



Programa de Pós-Graduação em

Computação Aplicada

Mestrado/Doutorado Acadêmico

Gilson Augusto Helfer

Tellus: um modelo computacional para análise de solo na agricultura ubíqua baseado em históricos de contextos

São Leopoldo, 2022

UNIVERSIDADE DO VALE DO RIO DOS SINOS — UNISINOS
UNIDADE ACADÊMICA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO APLICADA
NÍVEL DOUTORADO

GILSON AUGUSTO HELFER

**TELLUS: UM MODELO COMPUTACIONAL PARA ANÁLISE DE SOLO NA
AGRICULTURA UBÍQUA BASEADO EM HISTÓRICOS DE CONTEXTOS**

São Leopoldo
2022

Gilson Augusto Helfer

**TELLUS: UM MODELO COMPUTACIONAL PARA ANÁLISE DE SOLO NA
AGRICULTURA UBÍQUA BASEADO EM HISTÓRICOS DE CONTEXTOS**

Tese apresentada como requisito parcial para a
obtenção do título de Doutor 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. Adilson Ben Costa

São Leopoldo
2022

H474t Helfer, Gilson Augusto.
Tellus: um modelo computacional para análise de solo na agricultura ubíqua baseado em históricos de contextos / Gilson Augusto Helfer. – 2022.
127 f. : il. ; 30 cm.

Tese (doutorado) – Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Computação Aplicada, 2022.
“Orientador: Prof. Dr. Jorge Luis Victória Barbosa
Coorientador: Prof. Dr. Adilson Ben Costa.”

1. Agricultura de precisão. 2. Análise de solo. 3. Computação ubíqua. 4. Históricos de contextos. 5. Aprendizado de máquina. 6. Ontologia. I. Título.

CDU 004.75.057.5

Dados Internacionais de Catalogação na Publicação (CIP)
(Bibliotecária: Amanda Schuster – CRB 10/2517)

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.

AGRADECIMENTOS

À Deus, pela sabedoria e discernimento necessários para chegar ao final deste trabalho.

Ao meu orientador, Prof. Dr. Jorge Barbosa, pela atenção, confiança e contínuo incentivo durante a trajetória desta investigação.

Ao meu coorientador, Prof. Dr. Adilson Ben da Costa, pela contribuição, parceria e pronta disponibilização.

Aos professores Dr. Adenauer Correa Yamin, Dr. Rodrigo da Rosa Righi e Dr. Valderi Reis Quietinho Leithardt por suas valiosas contribuições no refinamento do trabalho.

Aos professores do PPGCA que de alguma forma contribuíram para o crescimento do meu conhecimento, em especial ao Prof. Dr. Sandro Rigo pelo diálogo aberto.

Ao Prof. Dr. Marco Flôres Ferrão por plantar uma ideia lá no passado.

Às funcionárias do PPGCA pela disponibilidade em auxiliar sempre que necessário.

Aos colegas do PPGCA, que compartilharam conhecimento e horas de estudo, Andresa Vargas, Bruno Martini, Helder Arruda, Luis Gubert, Joneval Gomes, Robson Lima e em especial ao também parceiro de viagem, Jorge Aranda.

À minha companheira Karina Meneghetti Brendler, pela compreensão nos inúmeros momentos em que estive ausente, mesmo presente. Aos meus filhos, Manuela, João Vitor e ao recém-chegado Thomas, a quem busco ser exemplo.

À minha família, meus pais Elmar João e Elaine Helfer, pelos braços sempre abertos; à família extensa, Gilson e Gilsa Jackish, Pedro Franz e Sueli Meneghetti Brendler, Bruno Brendler, Clara Brendler e Florian Baumgart pelo apoio incondicional.

Aos amigos Samuel Weis, Laone Kuentzer, Anderson e Alex Muller, Ricardo Macedo cuja amizade ultrapassa o tempo.

À Central Analítica da UNISC, pela parceria nas análises de solos.

À Capes, pelo apoio financeiro.

À todos aqueles que colaboraram direta ou indiretamente para a elaboração deste trabalho.

RESUMO

As aplicações da computação ubíqua têm aumentado nos últimos anos, principalmente devido ao desenvolvimento de tecnologias como a computação móvel e sua integração com o mundo real. Um dos desafios nesta área é o uso da sensibilidade ao contexto. Na agricultura, pode ser considerado o contexto relacionado ao meio ambiente, como os aspectos químicos e físicos que caracterizam os diferentes tipos de solo. Esse cenário muda periodicamente devido a fatores como clima, tipo de cultivar e técnica de manejo do solo utilizada, entre outros aspectos. Essa tese apresenta um modelo computacional chamado Tellus, aplicado na agricultura ubíqua que emprega históricos de contextos para predição de propriedades físico-químicas do solo. Para avaliar o modelo foi criado um protótipo baseado numa estação de telemetria e instalada a campo além de um aplicativo móvel para gerenciamento das informações. Para o treinamento do Agente de Predição foram selecionadas 43 amostras de solo com resultado de referência de diversos pontos de coleta do Vale do Rio Pardo, cujas concentrações de matéria orgânica variaram entre 0,6% e 5,9% e argila entre 8% e 60%, respectivamente. Para predição de matéria orgânica e argila no solo foram obtidos coeficientes de determinação (R^2) de 0,9738 e 0,9536 para erros quadráticos médios de calibração de (RMSEC) de 0,26% e 2,95%, respectivamente. Já para recomendação de irrigação, foram utilizadas 192 imagens para o treinamento e obtida uma acurácia de 82,55%. A partir do AgroXML, foi proposta uma ontologia denominada Tellus-Onto que estende o estado da arte na classificação de solos brasileiros de acordo com a composição orgânica e textural. Uma série de axiomas e regras semânticas foram empregadas para proporcionar a realização de consultas e inferências sobre sua base instanciada. Além disso, a partir das informações de análise do solo, a ontologia infere recomendações para adubação e calagem. Para testar a ontologia foram instanciados 98 resultados de amostras de solos e inferidos suas classificações de modo preciso e automático. O modelo computacional e seus agentes de predição juntamente com a ontologia são as contribuições do Tellus na área da agricultura ubíqua aplicada às análises de solo.

Palavras-chave: Agricultura de Precisão. Análise de Solo. Computação Ubíqua. Históricos de Contextos. Aprendizado de Máquina. Ontologia.

ABSTRACT

The applications of ubiquitous computing have increased in recent years, mainly due to the development of technologies such as mobile computing and its integration with the real world. One of the challenges in this area is the use of context awareness. In agriculture, the context related to the environment can be considered, such as the chemical and physical aspects that characterize the different types of soil. This scenario changes periodically due to factors such as climate, type of cultivar and soil management technique used, among other aspects. This thesis presents a computational model called Tellus applied in precision agriculture that uses historical contexts to predict soil physicochemical properties. A prototype was created to evaluate the model based on a telemetry station and installed in the field, as well as a mobile application for information management. The Prediction Agent training had 43 soil samples from different collection points in Vale do Rio Pardo, whose concentrations of organic matter varied between 0.6% and 5.9% and clay between 8% and 60%, respectively. For prediction of organic matter and clay in the soil, coefficients of determination (R^2) of 0.9738 and 0.9536 were obtained and mean square errors of calibration (RMSEC) of 0.26% and 2.95%, respectively. For the irrigation recommendation, 192 images were used for training and an accuracy of 82.55% was achieved. In addition, an AgroXML based ontology called Tellus-Onto was proposed that extends the state of the art in the classification of Brazilian soils according to organic and textural composition. A series of axioms and semantic rules were used to provide queries and inferences about its instantiated base. In addition, from the soil analysis information, the ontology infers recommendations for fertilization and liming. To test the ontology, 98 soil sample results were instantiated and their classifications were inferred in a precise and automatic way. The computational model and its prediction agents together with the ontology are the contributions of Tellus in ubiquitous agriculture applied to soil analysis.

Keywords: Precision Agriculture. Soil Analysis. Ubiquitous Computing. Context History. Machine Learning. Ontology.

LISTA DE FIGURAS

Figura 1 – Quantidade de amostras analisadas pela Central Analítica (UNISC) entre os anos de 2009 e 2021	28
Figura 2 – Distribuição dos tipos de solo no estado do Rio Grande do Sul	30
Figura 3 – Triângulo de classificação textural dos solos no Brasil	32
Figura 4 – Paradigmas da programação tradicional e Aprendizado de Máquina	33
Figura 5 – Fases de aprendizagem e predição na quimiometria	34
Figura 6 – Etapas do processo de filtragem	42
Figura 7 – Bancos de dados onde as pesquisas foram encontradas antes da etapa de combinação.	43
Figura 8 – Densidade dos termos de pesquisa por ano de publicação	48
Figura 9 – Número de publicações entre 2009 e 2019	49
Figura 10 – Visão geral do Tellus	60
Figura 11 – Arquitetura do modelo Tellus	61
Figura 12 – Modelo de Entidade Relacionamento Tellus	62
Figura 13 – Interface do aplicativo: tela de login (a) e mapa com região de amostragem (b)	66
Figura 14 – Mecanismo interno do Agente de Predição	67
Figura 15 – Exemplo do histórico de contextos do modelo Tellus	68
Figura 16 – Dados de infravermelho próximo no formato <i>raw</i> (a) e tratados (b)	69
Figura 17 – Estação de telemetria para os históricos de contexto	70
Figura 18 – Registro fotográfico da lavoura de tabaco.	71
Figura 19 – Análise dos Históricos de Contextos por TensorFlow	72
Figura 20 – Alerta modo <i>PUSH</i> recebido pelo Tellus-Mobile (a) e sua localização (b)	73
Figura 21 – Modelo Aprendizado de Máquina - treinamento para matéria orgânica	74
Figura 22 – Modelo Aprendizado de Máquina - treinamento para argila	74
Figura 23 – Detalhe da ontologia AgroRDF/AgroXML	78
Figura 24 – Visão hierárquica que compreende as classes e relacionamentos da ontologia Tellus-Onto.	78
Figura 25 – Propriedades de dados da ontologia Tellus-Onto.	80
Figura 26 – Mecanismo interno do Tellus-Onto	82
Figura 27 – Lista de instâncias manualmente gerada para teste do Tellus-Onto.	86
Figura 28 – Resultado do processo de inferência da amostra de solo ID 195551/21 (s03-T)	87
Figura 29 – Laudo de análise de solo ID 195551/21 (s03-T)	87
Figura 30 – Explicação em linguagem lógica para inferência de uma dada concentração de matéria orgânica de nível baixo.	88
Figura 31 – Inferência para nível de OM - amostra S03T.	121
Figura 32 – Inferência para nível de CTC - amostra S03T.	121
Figura 33 – Inferência para nível de K - amostra S03T.	122
Figura 34 – Inferência para nível de P - amostra S03T.	122

Figura 35 – Inferência para categoria de solo - amostra S03T.	122
Figura 36 – Inferência para classe de argila - amostra S03T.	123
Figura 37 – Inferência para recomendação de N - amostra S03T.	123
Figura 38 – Inferência para recomendação de P - amostra S03T	123
Figura 39 – Inferência para recomendação de K - amostra S03T	124
Figura 40 – Inferência para recomendação de calagem - amostra S03T	124
Figura 41 – Algoritmo para classificação do solo – triângulo textural	125

LISTA DE TABELAS

Tabela 1 – Faixas de concentração de matéria orgânica e argila	31
Tabela 2 – Questões de pesquisa	40
Tabela 3 – Termos de pesquisa	40
Tabela 4 – Tecnologias que apoiam a agricultura de precisão	44
Tabela 5 – Aplicação da tecnologia na agricultura de precisão	55
Tabela 6 – Referência do número de publicações da Figura 9	56
Tabela 7 – Comparativo dos trabalhos relacionados	57
Tabela 8 – Artigos selecionados para atualização bibliográfica	57
Tabela 9 – Propriedade dos históricos de contextos do clima	70
Tabela 10 – Teste de diagnóstico para recomendação de irrigação por contextos	74
Tabela 11 – Comparativo dos trabalhos relacionados à ontologia	77
Tabela 12 – Métricas da ontologia Tellus-Onto	79
Tabela 13 – Regra SWRL para representar matéria orgânica de nível médio e argila de classe 3	81
Tabela 14 – Regra SWRL para representar a categoria de solo tipo Areia (<i>Sand</i>)	81
Tabela 15 – Regra SWRL para recomendar a quantidade de fósforo necessária (kg de P_2O_5 /ha)	81
Tabela 16 – Classificação textural dos solos no Brasil	83
Tabela 17 – Tipo de solo no Brasil conforme Instrução Normativa Federal.	83
Tabela 18 – Recomendação de Nitrogênio	84
Tabela 19 – Recomendação de Fósforo	84
Tabela 20 – Recomendação de Potássio	85
Tabela 21 – Recomendação de calagem	85

LISTA DE ABREVIATURAS

Ah	Ampère por hora
AI	Artificial intelligence
AP	Agricultura de Precisão
API	Application Programming Interface
atm.	atmosférica
CEC	Cation Exchange Capacity
CPU	Central Processing Unit
CTC	Capacidade de Troca de Cátions
DA	Data analytics
DL	Description Logic
GSM	Global System for Mobile Communications
GPU	Graphics Processing Unit
HCA	Hierarchical Clustering Analysis
hPa	Hecto Pascal
IR	Infrared
IoT	Internet of Things
MIR	Mid-infrared Spectroscopy
ML	Machine Learning
MLR	Multivariate Linear Regression
MO	Matéria Orgânica
NPK	Nitrogênio-Fósforo-Potássio
OM	Organic Matter
OWL	Ontology Web Language
NIR	Near Infrared Spectroscopy
PCA	Principal Component Analysis
PLS	Partial Least Squares
RDF	Resource Description Framework
RESTful	Representational State Transfer
SNV	Singular Normal Variate
SWRL	Semantic Web Rule Language
TAM	Standard for Technical Architecture Modeling
temp.	temperatura
TPU	Tensor Processing Unit

v. versão
Vis Região visível da luz
UV Ultra-violeta
WSN Wireless Sensor Network

LISTA DE SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
CAPES	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
FAPERGS	Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul
SBCS	Sociedade Brasileira de Ciência do Solo
SBCUP	Simpósio Brasileiro de Computação Ubíqua e Pervasiva
SBSI	Simpósio Brasileiro de Sistemas de Informação
UNISC	Universidade de Santa Cruz do Sul
USDA	Departamento de Agricultura dos Estados Unidos
WebMedia	Simpósio Brasileiro de Sistemas Multimídia e Web

LISTA DE SÍMBOLOS

CaCO_3 Carbonato de Cálcio

$^{\circ}\text{C}$ Graus Celsius

K Potássio

K_2O Óxido de Potássio

N Nitrogênio

P Fósforo

P_2O_5 Pentóxido de Fósforo

SUMÁRIO

1 INTRODUÇÃO	23
1.1 Definição do Problema e Questões de Pesquisa	24
1.2 Objetivos	24
1.2.1 Objetivo geral	24
1.2.2 Objetivos específicos	25
1.3 Etapas da pesquisa	25
1.4 Organização da tese	26
2 FUNDAMENTAÇÃO TEÓRICA	27
2.1 Agricultura de precisão	27
2.1.1 Análise se solos	28
2.1.2 Características químicas e físicas do solo	29
2.1.3 Matéria orgânica	29
2.1.4 Textura	30
2.1.5 Classificações do solo no Brasil	31
2.2 Aprendizado de Máquina	32
2.2.1 Regressões	33
2.2.2 Aprendizado Profundo	34
2.3 Computação Ubíqua	35
2.4 Contextos e históricos de contextos	35
2.5 Web Semântica	37
2.6 Ontologias	37
2.6.1 Motores de inferência	38
3 TRABALHOS RELACIONADOS	39
3.1 Metodologia	39
3.1.1 Definição das questões de pesquisa	39
3.1.2 Processo de pesquisa	40
3.1.3 Aplicação de filtros	41
3.1.4 Ameaças à validade da pesquisa	42
3.2 Análise e classificação	43
3.2.1 RQ1 – Quais tecnologias suportam a agricultura de precisão?	43
3.2.2 RQ2 – Onde essas tecnologias estão sendo aplicadas na agricultura de precisão?	45
3.2.3 RQ3 – Como a computação ubíqua está sendo usada para apoiar a agricultura de precisão?	45
3.2.4 RQ4 – Quais são os principais termos de pesquisa que expressam computação ubíqua e agricultura de precisão?	47
3.2.5 RQ5 - Qual é o número de publicações por banco de dados e ano?	48
3.3 Trabalhos selecionados e comparativos	49
3.3.1 Comparativos	50
3.4 Atualização bibliográfica	51
3.5 Considerações finais	54

4	MODELO TELLUS	59
4.1	Modelo conceitual	59
4.2	Arquitetura	60
4.3	Modelo de dados	62
4.4	Considerações finais	63
5	DESENVOLVIMENTO E ANÁLISE DOS RESULTADOS	65
5.1	Implementação do Tellus	65
5.1.1	Históricos de contextos químicos	66
5.1.2	Históricos de contextos climáticos	68
5.2	Avaliação e resultados do Tellus	71
5.3	Considerações finais	73
6	TELLUS-ONTO: UMA ONTOLOGIA PARA CLASSIFICAÇÃO E INFERÊNCIAS NA AGRICULTURA UBÍQUA DE SOLOS	75
6.1	Trabalhos relacionados às ontologias na agricultura de solos	75
6.2	Desenvolvimento da ontologia	77
6.3	Representação do domínio através do Tellus-Onto	77
6.4	Regras semânticas	79
6.5	Implementação da ontologia	81
6.6	Classificação do solo por inferência	83
6.7	Recomendação de adubação por inferência	83
6.8	Recomendação de calagem por inferência	84
6.9	Avaliação da ontologia	85
6.10	Considerações finais	86
7	CONCLUSÕES	89
7.1	Contribuições	90
7.2	Trabalhos futuros	90
7.3	Publicações	91
	REFERÊNCIAS	93
	ANEXO A – REGRAS SEMÂNTICAS - TELLUS-ONTO	105
	ANEXO B – EXPLICAÇÕES DA INFERÊNCIA PARA AMOSTRA S03T	121
	ANEXO C – ALGORITMOS	125
	ANEXO D – ARTIGOS PUBLICADOS	127

1 INTRODUÇÃO

A agricultura de precisão tem como principal objetivo aumentar a produtividade e permitir o uso racional de insumos, reduzindo assim, os impactos ambientais causados pelas práticas agrícolas. Com ela, os insumos podem ser utilizados de forma variável, visando atender as demandas específicas de cada localidade, otimizando o processo produtivo. Para isso, é necessário caracterizar a variabilidade dos atributos químicos e físicos do solo por meio de uma amostragem representativa (COSTA et al., 2014).

Os solos diferem ao longo do tempo em termos de concentrações de íons, com variações nos níveis de nutrientes, pH e condutividade elétrica. A composição química do solo depende do seu teor de água, da camada amostrada e do nutriente alvo. Assim, a amostragem em uma única vez não reflete suas variações na composição em diferentes estações climáticas. Ao longo do tempo, as variações na composição do solo ficam mais evidentes com teores elevados de matéria orgânica e textura em comparação aos solos com baixo teor de argila e carbono, já em solos ricos em textura argilosa, os reservatórios de nutrientes mineralizados são maiores, aumentando os teores de sal e íons no solo. Mudanças no pH dependem das características do solo estudado e este é um fator chave que regula a concentração de íons presentes (MIRANDA et al., 2006).

A análise de solos é a forma mais simples, econômica e eficiente de diagnosticar a sua fertilidade assim como servir de base para a recomendação de quantidades adequadas de corretivos e fertilizantes visando aumentar a produtividade das culturas e, como consequência, a produção e a lucratividade das lavouras (PHAM; WEINDORF; DANG, 2021).

Programas de controle de qualidade inter-laboratoriais como a Rede Oficial de Laboratórios de Análise de Solo e de Tecido Vegetal dos Estados do Rio Grande do Sul e de Santa Catarina (ROLAS) garantem o monitoramento dos erros de medição das análises de solos, além de sugerirem métodos de análises (GRIEBELER et al., 2016).

A computação ubíqua estuda o desenvolvimento de técnicas para integrar a tecnologia da informação no cotidiano das pessoas, de forma que elas sejam assistidas proativamente pela tecnologia enquanto executam suas atividades. Ela busca também novas formas de comunicação e interação que se distribuem no ambiente de forma perceptível ou imperceptível. Além disso, através do uso de sensores, os computadores podem detectar e extrair dados do ambiente, ajudando os usuários a realizarem suas tarefas (MAO et al., 2021).

Um aspecto fundamental para que essa visão se torne realidade é a possibilidade de desenvolver aplicações que sejam sensíveis ao contexto (PRADEEP; KRISHNAMOORTHY; VASILAKOS, 2021). Através do conhecimento de dados contextuais, uma aplicação pode ajustar seu próprio funcionamento ou até mesmo agir de forma proativa, alertando o usuário para um cenário específico ou auxiliando-o a desenvolver suas atividades com mais eficiência. As informações geradas permitem a construção de históricos de contextos para posterior tomada de decisão (HONG et al., 2009; CIARAMELLA et al., 2010; BARBOSA et al., 2016, 2018).

1.1 Definição do Problema e Questões de Pesquisa

Diversos procedimentos empregados para analisar o solo são onerosos, geram resíduos poluentes além de um enorme tempo de preparação das amostras. A análise de matéria orgânica e argila, que de uma forma geral representam a fertilidade do solo em questão, demandam 21 horas para determinação de seus valores. Além disso, geram resíduos extremamente danosos ao meio ambiente. Em contrapartida, técnicas modernas vêm sendo estudadas nos últimos anos para substituírem as técnicas oficiais. Dentre elas pode-se citar a espectroscopia molecular na região do infravermelho próximo (NIR) (MUÑOZ; KRAVCHENKO, 2011).

Outras determinações como pH, condutividade elétrica, temperatura e umidade do solo há muito tempo já podem ser realizadas a campo devido a existência de equipamentos e sensores portáteis. O pH do solo é um preditor de várias atividades químicas assim como uma ferramenta útil na tomada de decisões de gestão relativas ao tipo de plantas adequadas para uma região (CARMO et al., 2016). Assim como o pH, os laboratórios de análise realizam a medição de vários parâmetros no solo que, mais tarde, com auxílio de uma consultoria agrônômica, é sugerido a dosagem de insumos (MEDICI et al., 2021). Todo esse processo demanda tempo, desde a coleta da amostra até o manejo do solo com fertilizantes, adubos e corretos.

Informações sobre matéria orgânica e argila são fundamentais para determinar a fertilidade do solo e prever a adição de corretivos e fertilizantes, no entanto, os procedimentos analíticos atuais, além de morosos, resultam em quantidades expressivas de resíduos tóxicos.

Dessa forma, a presente tese aborda o desenvolvimento de um modelo computacional que utiliza o paradigma de computação ubíqua na agricultura para predição de propriedades do solo através de históricos de contextos. Assim, a presente tese busca responder a seguinte questão de pesquisa: Como seria um modelo computacional, considerando históricos de contextos de informações do solo, visando predição de propriedades físico-químicas na agricultura de precisão?

Após a definição da questão de pesquisa é defendida a seguinte hipótese: “É possível definir um modelo computacional na agricultura de precisão que faça uso de históricos de contextos de informações de solos e auxilie a otimização do uso de insumos agrícolas”.

1.2 Objetivos

O desenvolvimento da tese está pautada nos objetivos geral e específicos descritos nas seções a seguir.

1.2.1 Objetivo geral

De acordo com a questão de pesquisa e a hipótese levantada, o objetivo geral desta tese é a criação de um modelo computacional baseada em históricos de contextos, intitulado Tellus,

para predição da fertilidade do solo.

1.2.2 Objetivos específicos

Nesse sentido espera-se atingir os seguintes objetivos específicos:

- a) realizar um estudo sobre o estado da arte da computação ubíqua, históricos e predição de contextos e reconhecimento de padrões voltados para propriedades do solo na agricultura de precisão;
- b) identificar trabalhos que envolvam a aplicação da computação ubíqua na agricultura com o objetivo de conhecer tecnologias aplicadas e resultados obtidos;
- c) especificar um modelo computacional para agricultura ubíqua orientado a fertilidade do solo baseado em históricos de contextos;
- d) avaliar o modelo através do desenvolvimento de um protótipo que gere históricos de contextos;
- e) implementar uma ontologia para representar o conhecimento no domínio da agricultura ubíqua de solos;
- f) avaliar a ontologia através da verificação das inferências realizadas;
- g) tabular e analisar os resultados extraídos das avaliações e posteriormente descrever os resultados.

Vale a pena ressaltar que, uma vez gerado o modelo computacional, o mesmo foi validado fazendo-se uso de ferramentas estatísticas para comprovação de sua eficácia na predição dos resultados.

1.3 Etapas da pesquisa

A partir da definição do modelo computacional para agricultura ubíqua orientada a fertilidade do solo, da implementação de um protótipo e de sua aplicação em uma lavoura de tabaco no município de Vera Cruz, a fim de avaliar a efetividade do modelo, foi possível fazer uma avaliação para o teste da hipótese definida na Seção 1.1. Para isso, ocorreram as seguintes etapas como método de pesquisa:

- a) na primeira etapa foram realizados os estudos sobre os temas básicos da pesquisa: agricultura de precisão, solos, computação ubíqua e histórico de contextos;
- b) a segunda etapa envolveu a pesquisa por trabalhos relacionados à métodos de aprendizado de máquina e análise de solos;

- c) a terceira etapa envolveu a criação de um modelo que suporte predição de resultados de solo através do uso de conceitos computacionais;
- d) após a definição do modelo, a quarta etapa foi a implementação de um protótipo utilizado para o capturar dados químicos e físicos do solo e da lavoura;
- e) a partir do protótipo, a quinta etapa utilizou os conceitos de histórico de contextos para realizar predições, a partir de modelos de aprendizado de máquina, e inferências para classificar e recomendar adubação e calagem do solo através de uma ontologia;
- f) a sexta etapa consistiu na documentação dos resultados obtidos pela avaliação da aplicabilidade do modelo na agricultura de precisão.

