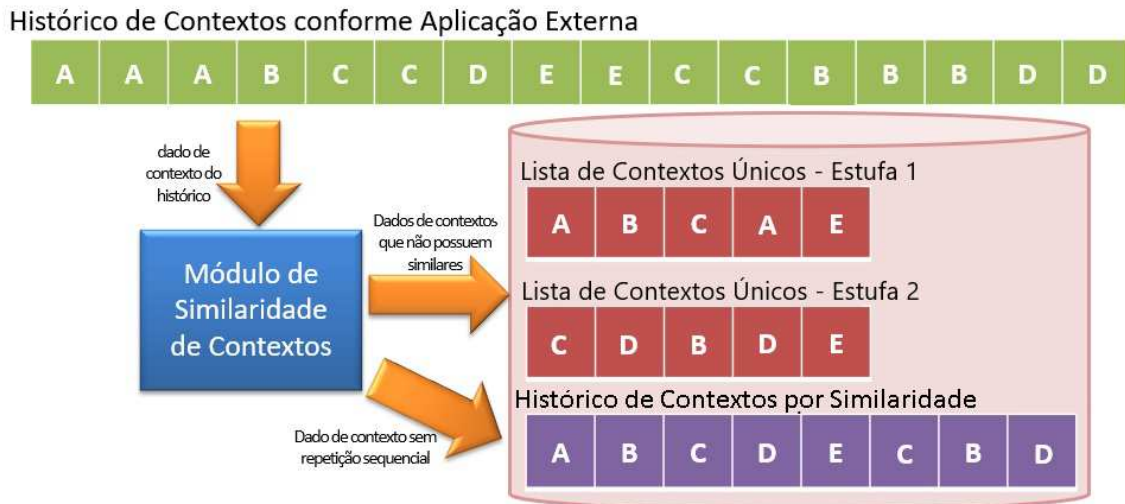
Foi utilizada no módulo uma regra para que seus resultados sempre possuam um valor entre  $[0,1]$ , onde 0 são para dados com valores completamente diferentes e 1 para dados com valores iguais. O módulo de similaridade usa como ponto de corte o valor de 0.8, ou seja, todos os contextos que após passarem pela regra e tiverem como escore o valor maior ou igual a 0.8 serão considerados similares e não serão adicionados na sua base de dados, conforme apresentado na Figura 12. Caso o escore seja menor que 0.8 os dados são classificados como não similares e são armazenados na base de dados.

O valor do ponto de corte do escore de similaridade varia de aplicação para aplicação, pois a similaridade também depende do que está sendo analisado. Por se tratar de contextos com algumas variáveis das estufas, foi instaurado o valor de 0.8, com isso não são criados poucos históricos de contextos, já que o valor não é próximo de 0, mas também não são criados muitos históricos pelo escore não ser tão próximo de 1. Havendo assim um equilíbrio maior no armazenamento dos históricos de contextos.

Com o armazenamento dos dados classificados como "não similares" na base de similaridade de contextos o módulo de similaridade é capaz de criar uma estrutura básica para que o IndoorPlant efetue recomendações e também predições. Caso os dados sejam classificados como "similares" o módulo apenas registra que mais um contexto foi similar e atualiza o valor referente ao tempo de entrada desses dados. Com isso o módulo de similaridade atualiza a Base de Históricos de Contextos toda vez que recebe um contexto novo, sendo com os valores novos se os dados forem "não similares" ou somente atualiza o valor do tempo se forem "similares".



Figura 12 – Funcionamento do Módulo de Similaridade de Contexto



Fonte: Adaptado de Martins (2019).

Para definir similaridade de dados numéricos o mais comum é utilizar medidas de distância. Entre as medidas de distância mais utilizadas pode-se citar as distâncias Euclidiana e Manhattan. A distância Euclidiana possui sua origem através do matemático grego Euclides, que estabeleceu que a menor distância entre dois pontos é uma reta. E é definida como a soma da raiz quadrada da diferença entre  $x$  e  $y$  em suas dimensões, conforme Equação 4.1. A distância Manhattan é mais simples, no qual a equação é apenas a soma das diferenças entre  $x$  e  $y$  em cada dimensão, conforme mostrada na Equação 4.2. Independente da função de cálculo da distância utilizada, quanto menor o valor verificado, maior a similaridade.

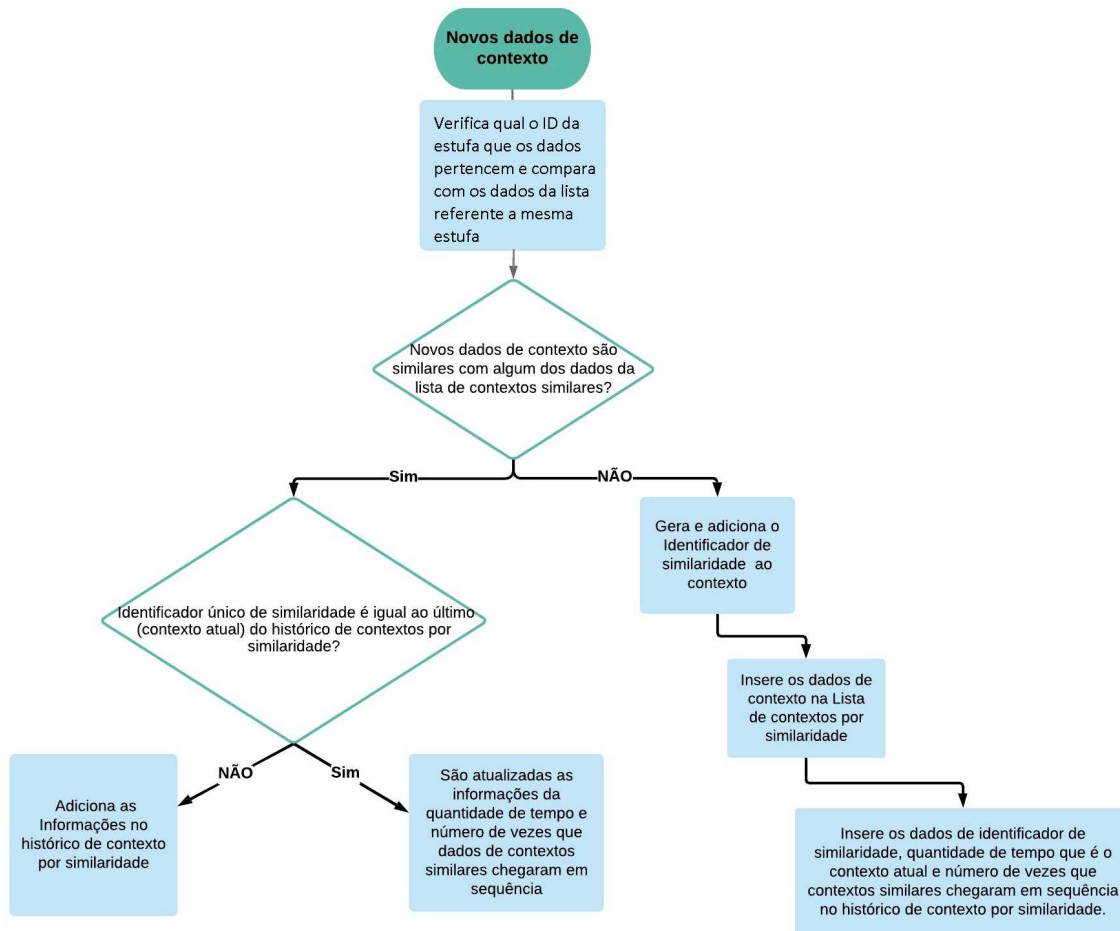
$$dist(X_i; X_j) = \sqrt{\sum_{r=1}^m (x_{i,r} - x_{j,r})^2} \quad (4.1)$$

$$dist(X_i; X_j) = \sum_{r=1}^m |x_{i,r} - x_{j,r}| \quad (4.2)$$

A principal função do módulo de similaridade é o não armazenamento de valores de contextos classificados como similares, conforme apresentado na Figura 12. Essa classificação ocorre seguindo o valor de similaridade (0.8) aplicado ao módulo. Ou seja, caso os valores calculados pelo módulo sejam iguais ou maiores que 0.8 os dados são descartados por já existirem similares na base de dados. Para realizar essa atividade o módulo controla dois tipos de informações na base de contextos por similaridade: (i) lista de contextos únicos e (ii) histórico de contextos por similaridade.

Os dados dos históricos de contextos enviados ao IndoorServer pelo Controlador de Estufas são os responsáveis por gerar a lista de contextos únicos. O módulo de similaridade ao receber novos históricos de contextos primeiro separa os dados relativos a cada estufa, para que os dados

Figura 13 – Fluxograma do Funcionamento do Módulo de Similaridade de Contexto



Fonte: Adaptado de Martins (2019).

não sejam somente indicados como "não similares" ao sofrer a ação do identificador da estufa. Após essa separação conforme as estufas, o módulo de similaridade compara com os contextos que já estão inseridos na lista de contextos únicos e que possuem identificadores únicos também. Essa comparação feita com os históricos de contextos ocorre através da análise de similaridade dos valores numéricos utilizando a equação euclidiana.

Caso esse histórico de contexto novo não seja similar a nenhum contexto da lista de contextos únicos, o mesmo recebe um identificador único e é inserido na lista, assim como apresentado por Martins (2019). Além da inserção do (i) identificador único para que o histórico de contexto seja inserido no histórico de contexto por similaridade também são inseridos mais duas informações: (ii) o valor referente a quantidade de tempo que o mesmo permaneceu como o contexto atual e (iii) a quantidade de vezes que os dados de contextos similares chegaram em sequência para o mesmo. A Figura 13 apresenta o funcionamento do módulo de similaridade e como os dados são tratados por ele.

Figura 14 – Perfis Considerados Diferentes Devido a ID da Estufa ser Diferente

```
{D_Estufa: "3", Especie_Planta: "Rucula", pH_Desejado: "5.5", Histerese_Limite_pH: "1.2",
EC_Desejada: "1.8", Histerese_Limite_EC: "0.6", Temp_Solucao_Desejada: "23.0",
Histerese_Temp_Solucao: "5.0", ml_acido: "60", ml_nutriente1: "350", ml_nutriente2: "350",
ml_nutriente3: "35", ml_nutriente4: "35"}

{D_Estufa: "1", Especie_Planta: "Rucula", pH_Desejado: "5.5", Histerese_Limite_pH: "1.2",
EC_Desejada: "1.8", Histerese_Limite_EC: "0.6", Temp_Solucao_Desejada: "23.0",
Histerese_Temp_Solucao: "5.0", ", ml_acido: "60", ml_nutriente1: "350", ml_nutriente2:
"350", ml_nutriente3: "35", ml_nutriente4: "35"}}
```

Fonte: Elaborado pelo autor.

#### 4.3.2 Módulo de Perfil

O módulo de Perfil é o responsável por criar um perfil para cada ator ou estufa que faz parte do IndoorPlant. Toda vez que o módulo recebe dados de algum perfil, ele interpreta os dados e faz a comparação entre os dados já existentes na base de dados que possui os perfis, denominada Base de Perfis. A comparação que o módulo faz é para analisar se algum perfil já salvo na Base de Perfis não é exatamente igual ao que está sendo recebido no momento. O módulo de perfil somente não vai acrescentar os dados referentes ao perfil recebido se forem completamente iguais.

Caso algum parâmetro seja diferente e todos os outros iguais, o módulo já interpreta como sendo um perfil diferente e com isso salva o perfil em sua base de dados. Isso ocorre porque caso o perfil seja referente aos parâmetros de controle de uma estufa e todos os índices sejam iguais, somente mudando o pH da água, essa pequena alteração já pode influenciar na produção. Devido a isso somente os perfis idênticos não são salvos. Outra situação é caso somente a estufa de cultivo seja diferente, mas todos os outros parâmetros sejam iguais, uma estufa diferente já influencia pois as mesmas podem não estarem dispostas lado a lado no terreno e com isso sofrer a ação da iluminação solar de uma forma diferente, conforme mostra a Figura 14.

#### 4.3.3 Módulo de Predição

O módulo de predição é o responsável por prever algo específico em relação as variáveis fornecidas ao IndoorPlant. O módulo de predição pode calcular a produtividade de uma estufa, calcular o tempo de cultivo das plantas, informar problemas futuros na estufa e assim por diante. O IndoorPlant não possui apenas um serviço de predição fixo, ou seja, ele não foi criado apenas para prever quando algum parâmetro vai ultrapassar o limite estabelecido, o IndoorPlant suporta diferentes predições, desde que os históricos de contextos recebidos por ele possuam as informações requeridas.

Essa diversidade nas predições ocorre pelas variáveis fornecidas nos históricos de contextos

Figura 15 – Amostra de Contexto do Cultivo de Morango com a Produtividade Informada

```
{ID_Estufa: "1", Especie_Planta: "Morango", pH_Atual: "5.7", EC_Atual: "1.6",
Temp_Solucao_Atual: "26.3", Nivel_Tanque: "correto", Umidade_Estufa: "68", Temp_Estufa:
"35.2", Morangos_Colhidos: "835"}
```

Fonte: Elaborado pelo autor.

Figura 16 – Contexto Atual da Estufa para Predizer a Produtividade de Morango

```
{ID_Estufa: "1", Especie_Planta: "Morango", pH_Atual: "5.5", EC_Atual: "1.54",
Temp_Solucao_Atual: "23.7", Nivel_Tanque: "correto", Umidade_Estufa: "75", Temp_Estufa:
"33.8"}
```

Fonte: Elaborado pelo autor.

e os resultados equivalentes que elas geram. Esses resultados que a predição fornece devem ter o mesmo significado/objetivo que os dados fornecidos anteriormente, ou seja, se o IndoorPlant recebe históricos de contextos com 8 variáveis e essas variáveis sempre estão relacionadas com a quantidade de morangos colhidos numa estufa conforme mostra a Figura 15. O IndoorPlant também irá predizer a quantidade de morangos que será possível colher com o contexto atual do plantio, conforme apresenta a Figura 16. O IndoorPlant não consegue predizer a produtividade de uma estufa caso os históricos de contextos anteriores não possuam essa informação anterior de quantos morangos foram colhidos, conforme apresenta a Figura 15.