1.4 Organização da tese

Esta tese é estruturada em seis capítulos, sendo que, no primeiro, encontra-se a introdução. Os demais capítulos são descritos a seguir:

- a) Capítulo 2: Fundamentação Teórica – trata dos conceitos utilizados neste trabalho. Neste capítulo, são descritos os conceitos referentes à agricultura de precisão. São apresentados ainda a visão de computação ubíqua, contextos, métodos ágeis e o modelo da teoria da atividade;
- b) Capítulo 3: Trabalhos Relacionados – inicialmente é apresentado um mapeamento sistemático realizado na área de gerenciamento de riscos para identificação de modelos que possuam relação com a tese, além de uma visão dos trabalhos selecionados e um comparativo entre estes;
- c) Capítulo 4: Modelo Tellus - contém a descrição do modelo, requisitos funcionais, requisitos não funcionais e arquitetura;
- d) Capítulo 5: Implementação e avaliação - apresenta o detalhamento do protótipo desenvolvido, a aplicação do estudo de caso para validar o modelo Tellus, com o objetivo de avaliar a assertividade das recomendações realizadas;
- e) Capítulo 6: Ontologia Tellus-Onto - demonstra o processo de representação do conhecimento visando a classificação de solos, recomendação de adubação e calagem e as abordagens para avaliar o modelo;
- f) Capítulo 7: Considerações finais – contém as considerações finais da tese, as contribuições, respondendo as questões de pesquisas com a validação das hipóteses elaboradas.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo sistematiza os principais conceitos utilizados para desenvolvimento do modelo apresentado nesta tese, intitulado Tellus. Inicialmente são apresentados os conceitos referentes a agricultura de precisão, as características dos solos e análises, para contextualização da proposta. Em seguida é apresentado o estado da arte sobre a computação ubíqua e suas abordagens através de modelos computacionais que relacionam contexto e históricos de contextos.

2.1 Agricultura de precisão

A utilização da Agricultura de Precisão (AP) vem crescendo exponencialmente e fortalecendo ainda mais o agronegócio. A falta de difusão de seu conhecimento, como dos fundamentos da técnica, é mais importante para a sua implantação do que propriamente máquinas e equipamentos caros. Sendo assim, o principal fator limitante não são os custos com maquinários modernos e sofisticados que, de fato, facilitam a implantação da AP na lavoura. O principal fundamento da AP é o cruzamento de informações, ou seja, o confronto das propriedades do solo, por grades georreferenciadas versus o mapa de produtividade da mesma área, possibilitando assim, a identificação da necessidade de correção do solo em cada ponto, uniformizando a produção da lavoura (BERNARDI et al., 2014).


O conceito básico da AP é a gestão da área de cultivo baseada no monitoramento da produtividade de pontos, apoiada na análise do solo dos mesmos, para correção e aplicação de fertilizante de acordo com a necessidade identificada visando a uniformização da produção. Com isso, além dos ganhos econômicos gerados pelo aumento da produtividade e uso racional de fertilizantes, a disponibilização de nutrientes conforme a necessidade das plantas aumenta a eficiência ecológica evitando desperdícios de fertilizantes que causam acidez e salinização do solo, comprometendo também a qualidade da água subterrânea e a eutrofização de lagos e rios pela lixiviação (HOCHMAN et al., 2013).

A análise do solo é um dos primeiros passos para a implantação da AP, contudo, não perde sua importância na agricultura convencional, sendo fundamental em qualquer tipo de sistema de produção agrícola. Entretanto, na AP as análises do solo são feitas em quantidades significativamente maiores, devido a necessidade de dados mais precisos para montar uma grade georreferenciada. Portanto, a tendência é de aumento da demanda por análises de solo seguindo o viés de crescimento dessa prática (COSTA et al., 2014).

A Central Analítica, situada na Universidade de Santa Cruz do Sul¹, um dos principais laboratórios de análises do sul do país, analisou em 2021 mais de 200 mil amostras de solo de diferentes regiões agrícolas do país. Nos últimos 10 anos houve uma demanda crescente de 830%, como pode ser observado na Figura 1, que apresenta a evolução do número de análise de solos nos últimos 16 anos.

¹<https://www.unisc.br/pt/central-analitica/quem-somos>

Figura 1 – Quantidade de amostras analisadas pela Central Analítica (UNISC) entre os anos de 2009 e 2021



Fonte: Central Analítica - UNISC, pelo autor.

2.1.1 Análise se solos

Considerando a importância do serviço de análise de solos nesta cadeia produtiva, é fundamental que os laboratórios consigam atender esta demanda, com qualidade e rapidez, de forma que a informação produzida possa ser utilizada de imediato pelo produtor, e que estes resultados representem corretamente a situação atual da área em estudo. Assim, cabe aos laboratórios acompanharem esta evolução, aprimorando continuamente as metodologias analíticas utilizadas (GRIEBELER et al., 2016).

Apesar disto, nas determinações de argila e matéria orgânica, dois parâmetros essenciais para o diagnóstico de fertilidade do solo, ainda são utilizadas metodologias antigas. Estas dependem muito tempo de análise, apresentam elevado consumo de reagentes, mão de obra e energia, liberando quantidades expressivas de resíduos químicos perigosos e, de oneroso tratamento (GIÁCOMO et al., 2015).

Atualmente, a utilização de equipamentos como espectrômetro óptico de emissão atômica com plasma indutivamente acoplado (ICP-OES) permite a determinação simultânea de macro e micronutrientes, tais como fósforo, potássio, sódio, cálcio, magnésio, enxofre, cobre, ferro, manganês, zinco, boro e molibdênio (TEDESCO et al., 1995).

O método empregado para determinação de MO, oxidação por via úmida, utiliza solução de dicromato de potássio com ácido sulfúrico concentrado, gerando, ao final, 25 mL de resíduos perigosos Classe 1, de acordo com ABNT (2004). Em relação a metodologia para determinação de argila, é empregado o método da densidade, o qual usa solução hidróxido de sódio que, ape-

sar de não ser uma solução de descarte complexo, o tempo desta análise é de aproximadamente 14 horas que, somadas as 20 horas necessárias para a análise MO, geram custos ao processo analítico (TEDESCO et al., 1995; TEIXEIRA et al., 2017).

2.1.2 Características químicas e físicas do solo

O solo é o suporte à vida humana no planeta, pois é dele que provêm os alimentos, indispensáveis à população. O solo, como matriz complexa, difere ao longo do tempo em termos de concentrações de íons na sua composição, com variações nos níveis de nutrientes, pH e condutividade elétrica sendo que sua constituição química depende do teor de água, da camada de solo amostrada e do nutriente alvo (MIRANDA et al., 2006). Assim, amostrar o solo apenas uma vez não reflete suas variações na composição ao longo de diferentes estações climáticas.

O estudo para o conhecimento das características do solo, em relação a sua composição para entender e otimizar o potencial produtivo, é um fator importante no aspecto sustentável, crucial para a sociedade. Para isso, bancos de dados globais vêm sendo criados para a compreensão das características do solo e, a espectroscopia no infravermelho próximo (NIR) desponta como uma ferramenta facilitadora para a obtenção destes dados (ROSSEL et al., 2016).

Dentre as características também relevantes, a cor é um aspecto importante, principalmente, em relação à avaliação do uso do solo para o cultivo, pois tons escuros são indicadores da presença de matéria orgânica apontando o local com propício para a implantação de lavouras (KETTERINGS; BIGHAM, 2000). Já a granulometria do solo está relacionada às porcentagens das partículas primárias (areia, silte e argila), distribuídas em diferentes tamanhos definidos por diâmetros específicos (KLEIN, 2014).

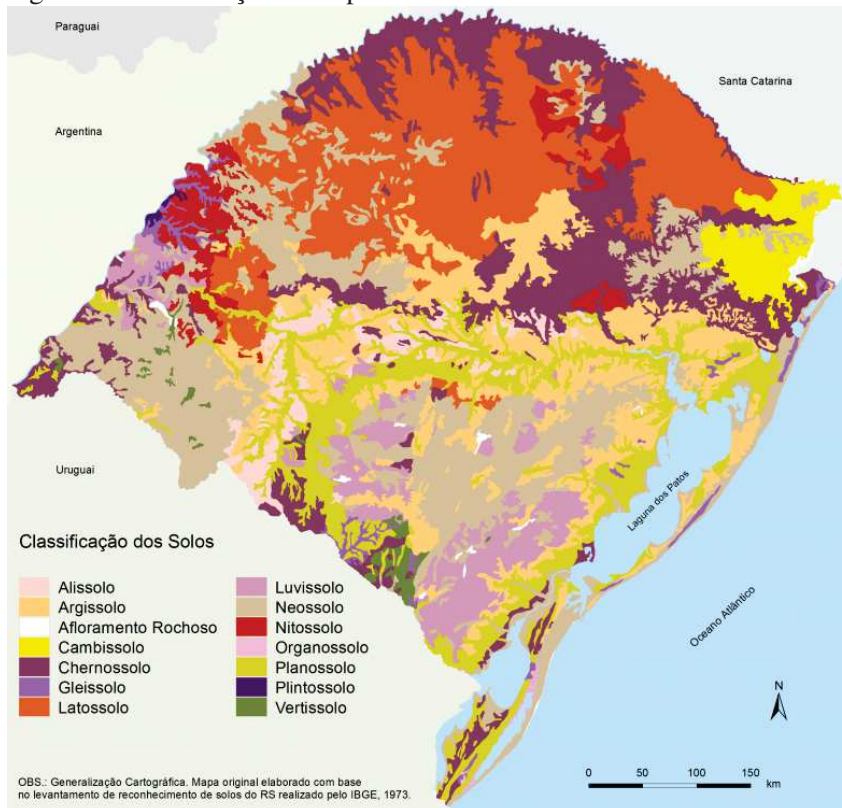
Os mapas de solos são gerados a partir de um perfil pedológico e caracterizam de forma específica uma determinada área. Tal conhecimento é fundamental para o planejamento ou desenvolvimento de um projeto em qualquer atividade na agricultura. O estado do Rio Grande do Sul apresenta uma grande diversidade nas classes de solos conforme pode ser observado na Figura 2. Nele foram identificados 14 tipos diferentes de solos o que demonstra uma complexidade para sistemas de recomendação de adubação e calagem visto a distribuição de propriedades físico-químicas encontradas (STRECK et al., 2008).

2.1.3 Matéria orgânica

A presença da matéria orgânica (MO) ou carbono orgânico no solo tem um papel imprescindível, não só para o cultivo agrícola, indispensável à alimentação humana, mas também na regulação do clima planeta. Portanto, a MO, desempenha um papel-chave nas funções do solo como o acúmulo de biomassa; filtragem e armazenamento de água; reciclagem de nutrientes e habitat para atividade biológica (WIESMEIER et al., 2019).

Além da MO, argila e sílica são compostos importantes na composição do solo, destinado a

Figura 2 – Distribuição dos tipos de solo no estado do Rio Grande do Sul



Fonte: Emater/DIT - UFRGS/Dept. Solos (STRECK et al., 2008).

agricultura, entretanto, estudos mostram que não há uma correlação direta entre a fração destes dois compostos e a quantidade de MO presente no solo. Temperatura, precipitação e teor de Fe também não serviram de parâmetro para correlacionar com o valor de MO (SAMUEL-ROSA et al., 2013).

2.1.4 Textura

A textura do solo é dividida em classes determinadas pela combinação de três componentes, a porcentagem de areia, silte e argila do solo (COSBY et al., 1984). As partículas minerais do solo apresentam propriedades e comportamentos bastante distintos. A areia permite maior permeabilidade à água e ao ar no solo, retendo menos água por ser menos coesiva, tendo ausência de cargas elétricas. As partículas de areia são maiores do que as de silte e argila. Partículas de silte, por sua vez, possuem poros menores e mais numerosos, retendo mais água e, se comparado à areia, tem menor taxa de drenagem por apresentar maior área superficial específica, e assim menor macroporosidade e maior microporosidade. A argila, em função do reduzido diâmetro, apresenta grande área superficial específica, com grande presença de cargas elétricas, o que acarreta elevada retenção de água (BRADY; WEIL, 2013).

A argila é definida como o material que ocorre naturalmente composto principalmente por minerais de grãos finos de rochas, que é geralmente plástico contendo certo teor de água e

endurecerá quando seco ou queimado. Embora a argila, geralmente seja a base de filossilicatos, que conferem plasticidade, pois significam “sílica em folhas”, as fases associadas na argila podem incluir materiais que não conferem plasticidade, além de matéria orgânica. Desta forma, qualquer mineral não filossilicato que confere plasticidade a uma argila e endurece ao secar ou queimar, esse mineral é um "mineral argiloso"(GUGGENHEIM; MARTIN, 1995).

Estudos recentes sugerem que as argilas também podem ser definidas de acordo com critérios de plasticidade baseados na correlação do Índice de Plasticidade com o Limite de Liquidez (PI/LL) sendo a tenacidade, a propriedade que melhor descreve a capacidade de deformação da argila. A relação dos parâmetros de plasticidade e tenacidade permitiu a detecção de importantes deficiências nos dois sistemas de classificação de solos mais difundidos, o gráfico de Casagrande e o triângulo do USDA, de modo que abordagens alternativas poderiam ser úteis em vários campos de pesquisa (MORENO-MAROTO; ALONSO-AZCÁRATE, 2018).

2.1.5 Classificações do solo no Brasil

A Sociedade Brasileira de Ciência do Solo (SBCS) define os teores de matéria orgânica em três níveis (baixo, médio e alto) e argila em quatro classes, conforme mostra a Tabela 1.

Tabela 1 – Faixas de concentração de matéria orgânica e argila

Matéria orgânica		Argila	
Faixa (%)	Interpretação	Faixa (%)	Classe
≤2.5	baixo	≤20	1
2.6 - 5.0	médio	21 - 40	2
>5.0	alto	41-60	3
		>60	4


Fonte: Santos et al. (2005)

Silva e Tadra (SILVA; TADRA, 2017) ressaltam que a combinação de areia, silte e argila em diferentes quantidades é o que define as classes texturais dos solos. A SBCS adota no Brasil 13 categorias diferentes de textura do solo: muito argiloso (*heavy clay*), argila (*clay*), argila arenosa (*sandy clay*), argila siltosa (*silty clay*), franco-argilo arenoso (*sandy clay loam*), franco argiloso (*clay loam*), franco argilo siltoso (*silty clay loam*), franco arenoso (*sandy loam*), franco (*loam*), franco siltoso (*silt loam*), areia (*sand*), areia franca (*loamy sand*) e silte (*silt*). Todos esses tipos podem ser ilustradas no Triângulo Textural da Figura 3 (SANTOS et al., 2005).

Já a Secretaria de Política Agrícola do Ministério da Agricultura, Pecuária e Abastecimento possui uma Instrução Normativa que define a Classificação do Tipo de Solo no Brasil. Ela adota, no Zoneamento Agrícola de Risco Climático, as seguintes especificações para os solos:

- Solos Tipo 1: Solos de textura arenosa, com teor mínimo de 10% de argila e menor do que 15% ou com teor de argila igual ou maior do que 15%, nos quais a diferença entre o percentual de areia e o percentual de argila seja maior ou igual a 50%.

Figura 3 – Triângulo de classificação textural dos solos no Brasil



Fonte: Santos et al. (2005)

- Solos Tipo 2: Solos de textura média, com teor mínimo de 15% de argila e menor do que 35%, nos quais diferença entre o percentual de areia e o percentual de argila seja menor do que 50.
- Solos Tipo 3: solos de textura argilosa, com teor de argila maior ou igual a 35%.

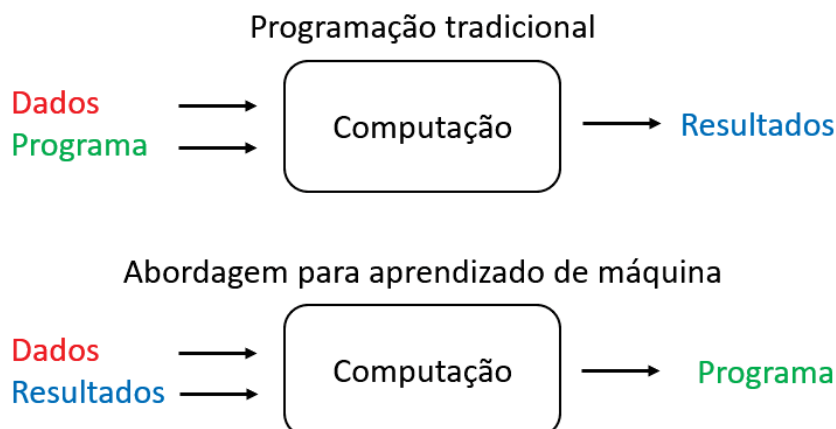
2.2 Aprendizado de Máquina

O aprendizado de máquina é uma abordagem que consiste em algoritmos matemáticos que permitem que os computadores tomem decisões sem serem explicitamente executados. Seus algoritmos aprendem com os dados e, com base nos *insights* do conjunto de dados, tomam decisões sem intervenção humana (MESHRAM et al., 2021).

A Figura 4 faz uma comparação entre a programação tradicional e o aprendizado de máquina. Enquanto que no primeiro obtém-se resultados, no segundo a saída do processo de computação consiste em um programa, também chamado de modelo.

A maioria dos modelos de aprendizado de máquina são baseados em algoritmos estatísticos. É um processo empírico onde é necessário experimentar e testar vários modelos com várias combinações de parâmetros e conjuntos de dados. Além disso, o grande número de modelos de aprendizado de máquina, abordagens de pré-processamento e critérios de avaliação e seleção de

Figura 4 – Paradigmas da programação tradicional e Aprendizado de Máquina



Fonte: Elaborado pelo autor.

modelos tornam essa técnica abrangente à diversas áreas do conhecimento (ALPAYDIN, 2016).

Quimiometria é a disciplina da química que faz uso do aprendizado de máquina para projetar ou selecionar procedimentos e experiências de medição ideais, além de fornecer o máximo de informações químicas por meio da análise de dados químicos (KOWALSKI, 1975).

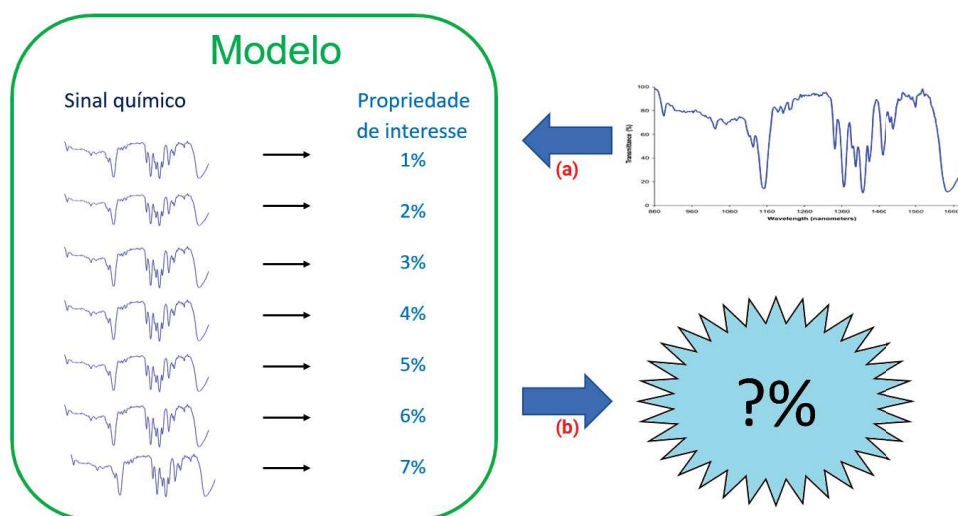
Ela permite relacionar as medidas realizadas em um método analítico (espectroscopia molecular, por exemplo), obtendo informações através da aplicação de métodos matemáticos e estatísticos, permitindo a manipulação de grandes quantidades de dados. Ela pode ser dividida em três áreas principais: planejamento e otimização de experimentos, reconhecimento de padrões e calibração multivariada. Nesse sentido, várias ferramentas de aprendizado de máquina são aplicadas na quimiometria para calibração multivariada. Esses algoritmos eliminam variáveis que não se correlacionam com a propriedade de interesse, como aquelas que adicionam ruído, não-linearidades ou informações irrelevantes (WISE; KOWALSKI, 1995; FERREIRA, 2015).

A Figura 5 ilustra uma técnica de regressão utilizando aprendizado de máquina nas etapas de aprendizagem, ou calibração, e teste, ou predição, onde um conjunto de sinais químicos (vetores) formam uma matriz correlacionada com uma propriedade de interesse (concentração da amostra). A entrada de um sinal amostral (a) tem como saída uma concentração estimada (b).

2.2.1 Regressões

Uma vez selecionadas as variáveis, métodos como Mínimos Quadrados Parciais (*Partial Least Squares* ou PLS) e Regressão Linear Múltipla (*Multiple Linear Regression* ou MLP) geralmente são aplicados, principalmente em situações onde variáveis de processo apresentam elevados níveis de correlação, ruído, observações faltantes e desbalanço na proporção de va-

Figura 5 – Fases de aprendizagem e predição na quimiometria



Fonte: Elaborado pelo autor.

riáveis e observações (ANZANELLO, 2013). Na regressão é gerada um reduzido número de combinações lineares independentes das variáveis de processo. Essas novas variáveis, chamadas de componentes, respondem pela maior parte da variância presente nas variáveis originais do processo. Normalmente, apenas três ou quatro componentes são retidos para representar dezenas ou mesmo centenas de variáveis de processo (LI et al., 2021).

Na literatura, diferentes aplicações utilizando regressões associadas à quimiometria são descritas com sucesso, seja, por exemplo, para amostras de petróleo e derivados (BARRA et al., 2020; HRADECKÁ et al., 2021), óleos vegetais e biocombustíveis (LIU et al., 2020) ou madeira e celulose (LI; VIA; LI, 2020).

2.2.2 Aprendizado Profundo

Uma das famílias mais promissoras de algoritmos de aprendizado de máquina são as abordagens de aprendizado profundo, sendo as Redes Neurais Convolucionais (*Convolutional Neural Network* ou CNN) um de seus representantes mais proeminentes. Elas são projetadas para processar dados por meio de várias camadas de matrizes e aplicada na análise de dados bi e tridimensionais, incluindo reconhecimento de imagem (SZEGEDY et al., 2015; HE et al., 2016) e análise de vídeo (KARPATHY et al., 2014). A abordagem CNN aproveita as conexões esparsas locais para estudar padrões locais a partir dos dados brutos e reduzir o risco de *overfitting* adotando um compartilhamento de peso (ZHANG et al., 2019; TSAKIRIDIS et al., 2020).

O TensorFlow é uma plataforma de aprendizado profundo de código aberto para desenvolver modelos a partir de dados de treinamento em um curto espaço de tempo usando recursos de computação heterogêneos como CPU's, GPU's e TPU's. Todas as operações são realizadas

com base em objetos tensores. Esses algoritmos de redes neurais são essencialmente uma combinação de operações básicas, como multiplicação e adição de tensores (ABADI et al., 2015).

O TensorFlow recebeu ampla aceitação entre a comunidade de aprendizado de máquina em um curto espaço de tempo devido à sua facilidade de uso, interface Python e capacidade de implantar modelos em navegadores da Web e dispositivos móveis. Embora o TensorFlow seja usado principalmente para aprendizado de máquina, ele também pode ser usado para desenvolver tarefas não ML que exigem computação numérica usando gráficos de fluxo de dados (JANARDHANAN, 2020).

2.3 Computação Ubíqua

O conceito de Computação Ubíqua foi apresentado pela primeira vez por Mark Weiser em seu clássico artigo 'The Computer for the 21th century' (WEISER, 1999). Para ele, as tecnologias que causariam mais impacto na vida das pessoas seriam aquelas imperceptíveis ao cotidiano, utilizadas de forma inconsciente. Embora não seja especificamente destacado por Weiser, a necessidade desses computadores para entender o contexto é claramente evidente.

Para Satyanarayanan (2001) a Computação Ubíqua é um evolução Computação Distribuída a partir de uma linha de pesquisa iniciada na década de 1970. Desde aquela época, observavam-se questões como segurança, alta disponibilidade, processamento remoto e tolerância a falhas. Logo, com a evolução da computação móvel, a visão de Weiser sobre uma tecnologia invisível, totalmente integrada ao cotidiano e disponível a todo momento em qualquer lugar, começa a se tornar realidade.

Weiser e Satyanarayanan convergem que Computação Ubíqua trata da construção de sistemas computacionais que conseguem se adaptar ao estilo de vida de seus usuários, podendo de forma pró-ativa, tomar decisões em prol do usuário em suas atividades.

Geralmente ela envolve comunicação sem fio e tecnologias de rede, dispositivos móveis, sistemas embarcados, computadores vestíveis, tags de identificação de radiofrequência, *middleware* e agentes de software. Recursos de Internet, reconhecimento de voz e inteligência artificial também são frequentemente incluídos. Os setores que mais investem em pesquisa e desenvolvimento para Computação Ubíqua agricultura, energia, entretenimento, saúde, logística e defesa (SHARMA et al., 2020; ZAHOOR; MIR, 2021).

2.4 Contextos e históricos de contextos

Segundo Abowd et al.(ABOWD et al., 1999), contexto é qualquer informação que possa ser utilizada para caracterizar a situação de uma entidade, seja ela um objeto, lugar ou pessoa, relevante para a interação entre um usuário e uma aplicação .

A computação sensível ao contexto foi descrita por Dey et al. (2001) como a área que estuda os mecanismos para fornecimento e utilização de informações de contexto a fim de

oferecer serviços e informações relevantes aos usuários e outras aplicações (DEY; ABOWD; SALBER, 2001). O termo sensível ao contexto foi utilizado pela primeira vez por Schilit e Theimer (SCHILIT; THEIMER, 1994), entretanto, as definições de contexto e sensibilidade ao contexto que são amplamente aceitas pela comunidade científica foram propostas por Abowd et al. (ABOWD et al., 1999).

Um sistema é sensível ao contexto quando está ciente do contexto atual do usuário e, em consequência, reage de forma proativa para fornecer informações ou serviços relevantes para o usuário. As informações de contexto, em geral, tendem a serem submetidas a um ciclo de vida de contexto, que consiste nas etapas de aquisição, modelagem, raciocínio e disseminação (PERERA et al., 2014):

- Aquisição: onde as informações de contexto são obtidas diretamente dos provedores de contexto.
- Modelagem: os dados coletados são representados por meio de técnicas de modelagem de contexto, as quais agregam semântica ao contexto.
- Raciocínio: são executadas técnicas de inferência de contexto com o objetivo de derivar contexto de mais alto nível em relação ao contexto entregue na etapa de modelagem.
- Disseminação: onde o ciclo de vida de contexto é encerrado e as informações geradas nas etapas de modelagem e raciocínio podem ser entregues para os consumidores.

Os registros históricos de uma entidade também podem ser observados numa aplicação sensível ao contexto. Os históricos de contextos são reconhecidos simplesmente como uma coleção de contextos passados. Uma vez utilizado, serviços inteligentes personalizados podem ser fornecidos aos usuários pela extração de padrões nele contidos. Logo, os históricos de contextos tem sido utilizado para a previsão de contexto futuro, como preferências, delineamento de perfis e hábitos de usuários (HONG et al., 2009).

Alguns autores como Barbosa et al. (2018) definiram o termo "históricos de contextos" como trilhas. Nela, registros do percurso dos inúmeros contextos formavam uma coleção de lugares frequentados com informações de contexto seguindo uma ordem cronológica.

Na literatura podem ser encontradas aplicações de históricos de contextos na saúde (VI-ANNA; BARBOSA, 2019; ARANDA et al., 2021; MACHADO et al., 2021), no gerenciamento de projetos (FILIPPETTO; LIMA; BARBOSA, 2021; LIMA et al., 2022), na educação (SILVA et al., 2021; FERREIRA et al., 2020), segurança (VIEGAS et al., 2021), entre outros. Informações geradas por essas aplicações permitem a criação de uma base histórica para posterior tomada de decisão (ROSA et al., 2015; MARTINI et al., 2021; WIEDEMANN et al., 2020).

2.5 Web Semântica

A Web Semântica é uma extensão da *web* através de padrões estabelecidos pelo World Wide Web Consortium (W3C). O objetivo da Web Semântica é tornar os dados da Internet legíveis pelas máquinas (BIKAKIS et al., 2013). Assim, para possibilitar a codificação das semânticas com os dados, são utilizadas tecnologias como Resource Description Framework (RDF) (BECKETT, 2004) e Web Ontology Language (OWL) (MCGUINNESS; HARMELEN, 2004). Essas tecnologias conseguem representar formalmente os metadados e oferecer vantagens significativas, como raciocínio sobre dados e operação com fontes de dados heterogêneas, permitindo descrever conceitos, relacionamentos entre entidades e categorias de coisas (CHUNG et al., 2018).

O RDF é um padrão do W3C originalmente projetado como um modelo de dados para metadados. Ele passou a ser usado como um método geral para descrição e troca de dados de gráficos. RDF fornece uma variedade de notações de sintaxe e formatos de serialização de dados, atualmente sendo a notação mais usada. O SPARQL é uma linguagem de consulta padrão para gráficos RDF (IDRISSI et al., 2021).

A OWL é uma linguagem da Web Semântica projetada para representar conhecimento rico e complexo sobre coisas, grupos de coisas e relações entre coisas. OWL é uma linguagem computacional baseada em lógica tal que o conhecimento expresso em OWL pode ser explorado por programas de computador, por exemplo, para verificar a consistência desse conhecimento ou tornar o conhecimento implícito explícito. Os documentos OWL, conhecidos como ontologias, podem ser publicados na World Wide Web e podem referir-se ou ser referidos a partir de outras ontologias OWL. A versão atual é conhecida como “OWL2” (GRAU et al., 2008).

2.6 Ontologias

Ontologia pode ser entendida como um artefato de software fornecendo um vocabulário geral sobre determinado domínio para representação do conhecimento nele contido, dotando os sistemas de inteligência e autonomia (CHUNG et al., 2018). Gruber (1993) definiu como uma especificação formal, explícita e compartilhada de uma conceitualização, pois a mesma descreve formalmente um domínio de conhecimento, ou seja, algo que é legível para os computadores (BORST, 1997). Ela explicita os conceitos, propriedades, relações, funções, restrições e axiomas definidos, além de ter a capacidade de representar um modelo abstrato de algum fenômeno do mundo real e compartilhar conhecimento (GRUBER, 1993).

Gruber (1993) e Borst (1997) afirmam também que o principal propósito da construção de ontologias é permitir compartilhamento e reutilização de conhecimento. Entretanto, o mais importante não é o vocabulário relacionado a uma área de interesse, mas sim as conceitualizações. Noy e McGuinness (2001) apresentaram cinco razões para o desenvolvimento de uma ontologia: permitir a reutilização do conhecimento do domínio, tornar explícitas os conceitos

de domínio, separar o conhecimento do domínio do conhecimento operacional, partilhar uma compreensão comum da estrutura da informação entre pessoas ou agentes de software e analisar o conhecimento do domínio.

Gruber (1993) sugere que as ontologias visem compartilhar o conhecimento e promover a interoperabilidade entre sistemas, de forma clara e objetiva, coerente em relação às inferências geradas e ao seu domínio, extensível quanto a sua projeção e representação.

Kotis, Vouros e Spiliotopoulos (2020) apresentaram recomendações para suportar ontologias, entre elas destacam-se a participação ativa de todos os envolvidos durante o ciclo de vida da ontologia, apoiando a colaboração, a evolução e sua reutilização. Além disso, reutilize recursos semânticos já pré-estabelecidos no domínio do conhecimento, promovendo o reuso. Os autores sugerem também que o objetivo e o escopo da ontologia seja cuidadosamente especificadas nos estágios iniciais do seu desenvolvimento, para que se torne flexível e impeça uma exploração limitada dentro de uma comunidade restrita.

As ontologias são utilizadas principalmente nas áreas relacionadas a recuperação de informação na internet e demais áreas do conhecimento como agricultura (MARTINI et al., 2021; HELFER et al., 2021a), gerenciamento de projetos (FILIPPETTO et al., 2016), saúde (LARENTIS et al., 2021), educação (VALMORBIDA et al., 2015), bem-estar social (DAMASCENO VI-ANNA et al., 2016), entre outros.

2.6.1 Motores de inferência

Um motor de inferência semântica, também chamado de *reasoner* ou raciocinador, é um software capaz de inferir consequências lógicas de um conjunto de fatos ou axiomas afirmados. As regras de inferência são comumente especificadas por meio de uma linguagem de ontologia (SWRL) e, muitas vezes, uma linguagem de lógica de descrição (DL). Muitos *reasoners* usam lógica de predicados de primeira ordem para realizar o raciocínio; a inferência geralmente procede por encadeamento para frente e encadeamento para trás. Há também exemplos de raciocinadores probabilísticos (GRAU et al., 2008; FARIAS; ROXIN; NICOLLE, 2016).

Os motores de inferência, desempenham um papel importante no desenvolvimento e uso de uma ontologia. Além de verificarem inconsistências, motores como Pellet, FaCT++ e HerMiT oferecem um conjunto de operações sobre os axiomas de uma ontologia, logo permitem realizar fatos ou associações a partir de um conhecimento previamente representado (SIRIN et al., 2007; CLASSIFICATION, 2010).

3 TRABALHOS RELACIONADOS

Esta tese usa a metodologia de revisão sistemática desenvolvida por Petersen et al. em 2008 e 2015 (PETERSEN et al., 2008; PETERSEN; VAKKALANKA; KUZNIARZ, 2015) para conduzir uma revisão sobre a aplicação da computação ubíqua na agricultura focada em análise de solos. Neste tema, guiado pela busca e processamento em duas fases, esta seção se concentra em descobrir os principais autores da área assim como os trabalhos mais relevantes. Esse tipo de metodologia não apenas discute a conclusão, mas também examina todas as atividades relacionadas à descoberta, além das possíveis lacunas de pesquisa e seus desafios. Assim, um estudo sistemático coleta dados quando a atividade ocorre e a mídia na qual foi publicada, e então mapeia essa conexão (COOPER, 2016).

O conteúdo desse capítulo foi publicado no periódico "Agris on-line" em dezembro de 2019 (HELPER et al., 2019a). Logo a busca por artigos concentrou-se num período de até 10 anos antecedentes, ou seja, desde 2009. As primeiras seções exaltam os mecanismos realizados para a revisão bibliográfica e a última seção destina-se a realizar uma atualização até o corrente ano (2022).

3.1 Metodologia

A metodologia aplicada consistiu na execução das seguintes etapas:

- a) definição das questões de pesquisa;
- b) definição do processo de pesquisa;
- c) definição dos critérios de seleção e extração dos documentos;
- d) análise e classificação dos documentos.

3.1.1 Definição das questões de pesquisa

As questões de pesquisa levaram este estudo a descobrir trabalhos relacionados ao tema. O objetivo dessas perguntas é entender como tecnologias onipresentes estão sendo usadas para ajudar na agricultura de precisão. Também é desejável descobrir como tecnologias específicas são aplicadas entre a agricultura e a sensibilidade ao contexto. Finalmente, grupos de termos comumente usados em artigos selecionados foram gerados para apoiar a identificação de tendências de interesse de pesquisa acadêmica. Portanto, cinco questões foram estabelecidas e apresentadas na Tabela 2.

Tabela 2 – Questões de pesquisa

Código	Questão
RQ1	Quais tecnologias apoiam a agricultura de precisão?
RQ2	Onde essas tecnologias estão sendo aplicadas na agricultura de precisão?
RQ3	Como a computação ubíqua está sendo usada para apoiar a agricultura de precisão?
RQ4	Quais são os principais núcleos de pesquisa que expressam os termos computação ubíqua e agricultura de precisão?
RQ5	Qual é o número de publicações por base de dados e por ano?

Fonte: Elaborado pelo autor.

3.1.2 Processo de pesquisa

Petersen et al. definiram três etapas de um processo de pesquisa: especificar a *string* de pesquisa, escolher as bases de dados para aplicá-las e obter os resultados. A primeira etapa começa identificando as palavras-chave e seus termos relacionados. Neste estudo, escolhemos as palavras-chave "*Ubiquitous*" e "*Agriculture*" e também outros termos relacionados, conforme indicado na Tabela 3.

Tabela 3 – Termos de pesquisa

Palavras-chave	Termos relacionados
Ubiquitous	Context-aware OR Context-sensitive OR Context awareness OR Pervasive OR Internet-of-things OR IoT
Agriculture	Agronomy OR Soil

Fonte: Elaborado pelo autor.

Esses termos geraram a seguinte *string* de pesquisa a ser usada nos bancos de dados de pesquisa: *((ubiquitous OR context-aware OR context-sensitive OR context awareness OR pervasive OR internet-of-things OR iot) AND (agriculture OR agronomy OR soil))*.

O termo “*soil*” foi inserido na *string* de busca porque o termo “*agriculture*” abrange outras subáreas de aplicação, como aquapônica, permacultura, agricultura de interior, orgânica, subsistência, entre outras. Isso possibilitou a este estudo filtrar apenas os trabalhos relacionados à agricultura intensiva aplicada ao solo; ou seja, que possuam alta produtividade, grandes extensões de terras e o uso de modernas técnicas e mecanizações.

Uma vez definida a *string* de pesquisa, foram construídos parâmetros de pesquisa a serem usados nas bases de dados. Na segunda etapa, foram selecionados oito bancos de dados de pesquisa relevantes para a área de computação, incluindo ACM Digital Library, Semantic Scholar (CiteSeerX), Google Scholar, IEEE Xplore Digital Library, Scopus, Science Direct, Springer e Wiley Library.

A pesquisa na Biblioteca Digital ACM exigiu o uso de recursos de pesquisa avançada, onde cada uma das *strings* foram inseridas na ferramenta “Editar Consulta”. Da mesma forma, essa prática foi aplicada nas bases de dados Semantic Scholar (CiteSeerX), Google Scholar, IEEE

Xplore e Scopus. Apenas nas bases do Science Direct e do Google Scholar a *string* foi aplicada em uma caixa de busca simples que está disponível na página principal desses sites.

3.1.3 Aplicação de filtros

Para filtrar os trabalhos mais relevantes, geramos os seguintes Critérios de Inclusão (IC) para esta seleção:

- IC1: O estudo deve ser publicado em processo de congresso ou periódico.
- IC2: O estudo deve estar relacionado ao contexto de uso da computação ubíqua na agricultura de solos.
- IC3: O estudo deve ser um artigo completo.

Por sua vez, os Critérios de Exclusão (EC) também foram definidos, conforme segue:

- EC1: Estudos publicados antes de 2009.
- EC2: Estudos que não estão escritos em inglês.
- EC3: Estudos relacionados a teses ou dissertações.
- EC4: Estudos não relacionados a questões de pesquisa.

Os critérios de inclusão e exclusão auxiliaram no processo de filtragem a obtenção dos estudos mais relevantes e a eliminação de ruídos gerados durante a busca. Os estudos obtidos no processo de busca foram filtrados, sendo retirados os que não se enquadraram nos critérios de inclusão. Os artigos foram armazenados no programa Mendeley Desktop© e organizados em pastas específicas para cada banco de dados. O próximo passo foi analisar as obras por título e resumo, para que posteriormente pudessem ser combinadas na mesma pasta. Seis artigos foram adicionados por heurística por serem relevantes para este estudo, embora não tenham sido encontrados durante o processo de busca.

O próximo filtro foi baseado nas duas primeiras passagens da abordagem de três passagens introduzida por Srinivasan Keshav (KESHAV, 2007). A primeira passagem é uma varredura rápida, consistindo em: 1) ler o título, o resumo e a introdução; 2) ler apenas o título da seção e subseção, mas ignorando todo o resto; 3) examinar os conteúdos matemáticos (se houver) para determinar os fundamentos teóricos subjacentes; e 4) leitura das conclusões. A segunda passagem consistiu em analisar cuidadosamente as figuras, diagramas e quaisquer outras ilustrações do artigo, dando atenção especial aos gráficos. Por fim, os demais artigos foram filtrados pela análise do texto completo e pela observação dos critérios de exclusão EC4.

A Figura 6 apresenta o processo de filtragem, com IC e EC aplicados em cada etapa, com as bases de dados Scopus e Science Direct reunindo trabalhos mais assertivos relacionados à

Figura 6 – Etapas do processo de filtragem

	Initial Search	Impurity Removal (EC1, EC2, EC3)	Filter By Title and Keywords	Filter By Abstract	Combination	Duplicate Removal	Addition by Heuristics	Filter By Three-pass Based method	Filter by Full Text (EC4)				
ACM Digital Library	40.46% filtered 435	95.36% filtered 259	68.18% filtered 12	7	56	49	55	46	32				
Semantic Scholar	54.32% filtered 81	89.19% filtered 37	75.0% filtered 4	1									
Google Scholar	35.71% filtered 28	72.22% filtered 18	0.0% filtered 5	5									
IEEE Xplore	91.96% filtered 246	18.18% filtered 22	55.55% filtered 18	8									
Scopus	80.48% filtered 292	52.63% filtered 57	48.15% filtered 27	14									
Science Direct	72.84% filtered 81	40.9% filtered 22	7.69% filtered 13	12									
Springer Library	71.85% filtered 270	80.26% filtered 76	53.33% filtered 15	7									
Wiley	12.8% filtered 164	95.8% filtered 143	66.67% filtered 6	2									
TOTAL	60.3% filtered 1597	84.23% filtered 634	44.55% filtered 100	12.5% filtered 56						12.24% found 49	16.36% filtered 55	30.43% filtered 46	30.43% filtered 32

Fonte: Elaborado pelo autor.

string de busca com 46,4% dos resultados filtrados. Os bancos de dados Semantic Scholar e Wiley apresentaram muitos trabalhos não relacionados.

A Figura 7 mostra o resultado desse processamento antes da etapa de combinação do artigo. O processo de filtragem também trouxe trabalhos relacionados a subáreas da computação, como arquitetura de hardware e redes aplicadas à agricultura de precisão.

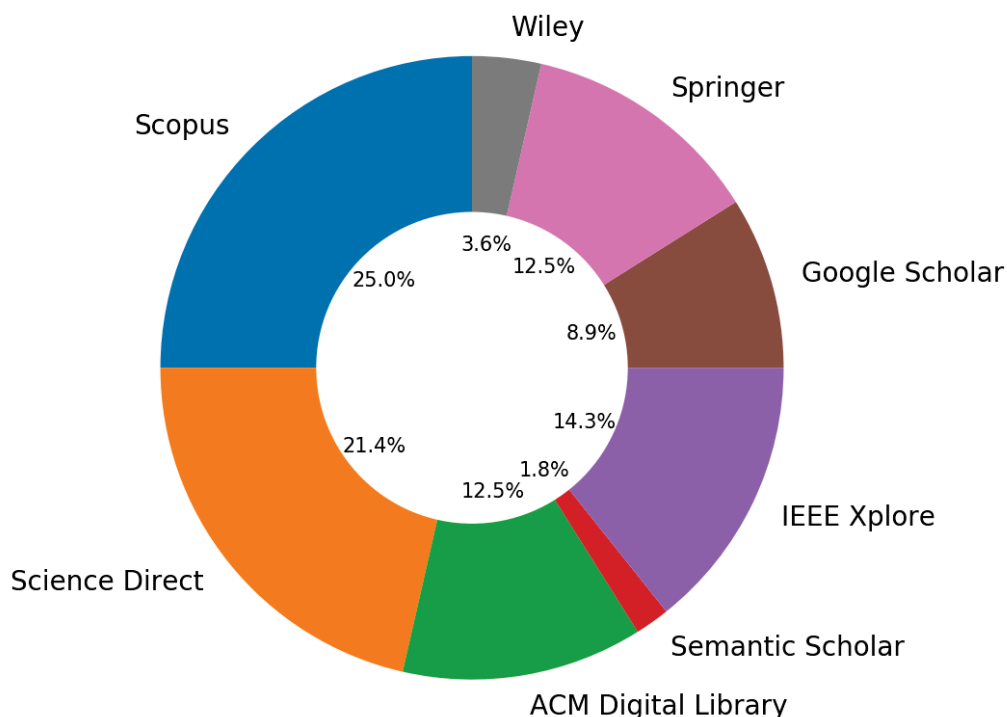
3.1.4 Ameaças à validade da pesquisa

Como em qualquer trabalho que envolva revisão sistemática, esta pesquisa apresenta alguns riscos que podem afetar os resultados obtidos. Esses riscos estão diretamente relacionados ao processo de filtragem de dados. Para reduzir a margem de risco, esta pesquisa buscou dados em nove bancos de dados diferentes, selecionados por sua relevância nas áreas de computação ubíqua e agricultura.

A *string* de pesquisa foi construída considerando os termos principais e algumas palavras relacionadas para garantir a maior cobertura possível de palavras-chave na busca, evitando uma busca ineficaz.

A técnica de Petersen foi usada para mitigar o risco de que trabalhos importantes possam ter sido retirados da pesquisa (PETERSEN et al., 2008; PETERSEN; VAKKALANKA; KUZNIARZ, 2015). Durante esse processo, os artigos foram analisados e selecionados sem uma

Figura 7 – Bancos de dados onde as pesquisas foram encontradas antes da etapa de combinação.



Fonte: Elaborado pelo autor.

revisão mais aprofundada. Para reduzir os riscos de que os resultados possam ter sido afetados, utilizamos o processo de revisão já realizado por outros autores (DÍAZ et al., 2011; VIANNA; BARBOSA, 2017), também utilizamos softwares que suportam este processo de seleção, especialmente o programa Mendeley Desktop®.

3.2 Análise e classificação

Esta seção detalha os resultados da pesquisa obtidos pela leitura e análise dos 32 estudos mapeados. Além disso, as perguntas da pesquisa foram respondidas e discussões e análises adicionais sobre os estudos foram apresentadas.

3.2.1 RQ1 – Quais tecnologias suportam a agricultura de precisão?

As tecnologias que suportam a agricultura de precisão foram analisadas e categorizadas como IoT & Sensores, Modelo de Arquitetura, Web-Semântica & Ontologia e, finalmente, *Wireless Sensor Network* (WSN). A Tabela 4 mapeia as obras com sua categorização.

Com base nessa pergunta, a maioria dos artigos enfocou as WSN. Há uma grande diferença entre IoT e WSN, o que faz com que esses termos sejam categorizados separadamente. Em um sistema IoT, todos os sensores enviam diretamente suas informações para a Internet, como

Tabela 4 – Tecnologias que apoiam a agricultura de precisão

Tecnologia	Artigos	Percentual
IoT e Sensores	Nash, Korduan e Bill (2009)	31,25%
	Córdoba et al. (2013)	
	Stojanovic et al. (2017)	
	Phillips et al. (2014)	
	Georgakopoulos e Jayaraman (2016)	
	Tzounis et al. (2017)	
	Shao, Meng e Sun (2017)	
	Aswathy e Malarvizhi (2018)	
	Dobrescu, Merezeanu e Mocanu (2019)	
	AlZu'bi et al. (2019)	
Modelo de Arquitetura	Steinberger, Rothmund e Auernhammer (2009)	25,0%
	Cho et al. (2011)	
	Kaloxylou et al. (2014)	
	Lopes et al. (2014)	
	Gelogo et al. (2014)	
	Babou et al. (2019)	
Web-Semântica & Ontologia	Jearanaiwongkul, Andres e Anutariya (2019)	6,25%
	chung et al. (2019)	
WSN	Sivamani, Bae e Cho (2013)	37,5%
	Schuster et al. (2011)	
	Lee et al. (2010)	
	Díaz et al. (2011)	
	Sabri et al. (2012)	
	Kaloxylou et al. (2012)	
	Rawat et al. (2014)	
	Shi et al. (2014)	
	Ndzi et al. (2014); Bhanu, Reddy e Hanumanthappa (2019)	
	Simbeye (2016)	
Ali et al. (2017)		
Sivamani et al. (2018)		
Keswani et al. (2019)		

Fonte: Elaborado pelo autor.

temperatura e umidade do solo. Nesse caso, uma conexão direta com a Internet será aberta imediatamente ou periodicamente para sincronizar os dados. Já em uma WSN, os vários sensores se conectam a algum tipo de roteador ou nó central. Uma grande coleção de sensores, como em uma rede em malha, pode ser usada para coletar dados individualmente e enviar dados por meio de um roteador para a Internet em um sistema IoT. Em outras palavras, WSN é um subconjunto da IoT.

3.2.2 RQ2 – Onde essas tecnologias estão sendo aplicadas na agricultura de precisão?

Analisando os resultados de acordo com a Tabela 5, a maior parte da tecnologia aplicada na agricultura de precisão tratava de melhorias na comunicação entre sensores, na mesma direção que apontou o RQ1. comunicação de rede seguida pela análise de solo e aplicações sensíveis ao contexto. Neste último caso, as centrais de controle coletam e processam dados em tempo real para auxiliar os produtores nas melhores decisões de plantio, fertilização e colheita.

3.2.3 RQ3 – Como a computação ubíqua está sendo usada para apoiar a agricultura de precisão?

De acordo com a Tabela 5, atualmente existe uma grande lacuna (56,25 % dos artigos) na melhoria da comunicação entre a distribuição dos sensores e a base. Tecnologia como WSN impulsionou a pesquisa agrícola porque não há mais necessidade de cabos para receber as informações, mas, em vez disso, existem soluções para evitar a perda de dados, para permitir a sincronização e melhorar a eficiência da energia do sensor.