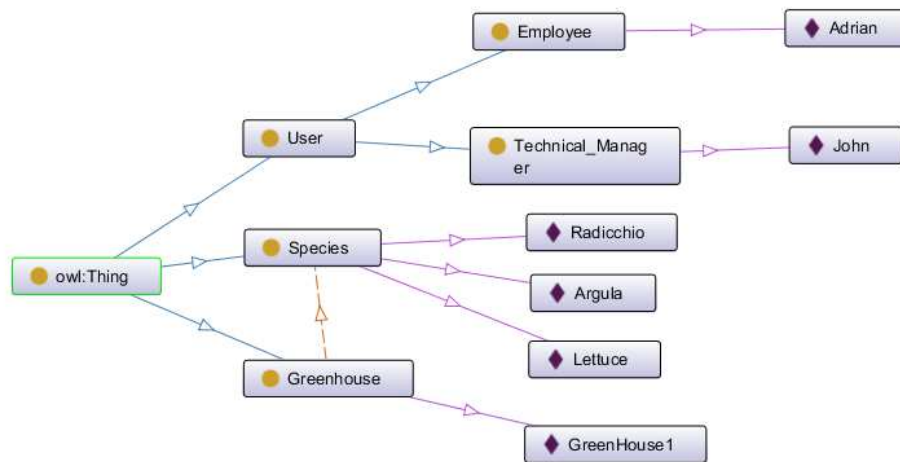
#### 4.4 Ontologia Proposta para o Modelo - Agrindoor

O IndoorPlant propõe uma ontologia para a agricultura *indoor* visando gerenciar três aspectos: o perfil das pessoas que utilizam o sistema, os parâmetros das estufas e as características de cada espécie cultivada. Essa ontologia é denominada Agrindoor e foi desenvolvida na ferramenta Protégé. Uma ontologia quando aplicada proporciona a padronização das informações, auxiliando na troca de mensagens, na visualização dos termos e no armazenamento. A ontologia gerencia o domínio das pessoas indicadas nos casos de uso acima, parâmetros das estufas, leitura dos sensores e especificações técnicas das plantas.

Um dos casos já levantados pelo IndoorPlant no capítulo 3 foi a grande quantidade de estudos existentes sobre agricultura *indoor* e predição, mas todos com o mesmo propósito de obter dados do cultivo e com a grande variedade de sensores iguais. Ou seja, muitos estudos com a mesma metodologia e buscando resultados próximos. A Agrindoor busca fazer essa conexão entre as informações existentes para que os resultados sejam mais expressivos e também que exista uma padronização das informações.

A Figura 17 apresenta as classes do IndoorPlant, sem mostrar todas as instâncias de cada uma das classes. Apenas são apresentadas instâncias das classes para exemplificar o uso da mesma. Além da classe User e suas subclasses (Technical Manager (RT) e Employee (Funcio-

Figura 17 – Ontologia Agrindoor e suas Classes e Exemplos de Instâncias



Fonte: Elaborado pelo autor.

nário)), também foi criada a ontologia para a classe Greenhouse (Estufa), que possui a capacidade de armazenar as condições da estufa como *data properties*. Por fim foi criada a ontologia da classe Species (Espécie) com as características das plantas sendo inseridas também como *data properties*.

#### 4.5 Considerações Sobre o Capítulo

Ao longo deste capítulo foram detalhados aspectos conceituais do modelo. Os casos de uso foram implementados e discutidos com diagramas UML. Os requisitos do modelo também foram apresentados para que no próximo capítulo o protótipo possa seguir essas diretrizes. Além disso o modelo foi apresentado e a arquitetura foi definida com uma descrição maior de seus módulos e funcionamento de cada um deles. Por fim, foi proposta a ontologia Agrindoor.



## 5 ASPECTOS DE IMPLEMENTAÇÃO E VALIDAÇÃO

Neste capítulo é descrito os aspectos de desenvolvimento do protótipo e detalhes sobre a avaliação, organizados em três seções. A primeira descreve as tecnologias que foram empregadas no desenvolvimento do protótipo, já na segunda seção são apresentadas as informações relacionadas com a avaliação do modelo. A avaliação ocorreu em três cenários de testes, compostos por dados reais de *datasets* de cultivo hidropônico. Também foi aplicado um questionário com base nos conceitos do Modelo de Aceitação de Tecnologia (*Technology Acceptance Model* (TAM)). Por fim, na terceira seção são apresentadas as considerações finais do capítulo.

### 5.1 Desenvolvimento do Protótipo


O IndoorServer foi implementado com o software Node-RED (NODE-RED, 2018). O protocolo de comunicação utilizado entre o IndoorServer e o Controlador de Estufas foi o MQTT (MQTT, 2017). O protótipo foi instalado numa empresa produtora de olericultura, situada na cidade de São Leopoldo/RS. A Figura 18 apresenta a localização da propriedade no município de São Leopoldo e mostra a proximidade da propriedade rural com a parte urbana da cidade. Para coletar os dados do cultivo hidropônico o Controlador de Estufas utilizado foi o Cultiva Fácil Hidroponia, sistema que foi desenvolvido pela empresa BGM Sistemas também de São Leopoldo/RS.

O Cultiva Fácil Hidroponia obtém as variáveis do microclima e da solução nutritiva dentro da estufa através dos sensores instalados e envia para o servidor, não tomando qualquer atitude além da reposição do nível do tanque sem a autorização do agricultor. Os dados foram coletados em 3 estufas de cultivo hidropônico, cada estufa com 500 m<sup>2</sup>. A distribuição das estufas é mostrada na Figura 19. Cada estufa possuía uma cultura de planta diferente, as culturas cultivadas foram alface, rúcula e radite. A Figura 20 apresenta a visão interna das estufas com o cultivo hidropônico presente em toda a estufa.

O banco de dados utilizado no IndoorServer foi o MongoDB, a criação das duas bases de dados foram feitas conforme é apresentada na arquitetura do modelo na Figura 11. Portanto foi criada a base de dados de perfis e a base de dados de históricos de contextos. O MongoDB foi escolhido por possuir a capacidade de ser escalável, possuir um alto desempenho e orientado a objetos. Essa escolha também se deve ao fato de que os dados de contextos que são armazenados possuem informações distintas, para cada tipo de cultivo ou de estufa.

Essa distinção nas informações estão relacionadas ao tipo de cultivo, e a tecnologia embarcada nas estufas, pois o IndoorPlant não suporta apenas um tipo de cultivo, e essa diversidade nos cultivos gera parâmetros bases diferentes para cada um deles. Parâmetros diferentes podem ser vistos na hidroponia e no gotejamento. Na hidroponia os parâmetros mais importantes são pH, condutividade elétrica e temperatura da solução. Já no gotejamento os parâmetros principais são umidade do solo, temperatura e umidade do ambiente.

Figura 18 – Localização da Empresa onde o IndoorPlant foi Instalado



Fonte: Elaborado pelo autor.

Figura 19 – Imagem Aérea das Estufas em que o Protótipo foi Instalado



Fonte: Elaborado pelo autor.



Figura 20 – Imagem dos Cultivos Hidropônicos Dentro das Estufas



Além da variedade de informações outro ponto importante que se encontra no Brasil é a grande variedade de tecnologia embarcada nas estufas. É possível encontrar estufas com todo o controle manual até estufas totalmente automatizadas. Esse controle da estufa está relacionado as condições do microclima, quantidade de irrigações, abertura e fechamento das estufas, entre outros. Devido a essa variação de tecnologia também são geradas informações distintas até com o mesmo tipo de cultivo.

Cada uma das bases utilizadas pelo IndoorServer foram implementadas separadamente, com isso o direcionamento dos históricos de contextos ou dos perfis já ocorrem quando os módulos recebem as informações. Além do Controlador de Estufas possuir uma sirene que é acionada quando algum parâmetro do cultivo chega ao limite ou ocorre algum problema na estufa, também foi desenvolvido um *bot* junto ao IndoorServer que informa o agricultor no seu smartphone.

Esse bot foi desenvolvido dentro do Node-RED (NODE-RED, 2018) e utiliza o aplicativo Telegram Messenger (TELEGRAM MESSENGER, 2019) para informar ao agricultor as indicações, problemas e alertas do cultivo. Entre as informações possíveis que o IndoorPlant pode enviar ao agricultor são: índices que ultrapassaram o limite, índices atuais das estufas, índices que atingirão o limite em determinado tempo, indicações de melhorias para o agricultor modificar nos parâmetros, entre outros. O agricultor também pode requisitar informações do seu cultivo e ou estufa em tempo real e colocar notas em relação a sua colheita de determinada estufa.

Figura 21 – Amostra dos Dados Recebidos do Controlador de Estufas

```
{ID_Estufa: "3", Especie_Planta: "Rucula", pH_Desejado: "5.0", pH_Atual: "5.1", EC_Desejada: "1.80", EC_Atual: "1.82", Temp_Solucao: "24.2", Nivel_Tanque: "OK", Bomba: "Ligada"}
```

Fonte: Elaborado pelo autor.

Essa nota que o agricultor dá para a sua colheita auxilia o IndoorPlant posteriormente a indicar quais os melhores parâmetros para cada cultura cultivada. O IndoorPlant considera os parâmetros que as plantas foram cultivadas juntamente das notas que o próprio agricultor forneceu na hora da colheita. Isso é um dos diferenciais do IndoorPlant, pois como dito anteriormente, no Brasil existe uma grande variedade de tecnologias embarcadas na estufa e pode ser que os índices para um agricultor no Rio Grande do Sul obter uma planta bonita e saudável sejam diferentes dos índices de um produtor de São Paulo. Devido a isso o IndoorPlant utiliza os históricos de contextos antigos juntamente das notas que os agricultores fornecem para indicar quais os melhores parâmetros para o cultivo de determinada planta.

## 5.2 Avaliação do Modelo

Todas as avaliações realizadas com o IndoorPlant foram utilizando o Controlador de Estufas (Cultiva Fácil Hidroponia) juntamente do IndoorServer com as funcionalidades que foram citadas anteriormente. As avaliações foram elaboradas para provar as contribuições do modelo através do uso de históricos de contextos para fornecer serviços inteligentes. Após obter o *dataset* com o Cultiva Fácil do cultivo hidropônico de 3 culturas foi possível começar os testes dos módulos de similaridade de históricos de contextos, perfil e de predição. Para validar a funcionalidade dos 3 módulos do IndoorPlant foram criados 3 cenários de avaliação do modelo que utilizam os serviços de recomendações, perfis e de predição do tempo de cultivo.

### 5.2.1 Cenário 1: Módulo de Similaridade de Contexto

O primeiro cenário de avaliação foi construído baseado no *dataset* com os históricos de contextos do cultivo hidropônico apresentado anteriormente. Esse *dataset* foi criado com os dados recebidos do Cultiva Fácil Hidroponia, conforme a Figura 21. Após o recebimento dos dados pelo IndoorServer os mesmos foram processados pelo módulo de similaridade de contexto para processar se são similares ou não e posteriormente enviados para a base de históricos de contextos. Os dados foram enviados para a base de dados conforme apresentado na Tabela 9. Como os contextos recebidos do Controlador de Estufas não possuíam exatamente todas as informações que a Tabela 9 apresentou, algumas informações foram alteradas para que os contextos possuam o maior número de variáveis possíveis, conforme mostra a Figura 22.

Essa classificação ocorreu com a utilização da equação Euclidiana e Manhattan e o valor como regra de 0.8. Ao utilizar as duas equações a quantidade de dados classificados como

Figura 22 – Amostra dos Dados Enviados para a Base de Históricos de Contextos

```
{Inicio_Contexto: "20190923_094356", Fim_Contexto: "20190923_100204", ID_Estufa: "3",
Especie_Planta: "Rucula", pH_Desejado: "5.0", pH_Atual: "5.1", EC_Desejada: "1.80",
EC_Atual: "1.82", Temp_Solucao: "24.2", Nivel_Tanque: "OK", Bomba: "Ligada"}
```

Fonte: Elaborado pelo autor.