Foi identificado um total de 14 artigos que utilizaram os contextos definidos por Dey, Abowd e Salber (2001). O principal objetivo desses pesquisadores era aprimorar o uso da tecnologia em prol do aumento da produção na área plantada. O maior desafio da computação ubíqua está relacionado à necessidade dos aplicativos serem sensíveis ao contexto para que, quando apropriado, respondam por meio da tomada de decisões. Todos esses estudos de sensibilidade ao contexto que foram selecionados no mapeamento são apresentados a seguir:

- Córdoba et al. (2013): este trabalho propôs e ilustrou a implementação de um novo método para delimitação de áreas de manejo utilizando imagens de satélite para entender a variação espacial dentro de um campo e otimizar o uso de insumos agrícolas (sementes, agroquímicos e corretivos de solo);
- Phillips et al. (2014): este trabalho discutiu uma série de recomendações chave para monitorar a dinâmica da umidade do solo em escala de campo para integração com modelos de sensoriamento remoto e suporte à decisão. Ele também concluiu que para o sensoriamento integrado ser utilizado para monitoramento operacional de longo prazo e serviços da Web de suporte à decisão, ferramentas de software e ferramentas de análise precisam

ser desenvolvidas. Assim, dados de fontes múltiplas podem ser analisados e integrados com vários modelos de produção agrícola, segurança alimentar e mudança ambiental;

- Tzounis et al. (2017): este trabalho apresentou uma visão geral das tecnologias IoT recentes, sua penetração atual no setor agrícola, seu valor potencial para futuros agricultores e os desafios que a IoT enfrenta para sua propagação a fim de otimizar a produção de várias maneiras, incluindo computação distribuída e pervasiva;
- Dobrescu, Merezeanu e Mocanu (2019): este trabalho controlou e monitorou um sistema de irrigação conectado a uma plataforma IoT para promover a integração de redes de sensores e a nuvem. Para essas tarefas, era necessário garantir a interoperabilidade semântica, desenvolver middleware de reconhecimento de contexto, implementar uma estrutura de desenvolvimento de controle em tempo real e manter um gerenciamento de monitoramento;
- AlZu'bi et al. (2019): neste trabalho, folhas amareladas e borões no solo foram observados usando sensores multimídia para detectar o nível de sede das plantas em agricultura inteligente. Os resultados experimentais mostraram que o uso de deep learning mostrase superior no ambiente da Internet of Multimedia Things para otimizar o processo de irrigação;
- Cho et al. (2011): esta pesquisa usou tecnologias sensíveis ao contexto e tecnologias de serviços da Web em ambientes agrícolas para tornar o processo de trabalho dos ambientes mais autônomo e inteligente. O modelo de serviço sugerido oferece um modelo de serviço inteligente com base em um fluxo de trabalho sensível ao contexto por meio de uma entidade, uma restrição baseada em RDF e operadores baseados em regras;
- Kaloxylou et al. (2014): este trabalho desenvolveu uma arquitetura aberta que incorpora um ambiente de trabalho personalizável e independente de domínio por meio da web. Também introduziu uma série de conceitos inovadores, como a noção de um mercado de serviços, reconhecimento de rede para que o sistema se adapte em links de Internet com mau funcionamento e identificação de componentes de sensor com mau funcionamento;
- Lopes et al. (2014): este trabalho abordou uma arquitetura para consciência situacional denominada EXEHDA-SA (Execution Environment for Highly Distributed Applications-Situation Awareness), que suporta a aquisição, processamento e disseminação de informação contextual de forma distribuída, independente da aplicação, em uma perspectiva baseada em regras e autonomia;
- Gelogo et al. (2014): este estudo propôs um projeto de estrutura de aplicativo móvel *u-farm* com capacidade de detecção ambiental (temperatura, nível de água, umidade, crescimento da planta, etc.). O objetivo principal é o monitoramento em tempo real, alertas e análises estatísticas das condições de cultivo e fatores ambientais através da geração de


palavras-chave. As palavras-chave serão então enviadas para o sistema especialista de conhecimento para análise;

- Jearanaiwongkul, Andres e Anutariya (2019): este trabalho recomenda que os tratamentos de doenças para plantas de agricultores devem ser considerados a partir de um conjunto de observações relacionadas. Assim, desenvolveu uma estrutura teórica para sistemas para gerenciar os dados de observação de um agricultor. Ele introduziu a representação de dados de observação, chamados *warncons*, com base nas informações de contexto do usuário com o objetivo de criar uma representação dos dados de aconselhamento;
- Sivamani, Bae e Cho (2013): este trabalho propôs um modelo de contexto com OWL baseado em ontologia para auxiliar no relacionamento entre os fatores do domínio; ou seja, para definir um padrão entre sistema e serviços. O modelo sugerido é analisado e derivado com o conjunto de conceitos como localização, usuário, sistema, contexto, parâmetro ambiental, usuário e rede. Os conceitos básicos propostos neste trabalho podem ser reutilizados e estendidos para ambientes inteligentes de base agrícola;
- chung et al. (2019): este estudo propõe um serviço de educação agrícola inteligente para disseminar soluções aos agricultores para auxiliar na tomada de decisões na gestão da propriedade. Este trabalho atinge um ambiente onipresente, onde os agricultores têm acesso interativo a uma variedade de materiais multimídia para ajudar a desenvolver sua proficiência em gestão;
- Sivamani et al. (2018): este artigo propôs uma ontologia de fazenda vertical. O modelo de contexto sugerido usa ontologia baseada em OWL para definir o entendimento comum e o relacionamento entre o sistema e os serviços. Com o modelo proposto, as informações da Internet das Coisas são recompostas como informações de contexto e tornadas compreensíveis para os demais sistemas. Os conceitos básicos aqui propostos podem ser reutilizados e estendidos para ambientes inteligentes baseados na agricultura;
- Keswani et al. (2019): este trabalho resume o uso ótimo da irrigação pelo gerenciamento preciso de uma válvula de água usando a previsão baseada em rede neural das necessidades de água do solo. Os comandos de controle da válvula de irrigação foram gerados com sucesso com um modelo climático de lógica difusa para atender aos requisitos uniformes de irrigação da fazenda em quase todas as condições climáticas e em regiões com deficiência de água.

3.2.4 RQ4 – Quais são os principais termos de pesquisa que expressam computação ubíqua e agricultura de precisão?

A Figura 8 apresenta o resultado de uma ferramenta de mapeamento bibliométrico conhecida como VOSViewer®, que foi utilizada para identificar trabalhos relevantes por ano de publi-

Figura 9 – Número de publicações entre 2009 e 2019



Fonte: Elaborado pelo autor.

necessária, descrita na seção 3.4, porém sem uma visualização nos gráficos.

3.3 Trabalhos selecionados e comparativos

Apenas 10 estudos ou 31,25 % dos artigos usaram IoT e sensores para apoiar a agricultura de precisão conforme mostra a Tabela 4 (NASH; KORDUAN; BILL, 2009; CÓRDOBA et al., 2013; STOJANOVIC et al., 2017; PHILLIPS et al., 2014; GEORGAKOPOULOS; JAYARAMAN, 2016; TZOUNIS et al., 2017; SHAO; MENG; SUN, 2017; ASWATHY; MALARVIZHI, 2018; DOBRESCU; MEREZEANU; MOCANU, 2019; ALZU'BI et al., 2019). Entre essas, a tecnologia mais popular foi WSN com 12 artigos (LEE et al., 2010; DÍAZ et al., 2011; SABRI et al., 2012; KALOXYLOS et al., 2012; RAWAT et al., 2014; SHI et al., 2014; NDZI et al., 2014; BHANU; REDDY; HANUMANTHAPPA, 2019; SIMBEYE, 2016; ALI et al., 2017; SIVAMANI et al., 2018; KESWANI et al., 2019).

A Tabela 5 mostra que melhorar a comunicação com WSN foi o tema mais relevante nos últimos 10 anos. Em termos de consciência de contexto, o uso de sensores para detectar a umidade do solo para irrigação automatizada foi encontrado em cinco artigos (STOJANOVIC et al., 2017; DOBRESCU; MEREZEANU; MOCANU, 2019; ALZU'BI et al., 2019; GELOGO et al., 2014; KESWANI et al., 2019). Porém, o uso de imagens na agricultura foi encontrado em apenas um artigo (CÓRDOBA et al., 2013). Esta técnica vem crescendo recentemente através do uso de drones e também pela diversidade de informações que podem ser obtidas com este equipamento, como detecção de espécies de plantas, tamanho da planta, cor dos frutos e doenças das plantas (PARISI et al., 2019).

Ao analisar todo o processo de filtragem apresentado na Figura 6 e a Questão de Pesquisa 1 (RQ 1), que apresenta em quais bases de dados os artigos foram publicados, é possível verificar que as bases de dados mais precisas que processaram a *string* de consulta foram Google Scholar e Science Direct. Ambas tiveram um número pequeno de artigos na pesquisa inicial, mas um número relativamente alto quando comparado ao total de artigos usados no mapeamento. O banco de dados menos preciso foi o Semantic Scholar — dos 81 artigos na busca inicial, apenas um estudo foi usado após a última filtragem.

3.3.1 Comparativos

A revisão sistemática apresentou o estado da arte na aplicação da computação ubíqua na agricultura de precisão. Além disso, também apresentou diferentes aplicações de tecnologias associadas à computação para melhores resultados na produção agrícola.

Embora muitos dos artigos selecionados tenham como objetivo resolver o problema das WSN, uma das lacunas que foi encontrada durante a avaliação desta pesquisa corresponde à aplicação de dados históricos na agricultura de precisão. Em particular, nenhum dos artigos mencionou o uso de um banco de dados histórico e como esses dados coletados poderiam efetivamente melhorar a produção com o suporte da tecnologia móvel.

Os dados contextuais podem levar a uma variabilidade espacial tridimensional das condições do solo, como fertilidade, umidade, pH, macro e micronutrientes e outros atributos do solo. Este tipo de visualização foi abordado por Stojanovic usando dados de rendimento (STOJANOVIC et al., 2017).

O histórico de dados contextuais pode apoiar a tomada de decisões na fazenda. Nesse sentido, a formalização de um contexto (DEY; ABOWD; SALBER, 2001) aplicado à agricultura de precisão permitiria a geração de histórias contextuais (ROSA et al., 2015) relacionadas a uma plantação inteira ou áreas dela. Esses dados podem ser analisados visando gerar previsões de contexto (ROSA; BARBOSA; RIBEIRO, 2016) das condições do solo. Assim, poderia ser determinado o momento certo para a distribuição dos insumos agrícolas, como agrotóxicos e fertilizantes, além da uniformidade de produtividade.

Foram considerados como trabalhos relacionados apenas as pesquisas que propuseram realizar previsões de dados em solos para tomada de decisão na agricultura de precisão. O comparativo entre os trabalhos, incluindo o Tellus, é apresentado na Tabela 7.

Nawar e Mouazen (2019): demonstraram o potencial de usar um espectrômetro *on-the-go* para realizar medições em tempo real por meio de espectroscopia de refletância de infravermelho próximo. Foram gerados modelos de calibração para matéria orgânica visando comparar resultados online (acoplado a um trator) e resultados de laboratório. Desempenho de previsão menos preciso foi obtido para a previsão on-line em comparação com a previsão de laboratório.

Huong et al. (2018) propuseram um modelo genérico utilizando Decisão de Markov para criar uma irrigação automática e precisa e que torne a agricultura mais eficiente em consumo

de energia e água. (TREBOUX; GENOUD, 2018) apresentaram o impacto do aprendizado de máquina junto a agricultura de precisão na segregação de cores em imagens de satélites. (GOAP et al., 2018) propuseram um sistema inteligente programado em código aberto para prever os requisitos de irrigação do campo com utilização de vários sensores de medições físicas do solo e ambientais;

Santos, Rosa Righi e Costa (2018) apresentaram um modelo de arquitetura de redes de sensores sem fio para realizar predição de umidade e temperatura do solo. Os resultados obtidos sinalizaram a viabilidade da tese e limitações quanto ao acompanhamento em tempo real do cultivo e nos mecanismos de segurança para a transmissão dos dados. Já (CONCEPCION; STEFANELLI; TRINCHERO, 2014) projetaram e implementaram uma rede de sensores sem fio para permitir a coleta de dados do ambiente agrícola, como temperatura, umidade e luz.

Para realizar a análise comparativa foram estabelecidos critérios como o tipo de sensores empregados, a proposta de uma arquitetura, o método aplicado para a análise dos dados e local do experimento. Uma vez analisados os trabalhos relacionados, não foram encontrados na literatura trabalhos diretamente relacionados à predição de fertilidade de solos na agricultura de precisão baseados na análise de históricos de contextos. As pesquisas que propuseram um modelo computacional e dados de sensores para tomada de decisão, fizeram na sua maioria uso de sensores de umidade e temperatura, ou seja, apenas aspectos físicos do solo ou do ambiente, e não químicos/orgânicos, como também sugere esta tese.

3.4 Atualização bibliográfica

Essa seção visa realizar uma atualização da bibliografia até o mês de fevereiro de 2022 utilizando as mesmas *strings* de consulta utilizadas no processo de mapeamento da Figura 6. Utilizando esses critérios, foram selecionados um total de 10 publicações, mostrados na Tabela 8.

Todos os estudos segregados para essa atualização bibliográfica são apresentados a seguir:

- Nigussie et al. (2020) propuseram um sistema de gerenciamento de baseado em IoT após investigar problemas de terras irrigadas em três países da África Subsaariana: Etiópia, Quênia e África do Sul. Foi desenvolvida uma arquitetura de IoT com eficiência de recursos para monitoramento de parâmetros do solo, microclima e água. Nela, a arquitetura, o processamento de dados, gerenciamento de rede e decisões de irrigação e comunicação com os agricultores foram realizados localmente sem o envolvimento de servidores *backend*, evitando assim a necessidade de conectividade de banda larga de longa distância e serviços em nuvem, utilizando dispositivos LoRaWAN.
- Debauche et al. (2020) deslocaram a computação dos dados no nível de borda para poder processar vídeos localmente, caso a conexão com a Internet seja limitada, permitindo também gerenciar o fornecimento de fertilizantes e o tratamento de doenças de plantas

e pragas. Sua pesquisa foi baseada num sistema multiagentes para melhor responder às necessidades de irrigação visando compensar a perda de desempenho dos aspersores de água ou a deficiência de um deles.

- Symeonaki, Arvanitis e Piromalis (2020) concentraram-se na questão de facilitar a gestão, processo, e troca dos numerosos e diversos pontos de dados gerados em vários ambientes da agricultura de precisão. A pesquisa introduziu uma solução de *middleware* com reconhecimento de contexto baseada em nuvem como parte de um sistema de apoio à decisão. Como prova de conceito, a funcionalidade do sistema proposto é estudada em condições reais onde são citados alguns resultados de avaliação quanto ao seu desempenho.
- Adi et al. (2020) propuseram um *framework* para permitir que aplicativos de IoT aprendam de forma adaptativa com outros aplicativos de IoT. No estudo, foram integradas técnicas de aprendizado adaptativo localmente, na borda, por meio de um nevoeiro ou na nuvem. Em relação à segurança cibernética, a pesquisa incluiu o estudo da influência de máquinas maliciosas em outros dispositivos que podem levar ao comprometimento do sistema. Em sistemas distribuídos, as máquinas precisam ser configuradas para distribuir recursos de forma transparente e permitir a escalabilidade de dispositivos IoT conectados.
- Javaid (2021) discute uma integração eficiente de dispositivos IoT com base na conscientização do contexto no setor agrícola. Uma estrutura de quatro camadas é proposta na qual as técnicas de automação são incorporadas para obter *insights* em tempo real do ecossistema da IoT. Além disso, o uso de análises de borda, com a incorporação de ML com serviços de IA e DA, permitirá que os agricultores tomem decisões mais precisas, mesmo quando não houver disponibilidade de internet, o que é um problema significativo em áreas remotas.
- Shen et al. (2021a) propuseram um esquema de localização de área baseado em RSSI (indicador de intensidade do sinal recebido) em sistemas de detecção pervasiva. Foram empregadas redes neurais para explorar a correlação entre a série temporal do sinal RSSI e as localizações dos sensores. O modelo de previsão gerado pode ser utilizado para localização de área em muitos cenários do mundo real e até em casos em que ocorrem perda de dados. O estudo foi capaz de manter uma precisão de localização relativamente alta mesmo quando os dados de alguns dos sensores inativos não estão disponíveis, e quando os sensores não são colocados na posição exata pré-treinada durante a colocação do sensor.
- Kumar et al. (2021) apresentaram uma abordagem de *deep learning* para uma estrutura versátil de previsão de microclima. Nela, uma estrutura genérica previu vários parâmetros climáticos, como umidade do solo, umidade, velocidade do vento, radiação, temperatura. Foram gerados vários cenários agrícolas e de energia do mundo real e relatados resultados com mais de 90% de precisão. Conforme os autores, as previsões microclimáticas são de

importância crítica em várias aplicações, como agricultura, silvicultura, energia, busca e salvamento.

- Elumalai e Anuncia (2021) geraram um modelo de conhecimento para armazenar diferentes composições do solo. Assim, uma composição mineral baseada em ontologia foi desenvolvida com um sistema de recomendação para solo agrícola. No estudo, observou-se que 21 regras estão fortemente associadas. Na convicção, 26 regras estão fortemente associadas, e na alavancagem, 26 regras são desejáveis. O modelo desenvolvido teve 91% de precisão. Conforme os autores, a precisão pode ser melhorada com a adição de mais regras em torno das premissas do conhecimento e a inferência, pela adição de fatos mais relevantes no domínio da investigação.
- Shankhdhar, Sharma e Darbari (2021) desenvolveram um modelo ontológico, SAGRO-Lite, uma parte maior de um sistema multi-agente chamado ABSMSA para uso em *Smart Farming*. O ABSMSA utiliza o metamodelo IoT-Lite para melhorias de desempenho e também fornece uma ontologia agrícola inteligente adaptada para uso por agricultores em países em desenvolvimento como a Índia. A modelagem semântica é apenas a parte inicial de todo o projeto. O SAGRO-Lite gerencia com seus agentes como os modelos são utilizados; como os dados anotados são indexados e consultados em tempo real. Todos os eventos acionados pelos sensores são tratados por uma ontologia dedicada chamada *Complex Event Service Ontology*.
- Rodić et al. (2022) demonstraram um novo conceito de sensor de baixo custo e baixo consumo de energia que atinge a detecção de umidade usando *deep learning*. Foi implementado um dispositivo com sensor de umidade do solo I2C baseado em LoRa que mediu a umidade e a temperatura do solo por um período de vários meses. Com uma taxa de amostragem de 5 minutos, a temperatura e a umidade do solo foram medidas e enviadas por um canal de rádio para dois dispositivos de *gateway* LoRaWAN que coletaram medições de intensidade de sinal do dispositivo sensor. A análise dos dados coletados mostrou notável correlação entre RSSI (indicador de intensidade do sinal recebido), SNR (relação sinal/ruído) e umidade do solo. Foi demonstrado ainda que a umidade do solo pode ser estimada com alta precisão a partir da intensidade do sinal, juntamente com técnicas de aprendizado de máquina relacionadas. O uso de Rede Neural Long Short-Term Memory (LSTM) forneceu resultados significativos em termos de precisão de estimativa em contraste com as técnicas tradicionais de ML de Regressão por Máquinas de Vetores de Suporte.

A maioria dos artigos selecionados trataram sobre sistemas de IoT de borda visando melhorar a produção no setor agrário a partir de monitoramento de condições seja no solo ou no clima da lavoura (DEBAUCHE et al., 2020; ADI et al., 2020; SHEN et al., 2021b; RODIĆ et al., 2022). O modelo Tellus não teve o condão de avaliar a conectividade para sua implantação

embora conectar lavouras na nuvem vem sendo um tema recorrente na comunidade científica. No entanto, as infraestruturas de IoT de borda e de neblina estão deixando de serem barreiras na criação de aplicativos de IoT inteligentes. Apenas 2 artigos selecionados propuseram uma ontologia visando inferir a composição do solo em países em desenvolvimento (ELUMALAI; ANOUNCIA, 2021; SHANKHDHAR; SHARMA; DARBARI, 2021). Vale ressaltar que a ontologia proposta pelo Tellus é focado na modelagem semântica do solo, na sua classificação e na definição de suas propriedades para recomendações de um manejo correto.

3.5 Considerações finais

Este capítulo teve como objetivo principal apresentar os trabalhos relacionados à computação ubíqua na agricultura. Como esse tema é muito vasto, foi adicionado o termo "solo" nas *strings* de buscas. Grande parte desse esforço foi publicado em um periódico, já relatado, em 2019. Portanto, houve necessidade de realizar-se uma atualização bibliográfica até o corrente ano de 2022. Após analisar as pesquisas segregadas pelas etapas do mapeamento sistemático, foram identificadas características que foram exploradas e utilizadas na especificação do Tellus. Dentre uma delas, uma das principais lacunas descobertas de forma científica foi uma representação do conhecimento da agricultura extensionista brasileira.

Tabela 5 – Aplicação da tecnologia na agricultura de precisão

Tecnologia	Artigos	Percentual
Melhorar a comunicação	Nash, Korduan e Bill (2009)	56,25%
	Stojanovic et al. (2017)	
	Shao, Meng e Sun (2017)	
	Aswathy e Malarvizhi (2018)	
	Georgakopoulos e Jayaraman (2016)	
	Steinberger, Rothmund e Auernhammer (2009)	
	Babou et al. (2019)	
	Schuster et al. (2011)	
	Lee et al. (2010)	
	Díaz et al. (2011)	
	Sabri et al. (2012)	
	Kaloxylou et al. (2012)	
	Rawat et al. (2014)	
	Shi et al. (2014)	
	Ndzi et al. (2014)	
	Bhanu, Reddy e Hanumanthappa (2019)	
	Simbeye (2016)	
Ali et al. (2017)		
Sensibilidade ao contexto	Córdoba et al. (2013)	43,75%
	Phillips et al. (2014)	
	Tzounis et al. (2017)	
	AlZu'bi et al. (2019)	
	Dobrescu, Merezeanu e Mocanu (2019)	
	Cho et al. (2011)	
	Kaloxylou et al. (2014)	
	Lopes et al. (2014)	
	Gelogo et al. (2014)	
	Jearanaiwongkul, Andres e Anutariya (2019)	
	Sivamani, Bae e Cho (2013)	
chung et al. (2019)		
Sivamani et al. (2018)		
(KESWANI et al., 2019)		

Fonte: Elaborado pelo autor.

Tabela 6 – Referência do número de publicações da Figura 9

Código	Artigo
11	Nash, Korduan e Bill (2009)
12	Córdoba et al. (2013)
13	Stojanovic et al. (2017)
14	Phillips et al. (2014)
15	Georgakopoulos e Jayaraman (2016)
16	Tzounis et al. (2017)
17	Shao, Meng e Sun (2017)
18	Aswathy e Malarvizhi (2018)
19	Dobrescu, Merezeanu e Mocanu (2019)
20	AlZu'bi et al. (2019)
21	Steinberger, Rothmund e Auernhammer (2009)
22	Cho et al. (2011)
23	Kaloxylou et al. (2014)
24	Lopes et al. (2014)
25	Gelogo et al. (2014)
26	Babou et al. (2019)
27	Jearanaiwongkul, Andres e Anutariya (2019)
28	chung et al. (2019)
29	Sivamani, Bae e Cho (2013)
30	Schuster et al. (2011)
31	Lee et al. (2010)
32	Díaz et al. (2011)
33	Sabri et al. (2012)
34	Kaloxylou et al. (2012)
35	Rawat et al. (2014)
36	Shi et al. (2014)
37	Ndzi et al. (2014)
38	Bhanu, Reddy e Hanumanthappa (2019)
39	Simbeye (2016)
40	Ali et al. (2017)
41	Sivamani et al. (2018)
42	Keswani et al. (2019)

Fonte: Elaborado pelo autor.

Tabela 7 – Comparativo dos trabalhos relacionados

Artigo	Arquitetura	Sensores	Análise	Local
Nawar e Mouazen (2019)	Não	Infravermelho	Aprendizado de Máquina	Bélgica
Huong et al. (2018)	Não	Umidade	Decisão de Markov	Vietnã
Treboux e Genoud (2018)	Não	Imagens de satélite	Aprendizado de Máquina	Suíça
Goap et al. (2018)	Sim	UV, Temperatura e Umidade	Aprendizado de Máquina	Índia
Santos, Rosa Righi e Costa (2018)	Sim	Temperatura e Umidade	Arima	Brasil
Concepcion, Stefanelli e Trincherro (2014)	Sim	Câmera, Temperatura e Umidade	N/A	Itália
Tellus	Sim	Infravermelho Temp. (ar e solo), Umidade (ar e solo), Pressão Atm., Luminosidade, Vel. e Direção Vento, Câmera	Aprendizado de Máquina e Aprendizado Profundo	Brasil

Fonte: Elaborado pelo autor.

Tabela 8 – Artigos selecionados para atualização bibliográfica

Tecnologia	Artigos	Percentual
IoT e & Sensores	Nigussie et al. (2020)	20,0%
	Javaid (2021)	
Modelo de Arquitetura	Symeonaki, Arvanitis e Piromalis (2020)	20,0%
	Kumar et al. (2021)	
Web-Semântica & Ontologia	Elumalai e Anuncia (2021)	20,0%
	Shankhdhar, Sharma e Darbari (2021)	
WSN	Adi et al. (2020)	40,0%
	Debauche et al. (2020)	
	Shen et al. (2021a)	
	Rodić et al. (2022)	

Fonte: Elaborado pelo autor.

4 MODELO TELLUS

Este capítulo apresenta a especificação de um modelo computacional denominado Tellus que consiste em agentes de predição e inferência, baseado numa arquitetura de inteligência artificial e numa ontologia. Ambos utilizam o paradigma de computação ubíqua na agricultura de precisão para predição de propriedades do solo através de histórico de contextos. O modelo Tellus foi inicialmente apresentado no SBCUP 2019 (HELPER et al., 2019b). Ainda em 2019 foram incluídos dados climáticos na predição para posterior apresentação no WebMedia (HELPER et al., 2019c). Em 2020 o modelo de predição ficou mais robusto com o uso de 450 amostras, sendo publicado no periódico *Computers and Electronics in Agriculture* (HELPER et al., 2020).

4.1 Modelo conceitual

O Tellus é um modelo computacional para agricultura ubíqua que utiliza as informações de contexto para promover serviços inteligentes. O Tellus concentra-se em atender às necessidades da lavoura em relação às informações sobre clima e uso correto e racional de insumos agrícolas. Para que isso ocorra de maneira adequada, o Tellus faz uso de serviços de notificação e mensagens a partir de dispositivos móveis.

Observando os trabalhos relacionados, encontrou-se muitos trabalhos focados na infraestrutura de comunicação entre sensores que realizam medições físicas e a nuvem. Diante desse fato, nenhuma das propostas cita ou considera também o uso de contextos químicos nas definições dos sistemas e nem a geração de um histórico que pudesse servir para consultas futuras apoiados numa ontologia.