Figura 23 – Comparação entre o Contexto Atual e os Melhores Contextos das Estufas 2 e 3

```
{ID_Estufa: "2", Especie_Planta: "Alface", pH_Desejado: "5.5", EC_Desejada: "1.45"
Temp_Solucao: "25.3", Nivel_Tanque: "OK", Bomba: "Ligada"}

{ID_Estufa: "2", Especie_Planta: "Alface", pH_Desejado: "5.5", EC_Desejada: "1.20",
Temp_Solucao: "24", Nivel_Tanque: "OK", Bomba: "Ligada", Nota: "9"}

{ID_Estufa: "3", Especie_Planta: "Rucula", pH_Desejado: "5.0", EC_Desejada: "1.80"
Temp_Solucao: "24.2", Nivel_Tanque: "OK", Bomba: "Ligada"}

{ID_Estufa: "3", Especie_Planta: "Rucula", pH_Desejado: "5.5", EC_Desejada: "1.80",
Temp_Solucao: "25", Nivel_Tanque: "OK", Bomba: "Ligada", Nota: "10"}
```

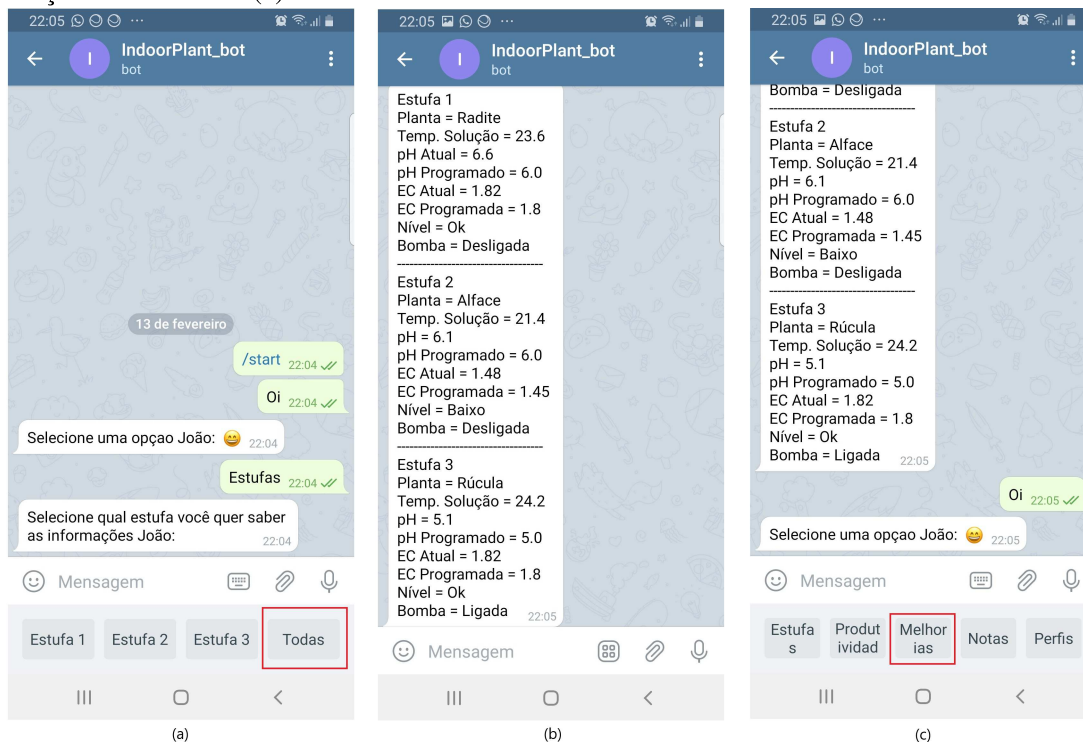
Fonte: Elaborado pelo autor.

similares aumentou em torno de 3%, o que consequentemente diminuiu em 3% a classificação dos dados como não similares e a inserção de novos dados na base de dados. Nesses casos houve somente a atualização do horário que o contexto se manteve similar.

Este cenário apresenta uma situação em que o agricultor responsável pelo cultivo está viajando para uma feira e o agricultor substituto alterou os parâmetros de cultivo do Controlador de Estufas. O IndoorPlant fez uma verificação dos parâmetros e nessa verificação dos contextos atuais em relação aos históricos de contextos que obtiveram as melhores notas, o IndoorPlant constatou variações nos parâmetros de duas estufas, conforme mostra a Figura 23. Com isso o IndoorPlant através de seu *bot* do Telegram gera indicações de ajustes a serem feitos em cada estufa.

Cenário 1: *"João é o agricultor responsável pelos gerenciamento do cultivo hidropônico onde trabalha, e uma de suas responsabilidades é programar os valores que o Cultiva Fácil Hidroponia mantém nos tanques das soluções. João viajou para participar de uma feira e deixou Carlos responsável pelo cultivo, porém Carlos modificou os parâmetros das soluções hidropônicas de duas estufas. João acessou o bot do Telegram primeiramente para verificar as estufas (Figura 24 (a)). João resolveu verificar os índices de todas as estufas (Figura 24 (b)) juntamente e notou algumas anormalidades. Com isso resolveu checar (Figura 24 (c)) se o IndoorPlant possuía alguma indicação de melhoria para as estufas e encontrou duas indicações de ajustes que esperavam a aprovação do João. Essas duas indicações (Figura 25*

Figura 24 – Menu do Bot Telegram Após Selecionar o Botão Estufas (a), Contextos Atuais das Estufas (b), Seleção de Melhorias (c)



Fonte: Elaborado pelo autor.

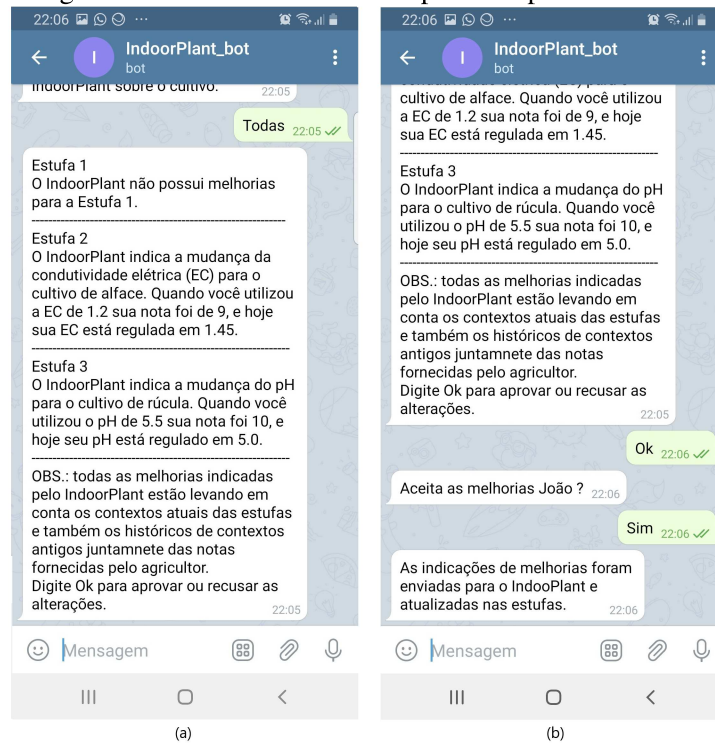
(a) do IndoorPlant levaram em conta o contexto atual da estufa e comparou com os históricos de contextos que obtiveram as melhores notas de colheita que o próprio João forneceu. Com a aprovação de João para o IndoorPlant modificar os parâmetros, a estufa 2 que possuía alface teve sua condutividade elétrica modificada de 1,45 para 1,2. Já a estufa 3 que continha rúcula teve o pH ajustado para 5,5 onde anteriormente seu pH estava regulado. Após as modificações do IndoorPlant o sistema confirmou (Figura 25 (b)) para o João que os parâmetros foram modificados."

## 5.2.2 Cenário 2: Módulo de Perfis

O segundo cenário de avaliação foi construído baseado no *dataset* com os dados de perfil do radite no cultivo hidropônico, conforme mostra a Figura 26. Esse *dataset* foi criado através dos parâmetros inseridos para o Cultiva Fácil manter nas estufas que cultivaram radite. Os dados foram enviados para o IndoorServer e processados pelo módulo de perfis. O módulo de perfis analisa os parâmetros para aquele tipo de planta e caso ainda não exista um perfil idêntico o IndoorServer salva esse novo perfil na base de perfis. Nesse módulo não são utilizadas as equações euclidiana e de manhattan porque somente não são salvos os perfis que forem idênticos a algum já registrado.

Caso o agricultor plante novas mudas e deseje utilizar algum perfil já conhecido por ele

Figura 25 – Melhorias Indicadas pelo Bot para as Estufas



Fonte: Elaborado pelo autor.

Figura 26 – Perfis das Plantas do Cultivo Hidropônico

```
{Especie_Planta: "Radite", Perfil: "1", pH_Desejado: "5.8", EC_Desejada: "1.70"
Temp_Solucao: "24.0", Nota: "9"}
{Especie_Planta: "Radite", Perfil: "2", pH_Desejado: "6.0", EC_Desejada: "1.80"
Temp_Solucao: "22.0", Nota: "10"}
{Especie_Planta: "Radite", Perfil: "3", pH_Desejado: "6.5", EC_Desejada: "1.90"
Temp_Solucao: "26.0", Nota: "6"}
{Especie_Planta: "Alface", Perfil: "1", pH_Desejado: "5.5", EC_Desejada: "1.20"
Temp_Solucao: "24.0", Nota: "9"}
{Especie_Planta: "Alface", Perfil: "2", pH_Desejado: "5.8", EC_Desejada: "1.40"
Temp_Solucao: "22.0", Nota: "8"}
{Especie_Planta: "Rucula", Perfil: "1", pH_Desejado: "6.5", EC_Desejada: "1.80"
Temp_Solucao: "23.0", Nota: "7"}
{Especie_Planta: "Rucula", Perfil: "2", pH_Desejado: "5.7", EC_Desejada: "1.75"
Temp_Solucao: "25.0", Nota: "9"}
```

Fonte: Elaborado pelo autor.

Figura 27 – Perfis Existentes de Radite Hidropônico no IndoorPlant

```
{Especie_Planta: "Radite", Perfil: "1", pH_Desejado: "5.8", EC_Desejada: "1.70"
Temp_Solucao: "24.0", Nota: "9"}

{Especie_Planta: "Radite", Perfil: "2", pH_Desejado: "6.0", EC_Desejada: "1.80"
Temp_Solucao: "22.0", Nota: "10"}

{Especie_Planta: "Radite", Perfil: "3", pH_Desejado: "6.5", EC_Desejada: "1.90"
Temp_Solucao: "26.0", Nota: "6"}
```

Fonte: Elaborado pelo autor.

mesmo, ele seleciona a planta que ele utilizou e com isso o IndoorPlant fornecerá os perfis existentes daquela mesma espécie juntamente das notas fornecidas na hora da colheita. O agricultor com isso poderá fazer a escolha livremente de qual perfil ele quer que o IndoorPlant utilize e seus parâmetros são enviados para o Cultiva Fácil Hidroponia.

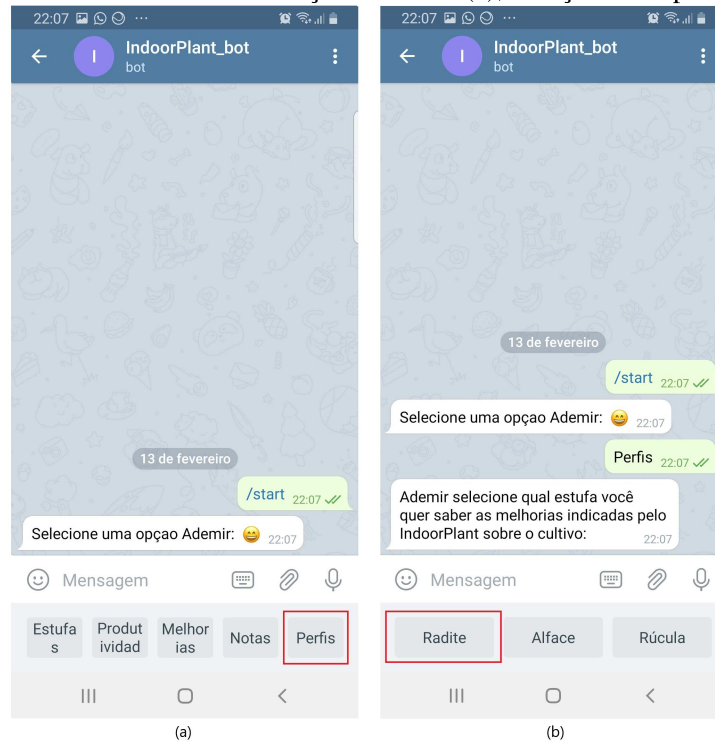
Este cenário apresenta uma situação em que o agricultor responsável pelo cultivo planta novas mudas de radite e deseja saber quais os perfis existentes no IndoorPlant, conforme mostra a Figura 27. Para auxiliar ele na escolha o bot do Telegram fornece os perfis em ordem decrescente de nota, para que o agricultor consiga visualizar mais facilmente os perfis com melhores resultados.

Cenário 2: *"Ademir que é o agricultor responsável pelo cultivo hidropônico e após higienizar toda a estufa e reativar o Cultiva Fácil Hidroponia precisa recolocar os parâmetros que geraram as plantas com melhor qualidade na hora da colheita. Com isso Ademir inicia o bot do Telegram e seleciona a opção de perfis (Figura 28 (a)) para posteriormente escolher entre as espécies de plantas já cultivadas (Figura 28 (b)). Após a seleção de radite como a espécie que está sendo plantada, o bot do Telegram mostra os perfis existentes na base de perfis juntamente das notas que o próprio agricultor forneceu na hora da colheita (Figura 29 (a)). Após a escolha do perfil selecionado pelo agricultor o bot informa que os parâmetros já foram selecionados e que o agricultor só falta informar qual estufa receberá esses parâmetros. Após a seleção da estufa, o bot informa que todos os parâmetros foram inseridos com sucesso na estufa (Figura 29 (b))"*.

### 5.2.3 Cenário 3: Módulo de Predição

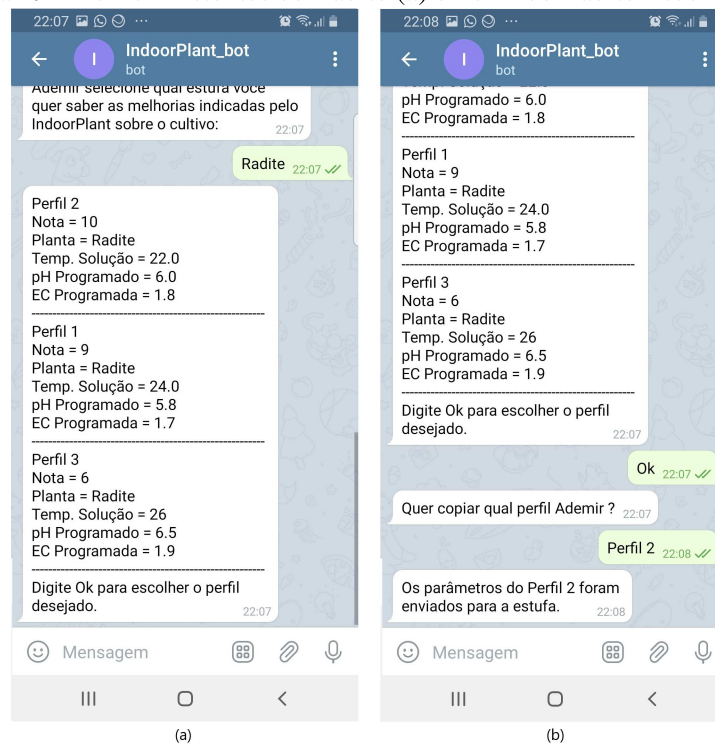
O terceiro cenário de avaliação foi construído baseado no *dataset* com os dados da base de históricos de contextos juntamente do tempo de cultivo de cada uma das plantas. A Figura 30 apresenta uma amostra dos contextos obtidos para o cultivo de radite. Esse tempo de cultivo desde o plantio até a colheita foi fornecido pelo próprio agricultor da empresa agrícola. A base de dados foi exportada do MongoDB no formato csv e adicionado os tempos de cultivo que o agricultor forneceu. Com essas informações o IndoorPlant juntamente da ferramenta de

Figura 28 – Menu do Bot com a Seleção de Perfis (a), Seleção da Espécie Radite (b)



Fonte: Elaborado pelo autor.

Figura 29 – Perfis Existentes de Radite (a) e Perfil de Radite Escolhido (b)



Fonte: Elaborado pelo autor.

Figura 30 – Amostra de Contextos Relacionados com o Tempo de Cultivo

```
{ID_Estufa: "1", Especie_Planta: "Radite", pH_Atual: "5.7", EC_Atual: "1.74",
Temp_Solucao_Atual: "26.1", Nivel_Tanque: "Correto", Umidade_Estufa: "62", Temp_Estufa:
"33.5", Dias_Cultivados: "16"}

{ID_Estufa: "1", Especie_Planta: "Radite", pH_Atual: "5.9", EC_Atual: "1.85",
Temp_Solucao_Atual: "33.6", Nivel_Tanque: "Correto", Umidade_Estufa: "74", Temp_Estufa:
"39.4", Dias_Cultivados: "26"}

{ID_Estufa: "1", Especie_Planta: "Radite", pH_Atual: "5.3", EC_Atual: "1.68",
Temp_Solucao_Atual: "23.8", Nivel_Tanque: "Correto", Umidade_Estufa: "52", Temp_Estufa:
"26", Dias_Cultivados: "23"}

{ID_Estufa: "1", Especie_Planta: "Radite", pH_Atual: "6.2", EC_Atual: "1.92",
Temp_Solucao_Atual: "34.2", Nivel_Tanque: "Correto", Umidade_Estufa: "83", Temp_Estufa:
"36.8", Dias_Cultivados: "29"}
```

Fonte: Elaborado pelo autor.

Figura 31 – Exemplo de Matriz com Dados Multivariados

$$X = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ \vdots \\ x_n \end{bmatrix} = \begin{bmatrix} x_{11} & x_{12} & \cdots & \cdots & x_{1m} \\ x_{21} & x_{22} & \cdots & \cdots & x_{2m} \\ \vdots & \vdots & \ddots & & \vdots \\ \vdots & \vdots & & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & \cdots & x_{nm} \end{bmatrix}$$

Fonte: Elaborado pelo autor.

predição consegue prever o tempo de cultivo das culturas plantadas.

A ferramenta utilizada para análise dos dados e predição do tempo de cultivo foi o ChemoStat (HELPER et al., 2015). O ChemoStat é uma ferramenta online de análise de dados multivariados. Esses dados multivariados normalmente possuem o formato de uma matriz X de valores, em que a matriz é composta de m variáveis para n amostras, conforme mostra a Figura 31.

Para gerar o modelo de calibração da produtividade das 3 culturas foram utilizadas as variáveis com os históricos de contextos das 3 estufas de 7 meses de cultivo, conforme apresentado na Figura 30. Cada estufa teve seu modelo de calibração gerado individualmente porque cada cultura possui um tempo de cultivo e índices diferentes, fazendo com que o modelo se torne mais preciso para cada uma das culturas. O ChemoStat utiliza o seu próprio algoritmo de predição. O algoritmo de *machine learning* empregado foi o *Partial Least Squares* (PLS) que possui 2 fases distintas, o treinamento e a predição.

Os treinamentos foram feitos com os dados dos 7 meses de cultivo, sendo feito um treinamento para cada estufa por se tratarem de plantas diferentes. Com isso é possível saber o tempo de cultivo para cada planta. Essa predição do tempo de cultivo auxilia o produtor a saber



Tabela 10 – Dias de Cultivo para Cada Planta

Plantas	Tempo Mínimo	Tempo Máximo	Dias Previstos	Dias Reais
Radite	16	29	21	20
Alface	28	44	31	33
Rúcula	21	32	25	26

Fonte: Elaborado pelo autor.

quando ele terá as plantas prontas para vender, e com isso ele pode também programar suas mudas (plantas recém germinadas) para estarem no tamanho certo conforme for liberando espaço nas estufas.

É importante salientar que a predição pelo ChemoStat não está automatizada junto ao IndoorPlant, então a predição foi treinada com 7 meses de cultivo, e a predição com o contexto atual é atualizada sempre que necessário. Não existe uma regra específica que indique de quanto em quanto tempo é necessário atualizar as predições do modelo, porém quanto mais seguidamente, melhor será seu resultado. No caso do terceiro cenário e validação do módulo de predição, o modelo utilizou o contexto atual em relação ao treinamento feito uma semana antes.

Este cenário apresenta uma situação em que o agricultor responsável pelo gerenciamento do cultivo necessita saber quanto tempo está levando para que as plantas cheguem no seu tamanho apropriado para venda. Essa necessidade é gerada por dois motivos principais para o agricultor que são:

- O agricultor não pode ter algum pedido e sua plantas estarem menores que o necessário, pois será preciso enviar mais plantas para equivaler ao peso do pedido, ou então caso as plantas estejam muito grandes também existe o problema de alguns compradores não aceitarem porque as plantas estão "velhas".
- O agricultor não pode sofrer com a falta de espaço nas estufas devido a quantidade de pedidos que possui para produzir durante o mês. Conforme os meses vão passando, o tempo de cultivo também varia devido as condições climáticas, onde mesmo dentro de estufas ocorrem variações. Com isso no inverno as plantas demoram um tempo maior para se desenvolverem, pois o clima é mais frio, existe uma menor incidência da luz solar, e assim por diante. Enquanto no verão as condições favorecem um desenvolvimento mais rápido das plantas, o que também necessita um espaço menor para cultivo já que as plantas estão prontas para colheita mais rapidamente.

Durante os 7 meses de cultivo o tempo de produção teve variações significativas, a Tabela 10 apresenta o menor e o maior tempo para cultivo de cada uma das 3 espécies de plantas, além do tempo previsto e do tempo real de cultivo. Lembrando que esse tempo de cultivo do plantio até a colheita foram fornecidos pelos agricultores e inseridos junto aos históricos de contextos referentes a cada uma das plantas.

Figura 32 – Menu do Bot para Solicitar a Predição de Produtividade (a) Indicação da Predição de Produtividade para as 3 Espécies de Plantas



Fonte: Elaborado pelo autor.

Cenário 3: "Jorge é o agricultor responsável pelo gerenciamento geral da sua empresa de hortifrutis e ele precisa programar as vendas possíveis para o mês de janeiro e fevereiro com a capacidade máxima em suas 3 estufas. Para isso ele precisa saber quando suas plantas estarão no tamanho ideal para venda e também que suas mudas já estejam prontas. Para ter essa estimativa de dias do ciclo produtivo Jorge acessou o bot do IndoorPlant no Telegram, no dia 07 de janeiro, para solicitar as predições (Figura 32 (a)) referentes aos contextos atuais das estufas. Jorge solicitou saber a estimativa de dias de cultivo para suas 3 estufas e o bot que informou em sequência a predição feita pelo IndoorPlant juntamente da ferramenta ChemoStat. Jorge obteve como resposta que o radite ficaria pronto em 21 dias, a alfaca em 31 dias e a rúcula em 25 dias (Figura 32 (b)). Com essa resposta do bot Jorge agora pode fazer o cronograma de suas mudas e vendas com maior tranquilidade. Como Jorge havia plantado radite, rúcula e alfaca no mesmo dia (02 de janeiro de 2020) ele tem a estimativa de que o radite ficaria pronto no dia 23 de janeiro, a rúcula no dia 27 de janeiro e a alfaca no dia 02 de fevereiro. Porém, ao chegar próximo dos dias estimados pelo IndoorPlant para colheita as plantas variaram um pouco seu tempo de cultivo e Jorge fez sua colheita nas 3 estufas com 20 dias para o radite, 33 dias para a alfaca e 26 dias para a rúcula".

A seguir são apresentados os resultados da predição para o tempo de cultivo das 3 espécies de plantas. Os resultados obtidos para a a predição do radite foram: ( $R^2$ ) de 0.964, (RMSE) de 1.06 e (RMSECV) de 1.94. Os resultados obtidos para a predição do alfaca foram: ( $R^2$ )

Tabela 11 – Itens relacionados à avaliação da utilidade percebida do IndoorPlant

Questão	Descrição
1	A possibilidade de acompanhar os índices em tempo real é útil.
2	A possibilidade de utilizar o aplicativo conectado à Internet é útil.
3	Os recursos de predição de tempo de cultivo são úteis à rotina de cultivo.
4	A indicação de melhorias é útil à rotina do cultivo.
5	O serviço de notas (classificação da colheita) e perfis são úteis à rotina do cultivo.
6	A utilização de perfis é útil à rotina do cultivo.

Fonte: Elaborado pelo autor.

Tabela 12 – Itens relacionados à avaliação da facilidade de uso percebida no IndoorPlant

Questão	Descrição
1	O aplicativo por ser via chat é de fácil manuseio e compreensão.
2	Os índices das estufas mostrados são de fácil compreensão.
3	A predição do tempo de colheita é de fácil compreensão.
4	As indicações de ajustes para melhoria do cultivo são de fácil compreensão.
5	A avaliação da colheita é de fácil compreensão.
6	Os perfis existentes e as escolhas deles são de fácil compreensão.

Fonte: Elaborado pelo autor.

de 0.947, (RMSE) de 1.37 e (RMSECV) de 3.31. Por fim, os resultados obtidos para a rúcula foram de: ( $R^2$ ) de 0.932, (RMSE) de 1.10 e (RMSECV) de 1.89.

#### 5.2.4 Avaliação TAM

O protótipo do IndoorPlant foi avaliado junto aos agricultores através do Modelo de Aceitação de Tecnologia (TAM) proposto por Davis (1989). O estudo de Davis (1989) posteriormente foi aplicado e expandido por Yoon e Kim (2007). O modelo TAM considera os seguintes itens como principais quesitos para a aceitação de uma nova tecnologia:

- Utilidade percebida: é o grau em que uma pessoa acredita que o uso da tecnologia poderia melhorar o seu desempenho.
- Facilidade de uso percebida: é o grau em que uma pessoa acredita que a tecnologia pode reduzir seus esforços.

Para responder ao questionário foi disponibilizado aos usuários a escala Likert com 5 níveis que são, 1 - discordo totalmente, 2 - discordo, 3 - indiferente, 4 - concordo, 5 - concordo totalmente. Os itens de avaliação são descritos nas Tabelas 11 e 12.


Outro ponto a ser considerado pelo modelo é o perfil dos 8 usuários, esses perfis podem ser vistos na Tabela 13. Os 8 entrevistados são agricultores que utilizaram o protótipo e possuem

Tabela 13 – Perfil dos Usuários que Utilizaram e Avaliaram o IndoorPlant

Idade	Escolaridade	Função
40	Ensino Fundamental	Agricultor de radite e couve
17	Ensino Fundamental	Agricultor de alface e brócolis
19	Técnico Agrícola	Responsável pelas mudas
34	Ensino Fundamental	Agricultor de alface e rúcula
30	Ensino Fundamental	Agricultor de alface e rúcula
49	Ensino Fundamental	Agricultor de radite e couve
52	Técnico Agrícola	Proprietário da empresa e agricultor
20	Ensino Médio	Agricultor de radite, couve

Fonte: Elaborado pelo autor.

Figura 33 – Utilidade percebida pelos usuários ao acessar os índices em tempo real (a) e conexão com a Internet (b)




Fonte: Elaborado pelo autor.

diferentes funções dentro da empresa agrícola, como também é possível ver na Tabela 13. A utilização do *bot* pelos agricultores ocorreu de forma individual e sempre com acompanhamento para possíveis dúvidas, porém antes da utilização os agricultores foram instruídos de como funcionava o *bot*. Os agricultores utilizaram o *bot* em situações iguais aos 3 cenários propostos anteriormente, ou seja, contemplando o modelo como um todo.

Os resultados do TAM para as questões relacionadas à utilidade do IndoorPlant (Tabela 11, foram que 63% dos usuários concordam totalmente que o acompanhamento em tempo real é útil na rotina deles, enquanto 37% apenas concordam, conforme mostra a Figura 33 (a). A Figura 33 (b) apresenta que 25% dos usuários são indiferentes quanto ao aplicativo estar conectado à Internet, já 37% concordam e 38% concordam totalmente. Alguns entrevistados comentaram que o fato do celular necessitar estar conectado à Internet até é melhor para eles porque o sinal comum de celular é precário na área da propriedade, mesmo estando próximo da cidade.