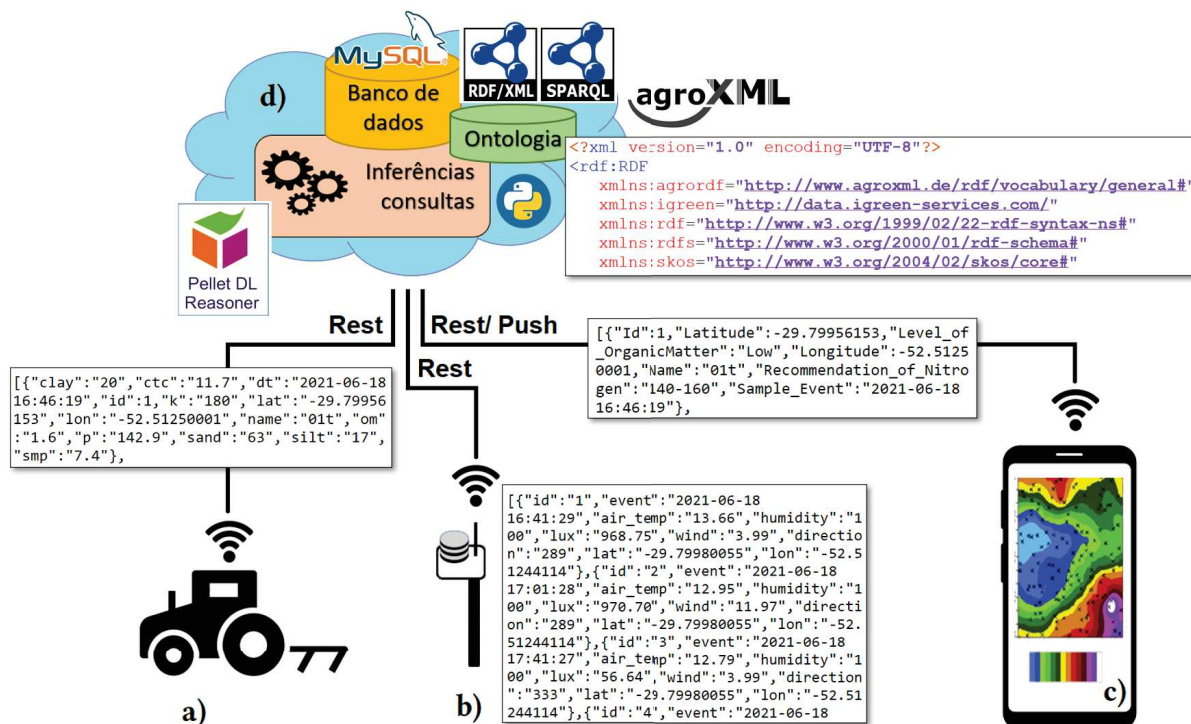
Logo, o Tellus tem como princípio fornecer serviços inteligentes como recomendações de insumos agrícolas, com o objetivo de corrigir solo para um aumento de produtividade, e promover consultas em tempo real das condições micro-climáticas da lavoura.

A Figura 10 apresenta a visão geral dos elementos que compõem o modelo Tellus, são eles: a) atuadores que realizam leituras móveis e atuam baseados em recomendações; b) sensoreamento que são representados pelas estações de telemetria; c) aplicativo que gerencia as informações, recebe notificações e mensagens provenientes das recomendações; d) modelo que possui mecanismos de recomendações, consultas e predições oriundos do banco de dados e da ontologia.

A função dos sensores é coletar informações do solo e do micro-clima. Essas informações correspondem a dados químicos como os infravermelho próximo ou dados físicos de sensores. O conjunto desses dados associados a um registro de data e hora formam as informações de contexto.

O aplicativo tem como objetivo tornar as informações acessíveis a qualquer instante por meio de mensagens, notificações e tabelas de dados formatadas num interface simples.

Figura 10 – Visão geral do Tellus



Fonte: Elaborado pelo autor.

A função do modelo é gerenciar as informações de contexto e históricos de contextos dos dados da lavoura, incluindo as dados dos sensores. A cada nova interação, um registro no histórico de contextos é inserido no banco de dados. Dependendo do tipo de informação, ocorrem recomendações ou somente tornam o contexto disponível para uso futuro.

Os históricos de contextos expressam condições de uma lavoura numa linha de tempo, ou seja, são representados por dados temporais. Eles são registrados em tabelas do banco de dados de forma sequencial. O objetivo de manter históricos é utilizá-lo para reconhecimento de padrões pois podem correlacionar algum fenômeno ou evento específico que resulte em tomada de decisões.

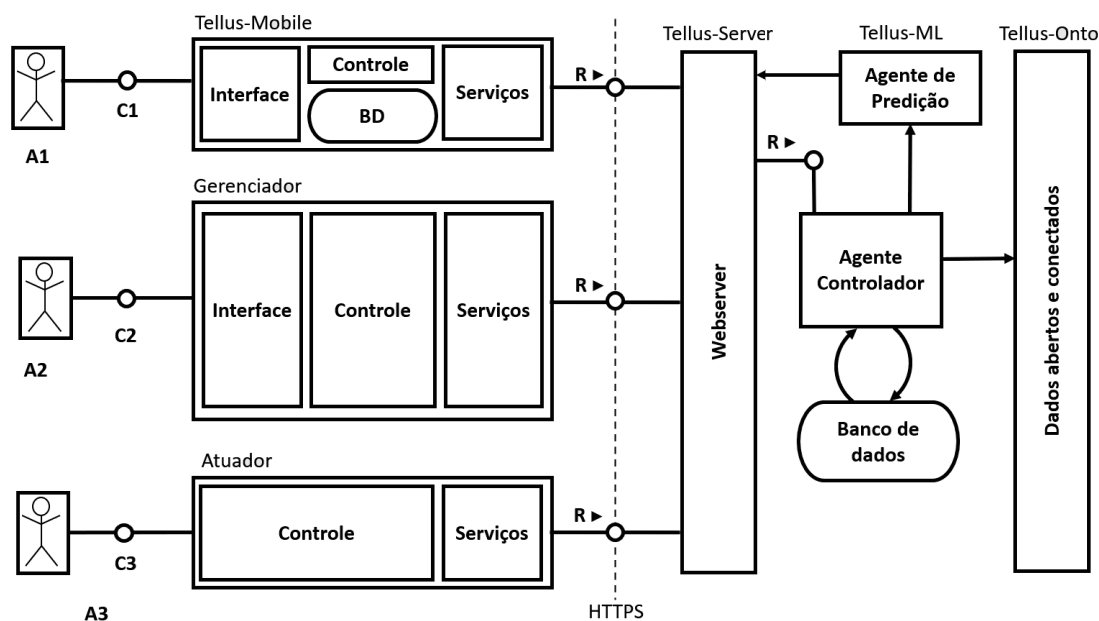
4.2 Arquitetura

Tellus foi projetado usando a modelagem técnica de arquitetura da SAP (TAM, do inglês, *Standard for Technical Architecture Modeling*) (SAP AG, 2007). Na Figura 11 é apresentada a arquitetura composta por atores (A1, A2 e A3), acessos, blocos (Assistente Móvel, Atuador, Gerenciador e Servidor) e componentes. Os componentes aparecem na parte interna dos blocos, também são apresentados os canais de comunicação, indicados pelos símbolos C1, C2 e C3.

O Tellus organiza o fluxo das informações de forma a obter dados gerados pelos atores, e após tratados, disponibiliza informações contextuais de acordo com a requisição realizada. Para isso o modelo contempla três blocos: um assistente móvel, um *middleware* para sensores

conectados em atuadores e um servidor.

Figura 11 – Arquitetura do modelo Tellus



Fonte: Elaborado pelo autor.

O assistente móvel, chamado de Tellus-Mobile 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 uma API *RESTful*. O Tellus-Mobile serve também para receber as recomendações e gerenciar as informações do Tellus-Server.

O Gerenciador recebe as ações do usuário utilizando *webservices* a partir de uma API *RESTful* (A2) por meio do canal de comunicação C2 e realiza configurações ou atualizações no agente de predição e na ontologia.

O Atuador agrícola é responsável por atender os casos de uso do cliente sensor (A3), pelo canal C3, possuindo métodos de comunicação para envio de dados ao servidor e também para recebimento de atualizações e novas configurações. O Atuador coleta os dados do solo e também recebe notificações caso o local de análise seja crítico para tratamento. Esta notificação é realizada após a predição de matéria orgânica e argila pelo Agente de Predição e é disparada também para o assistente móvel. Com base nessas análises, ele verifica se há necessidade de correção de solo com fertilizantes além da quantidade a ser utilizada. Este agente insere marcações nos históricos de contextos correspondentes.

O Atuador pode também representar outros equipamentos conectados a sensores como estações de telemetria do solo ou do ambiente. Neste caso, as informações de históricos de contextos podem recomendar situações de manejo de solo como irrigação, condições meteorológicas favoráveis para sementeira, colheita ou aviação agrícola.

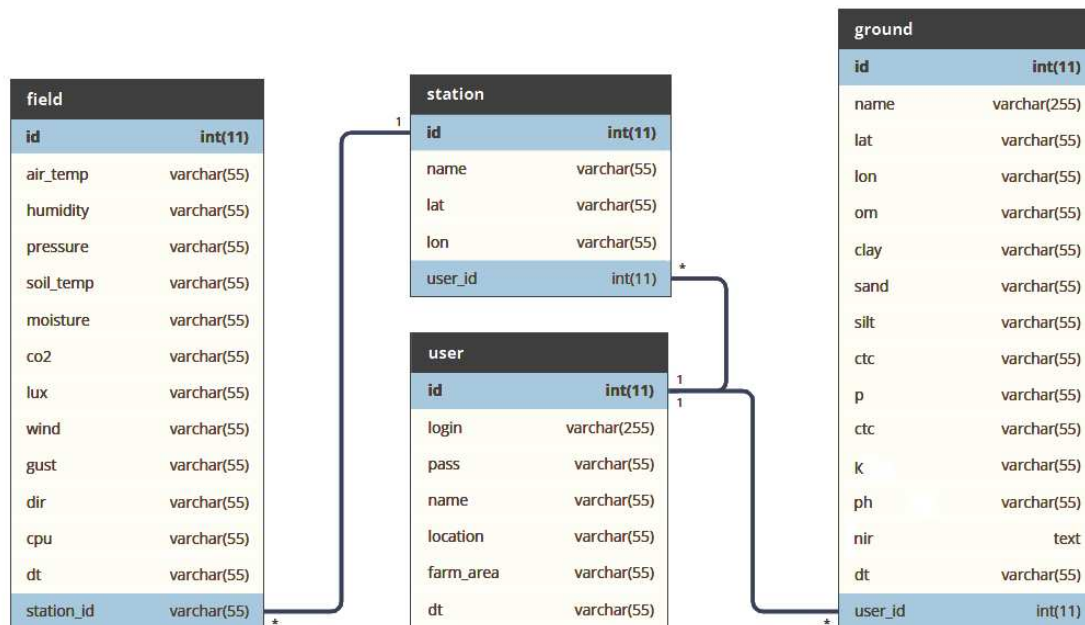
O Agente Controlador é o elemento do modelo que contém as regras de negócio, ou seja, define como o modelo funciona. As regras são executadas conforme as solicitações são requi-

sitadas. Sua função é gerenciar as informações de contexto e históricos de contextos do solo, incluindo as propriedades do solo e as informações climáticas vinda dos sensores.

4.3 Modelo de dados

Para armazenamento das informações referentes à telemetria (sensores do clima) e às análises de solo foi utilizado um banco de dados relacional. O modelo Entidade Relacional (ER) do banco de dados foi projetado para comportar todas as informações, dando suporte às recomendações e previsões do Tellus. A Figura 12 exibe o modelo ER do banco de dados.

Figura 12 – Modelo de Entidade Relacionamento Tellus



Fonte: Elaborado pelo autor.

As entidades do modelo são representadas através das tabelas *station*, *field*, *ground* e *user*. A tabela *field* acomoda os dados da estação de telemetria enquanto que a tabela *ground* contém as informações químicas e físicas do solo referente aos laudos laboratoriais, como latitude (lat) e longitude (lon) do ponto de coleta, concentrações de matéria orgânica (om), argila (clay), silte (silt), areia (sand), capacidade de troca de cátions (ctc), fósforo (p), potássio (k), índice SMP (smp), pH, dados de infravermelho próximo (nir) e data/hora do evento (dt).

A tabela *station* mantém principalmente as informações de geolocalização da tabela *field*, composta por informações de contexto como temperatura do ar (air_temp) e do solo (air_soil), umidade do ar (humidity) e do solo (moisture), pressão atmosférica (pressure), nível de dióxido de carbono (CO₂), luminosidade (lux), velocidade (wind), rajadas (gust) e direção (dir) dos ventos, temperatura do dispositivo (cpu) e data/hora do evento (dt). A tabela *user* relaciona as tabelas *station*, *ground* e *field* a um usuário.

4.4 Considerações finais

O presente capítulo apresentou o Tellus, um modelo computacional para agricultura de precisão em solos. O Tellus tem sua base sendo executada na nuvem e contém um aplicativo para *smartphones* para visualização das recomendações. Todas as interações ocorrem a partir de uma API *RESTfull*. O Tellus possui também agentes de controle e predição além de uma banco de dados para armazenar os históricos de contextos. A arquitetura do Tellus foi desenvolvida considerando que a propriedade rural tem acesso à Internet a qualquer momento.

5 DESENVOLVIMENTO E ANÁLISE DOS RESULTADOS

Para desenvolver o Tellus foi necessário também implementar um protótipo que gerasse as informações de contexto da lavoura, também chamados de atuadores. Assim o Tellus abrangeu todos os elementos caracterizados no Capítulo 4 que consistia em atuadores, aplicativo móvel para disponibilização das informações e o modelo na nuvem que provia serviços inteligentes.

5.1 Implementação do Tellus

O Tellus foi instalado num servidor Debian Buster (v. 10.8) na plataforma Amazon® (AWS LightSail) em linguagem de programação Python 3.7 com as bibliotecas Scikit-Learn (v. 1.0.1), TensorFlow (v. 2.8), OwlReady2 (v. 0.35)(LAMY, 2017), RDFlib (v. 6.1.1), Matplotlib (v. 3.02), Flask (v. 2.02) e demais dependências conectadas à um banco de dados MySQL (v. 5.7.36).

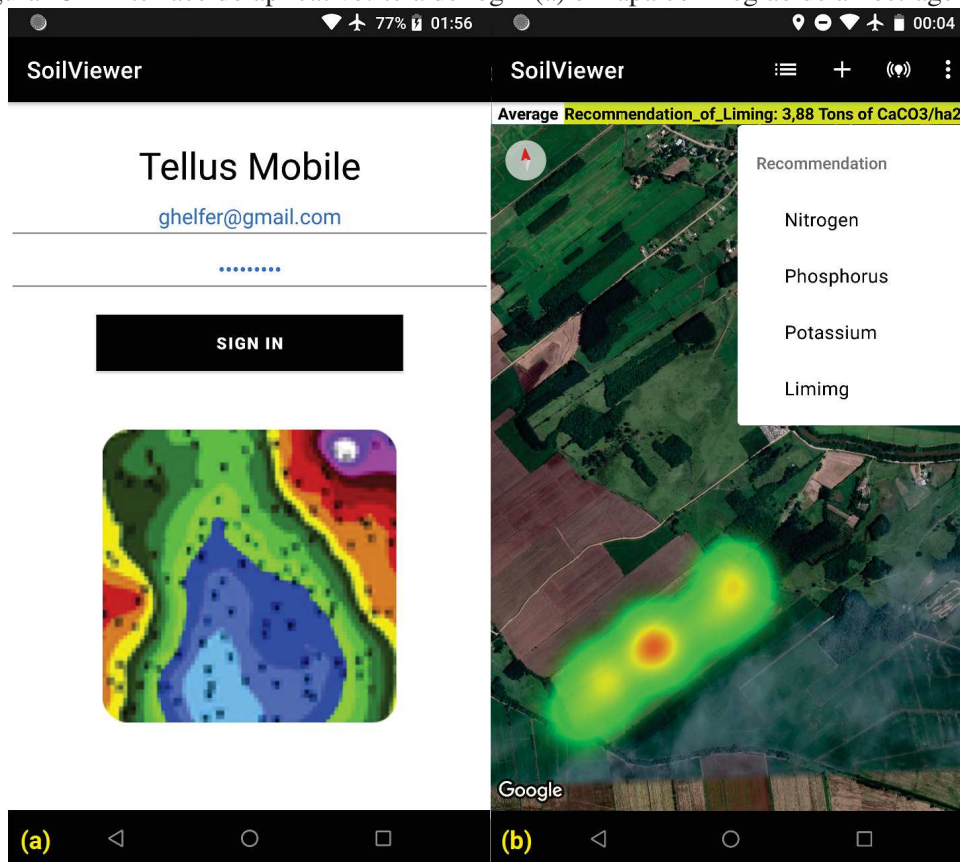
O assistente móvel denominado Tellus-Mobile foi desenvolvido para os dispositivos com sistema operacional Android. Dessa forma foi possível atender as requisições de coleta de amostra, gerenciamento dos resultados de análise de solo e suas recomendações e predições de matéria orgânica e argila pelo envio de dados de infravermelho ao Tellus-ML. Vale ressaltar que os algoritmos de predição desses componentes por NIR (aprendizado de máquina) podem ser também embarcados em *smartphones* Android ou dispositivos móveis que possuem sistema operacional, como Raspberry Pi, Orange Pi, Nvidia Jetson Nano, entre outros. A Figura 13 ilustra algumas interfaces do aplicativo como o login (a) e um mapa de calor que representa a recomendação de calagem (b) por amostragem.

O Agente de Predição possui mecanismos de tratamento e previsão de dados relacionados à análise de solo (dados químicos/ laboratoriais) e informações climáticas (aspectos físicos), bem como de localização. Portanto, utilizando algoritmos de regressão supervisionado (Aprendizado de Máquina), é realizada a predição de resultados de matéria orgânica, argila e a recomendação de nitrogênio, assim como algoritmos de redes neurais convolucionais recomendam a necessidade de irrigação.

A Figura 14 apresenta o mecanismo interno para suportar as predições realizadas pelo Agente de Predição denominado Tellus-ML. Os dados sensíveis ao contexto vindos dos atuadores e do Tellus-Mobile interagem com o Agente de Predição através de um serviço de API, que disponibiliza todos os *end-points* de comunicação de dados.

O funcionamento do Agente de Predição depende do tipo de dados de contexto recebidos podendo ser proveniente de informações químicas ou físicas.

Figura 13 – Interface do aplicativo: tela de login (a) e mapa com região de amostragem (b)



Fonte: Elaborado pelo autor.

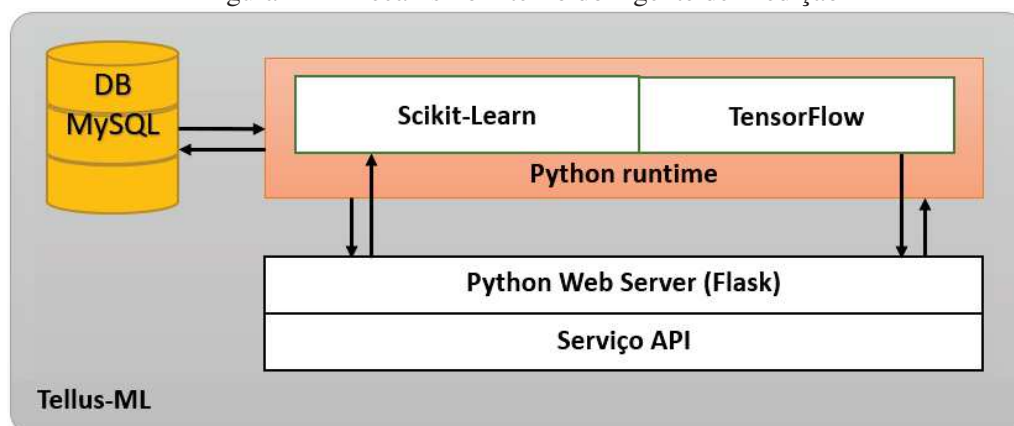
5.1.1 Históricos de contextos químicos

Como atuador agrícola utilizou-se um sensor móvel de infravermelho próximo (Texas Instruments DLP NIRScan Nano) conectado ao Tellus-Mobile via Bluetooth. Este mesmo sensor poderia ser instalado em um dispositivo móvel com sistema operacional. Especialmente neste último caso, seriam também integrados um módulo GPS (GY-GPS6MV2) para capturar a latitude e longitude do local e um módulo GPRS/2G (SIM800L) para comunicação dos dados. Um exemplo de base de dados de históricos de contextos referente ao modelo Tellus é ilustrado na Figura 15.

O agente de predição Tellus-ML foi implementado em linguagem *Python* utilizando o módulo *Scikit-Learn*. Para o treinamento do modelo foram selecionadas 43 amostras de solo com resultado de referência de diversos pontos de coleta do Vale do Rio Pardo, cujas concentrações de matéria orgânica variaram entre 0,6% e 5,9% e argila entre 8% e 60%, respectivamente. Cada amostra foi submetida a quatro varreduras (leituras) pelo sensor móvel de infravermelho próximo (Texas Instruments DLP NIRScan Nano).

Essas amostras foram fornecidas pela Central Analítica da UNISC, onde as amostras foram preparadas por secagem em estufa modelo Marconi-MA037 com circulação de ar por um período de no mínimo 24 horas com temperatura entre 45 e 60°C. Após, as amostras foram

Figura 14 – Mecanismo interno do Agente de Predição



Fonte: Elaborado pelo autor.

moídas em moinho de martelo modelo Marconi-N1040, com peneira de 2 mm, e armazenadas em caixas de papelão (TEDESCO et al., 1995; BERNARDI et al., 2014).

Cada informação gerada pelo sensor DLP possui 228 variáveis e compreende a região do infravermelho do espectro eletromagnético, entre 901 e 1701 nanômetros, denominada região do infravermelho próximo, como apresentado na Figura 16. Nele aparecem dois formatos, um *raw*, ou seja, extraído diretamente pelo sensor ao ler uma amostra de solo (a) e outro já tratado com algoritmos de correção de sinal (b) visando a predição de matéria orgânica e argila pelo Agente de Predição via regressão PLS. A aquisição dos dados foi realizada diretamente sobre a superfície da amostra.

Para corrigir erros de aquisição dos espectros de infravermelho, foram empregados os seguintes métodos de pré-processamento (filtros): SNV e Savitzky-Golay. O filtro SNV é utilizado para compensar o espalhando da luz pela amostra, muito utilizada em espectrometria NIR. O filtro de suavização Savitzky-Golay, desenvolvido em 1964, baseia-se na realização de uma regressão de mínimos quadrados lineares através de um ajuste polinomial em torno de cada registro numa janela de pontos deslizantes. Sua função é de excluir os efeitos do ruído aleatório de alta frequência produzido pela interposição de sinais (INC., 2016; PHAM; WEINDORF; DANG, 2021)

5.1.1.1 Recomendação de nitrogênio e classificação de solo por NIR

A recomendação da quantidade de nitrogênio utilizada pode ser calculada a partir dos resultados de matéria orgânica no solo, comumente reportada por laboratórios de análise de solo através de laudos. O mesmo ocorre com a classificação de argila, também reportada nestes laudos.

Na determinação de matéria orgânica e argila são utilizadas metodologias clássicas, que além de morosas geram um grande volume de resíduos perigosos, limitando a ampliação da capacidade analítica dos laboratórios agrônomicos.

Figura 15 – Exemplo do histórico de contextos do modelo Tellus

```

{
  "owner": 1,
  "name": "Falkland Farm",
  "location": "NC",
  "sample": [
    {
      "id": 1
      "dt": "2018-11-22 10:44:29",
      "latitude": "-29.8601376",
      "longitude": "-52.9074892",
      "infrared": "0.334,0.332,...,0.218",
      "om": "1.85045875108",
      "clay": "6.876870040",
    },
    {
      "id": 2
      "dt": "2018-11-22 11:05:33",
      "latitude": "-29.955723",
      "longitude": "-52.970877",
      "infrared": "0.488,0.4914,...,0.7974",
      "om": "4.582415269666079",
      "clay": "12.6565479425",
    }
  ]
}

```

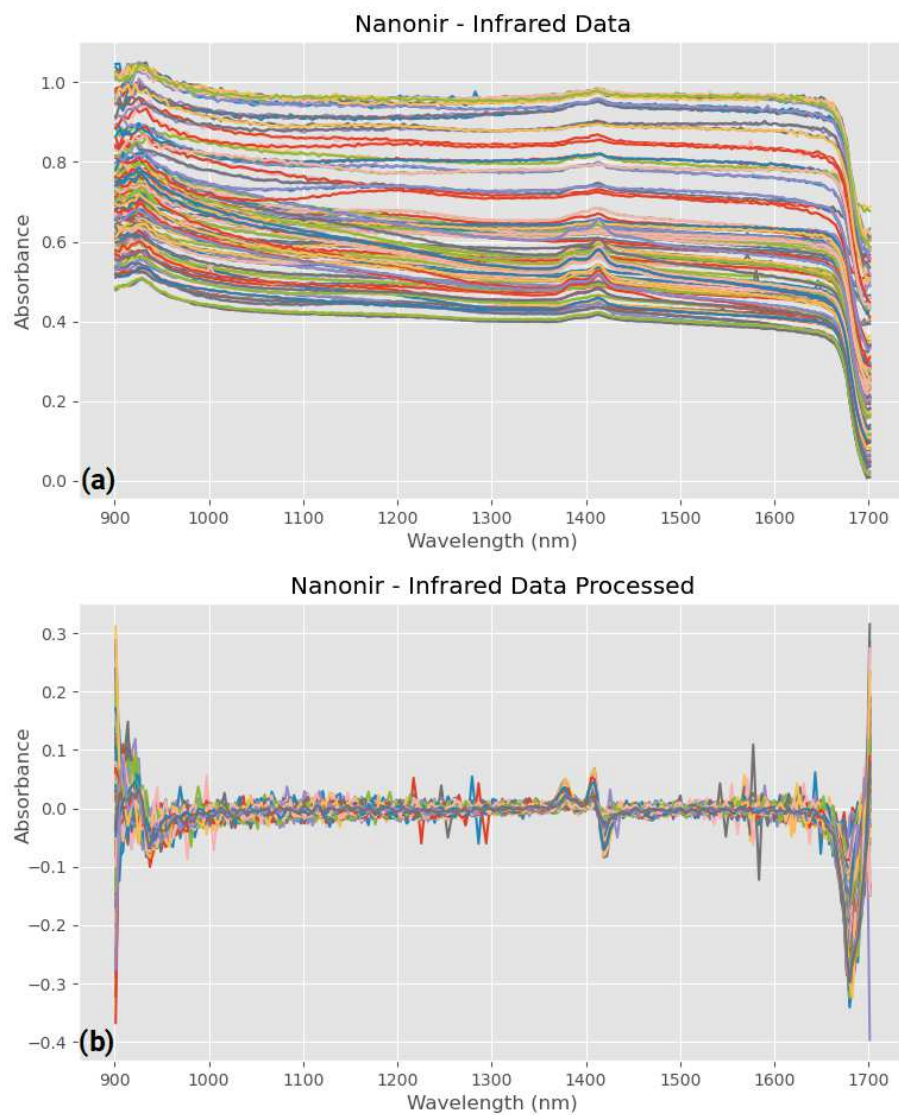
Fonte: Elaborado pelo autor.

Os dados desse contexto foram gerados por um equipamento móvel de infravermelho próximo como DLP® NIRscan™ da Texas Instruments (Texas Instruments Incorporated, 2017).

5.1.2 Históricos de contextos climáticos

Ao longo do tempo, uma lavoura acaba sendo submetida às alterações climáticas, da sua região, as quais podem resultar em alterações nas características físicas e químicas do solo. Assim, para salvar os dados da área de estudo, foi construído um protótipo que captura as informações de sensores e realiza o envio para a nuvem. Esses eventos são registrados no banco de dados, disponíveis como históricos de contextos. Este experimento foi realizado numa região que possuía sinal de telefonia celular para que os dados pudessem ser enviados por tecnologia 2G/GSM. A Figura 17 mostra a estação de telemetria desenvolvida e instalada numa lavoura de tabaco utilizada neste estudo.

A estação de telemetria consistiu num controlador solar ligado entre uma placa solar de 30 W (modelo RSM030P) e numa bateria de 12V com capacidade de 12 Ah que alimentavam um dispositivo Raspberry Pi Model A+. Conectado ao Raspberry havia um sensor modelo BME-280, que realizava as medições de temperatura e umidade ambientais além da pressão atmosférica, um modem 2G/GSM modelo SIM808L e um Arduino modelo UNO. Um relé modelo SRD-05 (5V 10A) ligava o Arduino periodicamente para que enviasse um conjunto de informações ao Raspberry via USB. Nesse conjunto, ou seja, conectado ao Arduino, haviam os demais sensores que coletavam dados de temperatura do solo (modelo Ds18B20) e umidade do solo (higrômetro modelo S12), luminosidade (modelo Temt6000), direção e velocidade dos

Figura 16 – Dados de infravermelho próximo no formato *raw* (a) e tratados (b)

Fonte: Elaborado pelo autor.

ventos (WRF Comercial).

Um relé foi incluído para economizar energia. Sem o mesmo, a bateria não suportava o protótipo após algumas horas de ausência de luz solar. As informações de contexto eram enviadas à nuvem a cada 30 minutos. A cada 2 horas durante o dia, uma câmera (Pi Cam OmniVision OV5647 v.1.3) registrava imagens visando acompanhar o plantio, crescimento e colheita da lavoura. A interface de visualização é ilustrada na Figura 18.

Para suportar os históricos de contextos climáticos foram armazenadas as informações mostradas na Tabela 9.

Figura 17 – Estação de telemetria para os históricos de contexto



Fonte: Elaborado pelo autor.

Tabela 9 – Propriedade dos históricos de contextos do clima

Propriedade	Formato	Descrição
1. Evento	Timestamp	Armazena data e hora atual
2. Latitude	Decimal	Latitude no formato de 17 dígitos
3. Longitude	Decimal	Longitude no formato de 17 dígitos
4. Temperatura do ar	Decimal	Valores em graus Celsius
5. Umidade do ar	Decimal	Valores percentuais
6. Pressão Atmosférica	Decimal	Valores em hPa
7. Temperatura do solo	Decimal	Valores em graus Celsius
8. Umidade do solo	Decimal	Valores percentuais
9. Luminosidade solar	Decimal	Valores em lux
10. Velocidade do vento	Decimal	Valores em Km/h
11. Direção do vento	Decimal	Valores em graus cardeais

Fonte: Elaborado pelo autor.

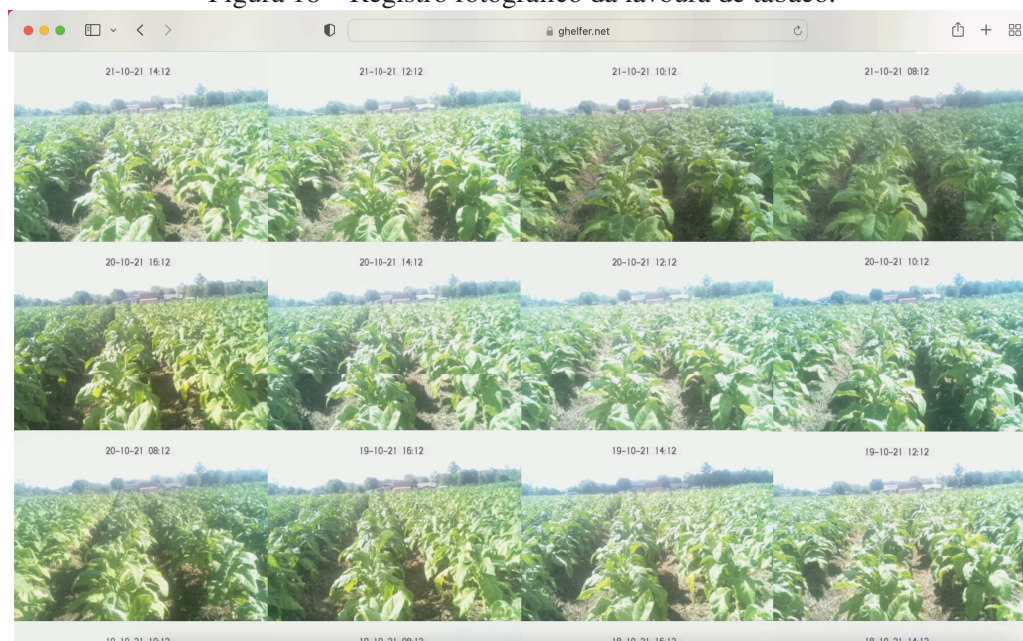
5.1.2.1 Recomendações por históricos de contextos climáticos

Na medida que os dados de contextos climático chegavam ao Tellus provenientes da estação de telemetria, inicia-se uma análise de similaridade utilizando algoritmos de redes neurais convolucionais visando recomendar a necessidade de irrigação. As propriedades envolvidas nessa recomendação, que possuem uma forte correlação, são temperatura do solo e ar e umidade do solo.

A Figura 19 mostra o mecanismo da análise dos históricos de contextos climáticos onde um cenário gráfico de contexto atual é comparado com um modelo de TensorFlow® que indica quando as informações tendem a um evento de falta de irrigação.

Não é comum encontrar lavouras de tabaco com infraestrutura para irrigação. Jones, Sparrow e Miles (1960) descrevem que solos propícios para cultura de tabaco tenham como parâmetro mínimo 50% de umidade. Com essa informação, estipulou-se que a cada contexto

Figura 18 – Registro fotográfico da lavoura de tabaco.



Fonte: Elaborado pelo autor.

registrado, fosse analisado os 4 últimos contextos. Caso a tendência de umidade de solo esteja diminuindo e as temperaturas do ar e solo com propensão ao aumento, uma notificação de irrigação era visualizado no Tellus-Mobile.

Esse cenário é definido pelo Agente de Predição. Via TensorFlow, previamente calibrado, analisava-se o gráfico das últimos 4 contextos, ou 2 horas, uma vez que cada informação chegava a nuvem numa frequência de 30 minutos. Caso a predição fosse superior que 75% um alerta era emitido. Esse percentual pode ser ajustado caso se deseje um cenário mais criterioso.

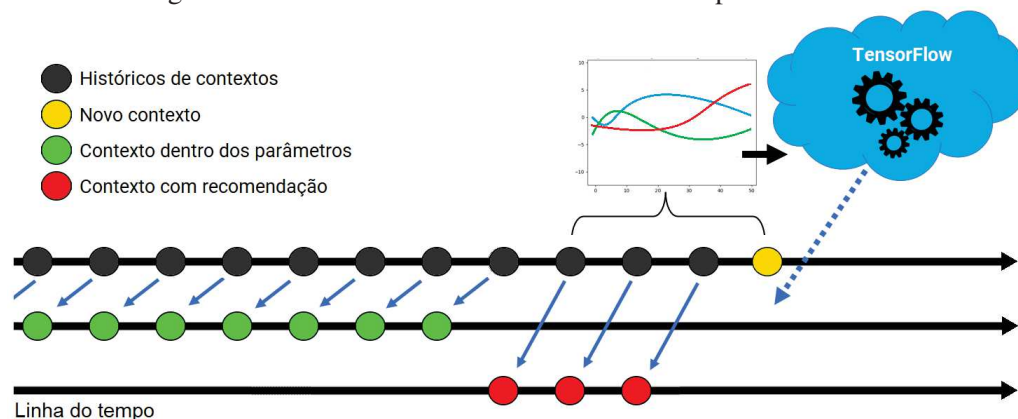
A Figura 20 mostra um exemplo de alerta com predição de saída igual a 100% e a localização do evento.

Outras recomendações também podem ser realizadas a partir das informações de contexto em tempo real. Na aviação agrícola, por exemplo, a aplicação de fertilizantes, sementes e agrotóxicos necessita condições climáticas específicas como umidade relativa superior à 50%, temperatura ambiente menor do que 30°C e velocidade dos ventos entre 3 a 10 km/h (em algumas literaturas, até 15 km/h) (DRESCHER, 2016).

5.2 Avaliação e resultados do Tellus

Para gerar o modelo de treinamento para contextos químicos foram necessários adquirir os resultados de referência das 43 amostras de solo. Portanto, elas foram analisadas por metodologias clássicas para que pudessem ser feitas as correlações necessárias via algoritmo de regressão supervisionado PLS. O mesmo foi configurado para que usasse 10 componentes ou variáveis latentes. Após gerado o modelo de calibração pertinente, o mesmo foi importado no Agente de

Figura 19 – Análise dos Históricos de Contextos por TensorFlow



Fonte: Elaborado pelo autor.

Predição.

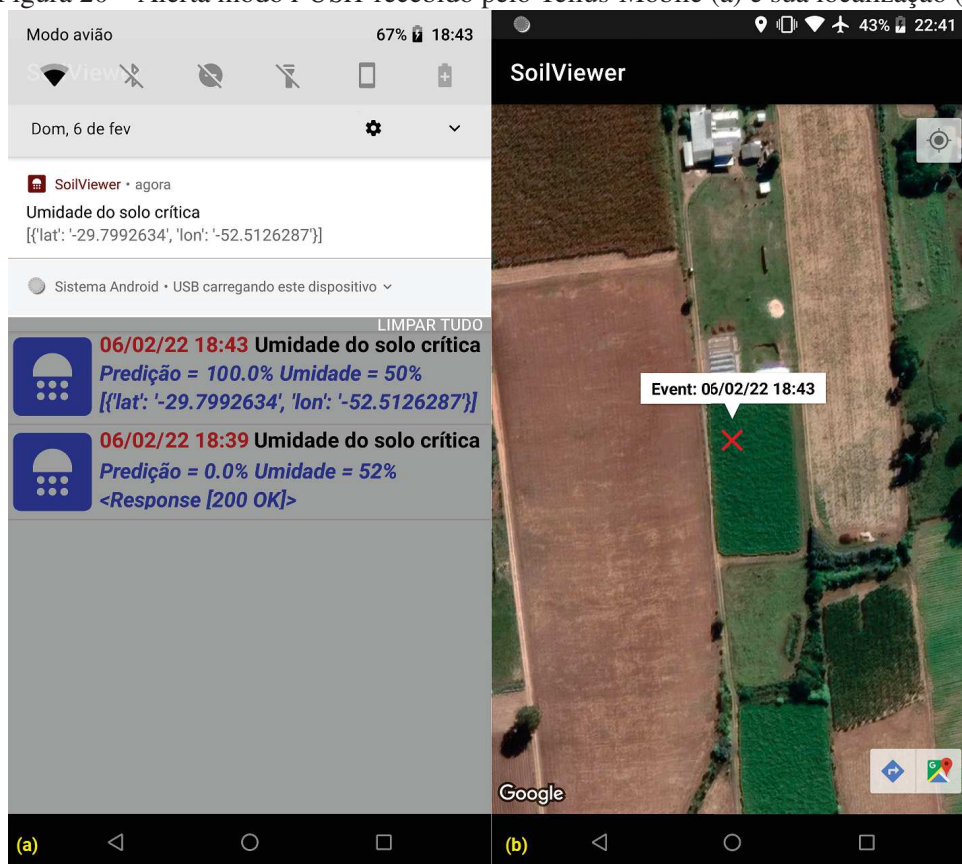
Os gráficos das Figuras 21 e 22 demonstram as performances desses modelos, da matéria orgânica, cujo coeficiente de determinação (R^2) foi de 0,97, erro médio de calibração (RMSEC) de 0,26% e erro médio de validação cruzada (RMSECV) de 1,30%, e da argila, com R^2 de 0,9536, RMSEC de 2,95% e RMSECV de 14,11%, respectivamente.

Comparando os resultados do modelo de calibração gerados pelos históricos de contextos do Tellus com trabalhos de diferentes autores, foram obtidos melhores índices de avaliação preditiva. Para matéria orgânica, Nawar e Mouazen (2019) apresentaram coeficiente de determinação (R^2) de até 0,84, porém um RMSEC menor, de 0,14%, assim como para argila, Adi et al. (2020) Wetterlind2015 obtiveram um R^2 de 0,76 e um RMSECV de 6,4%. Os erros predição menores desses autores se devem à baixa representatividade amostral. Ambos focaram seus experimentos em lotes de aproximadamente 0,5 km² enquanto que o Agente de Predição do Tellus representou diversos pontos do Vale do Rio Pardo - RS, totalizando cerca de 13.000 km² de área rural e urbana. Além disso, outros fatores como sensibilidade, reprodutibilidade e interferências dos equipamentos, intrínsecos ao método, poderiam ser também discutidos. Vale ressaltar que o modelo tende melhorar sua capacidade de predição à medida que novos dados de contexto vão incorporando a base histórica.

Em relação às recomendações de irrigação por históricos de contextos, foram utilizadas 192 imagens de gráficos que apontavam ou não a necessidade de irrigação para a fase de treinamento. Além disso, foram simulados vários cenários no Agente de Predição que gerassem tomada de decisões. A Tabela 10 mostra os testes de diagnósticos com os valores de sensibilidade, especificidade e acurácia.

Aplicando as fórmulas de teste de diagnóstico foram obtidos os seguintes valores: sensibilidade de 78,06%, especificidade de 87,23% e acurácia de 82,55%. Vij et al. (2020) demonstraram que irrigação controlada por *Random Forest* atinge até 81,6% de acurácia. Já sistemas com *Support Vector Machines* costuma ser mais precisos, entre 89,4%, à 93,6%, dependendo do período do plantio (SHEN et al., 2021a).

Figura 20 – Alerta modo *PUSH* recebido pelo Tellus-Mobile (a) e sua localização (b)



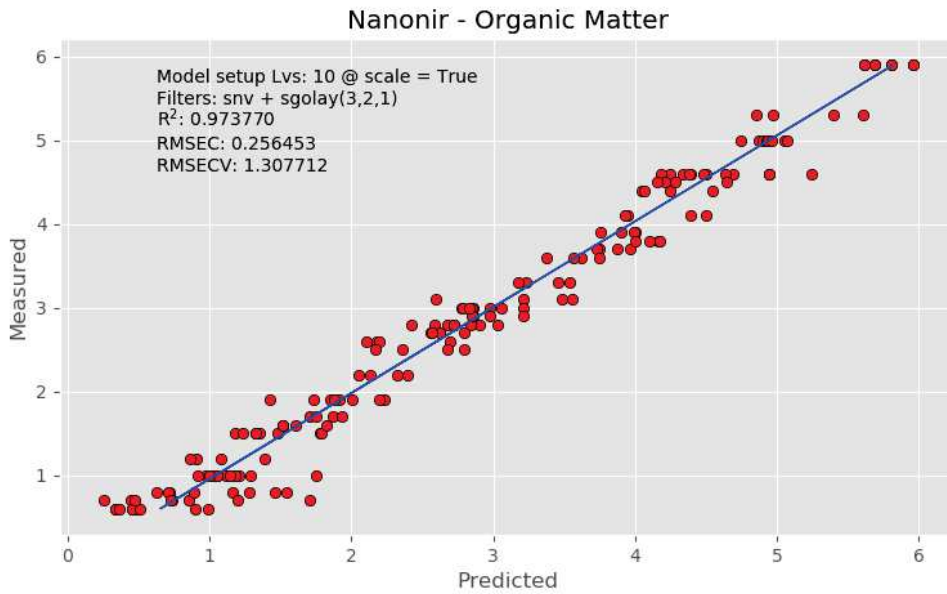
Fonte: Elaborado pelo autor.

5.3 Considerações finais

Este capítulo descreveu o desenvolvimento e a avaliação do Tellus. Com base nas informações utilizadas, foi possível construir um banco de dados histórico para uso posterior em previsões e na ontologia. Em relação à fertilidade, os dados de infravermelho foram analisados para que se pudesse prever as concentrações de matéria orgânica e argila com a aplicação de aprendizado de máquina supervisionado. Para a irrigação, os dados do passado serviram para avaliar a acurácia da proposta utilizando aprendizado profundo.

Quando comparado à trabalhos similares, o coeficiente de determinação do Agente de Predição para previsão de argila poderia ser melhor. Devido a isso, sugere-se a utilização de uma técnica de seleção de região espectral, utilizando modelos de similaridade e processamento paralelo, bem como um estudo mais aprofundado para eliminar *outliers*, ambos visando melhorar a capacidade preditiva. Já para irrigação a utilização da ferramenta TensorFlow permitiu uma predição rápida e com resultados dentro da margem esperada pela literatura.

Figura 21 – Modelo Aprendizado de Máquina - treinamento para matéria orgânica




Fonte: Elaborado pelo autor.

Tabela 10 – Teste de diagnóstico para recomendação de irrigação por contextos

Propriedade	Quantidades
Total de Negativos	207
Negativos	164
Falsos-negativos	43
Total de Positivos	177
Positivos	153
Falsos-Positivos	24

Fonte: Elaborado pelo autor.

Figura 22 – Modelo Aprendizado de Máquina - treinamento para argila



Fonte: Elaborado pelo autor.

6 TELLUS-ONTO: UMA ONTOLOGIA PARA CLASSIFICAÇÃO E INFERÊNCIAS NA AGRICULTURA UBÍQUA DE SOLOS

O Tellus-Onto inicialmente foi apresentado no XVII Simpósio Brasileiro de Sistemas de Informação (SBSI 2021) (HELPER et al., 2021a). Essa primeira versão inferia a classificação de solos brasileiros a partir de regras do triângulo textural e de resultados de argila, silte e areia oriundos de análises laboratoriais.

As ontologias podem apresentar um gerenciamento de dados de solo mais intuitivo e eficiente, fornecendo suporte a automatização e inteligência computacional. A literatura carece deste tipo de abordagem para classificação de solos brasileiros por existir mais de 300 laboratórios de análise de solo no Brasil (SOLOS, 2016; SOLO SBCS, 2019, 2020) e uma crescente demanda de análises provenientes da agricultura de precisão.

6.1 Trabalhos relacionados às ontologias na agricultura de solos

Os trabalhos selecionados foram extraídos de uma pesquisa bibliográfica nas bases ACM Digital Library, Scopus e Science Direct. Como critério de seleção, utilizou-se artigos publicados em periódicos ou conferências a partir de 2016 (inclusive). As palavras-chave utilizadas na busca foram: (*ontology AND semantic AND agriculture AND soil*). Os artigos selecionados são descritos a seguir.

- a) Muñoz, Soriano-Disla e Janik (2017) propuseram uma ontologia para seleção e classificação de 458 solos da Austrália a partir de uma série de atributos físicos e químicos como tamanho da partícula, densidade, condutividade elétrica, carbono orgânico, entre outros. Utilizando um processo de *reasoning* foram classificadas determinadas ordens de solos (cromossol, sodosol e vertosol) de forma rápida e automática com acurácia superior a 80% na maioria dos casos. Os resultados mostraram o potencial das abordagens de ontologia para selecionar amostras de grandes bibliotecas de uma forma eficiente e intuitiva.
- b) Andrés et al. (2017) implementaram um protótipo baseado em ontologia para classificar terrenos automaticamente por imagens de satélite (Landsat) com base em regras espectrais explícitas. Uma ontologia foi projetada de forma modular, a fim de conseguir uma representação genérica e versátil de conceitos sobre sensoriamento remoto. Os resultados confirmaram o potencial das ontologias para formalizar o conhecimento especializado e classificar as imagens de sensoriamento remoto. Uma das limitações destacadas foi tempo de processamento necessário.
- c) Helfer et al. (2019b) utilizou o padrão AgroRDF (PROJEKT, 2012) apenas como guia no desenvolvimento de módulos, agentes e tabelas do banco de dados, não utilizando a

ontologia para inferências ou consultas, apenas para representação geral das entidades e suas relações com o objetivo de implementar um modelo computacional.

- d) Deb, Marwaha e Pandey (2020) desenvolveram um software baseado na web com arquitetura N-camadas utilizando uma ontologia para consultas. A ontologia foi estendida até o nível de família e série, além de cobrir todas as doze ordens da taxonomia de solo do Departamento Agrícola Norte Americano (USDA). O módulo de pesquisa do software fornece dados sobre a taxonomia do solo e o módulo de edição fornece a facilidade de adicionar, excluir e editar as informações da ontologia.
- e) Giakoumatos e Gkionakis (2021) publicaram um trabalho sobre desenvolvimento de uma rede de conhecimento baseada em ontologia de propriedades físico-químicas e biológicas do conceito de solo/água, derivada dos métodos padrão ASTM e referências científicas. O objetivo da pesquisa foi preencher a lacuna da ciência da informação entre as Normas citadas e o vocabulário conceitual da disciplina de infiltração. Os conceitos da ontologia sobre solo/água correspondem às suas propriedades físico-químicas e biológicas, todas localizadas no processo de infiltração de água contaminada através de meios porosos do solo. Conforme os autores, essa abordagem fornece vantagens significativas para desenvolvedores da web semântica e usuários da web por meio de navegação rápida de conhecimento, rastreamento, recuperação e uso.

A comparação do modelo proposto e os trabalhos relacionados podem ser visualizados na Tabela 11. Para comparar os trabalhos estudados e identificar características relevantes para avaliação foram criados critérios, a seguir definidos:

- Inferências: verifica se é utilizado algum processo de inferência na ontologia proposta;
- SPARQL: verifica se é utilizada alguma linguagem de consulta sobre a ontologia;
- Equivalência: verifica se a ontologia utiliza alguma base já publicada como AgroRDF, AGROVOC ou outras;
- Domínio: verifica se a ontologia utilizada possui domínio em solos;
- Avaliação: verifica se testada com dados reais ou simulados.

Não foram encontrados na literatura trabalhos diretamente relacionados à ontologia e classificação de solos na agricultura de precisão. As pesquisas que apresentaram uma ontologia estabelecendo relacionamentos e conceitos no domínio de solos visavam alcançar a interoperabilidade entre sistemas agrícolas heterogêneos. Outros trabalhos usavam ontologias apenas para facilitar a visualização de entidades e seus relacionamentos para implementação de uma arquitetura computacional.

O trabalho apresentado por Muñoz et al. (MUÑOZ; SORIANO-DISLA; JANIK, 2017) possui as maiores semelhanças a esta proposta. Embora o desenvolvimento do modelo da ontologia

Tabela 11 – Comparativo dos trabalhos relacionados à ontologia

Artigos Critérios	a)	b)	c)	d)	e)	Tellus-Onto
Inferências	sim	sim	não	não	não	sim
SPARQL	sim	não	não	não	não	sim
Equivalência	AGROVOC	não	AgroRDF	USDA Soil Taxonomy	não	AgroRDF
Domínio	solos da Austrália	solos via satélite	análise de solos e clima	taxonomia do solo	solo água	solos do Brasil
Avaliação	amostras reais	amostras reais	sem avaliação	amostras reais	sem avaliação	amostras reais

Fonte: Elaborado pelo autor.

seja bem explicado, o domínio e a finalidade da metodologia desenvolvida são totalmente diferentes mas podem servir como uma complementação. Seu trabalho estuda ordens de solo, ou seja, faz uma classificação baseada no acúmulo de sedimentos baseado no solo australiano que possui regras de classificação textural que não se aplicam para solos brasileiros (LTD, 2021).

6.2 Desenvolvimento da ontologia

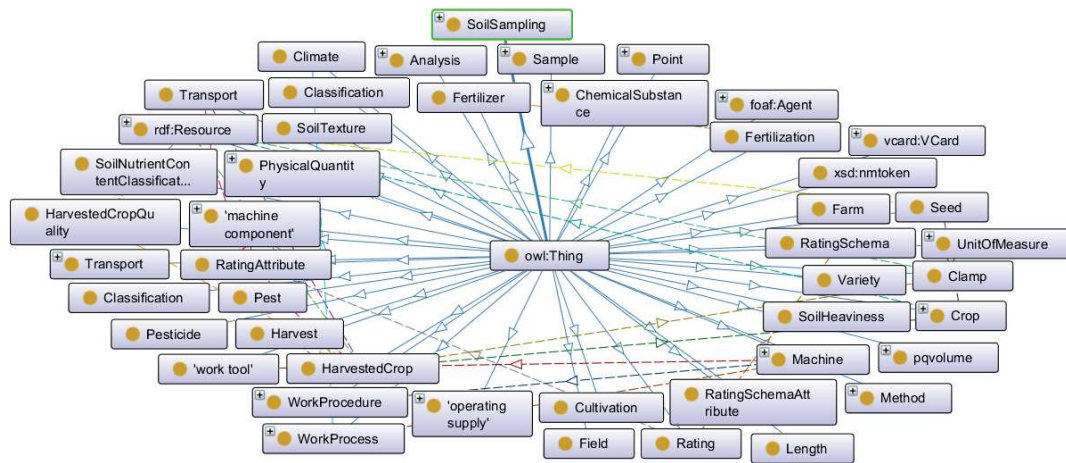
Uma ontologia é uma descrição formal de conceitos de um domínio do conhecimento, sendo utilizada para buscar respostas a questões formuladas para esse domínio (GRIMM et al., 2011). O Tellus-Onto foi desenvolvida na linguagem RDF usando o software Protégé (v. 5.5) (MUSEN, 2015). Seus conceitos e relacionamentos foram criados visando suportar e estender a proposta AgroRDF mantida pelo consórcio AgroXML (DOLUSCHITZ et al., 2005), cujo propósito é promover um formato para troca de dados amplamente aceito na agricultura além de concentrar conceitos de acordo com requisitos internacionais. A opção de utilizar o AgroRDF vai ao encontro dos princípios da ontologia que é a extensibilidade, ou seja, permitir extensões e especializações sem a necessidade de uma revisão de teoria. A ontologia a nível de classes do AgroRDF podem ser visualizada na Figura 23.