A Figura 34 (a) apresenta que 75% dos usuários concordaram plenamente que a possibilidade de o IndoorPlant prever o tempo de cultivo das plantas é útil para eles. Os usuários restantes (25%) também concordaram que é útil no dia a dia deles. As melhorias de ajustes no cultivo que o IndoorPlant fornece aos usuários teve sua utilidade aprovada em 100% (Figura 34

Figura 34 – Utilidade percebida pelos usuários ao utilizar a previsão para o tempo de cultivo (a) e para a indicação de melhorias (b)



Fonte: Elaborado pelo autor.

Figura 35 – Utilidade percebida pelos usuários ao poder avaliar a colheita (a) e para a utilização de perfis existentes (b)




Fonte: Elaborado pelo autor.

(b)), sendo que 50% dos usuários concordaram plenamente e os outros 50% concordaram com o item.

Todos os usuários (100%) concordaram plenamente que é útil poder avaliar a colheita feita (Figura 35 (a)), pois o IndoorPlant salva o contexto atual da estufa, e pode ser que o contexto atual da mesma seja diferente do contexto programado no Controlador de Estufas. A possibilidade de utilizar perfis para as plantas (Figura 35 (b)) foi avaliado como indiferente por 25% dos usuários, porém 62% concordaram plenamente que é útil no dia a dia e 13% também concordaram que é útil. Os usuários que avaliaram como indiferente o modelo possuir perfis para as plantas relataram que eles nunca alteram a espécie de planta cultivada, com isso é sempre o mesmo parâmetro que está programando no Controlador de Estufas.


Em relação a avaliação do aplicativo ser via chat, 88% dos usuários concordaram plenamente que facilita o uso por ser parecido com os aplicativos que utilizam normalmente e 12% concordaram que facilita também, conforme é mostrado na Figura 36 (a). Todos os usuários concordaram que é de fácil compreensão a leitura e entendimento dos índices das estufas, sendo que 88% dos usuários concordaram totalmente e 12% concordaram, conforme apresenta a Figura 36 (b). Alguns dos usuários comentaram que a visualização dos índices atuais das estufas

Figura 36 – Facilidade percebida dos usuários pelo aplicativo ser via chat (a) e compreensão dos índices das estufas (b)



Fonte: Elaborado pelo autor.

Figura 37 – Facilidade percebida pelos usuários para compreender a predição do tempo de colheita (a) e compreensão das melhorias indicadas pelo modelo (b)




Fonte: Elaborado pelo autor.

ficaram muito mais fáceis de serem compreendidos e vistos do que no próprio Controlador de Estufas.

A Figura 37 (a) apresenta que 100% dos usuários concordaram que é de fácil entendimento a predição para o tempo de colheita. Do mesmo modo que na Figura 37 (b) 100% dos usuários avaliaram que concordavam totalmente que as indicações de ajustes informadas pelo modelo são de fácil compreensão. Dois usuários (25%) até comentaram que se essas indicações existissem anteriormente teria evitado perdas. Pois eles não trabalhariam com índices errados nos cultivos, como já ocorreu em outros momentos.


Por fim, a Figura 38 (a) apresenta que 50% dos usuários concordaram plenamente que a avaliação da colheita é fácil de utilizar e os outros 50% também concordaram que é fácil de avaliar a colheita. Três dos usuários até indicaram uma melhoria nesse serviço que é a adição de valores intermediários entre os valores já existentes hoje. Pois como só tem valores inteiros, algumas vezes eles ficam forçados a dar uma nota maior ou menor sem que seja a nota verdadeira e caso existam notas com 0,5 de diferença, já facilitaria a avaliação da colheita. A Figura 38 apresenta que 50% dos usuários concordaram totalmente e 38% concordaram que a utilização de perfis para as plantas é útil no cultivo. Apenas 12% avaliaram como indiferente a questão

Figura 38 – Facilidade percebida pelos usuários para avaliar a colheita (a) e escolher e compreender os perfis existentes (b)



Fonte: Elaborado pelo autor.

Figura 39 – Utilidade Total Percebida pelos Usuários

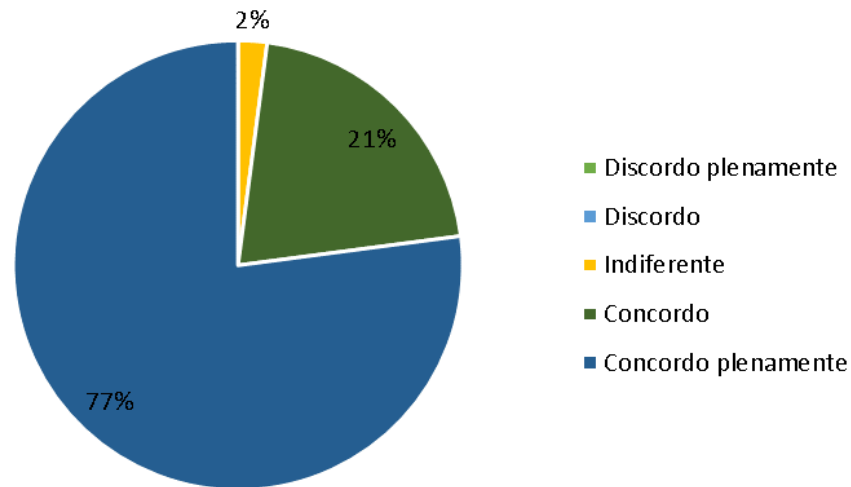


Fonte: Elaborado pelo autor.

dos perfis das plantas, pois como já dito anteriormente existem estufas que sempre possuem as mesmas espécies de plantas sendo cultivadas.

Analisando o TAM é possível ver que, em uma visão geral, o modelo proposto quanto a utilidade foi avaliado positivamente em 91,66% das questões, sendo que 56% concordaram plenamente e 36% concordaram com a utilidade do mesmo. Apenas 8% dos itens foram avaliados como indiferentes pelo usuários, conforme apresenta a Figura 39. A Figura 40 mostra que em relação a facilidade de uso apenas 2% do modelo foi avaliado como indiferente, enquanto os outros 98% dos itens foram avaliados positivamente pelos usuários. Desses itens avaliados positivamente, 21% dos usuários concordaram com os itens e 77% concordaram plenamente que as funcionalidades do modelo são de fácil compreensão e utilidade.

Figura 40 – Facilidade Total Percebida pelos Usuários



Fonte: Elaborado pelo autor.

### 5.3 Considerações sobre o capítulo

Neste capítulo foram apresentados três cenários para validação do modelo, os quais servem de suporte para os cultivos internos de agricultores. Nesses três cenários foram testados os serviços de similaridade de contextos das estufas, gerenciamento de perfis das plantas e predição de produtividade das plantas. Os 3 cenários utilizaram os históricos de contextos como base para ter a capacidade de indicar as melhorias, mostrar os perfis existentes e fazer a predição do tempo de cultivo. Os cenários utilizaram um bot no Telegram para validação junto ao agricultor e comunicação com o IndoorServer. Os dados obtidos dos cultivos foram guardados nas suas respectivas bases de dados, onde também houve consultas nas mesmas. Os dados utilizados nos cenários foram de 3 cultivos reais de hidroponia, e foram obtidos através do controlador de estufas denominado Cultiva Fácil Hidroponia.

Com a utilização dos históricos de contextos foi possível fornecer serviços que atenderam as solicitações, sendo através das melhorias que o modelo indica, pela exibição e seleção de perfis existentes e também pela predição do tempo de cultivo. Os três cenários foram testados em uma rede externa ao IndoorServer e obtiveram respostas coerentes do servidor concluiu-se que o IndoorServer atendeu as requisições solicitadas por completo. O servidor suportou o recebimento dos dados de três estufas durante 7 meses e as armazenou corretamente em suas bases de dados. Porém foi necessário a cópia dos dados das duas bases de dados 2 vezes durante o período. Isso porque a versão do MongoDB instalada somente aceitava até 2 GB de dados em suas bases, mesmo que o sistema operacional Raspbian tivesse espaço livre de armazenamento.

Os resultados dos dois primeiros cenários foram satisfatórios pois as respostas geradas e os resultados obtidos foram coerentes com a realidade dos agricultores e também com o funcio-



Tabela 14 – Relação de Produtividade Real e Prevista

Plantas	Dias Reais	Dias Previstos
Radite	20	21
Alface	33	31
Rúcula	26	25

Fonte: Elaborado pelo autor.

namento sem nenhum imprevisto junto a implementação do modelo. Já no terceiro cenário o IndoorPlant indicou certos tempo para que cada planta chegasse em seu tamanho indicado para colheita e o resultado teve pequenas divergências como mostra a Tabela 14.

Esse erro não é algo preocupante, pois como já dito anteriormente o IndoorPlant conseguiu obter apenas 7 meses de cultivo, o que também mostra que nem todas as estações do ano o modelo teve em seus históricos de contextos. Com isso o erro de um, ou dois dias na predição do tempo de cultivo é totalmente tolerável. A Tabela 14 mostra que os dados reais e os dados previstos estão próximos, confirmando que o modelo obteve sucesso ao predizer o tempo de cultivo das plantas. Esse sucesso do modelo em predizer o tempo de cultivo fica mais claro quando são apresentados os dados de cada uma das predições das plantas, onde o radite obteve os valores ( $R^2$ ) de 0.964, (RMSE) de 1.06 e (RMSECV) de 1.94. O alface obteve os valores ( $R^2$ ) de 0.947, (RMSE) de 1.37 e (RMSECV) de 3.31 e a rúcula obteve os valores ( $R^2$ ) de 0.932, (RMSE) de 1.10 e (RMSECV) de 1.89.

Também é importante levar em conta que durante a coleta de dados o tempo de cultivo foi fornecido pelo próprio agricultor, o que também pode haver algum pequeno erro de informação por esses dados não serem obtidos automaticamente. Além disso o erro da predição de 1 dia para radite e rúcula e de 2 dias para o alface também pode ter sofrido com a limpeza dos tanques das soluções hidropônicas. Essa limpeza dura em torno de um dia e com isso as soluções durante a limpeza ficam fora dos padrões porque o tanque é limpo em sua totalidade, ou seja, mais um motivo para mostrar que o resultado é de grande importância.

Com base no comportamento apresentado pelo bot do Telegram, pelo IndoorServer e seus cenários de aplicação, é possível concluir que o protótipo atende o que foi especificado no modelo. Através da comparação e armazenamento dos históricos de contextos, utilização dos históricos para gerar indicações de melhorias no cultivo, fornecer os melhores perfis para o cultivo de cada planta, e a previsão do tempo de cultivo para as 3 culturas controladas pelo Cultiva Fácil Hidroponia.

Através da avaliação do TAM, foi possível constatar uma aprovação de 91,66% dos itens referentes a utilidade do modelo. Quanto a facilidade de uso percebida pelo TAM, o modelo obteve a uma aprovação de 98%. Junto dessas aprovações vieram algumas dicas de melhorias que os usuários fizeram, com isso é possível ver alguns pontos a serem ajustados no IndoorPlant. Um dos fatores do TAM que mostrou grande aprovação por parte dos usuários foi a questão do aplicativo ser em forma de texto, com isso facilita o uso para eles que não são assíduos usuários

de smartphones.

## 6 CONSIDERAÇÕES FINAIS

Esta dissertação apresentou o IndoorPlant que é um modelo focado na agricultura indoor que suporta serviços inteligentes e abordou os principais problemas envolvendo sistemas da agricultura que utilizam predição e/ou sensibilidade ao contexto. O objetivo do modelo é utilizar os históricos de contextos para proporcionar um sistema que auxilie e forneça serviços inteligentes para os cultivos internos como indicações de melhorias, aviso e alertas de problemas no cultivo, cálculo da produtividade, entre outros aspectos. A infraestrutura proposta oferece suporte através do monitoramento dos contextos das estufas, indicações de parâmetros relacionados aos perfis das plantas.

Além disso o modelo suporta a utilização das próprias informações geradas próprias predições que podem ser feitas. O modelo utiliza perfil dos usuários, monitora e gerencia as estufas, disponibilizando as informações, por meio do IndoorServer, e do bot do Telegram. A computação ubíqua, a sensibilidade ao contexto e a predição são o ponto de partida para o modelo proposto, integrando as demais tecnologias, inclusive possibilitando a adição de outros dispositivos, tais como controladores de estufas diferentes que tenham outros sensores, novas predições que o modelo pode fazer, entre outros. Esse último capítulo apresenta as principais conclusões e contribuições do trabalho, bem como sugestões de trabalhos futuros ainda sobre esse tema. Por último são apresentados os artigos publicados e submetidos que possuem relação com o modelo proposto.

### 6.1 Conclusão e Contribuições

No início do capítulo 2 foram introduzidos os conceitos sobre tecnologias adotadas e também uma visão geral sobre a agricultura *indoor* e as técnicas de predição utilizadas. No capítulo 3 foi apresentada a revisão sistemática feita sobre o tema e os trabalhos relacionados ao IndoorPlant, bem como uma relação de critérios para compará-los. Os trabalhos relacionados discutidos na seção 3 não utilizaram técnicas de predição para a produtividade, porém esses trabalhos predizem outras informações do cultivo. Entre as informações previstas estão a temperatura e umidade da estufa (SANTOS et al., 2018). Também foram encontrados estudos focados na diminuição do consumo de água e na irrigação inteligente do cultivo (GOAP et al., 2018) e (HUONG et al., 2018).

No capítulo 4 foi descrito o modelo IndoorPlant juntamente de sua visão geral, arquitetura, requisitos e seus casos de uso e a ontologia proposta denominada Agrindoor. No capítulo 5 foram apresentados os aspectos de implementação e avaliação do IndoorPlant, detalhando tecnologias aplicadas no IndoorServer, bot do Telegram, controlador de estufas (Cultiva Fácil Hidroponia) e três cenários de avaliação do modelo. Os três cenários utilizaram *datasets* de cultivos hidropônicos reais, o que mostra a real capacidade do modelo com dados e situações do dia a dia da agricultura. O protótipo apresentou resultados relevantes ao predizer o tempo de

cultivo das três estufas, e também forneceu para o agricultor serviços de auxílio e recomendação que consideraram os históricos de contextos e os perfis salvos nas bases de dados.

A aplicação de um questionário no modelo TAM serviu para coletar dados de usabilidade do modelo e provar que o mesmo foi bem aceito pelos usuários. Além disso algumas indicações de melhorias feitas pelos próprios agricultores já mostra a aceitação do modelo proposto. Essas indicações também mostra o interesse deles em utilizar a tecnologia para facilitar a sua rotina diária.

Uma das principais contribuições do IndoorPlant é a utilização dos históricos de contextos para gerar serviços inteligentes das mais variadas utilidades. Um desses serviços inteligentes que foi testado pelo modelo foi a predição de produtividade que não foi encontrada em outros trabalhos. A utilização dos históricos de contextos, sensibilidade ao contexto e análise de similaridade serviram para gerar indicações sobre os cultivos internos. A diversificação dos tipos de cultivo suportado pelo modelo (suportando todos os cultivos internos), e a criação de perfis vinculados as notas de colheitas para posterior uso dos mesmos perfis nos próximos cultivos são outras contribuições do modelo. Além dos itens comparados na Tabela 8 o IndoorPlant é o único estudo que faz indicações de melhorias no cultivo levando em conta os dados dos históricos de contextos.

## 6.2 Trabalhos Futuros

Como trabalho futuro para o IndoorPlant destaca-se o desenvolvimento de inferências utilizando a ontologia proposta e interligação com os dados dos perfis gerados e também de interligação com dados já existentes de outros estudos. Outro trabalho futuro que agregará mais valor ao IndoorPlant é a utilização do mesmo em outros tipos de cultivos como aquaponia, semi hidroponia e gotejamento. Com a utilização em outros cultivos também mostrará o potencial e capacidade do IndoorPlant em monitorar, gerenciar e controlar mais de um cultivo por vez.

Outro trabalho futuro para o IndoorPlant é a automatização das predições, onde somente os treinamentos da *machine learning* seriam manuais. Esse trabalho manual somente seria feito quando fosse capaz de notar que as predições estão com um erro maior que o desejado. Já o envio do contexto atual e obtenção da resposta da predição poderiam ser automatizadas, com isso a predição sempre estaria utilizando o contexto mais novo e atual dos cultivos.

A utilização de outras técnicas de predição também valorizaria mais o IndoorPlant e poderia ser feita uma comparação entre as técnicas utilizadas para informar qual tem o melhor resultado. A criação de outros serviços de predição também podem ser citadas como trabalhos futuros, afinal o modelo foi projetado para suportar diferentes serviços inteligentes.

As dicas dadas pelos agricultores para melhorias no bot também são pontos a serem ajustados para facilitar a utilização e melhorar os resultados obtidos nas suas rotinas. Também espera-se avaliar o IndoorPlant com um grupo maior de agricultores e por um período mais longo, permitindo assim uma avaliação mais conclusiva sobre a utilização do modelo.

### 6.3 Trabalhos Publicados e Submetidos

Os seguintes artigos foram publicados no âmbito de temas relacionados com essa dissertação:

1. HELFER, Gilson A.; BARBOSA, Jorge L. V.; MARTINI, BRUNO G.; DOS SANTOS, RONALDO B.; DA COSTA, ADILSON B.. Ubiquitous Computing in Precision Agriculture: A Systematic Review. *Agris on-line Papers in Economics and Informatics*, v. 11, p. 3-13, 2019.

2. HELFER, Gilson A.; MARTINI, Bruno G.; MELLO, Ronaldo S.; COSTA, Adilson B.; BARBOSA, Jorge L. V.. Tellus: um modelo computacional para a predição da fertilidade do solo na agricultura de precisão. In: XI Simpósio Brasileiro de Computação Ubíqua e Pervasiva (SBCUP), 2019, Belém. Anais do SBCUP 2019. Porto Alegre: SBC, 2019. p. 1-10.

3. MARTINI, Bruno G.; HELFER, Gilson A.; Barbosa, Jorge L. V.; SILVA, MARCIO R. DA; DE FIGUEIREDO, RODRIGO M.; MODOLO, REGINA C. E.; YAMIN, ADENAUER C.. A computational model for ubiquitous intelligent services in indoor agriculture. In: the 25th Brazillian Symposium, 2019, Rio de Janeiro. Proceedings of the 25th Brazillian Symposium on Multimedia and the Web - WebMedia '19. New York: ACM Press, 2019. p. 497-500.

4. HELFER, GILSON A.; Barbosa, Jorge L. V.; DA COSTA, ADILSON B.; MARTINI, Bruno G.; SANTOS, RONALDO DOS . A model for productivity and soil fertility prediction oriented to ubiquitous agriculture. In: the 25th Brazillian Symposium, 2019, Rio de Janeiro. Proceedings of the 25th Brazillian Symposium on Multimedia and the Web - WebMedia '19. New York: ACM Press, 2019. p. 489-492.

O seguinte artigo foi submetido para o *journal* "Agris on-line Papers in Economics and Informatics" no âmbito de tema relacionado com essa dissertação:

1. MARTINI, Bruno G.; HELFER, Gilson A.; Barbosa, Jorge L. V.; SILVA, MARCIO R. DA; DE FIGUEIREDO, RODRIGO M.; MODOLO, REGINA C. E.. Prediction and Context Awareness in Agriculture: A Systematic Mapping.



## REFERÊNCIAS

- ALIPIO, M. I. et al. A smart hydroponics farming system using exact inference in bayesian network. In: IEEE 6TH GLOBAL CONFERENCE ON CONSUMER ELECTRONICS, 2017, Nagoya, Japan. **Anais...** [S.l.: s.n.], 2017.
- ARAKERI, M. P. et al. Computer vision based robotic weed control system for precision agriculture. In: INTERNATIONAL CONFERENCE ON ADVANCES IN COMPUTING, COMMUNICATIONS AND INFORMATICS (ICACCI), 2017., 2017, Udupi, India. **Anais...** [S.l.: s.n.], 2017.
- ATHANI, S. et al. Soil moisture monitoring using iot enabled arduino sensors with neural networks for improving soil management for farmers and predict seasonal rainfall for planning future harvest in north karnataka — india. In: INTERNATIONAL CONFERENCE ON I-SMAC (IOT IN SOCIAL, MOBILE, ANALYTICS AND CLOUD) (I-SMAC), 2017., 2017, Palladam, India. **Anais...** [S.l.: s.n.], 2017.
- BANDYOPADHYAY, D.; SEN, J. Internet of things: applications and challenges in technology and standardization. , [S.l.], v. 58, n. 1, p. 49–69, may 2011.
- BARBOSA, J. L. V. et al. Trailcare: an indoor and outdoor context-aware system to assist wheelchair users. **International Journal of Human-Computer Studies**, [S.l.], v. 116, p. 01–14, aug 2018.
- BATISTA, A. C.; RODRÍGUEZ, A. C.; QUINTANA, M. S. Using iot resources to enhance the accuracy of overdrain measurements in greenhouse horticulture. In: IEEE 36TH CENTRAL AMERICAN AND PANAMA CONVENTION (CONCAPAN XXXVI), 2016., 2016, São José, Costa Rica. **Anais...** [S.l.: s.n.], 2016.
- BISCHOFF, V. et al. Integration of feature models: a systematic mapping study. **Information and Software Technology**, [S.l.], v. 105, p. 209–225, jan 2019.
- BOBADILLA, J. et al. Recommender systems survey. **Knowledge-Based Systems**, [S.l.], v. 46, p. 109–132, jul 2013.
- C. BERNARDI, A. C. de et al. **Agricultura de precisão: resultados de um novo olhar**. Brasília, Brasil: EMBRAPA Instrumentação, 2014.
- CHA, S.-H. Comprehensive survey on distance/similarity measures between probability density functions. **Int. J. Math. Model. Meth. Appl. Sci.**, [S.l.], v. 1, 01 2007.
- CONCEPCION, A. R.; STEFANELLI, R.; TRINCHERO, D. A wireless sensor network platform optimized for assisted sustainable agriculture. In: IEEE GLOBAL HUMANITARIAN TECHNOLOGY CONFERENCE (GHTEC 2014), 2014, San Jose, Califórnia, USA. **Anais...** [S.l.: s.n.], 2014.
- COSTA, C. A. da. **Software infrastructure for ubiquitous computing: a context-aware service-based approach**. Saarbrücken, Germany: VDM Verlag, 2009.
- DALMINA, L.; BARBOSA, J. L. V.; VIANNA, H. D. A systematic mapping study of gamification models oriented to motivational characteristics. **Behaviour and Information Technology**, [S.l.], p. 209–225, feb 2019.

DAVIS, F. D. Perceived usefulness, perceived ease of use, and user acceptance of information technology. **MIS Quarterly**, [S.l.], v. 13, p. 319–340, 1989.

DEY, A. K.; ABOWD, G. D.; SALBER, D. A conceptual framework and a toolkit for supporting the rapid prototyping of context-aware applications. **Human–Computer Interaction**, [S.l.], v. 16, n. 2-4, p. 97–166, dec 2001.

DIAS, L. P. S.; BARBOSA, J. L. V.; VIANNA, H. D. Gamification and serious games in depression care: a systematic mapping study. **Telematics and Informatics**, [S.l.], v. 35, n. 1, p. 213–224, apr 2014.

DIVYA, P. et al. Cawis: context aware wireless irrigation system. In: INTERNATIONAL CONFERENCE ON COMPUTER, COMMUNICATIONS, AND CONTROL TECHNOLOGY (I4CT), 2014, Langkawi, Malásia. **Anais...** [S.l.: s.n.], 2014.

DOSHI, J.; PATEL, T.; BHARTI, S. kumar. Smart farming using iot, a solution for optimally monitoring farming conditions. **Procedia Computer Science**, [S.l.], v. 160, p. 746–751, 2019.

FELTES, L. H.; BARBOSA, J. L. V. Md-uts: um modelo para desenvolvimento de sistemas ubíquos de transporte. In: IX SIMPÓSIO BRASILEIRO DE SISTEMAS DE INFORMAÇÃO (SBSI), 2013, João Pessoa, Brasil. **Anais...** [S.l.: s.n.], 2013. p. 649–660.

FIEHN, H. B. et al. Smart agriculture system based on deep learning. In: ICSDE'18 PROCEEDINGS OF THE 2ND INTERNATIONAL CONFERENCE ON SMART DIGITAL ENVIRONMENT, 2018, Rabat, Morocco. **Anais...** [S.l.: s.n.], 2018.

FUKATSU, T.; HIRAFUJI, M. Web-based sensor network system field servers for practical agricultural applications. In: IWWISS '14 PROCEEDINGS OF THE 2014 INTERNATIONAL WORKSHOP ON WEB INTELLIGENCE AND SMART SENSING, 2014, Saint Etienne, França. **Anais...** [S.l.: s.n.], 2014. p. 01–08.

GOAP, A. et al. An iot based smart irrigation management system using machine learning and open source technologies. **Computers and Electronics in Agriculture**, [S.l.], v. 155, p. 41–49, dec 2018.

GONÇALES, L. et al. Model comparison: a systematic mapping study. In: SOFTWARE ENGINEERING AND KNOWLEDGE ENGINEERING (SEKE 2015), 2018, Pittsburgh, PA. **Anais...** [S.l.: s.n.], 2018.

GUARINO, N. Understanding, building and using ontologies. , [S.l.], v. 46, n. 2, p. 293–310, feb 1997.

GUARINO, N. Formal ontology in information systems. In: FOIS'98, 1998, Trento, Italy. **Proceedings...** [S.l.: s.n.], 1998. p. 3–15.

HELPER, G. A. et al. Chemostat: exploratory multivariate data analysis software. **Química Nova**, [S.l.], v. 38, n. 4, p. 575–579, 2015.

HEMMATI, H.; ARCURI, A.; BRIAND, L. Achieving scalable model-based testing through test case diversity. **ACM Transactions on Software Engineering and Methodology (TOSEM)**, [S.l.], v. 22, 02 2013.