6.3 Representação do domínio através do Tellus-Onto

Todos os tipos de solo foram modelados como disjuntos dentro de cada grupo de classe textural e de argila, níveis de matéria orgânica, fósforo e potássio. Desta forma, a mesma amostra de solo terá apenas uma classificação de cada grupo, como por exemplo: argila siltosa, tipo 1, classe 2 de argila, níveis médio de matéria orgânica, baixo de fósforo e muito baixo de potássio.

A Figura 24 ilustra as relações entre os conceitos de solo levadas em consideração na atual

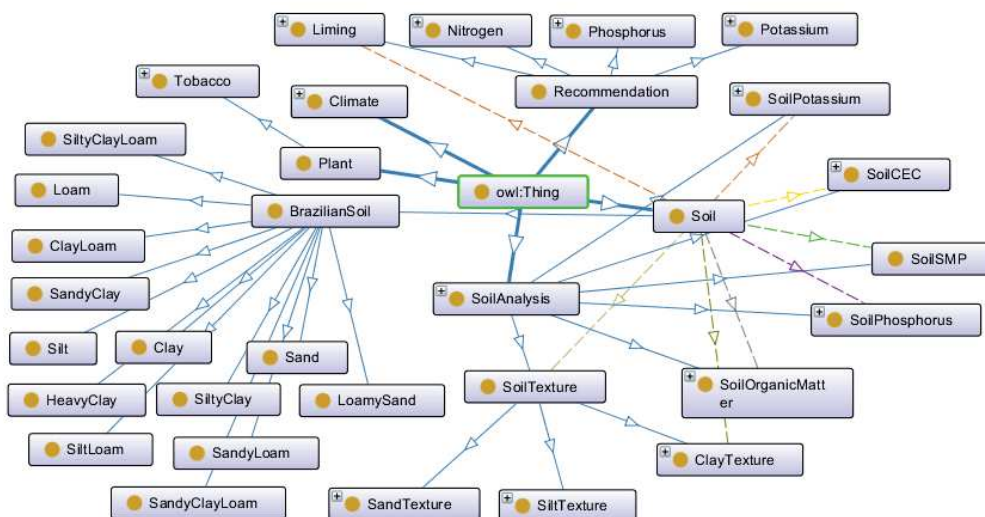
Figura 23 – Detalhe da ontologia AgroRDF/AgroXML



Fonte: Doluschitz et al. (2005)

tese: um solo possui uma classificação de textura e uma faixa de matéria orgânica. A categoria da textura varia conforme os países e depende exclusivamente da mistura de três componentes: argila, silte e areia. Deste modo, ela apresenta uma hierarquia de conceitos dentro de um domínio, as descrições de cada conceito e as propriedades definidas por atributos do tipo valor. As relações entre *Soil*, *SoilAnalysis* e *SoilTexture* são provenientes da ontologia AgroRDF/AgroXML. As demais classes e subclasses foram modeladas para o desenvolvimento deste trabalho.

Figura 24 – Visão hierárquica que compreende as classes e relacionamentos da ontologia Tellus-Onto.



Fonte: Elaborado pelo autor.

Neste contexto, é possível atribuir resultados de análises de solos, ou seja, valores de argila, silte, areia, matéria orgânica, fósforo, potássio, CTC, índice SMP e, a partir das regras

estabelecidas na ontologia, inferir a classificação do solo dessas amostras instanciadas além da recomendação de adubação e calagem de forma automática.

Em relação a textura, na grande maioria das vezes, os laboratórios de solo emitem laudos com uma análise básica de constituintes, incluindo apenas a argila. Valores de silte e areia quando solicitados agregam um custo maior devido ao emprego de metodologia analítica adicional.

A classe *Climate* apresenta equivalência de outra com mesmo nome do AgroRDF e se relaciona com os dados climáticos da lavoura, como temperatura e umidade do ar, pressão atmosférica, direção e velocidade dos ventos, luminosidade solar, incluindo os sensores que analisam temperatura e umidade do solo.

A Tabela 12 mostra métricas do Tellus-Onto extraídas do software Protégé e indicam a expressividade da ontologia.

Tabela 12 – Métricas da ontologia Tellus-Onto	
Métricas	Valores
Axiomas	482
Axiomas lógicos	367
Declaração de axiomas	111
Total de classes	51
Total de subclasses	45
Total de propriedades de objetos	9
Total de propriedades de dados	34
Total de indivíduos	113
Total de regras semânticas	145

Fonte: Elaborado pelo autor.

Os axiomas são expressões lógicas que definem um conceito. As propriedades de objeto indicam os relacionamentos entre instâncias de duas classes, enquanto as propriedades de dados indicam relações entre instâncias de classes e tipos de dados literais. As métricas "Total de classes" e "Total de subclasses" representam a quantidade de elementos encontrados na ontologia enquanto os indivíduos representam as instâncias populadas para realizar as inferências e as consultas do tipo SPARQL. Nessas instâncias encontram-se as amostras de solos importadas de uma base real.

A Figura 25 ilustra todas as *data properties* desenvolvidas para o Tellus-Onto.

6.4 Regras semânticas

Toda a classificação do solo e recomendação de adubação e calagem apresentadas nesta seção foram concebidas a partir da definição de SWRL's (*Semantic Web Rule Language*) devido à complexidade dos cálculos envolvidos. A SWRL permite que os usuários escrevam regras para raciocínio sobre os indivíduos (instâncias) que podem inferir novos conhecimentos sobre esses indivíduos.

Figura 25 – Propriedades de dados da ontologia Tellus-Onto.

The screenshot displays the Protégé interface for the ontology Tellus-Onto. On the left, a tree view shows the 'Data property hierarchy: Type_of_BrazilianSoil'. The 'Type_of_BrazilianSoil' property is highlighted. The right pane shows the 'Annotations: Type_of_BrazilianSoil' section, which is currently empty. Below this, the 'Characteristic' section shows the 'Functional' checkbox is unchecked. The 'Description: Type_of_BrazilianSoil' section shows the following characteristics: 'Equivalent To' (owl:topDataProperty), 'SubProperty Of' (owl:topDataProperty), 'Domains (intersection)' (SoilTexture), 'Ranges' (xsd:string), and 'Disjoint With'.

Fonte: Elaborado pelo autor.

Regras em SWRL são compostas de duas partes: o antecedente (*body*) e o conseqüente (*head*). Cada regra é uma implicação entre o antecedente e o conseqüente, que pode ser entendida como: quando as condições do antecedente são verdadeiras, então as condições do conseqüente também são verdadeiras.

De acordo com a Tabela 1 é possível classificar a matéria orgânica do solo em 3 níveis e a argila em 4 classes de acordo com suas concentrações. Convertendo-se para SWRL, tem-se o exemplo da Tabela 13 que apresenta “Qualquer concentração de matéria orgânica maior que 2.5% e menor ou igual à 5% é classificada como nível médio”. Logo, regras semelhantes são definidas para o nível baixo e alto, conforme seus intervalos, individualmente.

No caso da argila, a mesma Tabela 13 descreve o exemplo da regra semântica para tipo de "Classe 3" onde “Qualquer concentração de argila maior que 20% menor ou igual à 40% é denominada classe 3”. Regras semelhantes são definidas para as demais classes conforme seus intervalos, individualmente.

A Tabela 14 apresenta a regra para a categoria Areia, uma das 13 possíveis categorias de textura do solo brasileiro. Nesse caso, foi criada uma propriedade de dado denominada "Category_of_BrazilianSoil" para que a inferência ocorra de modo correto.

Situação semelhante ocorre nas recomendações. Por exemplo, para recomendar a quanti-

Tabela 13 – Regra SWRL para representar matéria orgânica de nível médio e argila de classe 3

Nome da Regra	Expressão SWRL
OM_Medium_Rule	SoilOrganicMatter(?o) ∧ organicMatterConcentration(?o, ?om) ∧ swrlb:greaterThan(?om, 2.5) ∧ swrlb:lessThanOrEqual(?om, 5.0) → Level_of_OrganicMatter(?o, "Medium")
Clay_Rule3	ClayTexture(?ct) ∧ clayConcentration(?ct, ?clay) ∧ swrlb:greaterThan(?clay, 20) ∧ swrlb:lessThanOrEqual(?clay, 40) → Class_of_Clay(?ct, "Class3")

Fonte: Elaborado pelo autor.

Tabela 14 – Regra SWRL para representar a categoria de solo tipo Areia (*Sand*)

Nome da Regra	Expressão SWRL
Sand_Rule	SoilTexture(?t) ∧ clayConcentration(?t, ?clay) ∧ siltConcentration(?t, ?silt) ∧ swrlb:multiply(?m, ?clay, 1.5) ∧ swrlb:add(?result, ?silt, ?m) ∧ swrlb:lessThan(?result, 15) → Category_of_BrazilianSoil(?t, "Sand")

Fonte: Elaborado pelo autor.

dade necessária de fósforo, é necessário primeiramente inferir qual classe de argila a amostra compreende e informar a quantidade de fósforo contido. Uma das regras aplicadas pode ser visualizada na Tabela 15. A expressão pode ser lida como "*Qualquer instância de textura c que possuir mais que 60 (%) de argila e instância fósforo p possuir seu conteúdo maior que 1.5 (mg/dm³), infere a recomendação de 120 (kg de P₂O₅/ha)* .

Todas as regras semânticas desenvolvidas no Tellus-Onto estão disponíveis no Anexo A.

Tabela 15 – Regra SWRL para recomendar a quantidade de fósforo necessária (kg de P₂O₅/ha)

Nome da Regra	Expressão SWRL
Low_P_Recomm_Rule	ClayTexture(?c) ∧ clayConcentration(?c, ?clay) ∧ swrlb:greaterThan(?clay, 60) ∧ SoilPhosphorus(?p) ∧ phosphorusConcentration(?p, ?pc) ∧ swrlb:lessThanOrEqual(?pc, 1.5) → Recommendation_of_Phosphorus(?p, "120")

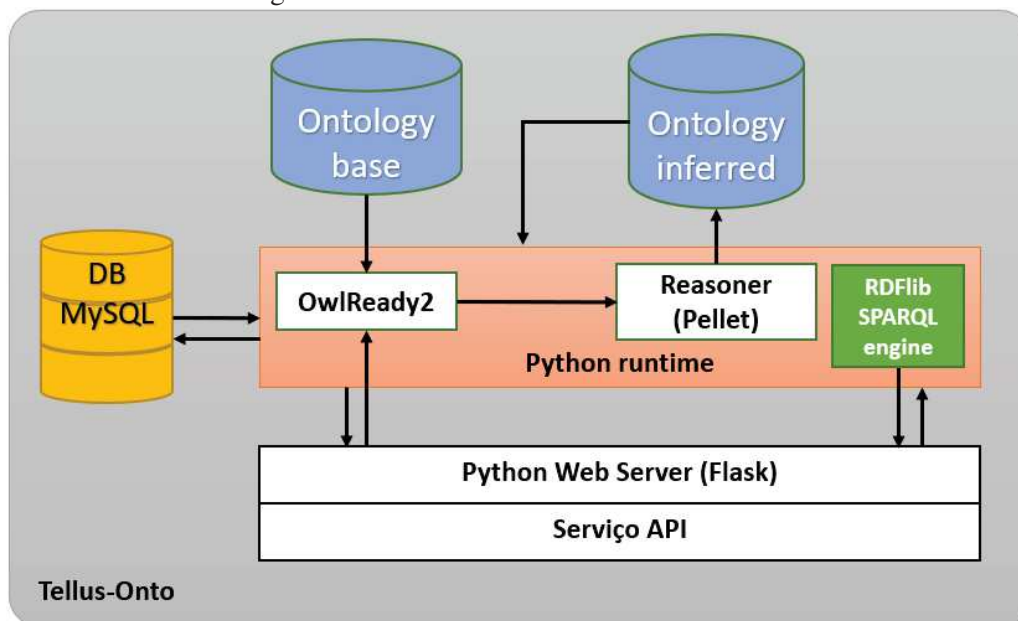
Fonte: Elaborado pelo autor.

6.5 Implementação da ontologia

A Figura 26 apresenta o mecanismo interno que suporta a ontologia Tellus-Onto. Toda a interação ocorre via API que fornece um canal de comunicação ou *endpoints* de consulta e

configuração do sistema. Assim, dados de sensores provenientes de estações de telemetria, ao serem registrados no banco de dados, ficam disponíveis para a ontologia. De maneira semelhante ocorre com as coletas de análise de solo georreferenciadas e os resultados das análises laboratoriais de solo. A disponibilização dos dados desse recurso ocorre via consultas SPARQL. Em relação à ontologia, o Tellus-Mobile possui a função de informar o tipo, as classificações do solo e recomendar a quantidade de adubo (fertilizantes) e correção de acidez necessárias, resultado das inferências realizadas.

Figura 26 – Mecanismo interno do Tellus-Onto



Fonte: Elaborado pelo autor.

A "ontologia base" descrita no mecanismo possui todas as classes, subclasses, propriedade de objetos e dados, além das regras semânticas descritas nas seções anteriores deste capítulo. Duas opções de configuração de inferência são possíveis: uma estática e outra dinâmica.

Na configuração estática, é necessária que o usuário realize uma requisição de *reasoner* para que uma nova ontologia com as inferências seja gerada, a partir da criação de *Individuals* provindos do banco de dados. Essa nova ontologia é publicada visando consultas e representa os dados abertos e conectados do modelo. Sua vantagem consiste na rapidez das consultas apesar do processo manual do raciocinador poder incidir em dados não atualizados.

Na configuração dinâmica, toda requisição de consulta realizada aciona previamente um processo de *reasoner*. Os *Individuals* também provêm do banco de dados, e conseqüentemente geram uma publicação da nova ontologia. Sua vantagem é a constante atualização apesar do maior tempo de processamento das informações. O gerenciamento dessa configuração ocorre pelo Tellus-Mobile.

As demais informações de contexto armazenadas estão disponíveis para consulta no módulo de ontologia a partir da ferramenta SPARQL.

6.6 Classificação do solo por inferência

Além de representar o conhecimento, o Tellus-Onto realiza a inferência do tipo de solo e as recomendações de adubação (aplicação de fertilizante NPK) e calagem (aplicação de calcário). Em adição, classifica o solo quanto aos níveis de matéria orgânica, classes de argila e nas 13 categorias do Triângulo Textural, já ilustrada na Figura 3 e detalhadas na Tabela 16.

Tabela 16 – Classificação textural dos solos no Brasil

Categoria	Regras para (%) de areia (d), argila (y) e/ou silte (t)
muito argiloso	$y \geq 60$
argila	$(\leq 40 y \leq 60) \wedge d \leq 45 \wedge t < 40$
argila arenosa	$y \geq 35 \wedge d > 45$
argila siltosa	$y \geq 40 \wedge t \geq 40$
franco-argilo arenoso	$(20 \leq y < 35) \wedge t < 28 \wedge d > 45$
franco argiloso	$(27 \leq y < 40) \wedge (20 < d \leq 45)$
franco argilo siltoso	$(27 \leq y < 40) \wedge (d \leq 20)$
franco arenoso	$((7 \leq y < 20) \wedge d > 52 \wedge ((t + 2 * y) \geq 30)) \vee$ $((y < 7 \wedge t < 50 \wedge (t + 2 * y) \geq 30))$
franco	$(7 \leq y < 27) \wedge (28 \leq t < 50) \wedge d \leq 52$
franco siltoso	$(t \geq 50 \wedge (12 \leq y < 27)) \vee ((50 \leq t < 80) \wedge y < 12)$
areia	$(t + 1,5 * y) < 15$
areia franca	$(t + 1,5 * y \geq 15) \wedge (t + 2 * y < 30)$
silte	$t \geq 80 \wedge y < 12$

Fonte: Elaborado pelo autor.

A classificação do tipo de solo ocorre de acordo com a Normativa da Secretaria de Política Agrícola do Ministério da Agricultura, Pecuária e Abastecimento e também está contida no Tellus-Onto, sendo que suas regras seguem a especificação mostradas na Tabela 17.

Tabela 17 – Tipo de solo no Brasil conforme Instrução Normativa Federal.

Solo	Regras para concentrações de argila (%) e areia (%)
Tipo 1	$10 \leq \text{argila} < 15$
Tipo 1	$\text{argila} < 10 \wedge \text{areia} \geq 60$
Tipo 1	$\text{argila} \geq 15 \wedge (\text{areia} - \text{argila}) \geq 50$
Tipo 1	$\text{areia} \geq 90$
Tipo 2	$15 \leq \text{argila} < 35 \wedge (\text{areia} - \text{argila}) < 50$
Tipo 3	$\text{argila} \geq 35$

Fonte: Elaborado pelo autor.

6.7 Recomendação de adubação por inferência

As recomendações utilizadas como padrão para esta tese seguem o Manual de Calagem e Adubação para os Estados do Rio Grande do Sul e de Santa Catarina, publicado pela Sociedade

Brasileira de Ciência do Solo – Núcleo Regional Sul - Comissão de Química e Fertilidade do Solo. Este manual é revisado periodicamente por diversos setores da cadeia produtiva, universidades e meio agrônomo, que o adotam amplamente na região sul (SBCS, 2016).

A interpretação dos teores de nitrogênio a serem recomendados são dependentes da quantidade de matéria orgânica do solo analisados pelo laboratório. Além disso, cada cultura possui recomendações específicas. Para o plantio de tabaco espécie Virgínia (*Nicotiana tabacum*), por exemplo, os valores de recomendação de N seguem as indicações da Tabela 18.

Tabela 18 – Recomendação de Nitrogênio

Tabaco (%)	Virgínia	Burley
M.O.	kg de N/ha	
≤1,0	160-180	190-210
1,1-2,0	140-160	180-190
2,1-3,0	120-140	160-180
3,1-4,0	110-120	140-160
4,1-5,0	100-110	120-140
>5,0	≤100	≤120

Fonte: Elaborado pelo autor,

A interpretação dos teores de fósforo são dependentes da classificação da argila e do parâmetro de P (mg/dm³) do solo emitidos por laudos, ou seja, também analisados pelo laboratório. Cada cultura também possui recomendações específicas. Para o plantio de tabaco espécie Virgínia, por exemplo, os valores de recomendação de potássio seguem as indicações da Tabela 19.

Tabela 19 – Recomendação de Fósforo

Argila	Classe1	Classe2	Classe3	Classe4	kg de P ₂ O ₅ /ha
Nível de P	Concentrações de Fósforo (mg/dm ³)				
Muito baixo (<i>Very Low</i>)	≤1,5	≤2,0	≤3,0	≤5,0	120
Baixo (<i>Low</i>)	1,6-3,0	2,1-4,0	3,1-6,0	5,1-10,0	80
Médio (<i>Medium</i>)	3,1-4,5	4,1-6,0	6,1-9,0	10,1-15,0	60
Alto (<i>High</i>)	4,6-9,0	6,1-12,0	9,1-18,0	15,1-30,0	40
Muito alto (<i>Very High</i>)	>9,0	>12,0	>18,0	>30,0	≤20

Fonte: Elaborado pelo autor.

A interpretação dos teores potássio a serem recomendados são dependentes dos valores de CTC (cmol_c/dm³) em pH7), do parâmetro de K (mg/dm³) do solo analisados pelo laboratório e da cultura a ser utilizada. Para o plantio de tabaco espécie Virgínia, os valores de recomendação de potássio seguem as indicações da Tabela 20.

6.8 Recomendação de calagem por inferência

Já para a calagem (*liming*), a recomendação de calcário considera a elevação do pH do solo ao nível desejado em uma única aplicação entre pH 5,5 e 6,5, dependendo do tipo de cultura

Tabela 20 – Recomendação de Potássio

CTC _{pH7}	≤7,5	7,6-15	15,1-30,0	>30,0	kg de K ₂ O/ha
Nível de K	Concentrações de Potássio (mg/dm ³)				
Muito baixo (<i>Very Low</i>)	≤15	≤20	≤30	≤35	200
Baixo (<i>Low</i>)	16-30	21-40	31-60	36-70	160
Médio (<i>Medium</i>)	31-45	41-60	61-90	71-105	140
Alto (<i>High</i>)	46-90	61-120	91-180	106-210	120
Muito alto (<i>Very High</i>)	>90	>120	>180	>210	≤105

Fonte: Elaborado pelo autor.

a ser plantada. No caso do tabaco Virgínia é desejável a elevação de pH para 6,0, baseado no valor do índice SMP do solo analisado pelo laboratório. A Tabela 21 detalha a recomendação completa da quantidade de toneladas de CaCO₃ por hectare².

Tabela 21 – Recomendação de calagem

SMP	desirable pH			SMP	desirable pH		
	5.5	6.0	6.5		5.5	6.0	6.5
	Tons of CaCO ₃ /ha				Tons of CaCO ₃ /ha		
≤4.4	15.0	21.0	29.0	5.8	2.3	4.2	6.3
4.5	12.5	17.3	24.0	5.9	2.0	3.7	5.6
4.6	10.9	15.1	20.0	6.0	1.6	3.2	4.9
4.7	9.6	13.3	17.5	6.1	1.3	2.7	4.3
4.8	8.5	11.9	15.7	6.2	1.0	2.2	3.7
4.9	7.7	10.7	14.2	6.3	0.8	1.8	3.1
5.0	6.6	9.9	13.3	6.4	0.6	1.4	2.6
5.1	6.0	9.1	12.3	6.5	0.4	1.1	2.1
5.2	5.3	8.3	11.3	6.6	0.2	0.8	1.6
5.3	4.8	7.5	10.4	6.7	0	0.5	1.2
5.4	4.2	6.8	9.5	6.8	0	0.3	0.8
5.5	3.7	6.1	8.6	6.9	0	0.2	0.5
5.6	3.2	5.4	7.8	7.0	0	0	0.2
5.7	2.8	4.8	7.0	7.1	0	0	0

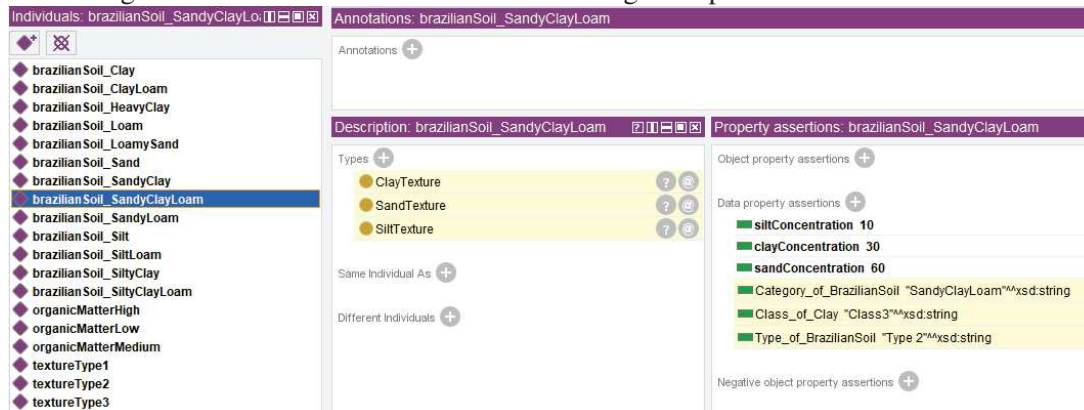
Fonte: Elaborado pelo autor.

6.9 Avaliação da ontologia

Primeiramente foram criadas instâncias que abrangessem toda a gama de tipos e classificação de solos para que a avaliação ocorra com o processo de *reasoning* automaticamente. Os *Individuals* manualmente gerados e uma das inferências podem ser visualizados na Figura 27.

Posteriormente foram populados 6 resultados de amostras de solo de um laboratório de análises coletadas numa lavoura de tabaco. As regras semânticas mostradas na seção anterior foram processadas pelo *reasoner* Pellet, um conhecido raciocinador de ontologias para a linguagem RDF/OWL incluída no Protégè e disponível no módulo Python OwlReady2.

Figura 27 – Lista de instâncias manualmente gerada para teste do Tellus-Onto.



Fonte: Elaborado pelo autor.

A Figura 28 mostra o processo da inferência onde uma amostra identificada como *s03-T* foi adicionada manualmente de acordo com o laudo número 195551/21 (Figura 29). Essa instância foi classificada como *Low* em relação ao teor de matéria orgânica, Classe 4 de argila, solo de Tipo 1 e categorizada como *SandyLoam* ou Franco-arenoso.

Vale ressaltar que o laboratório não realiza a categorização do solo, apenas mede suas propriedades químicas e físicas (textura), ficando a cargo do engenheiro ou técnico agrônomo essa atribuição, a partir das informações dos laudos de análise.

A explicação dessa inferência é ilustrada na Figura 30 que evidencia seu pertencimento ao domínio *SoilOrganicMatter* além da aplicação da regra *OM_Low_Rule* (Anexo A).