- HUONG, T. T. et al. Water and energy-efficient irrigation based on markov decision model for precision agriculture. In: IEEE SEVENTH INTERNATIONAL CONFERENCE ON COMMUNICATIONS AND ELECTRONICS (ICCE), 2018., 2018, Hue, Vietnã. **Anais...** [S.l.: s.n.], 2018.
- IVANOV, I.; TSVETKOV, V. Intelligent planting. In: COMPSYTECH'17 PROCEEDINGS OF THE 18TH INTERNATIONAL CONFERENCE ON COMPUTER SYSTEMS AND TECHNOLOGIES, 2017, Ruse, Bulgaria. **Anais...** [S.l.: s.n.], 2017. p. 265–271.
- JACOB, N. K. Iot powered portable aquaponics system. In: SECOND INTERNATIONAL CONFERENCE ON INTERNET OF THINGS, DATA AND CLOUD COMPUTING (ICC),, 2017, New York, USA. **Proceedings...** [S.l.: s.n.], 2017. p. 00–05.
- JI, M. et al. Lora-based visual monitoring scheme for agriculture iot. In: IEEE SENSORS APPLICATIONS SYMPOSIUM (SAS), 2019. **Anais...** [S.l.: s.n.], 2019. p. 1–6.
- JOSHI, J. et al. Machine learning based cloud integrated farming. In: ICMLSC '17 PROCEEDINGS OF THE 2017 INTERNATIONAL CONFERENCE ON MACHINE LEARNING AND SOFT COMPUTING, 2017, Ho Chi Minh City, Vietnam. **Anais...** [S.l.: s.n.], 2017.
- KALE, A. P.; SONAVANE, S. Iot based smart farming : feature subset selection for optimized high-dimensional data using improved ga based approach for elm. **Computers and Electronics in Agriculture**, [S.l.], v. 161, p. 225–232, 2019.
- KOKKONIS, G.; KONTOGIANNIS, S.; TOMTSIS, D. Fitra: a neuro-fuzzy computational algorithm approach based on an embedded water planting system. In: ICC '17 PROCEEDINGS OF THE SECOND INTERNATIONAL CONFERENCE ON INTERNET OF THINGS, DATA AND CLOUD COMPUTING, 2017, Cambridge, Reino Unido. **Anais...** [S.l.: s.n.], 2017.
- KUBICEK, P. et al. Prototyping the visualization of geographic and sensor data for agriculture. **Computers and Electronics in Agriculture**, [S.l.], v. 97, p. 83–91, sep 2013.
- KUMAR, V. S. et al. Smart autonomous gardening rover with plant recognition using neural networks. **Procedia Computer Science**, [S.l.], v. 93, p. 975–981, 2016.
- LEE, R. C.; TEPFENHARDT, M. **Uml and c++**: a practical guide to object-oriented development. Upper Saddle River, NJ, USA: Prentice Hall, 2000.
- LOKE, S. **Context-aware pervasive systems**: architectures for a new breed of applications. Boca Raton, USA: Auerbach Publications, 2006.
- LUIMULA, M. et al. Developing geosensor network support for locawe platform - application of standards in low-rate communication context. In: ICPS'09 - PROCEEDINGS OF THE 2009 INTERNATIONAL CONFERENCE ON PERVASIVE SERVICES AND CO-LOCATED WORKSHOPS, 2009. **Anais...** [S.l.: s.n.], 2009.
- LÓPEZ-RIQUELME, J. A. et al. A software architecture based on fiware cloud for precision agriculture. **Agricultural Water Management**, [S.l.], v. 183, p. 123–135, mar 2017.
- MA, J. et al. A key frame extraction method for processing greenhouse vegetables production monitoring video. **Computers and Electronics in Agriculture**, [S.l.], v. 111, p. 92–102, feb 2015.

MARTINS, M. G. **Delfos**: um modelo para análise multitemporal baseado em históricos de contextos. 2019. 105 p. Tese (Doutorado em Computação Aplicada) — Programa de Pós-Graduação em Computação Aplicada (PPGCA), Universidade do Vale do Rio dos Sinos, São Leopoldo, Brasil, 2019.

MARTINS, M. V. L. **Frametrail**: um framework para o desenvolvimento de aplicações orientadas a trilhas. 2011. Dissertação (Mestrado em Ciência da Computação) — Programa de Pós-Graduação em Computação Aplicada (PIPCA), Universidade do Vale do Rio dos Sinos, São Leopoldo, Brasil, 2011.

MEHRA, M. et al. Iot based hydroponics system using deep neural networks. **Computers and Electronics in Agriculture**, [S.l.], v. 155, p. 473–486, dec 2018.

MIDDLETON, S. E.; SHADBOLT, N. R.; ROURE, D. C. D. Ontological user profiling in recommender systems. **ACM Transactions on Information Systems (TOIS)**, [S.l.], v. 22, n. 1, p. 54–88, jan 2004.

MOTIK, B.; SHEARER, R.; HORROCKS, I. Hypertableau reasoning for description logics. **Journal of Artificial Intelligence Research**, [S.l.], v. 36, n. 1, p. 165–228, sep 2009.

MQTT. **Welcome to the mqtt community**. 2017. Disponível em: <<https://github.com/mqtt/mqtt.github.io/wiki>>. Acesso em: 27 mar. 2019.

NAÇÕES UNIDAS BRASIL. **Se o atual ritmo de consumo continuar, em 2050 mundo precisará de 60% mais alimentos e 40% mais água**. 2015. Disponível em: <<https://nacoesunidas.org/fao-se-o-atual-ritmo-de-consumo-continuar-em-2050-mundo-precisara-de-60-mais-alimentos-e-40-mais-agua/>>. Acesso em: 20 abr. 2019.

NAGINI, S.; KANTH, T. V. R.; KIRANMAYEE, B. V. Agriculture yield prediction using predictive analytic techniques. In: INTERNATIONAL CONFERENCE ON CONTEMPORARY COMPUTING AND INFORMATICS (IC3I), 2., 2016, Noida, India. **Anais...** [S.l.: s.n.], 2016.

NODE-RED. **Node-red flow-based programming for the internet of things**. 2018. Disponível em: <<https://nodered.org/about/>>. Acesso em: 12 abr. 2019.

ONG, Z.; NG, A.; KYAW, T. Intelligent outdoor aquaponics with automated grow lights and internet of things. In: 2ND , 2019. **Anais...** [S.l.: s.n.], 2019. p. 1778–1783.

PARK, J. et al. A layered features analysis in smart farm environments. In: INTERNATIONAL CONFERENCE ON BIG DATA AND INTERNET OF THING (BDIOT2017), 2017, Londres, Reino Unido. **Proceedings...** [S.l.: s.n.], 2017.

PATIL, S. S.; THORAT, S. A. Early detection of grapes diseases using machine learning and iot. In: SECOND INTERNATIONAL CONFERENCE ON COGNITIVE COMPUTING AND INFORMATION PROCESSING (CCIP), 2016., 2016, Mysore, India. **Anais...** [S.l.: s.n.], 2016.

PETERSEN, K.; VAKKALANKA, S.; KUZNIARZ, L. Guidelines for conducting systematic mapping studies in software engineering: an update. **Information and Software Technology**, [S.l.], v. 64, p. 1–18, 2015.

PIMENTEL, D. et al. Water resources: agricultural and environmental issues. **BioScience**, [S.l.], v. 54, n. 10, p. 909–918, oct 2004.

PLAZAS, J. A. P.; GAONA-GARCÍA, P. A.; MARIN, C. E. M. Proposal of a computational intelligence prediction model based on internet of things technologies. In: IEEE INTERNATIONAL CONFERENCE ON SMART INTERNET OF THINGS (SMARTIOT), 2018., 2018, Xi'an, China. **Anais...** [S.l.: s.n.], 2018.

POPOVIC, T. et al. Architecting an iot-enabled platform for precision agriculture and ecological monitoring: a case study. **Computers and Electronics in Agriculture**, [S.l.], v. 140, p. 255–265, 2017.

QIN, W.; SHI, Y.; SUO, Y. Ontology-based context-aware middleware for smart spaces. **Tsinghua Science and Technology**, [S.l.], v. 12, n. 6, p. 707–713, dec 2007.

RAJENDRAKUMAR, S. et al. An intelligent report generator for efficient farming. In: INTERNATIONAL CONFERENCE ON ELECTRICAL, ELECTRONICS, COMMUNICATION, COMPUTER, AND OPTIMIZATION TECHNIQUES (ICEECCOT), 2017., 2017, Mysuru, India. **Anais...** [S.l.: s.n.], 2017.

RODRÍGUEZ, S.; GUALOTUÑA, T.; GRILO, C. A system for the monitoring and predicting of data in precision agriculture in a rose greenhouse based on wireless sensor networks. **Procedia Computer Science**, [S.l.], v. 121, p. 306–313, 2017.

RUPANAGUDI, S. R. et al. A novel cloud computing based smart farming system for early detection of borer insects in tomatoes. In: INTERNATIONAL CONFERENCE ON COMMUNICATION, INFORMATION COMPUTING TECHNOLOGY (ICCICT)), 2015., 2015, Mumbai, India. **Anais...** [S.l.: s.n.], 2015.

SAHA, S. et al. Smart agricultural system: better accuracy and productivity. In: DEVICES FOR INTEGRATED CIRCUIT (DEVIC), 2017., 2017, Kalyani, India. **Anais...** [S.l.: s.n.], 2017.

SANTOS, U. J. L. dos et al. Agriprediction: a proactive internet of things model to anticipate problems and improve production in agricultural crops. **Computers and Electronics in Agriculture**, [S.l.], v. 161, p. 202–213, jun 2018.

SAP AG. **Standardized technical architecture modeling - conceptual and design level**. 2007. Disponível em: <<http://www.fmc-modeling.org/download/fmc-and-tam/SAP-TAMstandard.pdf>>. *Acesso em* : 03abr. 2019.

SARANGDHAR, A. A.; PAWAR, V. R. Machine learning regression technique for cotton leaf disease detection and controlling using iot. In: INTERNATIONAL CONFERENCE OF ELECTRONICS, COMMUNICATION AND AEROSPACE TECHNOLOGY (ICECA), 2017., 2017, Combaitore, India. **Anais...** [S.l.: s.n.], 2017.

SATYANARAYANAN, M. Pervasive computing: vision and challenges. **IEEE Personal Communications**, [S.l.], v. 8, n. 4, p. 10–17, 2001.

SHAHRIAR, S.; MCCULLUCH, J. A dynamic data-driven decision support for aquaculture farm closure. **Procedia Computer Science**, [S.l.], v. 29, p. 1236–1245, 2014.

SISYANTO, R. E. N.; SUHARDI; KURNIAWAN, N. B. Hydroponic smart farming using cyber physical social system with telegram messenger. In: INTERNATIONAL CONFERENCE ON INFORMATION TECHNOLOGY SYSTEMS AND INNOVATION (ICITSI), 2017., 2017, Bandung, Indonesia. **Anais...** [S.l.: s.n.], 2017.

SMART AKIS. **What is smart farming?** 2017. Disponível em: <<https://www.smart-akis.com/index.php/network/what-is-smart-farming/>>. Acesso em: 23 maio. 2019.

TAN, L. Cloud-based decision support and automation for precision agriculture in orchards. **IFAC - Papers OnLine**, [S.l.], v. 49, n. 16, p. 330–335, 2016.

TAN, W.; ZHAO, C.; WU, H. Intelligent alerting for fruit-melon lesion image based on momentum deep learning. **Multimedia Tools and Applications**, [S.l.], v. 75, n. 24, p. 16741–16761, 2015.

TELEGRAM MESSENGER. **Telegram - a new era of messaging**. 2019. Disponível em: <<https://telegram.org/>>.

TELLES, M. J. **Masc**: um modelo computacional para cidades inteligentes assistivas. 2015. Dissertação (Mestrado em Ciência da Computação) — Programa de Pós-Graduação em Computação Aplicada (PIPICA), Universidade do Vale do Rio dos Sinos, São Leopoldo, Brasil, 2015.

TIWARI, O. et al. An experimental set up for utilizing convolutional neural network in automated weed detection. In: INTERNATIONAL CONFERENCE ON INTERNET OF THINGS: SMART INNOVATION AND USAGES (IOT-SIU), 2019. **Anais...** [S.l.: s.n.], 2019. p. 1–6.

TREBOUX, J.; GENOUD, D. Improved machine learning methodology for high precision agriculture. In: GLOBAL INTERNET OF THINGS SUMMIT (GIOTS), 2018., 2018, Bilbao, Espanha. **Anais...** [S.l.: s.n.], 2018.

USCHOLD, M.; GRUNINGER, M. Ontologies: principles, methods and applications. **The Knowledge Engineering Review**, [S.l.], v. 11, n. 2, p. 93–136, jun 1996.

VADIVEL, R. et al. Hypaponics - monitoring and controlling using internet of things and machine learning. In: INTERNATIONAL CONFERENCE ON INNOVATIONS IN INFORMATION AND COMMUNICATION TECHNOLOGY (ICIICT), 2019. **Anais...** [S.l.: s.n.], 2019. p. 1–6.

WAGNER, A. **Um modelo para gerenciamento de perfis de entidade através de inferência em trilhas**. 2013. Dissertação (Mestrado em Ciência da Computação) — Programa de Pós-Graduação em Computação Aplicada (PIPICA), Universidade do Vale do Rio dos Sinos, São Leopoldo, Brasil, 2013.

WEISER, M. **The computer for the 21st century**. New York, USA: New York: Scientific American, 1991.

WINICZENKO, R. et al. Optimisation of ann topology for predicting the rehydrated apple cubes colour change using rsm and ga. **Neural Computing and Applications**, [S.l.], v. 30, n. 6, p. 1795–1809, 2016.

WOLFERT, S. et al. Big data in smart farming - a review. **Communications of the ACM**, [S.l.], v. 153, p. 69–80, may 2017.

XU, D. et al. A gprs-based low energy consumption remote terminal unit for aquaculture water quality monitoring. In: INTERNATIONAL CONFERENCE ON COMPUTER AND COMPUTING TECHNOLOGIES IN AGRICULTURE, 2014. **Anais...** [S.l.: s.n.], 2014. p. 492–503.

YAHATA, S. et al. A hybrid machine learning approach to automatic plant phenotyping for smart agriculture. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (IJCNN), 2017., 2017, Anchorage, USA. **Anais...** [S.l.: s.n.], 2017.

YE, J.; DOBSON, S.; MCKEEVER, S. Situation identification techniques in pervasive computing: a review. , [S.l.], v. 8, n. 1, p. 33–66, feb 2012.

YOON, C.; KIM, S. Convenience and tam in a ubiquitous computing environment: the case of wireless lan. **Electron. Commer. Res. Appl.**, [S.l.], v. 6, p. 102–112, 2007.

ZHANG, P. et al. The construction of the integration of water and fertilizer smart water saving irrigation system based on big data. In: IEEE INTERNATIONAL CONFERENCE ON COMPUTATIONAL SCIENCE AND ENGINEERING (CSE) AND IEEE INTERNATIONAL CONFERENCE ON EMBEDDED AND UBIQUITOUS COMPUTING (EUC), 2017., 2017, Guangzhou, China. **Anais...** [S.l.: s.n.], 2017.

ZHOU, B.; LI, L. Security monitoring for intelligent water-saving precision irrigation system using cloud services in multimedia context. **Multimedia Tools and Applications**, [S.l.], 2017.

ZHOU, H.; LIU, B.; DONG, P. The technology system framework of the internet of things and its application research in agriculture. In: INTERNATIONAL CONFERENCE ON COMPUTER AND COMPUTING TECHNOLOGIES IN AGRICULTURE, 2011. **Anais...** [S.l.: s.n.], 2011. p. 293–300.

ZHOU, L. et al. Applications of internet of things in the facility agriculture. In: INTERNATIONAL CONFERENCE ON COMPUTER AND COMPUTING TECHNOLOGIES IN AGRICULTURE, 2012. **Anais...** [S.l.: s.n.], 2012. p. 297–303.



## APÊNDICE A – RELAÇÃO DOS ARTIGOS SELECIONADOS NO MAPEAMENTO SISTEMÁTICO

Tabela 15 – Relação dos Estudos Seleccionados no Mapeamento Sistemático

<b>Autores</b>	<b>Título do Trabalho</b>	<b>Objetivo</b>	<b>ID</b>
LUIMULA et al., 2009	Developing Geosensor Network Support for Locawe Platform – Application of Standards in Low-rate Communication Context	Estudar os padrões geoespaciais e com isso desenvolver uma plataforma e testar a mesma com sensores sem fio e atuadores sem fio	[1]
ZHOU; LIU; DONG, 2011	The Technology System Framework of the Internet of Things and Its Application Research in Agriculture	Analisar e pesquisar na internet das coisas em termos de níveis tecnológicos e sistemas que podem ser aplicados na agricultura	[2]
ZHOU et al., 2012.	Applications of Internet of Things in the Facility Agriculture	Propor soluções e tecnologias importantes para as instalações baseadas na IoT para a agricultura. Também tem como objetivo projetar e implementar as instalações das estufas de cultivo	[3]
KUBICEK et al., 2013	Prototyping the visualization of geographic and sensor data for agriculture	Descrever abordagens conceituais de métodos de visualização cartográfica de contexto para dados agrícolas e meteorológicos e criar um protótipo para visualização	[4]
FUKATSU; HIRAFUJI, 2014	Web-based sensor network system “Field Servers” for practical agricultural applications	Desenvolver um Open Field Server que permite o monitoramento fácil e flexível de vários tipos de campos agrícolas e contextos	[5]
DIVYA et al., 2014	CAWIS: Context Aware Wireless Irrigation System	Criar um sistema que utilize o contexto para irrigar corretamente o plantio e sem desperdício	[6]

CONCEPCION; STEFANLLI; TRINCHERO, 2014.	A Wireless Sensor Network Platform Optimized for Assisted Sustainable Agriculture	Criar um sensor sem fio eficiente para ser utilizado em rede e que seja adequado para aplicar na agricultura em países em desenvolvimento e regiões remotas	[7]
SHAHRIAR; MCCULLUCH, 2014	A Dynamic Data-driven Decision Support for Aquaculture Farm Closure	Apresentar um suporte decisivo dinâmico orientado por dados para o fechamento de fazendas de aquicultura através do aprendizado de máquinas	[8]
XU et al., 2014.	A GPRS-Based Low Energy Consumption Remote Terminal Unit for Aquaculture Water Quality Monitoring	Projetar e desenvolver um sistema (hardware e software) de monitoramento de parâmetros de qualidade da água, como DO, pH, salinidade e a temperatura para manter a qualidade da água boa para a vivência de seres vivos aquáticos	[9]
RUPANAGUDI et al., 2015	A Novel Cloud Computing based Smart Farming System for Early Detection of Borer Insects in Tomatoes	Desenvolver metodologias com a utilização do processamento de vídeo para detectar pragas em tomates	[10]
MA et al., 2015	A key frame extraction method for processing greenhouse vegetables production monitoring video	Melhorar a identificação de doenças vegetais em estufa com base no vídeo de monitoramento das estufas	[11]
TAN; ZHAO; WU, 2015	Intelligent alerting for fruit-melon lesion image based on momentum deep learning	Realizar um alerta autônomo inteligente para pragas de melão, utilizando rede neural convolucional para reconhecimento de imagem de lesão cutânea da fruta que é adquirido em tempo real por um sensor de vídeo infravermelho	[12]



TAN, 2016	Cloud-based Decision Support and Automation for Precision Agriculture in Orchards	Desenvolver uma estrutura para sistemas de suporte à decisão e automação baseados em nuvem que podem adquirir dados de várias fontes, sintetizar decisões específicas de aplicativos e controlar dispositivos de campo da nuvem	[13]
PATIL; THORAT, 2016.	Early Detection of Grapes Diseases Using Machine Learning and IoT	Desenvolver um sistema de monitoramento que identifique as chances de doenças nas uvas em seus estágios iniciais utilizando Modelo Oculto de Markov	[14]
KUMAR et al., 2016	Smart Autonomous Gardening Rover with Plant Recognition using Neural Networks	Construir um veículo robótico de jardinagem autônomo que identifica e classifica automaticamente as espécies de plantas usando algoritmos de extração e redes neurais	[15]
WINICZENKO et al., 2016	Optimisation of ANN topology for predicting the rehydrated apple cubes colour change using RSM and GA	Introduzir um método de otimização eficiente combinando metodologia de superfície de resposta e algoritmo genético para encontrar a topologia de redes neurais artificiais para prever mudanças de cor em cubos de maçã reidratados	[16]
BATISTA; RODRÍGUEZ; QUINTANA, 2016.	Using IoT resources to enhance the accuracy of overdrain measurements in greenhouse horticulture	Projetar e desenvolver um sistema que utilize IoT para aumentar o crescimento das plantas em estufas	[17]
IVANOV; TSVETKOV, 2017	Intelligent Planting	Desenvolver um sistema para facilitar o trabalho das pessoas no campo da agricultura	[18]
ALIPIO, et al., 2017	A Smart Hydroponics Farming System Using Exact Inference in Bayesian Network	Desenvolver um sistema de hidroponia inteligente que seja usado na automação do processo de crescimento das culturas usando inferência pelas Redes Bayesianas	[19]

RAJENDRA-KUMAR et al., 2017	An Intelligent Report Generator for Efficient Farming	Desenvolver um sistema que obtenha as informações do cultivo e com isso gerar um relatório para o produtor rural	[20]
SISYANTO; SUHARDI; KURNIAWAN, 2017	Hydroponic Smart Farming Using Cyber Physical Social System with Telegram Messenger	Criar um sistema que possibilita o agricultor a monitorar sua hidroponia através do Telegram Messenger	[21]
YAHATA et al., 2017	A Hybrid Machine Learning Approach to Automatic Plant Phenotyping for Smart Agriculture	Desenvolver dois métodos de detecção de imagens que permitam a observação automática para capturar flores e vagens de soja em campos de cultivo	[22]
ZHANG et al., 2017	The Construction of the Integration of Water and Fertilizer Smart Water Saving Irrigation System Based on Big Data	Criação de um sistema que utiliza IoT e outras tecnologias para monitorar e coletar dados automaticamente para relacioná-los com o crescimento dos campos	[23]
POPOVIC et al., 2017	Architecting an IoT-enabled platform for precision agriculture and ecological monitoring: A case study	Discutir um estudo de caso sobre a criação de uma plataforma privada para Internet das Coisas (IoT) voltada para a agricultura de precisão e monitoramento ecológico	[24]
SAHA et al., 2017	Smart Agricultural System: Better Accuracy and Productivity	Utilizar um método para monitorar campos agrícolas de qualquer lugar remoto e avaliar a condição do mesmo	[25]
LÓPEZ-RIQUELME et al., 2017	A software architecture based on FIWARE cloud for PrecisionAgriculture	Demonstrar que o uso de serviços em nuvem no contexto agrônômico pode ser considerado altamente benéfico	[26]

ATHANI et al., 2017	Soil moisture monitoring using IoT enabled arduino sensors with neural networks for improving soil management for farmers and predict seasonal rainfall for planning future harvest in North Karnataka - India	Delinear uma técnica gerenciável e fácil de instalar para detectar e especificar o nível de umidade do solo que é gerido interminavelmente com o objetivo de crescimento das plantas em morros e aumentar concomitantemente os recursos de irrigação disponíveis	[27]
ARAKERI et al., 2017	Computer Vision Based Robotic Weed Control System for Precision Agriculture	Desenvolver um sistema robótico para o controle de plantas daninhas em tempo real em campos de cebola	[28]
RODRIGUEZ; GUATOLUÑA; GRILO, 2017	A System for the Monitoring and Predicting of Data in Precision Agriculture in a Rose Greenhouse Based on Wireless Sensor Networks	Projetar e implementar uma rede de sensores sem fio para para permitir a coleta de dados do ambiente agrícola, como temperatura, umidade e luz	[29]
SARANGDHAR; PAWAR, 2017	Machine Learning Regression Technique for Cotton Leaf Disease Detection and Controlling using IoT	Apresentar um sistema para detecção e controle de doenças na folha de algodão junto com o monitoramento e qualidade do solo	[30]
ZHOU; LI, 2017	Security monitoring for intelligent water-saving precision irrigation system using cloud services in multimedia context	Propor uma visualização remota inteligente do sistema de irrigação baseado em serviços em nuvem	[31]
KOKKONIS; KONTOGIANNIS; TOMTSIS, 2017	FITRA - A Neuro-fuzzy computational algorithm approach based on an embedded water planting system	Propor um novo algoritmo computacional neuro-difuso para sistemas de irrigação embarcado	[32]
JACOB, 2017	IoT Powered Portable Aquaponics System	Projetar e desenvolver um sistema de aquaponia indoor inteligente e portátil	[33]

JOSHI et al., 2017	Machine Learning Based Cloud Integrated Farming	Criação de um bot que pode ser usado para agricultura de pequena escala em áreas como jardins ou quintal utili- zando métodos baye- sianos	[34]
PARK et al., 2017	A Layered Features Analysis in Smart Farm Environments	Propor uma estrutura de análise de dados escalável para prever o rendimento da colheita	[35]
SANTOS et al., 2018.	AgriPrediction: A proactive internet of things model to anticipate problems and improve production in agricultural crops	Apresenta um modelo que combina um sistema de alcance de rede sem fio com um mecanismo de predição que antecipa possíveis disfunções nas culturas proativamente, notificando o agricultor para ações corretivas o mais rápido possível	[36]
GOAP et al., 2018.	An IoT based smart irrigation management system using Machine learning and open source technologies	Propor um sistema inteli- gente programado em código aberto e para pre- ver os requisitos de irriga- ção do campo com utiliza- ção de sensores	[37]
MEHRA, et al., 2018	IoT based hydroponics system using Deep Neural Networks	Propor o desenvolvimento de um sistema hidropôni- co baseado em IoT inteli- gente empregando Redes Neurais. O sistema desen- volvido é inteligente o sufi- ciente para controlar as ações do ambiente hidro- pônico	[38]
PLAZAS; GAONA- GARCIA; MARIN, 2018	Proposal of a computational intelligence prediction model based on Internet of Things technologies	A proposta é orientada para o uso de dados base- ados na rede IoT que for- necem informações para o modelo de previsão do tempo usando técnicas de inteligência computacional para realizar predição de inundações	[39]

HUONG et al., 2018.	Water and Energy-Efficient Irrigation based on Markov Decision Model for Precision Agriculture	Propor um modelo genérico utilizando o Modelo de Decisão de Markov para criar uma irrigação automática e precisa e que torne a agricultura mais eficiente em consumo de energia e água	[40]
TREBOUX; GENOUD, 2018	Improved Machine Learning Methodology for High Precision Agriculture	Apresentar o impacto do aprendizado de máquina junto a agricultura de precisão	[41]
FIEHN et al., 2018	Smart Agriculture System Based on Deep Learning	Monitorar com IoT o meio ambiente e empregar um sistema neural convolucional na rede para controlar do fluxo de dados	[42]
RAJENDRA-KUMAR; et al., 2019	Automation of Irrigation System through Embedded Computing Technology	Criar um aplicativo autômato para prever o conhecimento diário de umidade e temperatura do cultivo	[43]
MISHRA et al., 2019	Smart Agriculture System Using IoT	Propor um método inteligente de cultivo em uma área limitada, usando sensores de temperatura e umidade e sensor de umidade do solo como nós	[44]
JI et al., 2019	LoRa-based Visual Monitoring Scheme for Agriculture IoT	Criar um novo sistema para transmitir imagens contínuas tiradas de uma câmera em um ambiente estático através do LoRa	[45]
GRIMBLATT et al., 2019	Precision agriculture for small to medium size farmers - An IoT approach	Criar um sistema para a agricultura de precisão de baixa potência e que processe as informações e envie as mais relevantes para a nuvem para análise adicional	[46]
VADIVEL et al., 2019	Hypaponics - Monitoring and Controlling using Internet of Things and Machine Learning	Hypaponics é um sistema de monitoramento que monitora a agricultura vertical integrada usando vários sensores e as previsões são tomadas com base nos dados usando algoritmos de aprendizado de máquina	[47]

TIWARI et al., 2019	An experimental set up for utilizing convolutional neural network in automated weed detection	Desenvolver um método que detecte ervas daninhas no campo e, em seguida pulverizar com o uso de drones um herbicida sobre elas para destruir completamente	[48]
ONG et al., 2019	Intelligent Outdoor Aquaponics with Automated Grow Lights and Internet of Things	Projetar e construir um sistema aquapônico externo inteligente com luzes de cultivo automatizadas e internet das coisas	[49]
KALE et al., 2019	IoT based Smart Farming: Feature subset selection for optimized high-dimensional data using improved GA based approach for ELM	Propor um sistema de suporte à decisão de fazendas inteligentes através da IoT com parâmetros multinível e baseado em algoritmo genético	[50]
DOSHI et al., 2019	Smart Farming using IoT, a solution for optimally monitoring farming conditions	Propor um sistema que gere mensagens em diferentes plataformas para notificar os agricultores e auxiliar a obterem dados ao vivo das plantações	[51]

Fonte: Elaborado pelo autor.