Todas as demais explicações dessa amostra resultante do processo de inferência encontram-se no Anexo B.

Para validar a classificação de solos via triângulo textural de uma maneira mais ampla foram criadas no Protégé instâncias a partir do plugin Cellfie. Nele foram importados resultados de 98 amostras de solo cedidos pela Central Analítica da UNISC. Utilizando o *reasoner* Pellet, o processo de inferência classificou corretamente todas as amostras. A comparação foi realizada por um rotina em Python mostrada no Anexo C.

6.10 Considerações finais

Este capítulo propôs uma ontologia chamada de Tellus-Onto para classificação de solos quanto à sua textura e concentrações de argila e matéria orgânica. Além disso, Tellus-Onto é capaz de inferir recomendações de adubação e calagem sensíveis ao contexto. A ontologia fica permanentemente disponível no Tellus-Onto e sua atualização ocorre sempre que uma nova informação de contexto é gerada. A partir de uma API, as informações ficam disponibilizadas para Tellus-Mobile ou qualquer outro serviço que necessite seu acesso.

Figura 28 – Resultado do processo de inferência da amostra de solo ID 195551/21 (s03-T)

The screenshot shows a web application interface for soil ontology inference. The browser address bar displays 's03 - T' and the URL 'https://ghelfer.net/ontologies/soil-ontology#195551/21'. The interface has a purple header with 'Annotations' and 'Usage' tabs. Below the header, there are several panels: 'Annotations: s03 - T' showing 'rdfs:label [type: xsd:string]' and 's03 - T'; 'Description: s03 - T' showing a list of types like ClayTexture, Liming, Nitrogen, etc.; and 'Property assertions: s03 - T' showing a list of object and data property assertions with their corresponding values, such as 'clayConcentration 18', 'siltConcentration 11', 'smpConcentration 7.1', etc.

Fonte: Elaborado pelo autor.

Figura 29 – Laudo de análise de solo ID 195551/21 (s03-T)

Amostra	Argila %	Classe	pH H ₂ O	Índice SMP	P mg.dm ⁻³	K mg.dm ⁻³	M.O. %	Al cmol _e .dm ⁻³	Ca cmol _e .dm ⁻³	Mg cmol _e .dm ⁻³	
195553/21	16	Classe 4	6,6	7,1	94,1	478	2,0	0,0	4,0	1,4	
Amostra	H + Al cmol _e .dm ⁻³	CTC (cmol _e .dm ⁻³)		% Saturação CTC			Relação Ca/Mg	Relação Ca/K	Relação Mg/K	Relação (Ca+Mg)/K	Soma de Bases (cmol _e .dm ⁻³)
		Efetiva	pH 7,0	Al	Bases	K					
195553/21	1,2	6,7	7,9	0,0	84,5	15,5	2,8	3,3	1,2	4,4	6,7
Amostra	Identificação da Amostra						Número de Hectares	Matrícula do Imóvel			
195553/21	03 - T						-	-			
ENSAIOS						MÉTODOS					
[P, Cu, Zn, Na, B, K]; [MO]; [Argila]						MEHLICH - I; Oxidação por Sulfocrômica; Densímetro					
[Ca, Mg, Al, Mn]; [Fe]						NH ₄ Cl 1M; Oxalato de Amônio					
[S]						Acetato de Amônio					
[pH Água; Índice SMP]						Potenciometria					
[Areia, Argila e Silte]						Densímetro de Bouyoucos					
Amostra	ANÁLISE FÍSICA										
	Argila %	Areia %	Silte %	Classificação							
195559/21	18	71	11	Tipo 1							
Amostra	Identificação da Amostra						Número de Hectares	Matrícula do Imóvel			
195559/21	03 - T						-	-			

Fonte: Elaborado pelo autor.

Figura 30 – Explicação em linguagem lógica para inferência de uma dada concentração de matéria orgânica de nível baixo.

Explanation 1 Display laconic explanation

```
Explanation for: 's03 - T' Level_of_OrganicMatter "Low"^^xsd:string
  organicMatterConcentration Domain SoilOrganicMatter
  's03 - T' organicMatterConcentration 2.0
  lessThanOrEqual(?om, 2.5), organicMatterConcentration(?o, ?om), SoilOrganicMatter(?o)
  -> Level_of_OrganicMatter(?o, "Low"^^xsd:string)
```

Fonte: Elaborado pelo autor.

7 CONCLUSÕES

Esta tese propôs um modelo computacional denominado Tellus para predição de propriedades do solo através de históricos de contextos. Com relação a estes, dados de infravermelho próximo foram extraídos de 43 amostras de solo por dispositivos de alta mobilidade para que concentrações de matéria orgânica e argila fossem previstas de uma maneira rápida e econômica.

Nas metodologias atuais empregadas pelos laboratórios de análise são geradas aproximadamente 100 litros de resíduos perigosos por 1000 amostras processadas em uma rotina analítica diária de 18 horas. Assim, a adoção de metodologias automatizadas baseadas na espectroscopia molecular (infravermelho) e métodos computacionais pode contribuir significativamente para a proposição de rotinas ambientalmente corretas, com alta escalabilidade e economicamente sustentáveis, contribuindo para a expansão da agricultura de precisão.

Vale ressaltar que os dados gerados serviram para avaliar o desempenho do modelo. Todos os modelos utilizaram a Regressão por Mínimos Quadrados Parciais como técnica multivariada devido à relação linear entre os dados e sua propriedade de interesse.

O Tellus-Onto proporcionou a classificação do solo e recomendações de adubação e calagem através de uma ontologia desenvolvida para o setor agrícola no Brasil. Com base nas informações utilizadas foi construída uma ontologia extensível ao AgroRDF para solos brasileiros permitindo a realização de inferências e a representação de entidades no modelo. Uma das características dessa modelagem é a sua forma mais generalista, uma vez que cada país tem suas próprias regras a respeito das classes texturais, permitindo que novos relacionamentos sejam estabelecidos entre os termos, conforme necessário. Através do processo de um *reasoner*, com a utilização de axiomas e de regras baseadas em SWRL, foi possível realizar uma série de inferências precisas e automáticas, assim como consultas em sua base de instâncias provenientes de laudos laboratoriais e dados de históricos de contextos. Este estudo confirmou o potencial da ontologia na agricultura como uma ferramenta eficiente numa plataforma de apoio à decisão.

A mesma ontologia também fornece dados informações do micro-clima da lavoura, permitindo a recomendação de irrigação por diferentes métodos disponíveis na literatura científica. Especificamente para o Tellus, foi empregada uma recomendação baseada em redes neurais convolucionais que demonstraram ter uma acurácia de 82,55%. Para tanto foram utilizadas 192 imagens para treinamento. A disponibilidade dessas informações em dados abertos e conectados permite também a aplicação de insumos agrícolas de forma mais eficaz, evitando assim desperdícios e um melhor equilíbrio com meio ambiente.

Deste modo, foram destacadas as seguintes estratégias de trabalho: desenvolvimento da arquitetura, predição de contextos de infravermelho baseada em aprendizado de máquina, recomendação de irrigação por aprendizado profundo, inferências de recomendação de adubação e calagem, validação dos resultados obtidos.

7.1 Contribuições

Este trabalho contribui na área da informática no setor agrícola de várias maneiras. Primeiramente, apresenta uma revisão sistemática sobre a aplicação da computação ubíqua na agricultura focada em solos. Também mostra um modelo computacional que suporta históricos de contextos que recomendam predições de constituintes relacionados a fertilidade do solo e recomendam a gestão de irrigação.

Esta pesquisa produziu uma ontologia para representar o conhecimento sobre o solo brasileiro com possibilidade de inferir recomendações para um manejo adequado na agricultura de precisão para a região Sul. Apesar de ter sido implementada para a cultura de tabaco, devidos ajustes de parâmetros nos regras semânticas permitiriam sua aplicação para qualquer tipo de lavoura no Brasil como soja, trigo, arroz, entre outras.

As limitações do modelo Tellus podem ser destacadas em relação ao Agente de Predição e as condições de conectividade da lavoura. Uma melhor acurácia na predição depende muito da precisão das análises de referência e de uma melhor resolução dos equipamentos de leitura. É sabido que as análises de referência atuais possuem um erro grande no método, sendo este transferido para o Agente de Predição no momento da correlação por aprendizado de máquina. Mitigar esse efeito adotando tecnologias mais precisas tendem a melhorar o resultado final.

Em relação à recomendação por irrigação, uma acurácia melhor pode ser obtida ao longo do tempo na medida que mais dados de contexto poderiam tornar o modelo de treinamento mais robusto.

Lavouras sem acesso a internet poderiam ser um obstáculo para a implementação do Tellus, apesar promessa de políticas públicas para expansão da conectividade em zonas rurais. Uma opção seria a adoção de internet de neblina, ou de borda, apesar de possuírem um custo necessário de infraestrutura local.

O termo agricultura ubíqua, cunhado no título dessa tese, vem ao encontro da inclusão de aspectos de ubiquidade na agricultura de precisão, uma área da ciência que faz uso de contextos para sua efetiva aplicação. Por fim, com a pesquisa realizada, comprova-se a hipótese de que é possível definir um modelo computacional na agricultura de precisão que faça uso de históricos de contextos de informações de solos e auxilie a otimização do uso de insumos agrícolas.

7.2 Trabalhos futuros

Com base nos resultados obtidos através do estudo de caso, foram encontradas questões que podem ser melhor exploradas em trabalhos futuros. A primeira em relação à predição de matéria orgânica e argila por históricos de contextos. Visando melhoria da capacidade preditiva, sugere-se a construção de modelos de regressão que compreendam faixas menores de concentração e um gerenciamento melhor dos resultados de referências, como análises em mais réplicas.

Outra questão seria a expansão da ontologia para outras culturas, visto que o Brasil é um

dos países líderes em exportação de grãos, como soja, trigo e milho. Para tanto, seriam necessários apenas alguns ajustes nos critérios estabelecidos pelas SWRL's uma vez que elas possuem capacidade de suportar diferentes culturas. Assim, um cenário de dados abertos e conectados poderia envolver toda a cadeia produtiva desses setores agrícolas, otimizando a gestão de processos e padronização das rotinas.

Por fim, o aumento da quantidade de sensores ou estações de telemetria poderia fornecer resultados climáticos mais precisos, uma vez que expandiria a malha de medições. Esse trabalho poderia executado com a utilização uma Rede de Sensores sem Fio, ou WSN, com adoção de protocolos como MQTT e CoAP.

7.3 Publicações

Capítulos ou partes desta tese foram publicados em eventos e periódicos. O mapeamento sistemático foi publicado em 2019 no periódico *Agris on-line* (HELFER et al., 2019a).

O modelo Tellus em sua primeira versão foi apresentado inicialmente no XI Simpósio Brasileiro de Computação Ubíqua e Pervasiva (SBCUP 2019) (HELFER et al., 2019b). Uma versão com históricos de contextos climáticos do Tellus foi apresentada no XV Simpósio Brasileiro de Sistemas Multimídia e Web (WebMedia 2019) (HELFER et al., 2019c). Uma versão mais completa com o uso de 450 amostras de solo analisadas num espectrômetro de bancada e ainda sem as inferências do Tellus-Onto foi publicada no periódico *Computers and Electronics in Agriculture* (HELFER et al., 2020). A inferência para classificação de solos brasileiros foi apresentado no XVII Simpósio Brasileiro de Sistemas de Informação (SBSI 2021) (HELFER et al., 2021a).

O mesmo algoritmo de aprendizado de máquina utilizado no Agente de Predição foi empregado na publicação de Martini et al. (2021). Derivações dessa mesma solução foram utilizadas em diferentes áreas do conhecimento em parceria com outras instituições acadêmicas (Da Costa et al., 2021; HELFER et al., 2022), inclusive determinando diretamente argila em solos por colorimetria em *Smartphones* (HELFER et al., 2021b), trabalho apresentado remotamente no 18th Chemometrics in Analytical Chemistry Conference - Chamonix, França.

O Anexo D apresenta mais informações sobre as publicações.

REFERÊNCIAS

- ABADI, M. et al. **TensorFlow**: large-scale machine learning on heterogeneous systems. Software available from tensorflow.org.
- ABOWD, G. D. et al. Towards a Better Understanding of Context and Context-Awareness. In: **Handheld and Ubiquitous Computing**. [S.l.]: Springer, 1999. p. 304–307.
- ADI, E. et al. Machine learning and data analytics for the IoT. **Neural Computing and Applications**, [S.l.], v. 32, n. 20, p. 16205–16233, may 2020.
- ALI, A. et al. A comprehensive survey on real-time applications of WSN. **Future Internet**, [S.l.], v. 9, n. 4, p. 77, nov 2017.
- ALPAYDIN, E. **Machine learning** : the new ai. Cambridge, MA: MIT Press, 2016.
- ALZU'BI, S. et al. An efficient employment of internet of multimedia things in smart and future agriculture. **Multimedia Tools and Applications**, [S.l.], v. 78, n. 20, p. 29581–29605, feb 2019.
- ANDRÉS, S. et al. Ontology-based classification of remote sensing images using spectral rules. **Computers & Geosciences**, [S.l.], v. 102, p. 158–166, may 2017.
- ANZANELLO, M. J. Seleção de variáveis para classificação de bateladas produtivas com base em múltiplos critérios. **Production**, [S.l.], v. 23, n. 4, p. 858–865, feb 2013.
- ARANDA, J. A. S. et al. A computational model for adaptive recording of vital signs through context histories. **Journal of Ambient Intelligence and Humanized Computing**, [S.l.], mar 2021.
- ASWATHY, R. H.; MALARVIZHI, N. Internet of things (IoT): a survey on protocols and security risks. **International Journal of Engineering & Technology**, [S.l.], v. 7, n. 1.7, p. 15, feb 2018.
- BABOU, C. S. M. et al. Home edge computing architecture for smart and sustainable agriculture and breeding. In: INTERNATIONAL CONFERENCE ON NETWORKING, INFORMATION SYSTEMS & SECURITY - NISS19, 2., 2019. **Proceedings...** ACM Press, 2019.
- BARBOSA, J. 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. 1–14, aug 2018.
- BARBOSA, J. L. V. et al. TrailTrade: a model for trail-aware commerce support. **Computers in Industry**, [S.l.], v. 80, p. 43–53, aug 2016.
- BARRA, I. et al. Predicting cetane number in diesel fuels using FTIR spectroscopy and PLS regression. **Vibrational Spectroscopy**, [S.l.], v. 111, p. 103157, nov 2020.
- BECKETT, D. **RDF/xml syntax specification (revised)**. [S.l.]: W3C, 2004. W3C Recommendation, <https://www.w3.org/TR/2004/REC-rdf-syntax-grammar-20040210/>.

BERNARDI, A. et al. **Agricultura de precisão**: resultados de um novo olhar. manual de métodos de análise de solos. 2. ed. São Carlos - SP: EMBRAPA, Brasília - DF, 2014. 596 p.

BHANU, K.; REDDY, T. B.; HANUMANTHAPPA, M. Multi-agent based context aware information gathering for agriculture using wireless multimedia sensor networks. **Egyptian Informatics Journal**, Amsterdam, The Netherlands, v. 20, n. 1, p. 33–44, mar 2019.

BIKAKIS, N. et al. The XML and semantic web worlds: technologies, interoperability and integration: a survey of the state of the art. In: **Semantic hyper/multimedia adaptation**. [S.l.]: Springer Berlin Heidelberg, 2013. p. 319–360.

BORST, W. **Construction of engineering ontologies for knowledge sharing and reuse**. 1997. Tese (Doutorado em Ciência da Computação) — Centre for Telematics and Information Technology (CTIT), Netherlands, 1997.

BRADY, N. C.; WEIL, R. R. **Elementos da natureza e propriedades dos solos**. Passo Fundo/ RS: Bookmann, 2013. 686 p.

CARMO, D. L. do et al. Electrical conductivity and chemical composition of soil solution: comparison of solution samplers in tropical soils. **Revista Brasileira de Ciência do Solo**, [S.l.], v. 40, 2016.

CHO, Y. et al. Towards a smart service based on a context-aware workflow model in u-agriculture. **International Journal of Web and Grid Services**, [S.l.], v. 7, n. 2, p. 117, 2011.

CHUNG, H. et al. Smart farming education service based on u-learning environment. In: INTERNATIONAL CONFERENCE ON ADVANCED COMMUNICATION TECHNOLOGY (ICACT), 2019., 2019. **Anais...** IEEE, 2019.

CHUNG, S.-H. et al. The mouse approach: mapping ontologies using uml for system engineers. **Computer Reviews Journal**, Punjab, India, v. 1, n. 1, p. 8—29, 2018.

CIARAMELLA, A. et al. Using context history to personalize a resource recommender via a genetic algorithm. In: INTERNATIONAL CONFERENCE ON INTELLIGENT SYSTEMS DESIGN AND APPLICATIONS, 2010., 2010. **Anais...** IEEE, 2010.

CLASSIFICATION, O. O. Birte Glimm and Ian Horrocks and Boris Motik and Giorgos Stoilos. In: INT. SEMANTIC WEB CONF. (ISWC 2010), 9., 2010, Shanghai, China. **Proceedings...** Springer, 2010. p. 225–240. (LNCS, v. 6496).

CONCEPCION, A. R.; STEFANELLI, R.; TRINCHERO, D. A wireless sensor network platform optimized for assisted sustainable agriculture. In: IEEE GLOBAL HUMANITARIAN TECHNOLOGY CONFERENCE (GHTC 2014), 2014. **Anais...** IEEE, 2014. p. 159–165.

COOPER, I. D. What is a “mapping study?”. **Journal of the Medical Library Association : JMLA**, [S.l.], v. 104, n. 1, p. 76–78, jan 2016.

CÓRDOBA, M. et al. Subfield management class delineation using cluster analysis from spatial principal components of soil variables. **Computers and Electronics in Agriculture**, Amsterdam, The Netherlands, v. 97, p. 6–14, sep 2013.

COSBY, B. et al. A statistical exploration of the relationships of soil moisture characteristics to the physical properties of soils. **Water Resources Research**, [S.l.], v. 20, p. 682–690, 1984.

COSTA, N. R. et al. Produtividade de laranja correlacionada com atributos químicos do solo visando a zonas específicas de manejo. **Pesquisa Agropecuária Tropical**, [S.l.], v. 44, n. 4, p. 391–398, dec 2014.

Da Costa, A. B. et al. Photometrix uvc: a new smartphone-based device for digital image colorimetric analysis using pls regression. **Journal of the Brazilian Chemical Society**, [S.l.], v. 32, n. 3, p. 675–683, 2021.

DAMASCENO VIANNA, H. et al. Pompilos onto: an ontology for detecting the spreading of happiness, obesity and smoking in social networks. In: XLII LATIN AMERICAN COMPUTING CONFERENCE (CLEI), 2016., 2016. **Anais...** [S.l.: s.n.], 2016. p. 1–9.

DEB, C. K.; MARWAHA, S.; PANDEY, R. Ontology learning algorithm for development of ontologies from taxonomic text and usda soil taxonomy ontology. **Journal of the Indian Society of Agricultural Statistics**, [S.l.], v. 1, n. 74, p. 77–84, 2020.

DEBAUCHE, O. et al. Edge AI-IoT pivot irrigation, plant diseases, and pests identification. **Procedia Computer Science**, [S.l.], v. 177, p. 40–48, 2020.

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.

DÍAZ, S. E. et al. A novel methodology for the monitoring of the agricultural production process based on wireless sensor networks. **Computers and Electronics in Agriculture**, Amsterdam, The Netherlands, v. 76, n. 2, p. 252–265, may 2011.

DOBRESCU, R.; MEREZEANU, D.; MOCANU, S. Context-aware control and monitoring system with IoT and cloud support. **Computers and Electronics in Agriculture**, Amsterdam, The Netherlands, v. 160, p. 91–99, may 2019.

DOLUSCHITZ, R. et al. agroxml - a standardized data format for information flow in agriculture. In: EFITA/WCCA 2005 JOINT CONFERENCE, 2005. **Proceedings...** Universidade de Trás-os-Montes e Alto Douro, 2005. p. 439–443. (EFITA/WCCA 2005).

DRESCHER, M. **Manual do piloto agrícola**. 1. ed. Porto Alegre-RS: Editora Bianch, 2016. 444 p.

ECK, N. J. van; WALTMAN, L. Software survey: VOSviewer, a computer program for bibliometric mapping. **Scientometrics**, [S.l.], v. 84, n. 2, p. 523–538, dec 2009.

ELUMALAI, M.; ANOUNCIA, S. M. Development of soil mineral classification using ontology mining. **Arabian Journal of Geosciences**, [S.l.], v. 14, n. 14, jul 2021.

FARIAS, T. M. de; ROXIN, A.; NICOLLE, C. SWRL rule-selection methodology for ontology interoperability. **Data & Knowledge Engineering**, [S.l.], v. 105, p. 53–72, sep 2016.

FERREIRA, L. G. et al. Using learner group profiles for content recommendation in ubiquitous environments. **International Journal of Information and Communication Technology Education**, [S.l.], v. 16, n. 4, p. 1–19, oct 2020.

- FERREIRA, M. M. C. **Quimiometria: conceitos, métodos e aplicações**. Campinas-SP: Editora da Unicamp, 2015. 493 p.
- FILIPPETTO, A. et al. A project management model based on an activity theory ontology. In: XLII LATIN AMERICAN COMPUTING CONFERENCE (CLEI), 2016., 2016. **Anais...** IEEE, 2016.
- FILIPPETTO, A. S.; LIMA, R.; BARBOSA, J. L. V. A risk prediction model for software project management based on similarity analysis of context histories. **Information and Software Technology**, [S.l.], v. 131, p. 106497, mar 2021.
- GELOGO, Y. E. et al. Development of u-farm mobile application architecture. In: ADVANCED SCIENCE AND TECHNOLOGY LETTERS, 2014. **Anais...** Science & Engineering Research Support soCiety, 2014.
- GEORGAKOPOULOS, D.; JAYARAMAN, P. P. Internet of things: from internet scale sensing to smart services. **Computing**, [S.l.], v. 98, n. 10, p. 1041–1058, aug 2016.
- GIÁCOMO, R. G. et al. ATRIBUTOS QUÍMICOS e FÍSICOS DO SOLO, ESTOQUES DE CARBONO e NITROGÊNIO e FRAÇÕES HÚMICAS EM DIFERENTES FORMAS VEGETAIS. **Ciência Florestal**, [S.l.], v. 25, n. 3, sep 2015.
- GIAKOUMATOS, S. D. V.; GKIONAKIS, A. K. T. Development of an ontology-based knowledge network by interconnecting soil/water concepts/properties, derived from standards methods and published scientific references outlining infiltration/percolation process of contaminated water. **Journal of Geoscience and Environment Protection**, [S.l.], v. 09, n. 01, p. 25–52, 2021.
- 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.
- GRAU, B. C. et al. OWL 2: the next step for OWL. **Journal of Web Semantics**, [S.l.], v. 6, n. 4, p. 309–322, nov 2008.
- GRIEBELER, G. et al. Avaliação de um programa interlaboratorial de controle de qualidade de resultados de análise de solo. **Revista Ceres**, [S.l.], v. 63, n. 3, p. 371–379, jun 2016.
- GRIMM, S. et al. Ontologies and the semantic web. In: **Handbook of semantic web technologies**. [S.l.]: Springer Berlin Heidelberg, 2011. p. 507–579.
- GRUBER, T. R. A translation approach to portable ontology specifications. **Knowledge Acquisition**, [S.l.], v. 5, n. 2, p. 199–220, jun 1993.
- GUGGENHEIM S.; MARTIN, R. T. Definition of clay and clay mineral: joint report of the AIPEA and CMS nomenclature committees. **Clay Minerals**, [S.l.], v. 30, n. 3, p. 257–259, sep 1995.
- HE, K. et al. Deep residual learning for image recognition. In: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR), 2016., 2016. **Anais...** IEEE, 2016.
- HELPER, G. A. et al. Ubiquitous computing in precision agriculture: a systematic review. **Agris on-line Papers in Economics and Informatics**, [S.l.], v. 11, n. 4, p. 3–13, dec 2019.

- HELPER, G. A. et al. A model for productivity and soil fertility prediction oriented to ubiquitous agriculture. In: XXV SIMPÓSIO BRASILEIRO DE SISTEMAS MULTIMÍDIA E WEB, 2019, Porto Alegre, RS, Brasil. **Anais...** SBC, 2019. p. 489–492.
- HELPER, G. A. et al. A computational model for soil fertility prediction in ubiquitous agriculture. **Computers and Electronics in Agriculture**, [S.l.], v. 175, p. 105602, 2020.
- HELPER, G. A. et al. Multispectral cameras and machine learning integrated into portable devices as clay prediction technology. **Journal of Sensor and Actuator Networks**, [S.l.], v. 10, n. 3, p. 40, jun 2021.
- HELPER, G. A. et al. The application of parallel processing in the selection of spectral variables in beer quality control. **Food Chemistry**, [S.l.], v. 367, p. 130681, jan 2022.
- HELPER, G. et al. 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. **Anais...** Sociedade Brasileira de Computação - SBC, 2019.
- HELPER, G. et al. Tellus-onto: uma ontologia para classificação e inferência de solos na agricultura de precisão. In: XVII SIMPÓSIO BRASILEIRO DE SISTEMAS DE INFORMAÇÃO, 2021, Porto Alegre, RS, Brasil. **Anais...** SBC, 2021.
- HOCHMAN, Z. et al. Prospects for ecological intensification of australian agriculture. **European Journal of Agronomy**, [S.l.], v. 44, p. 109–123, jan 2013.
- HONG, J. et al. Context-aware system for proactive personalized service based on context history. **Expert Systems with Applications**, Amsterdam, The Netherlands, v. 36, n. 4, p. 7448–7457, may 2009.
- HRADECKÁ, I. et al. Rapid determination of diesel fuel properties by near-infrared spectroscopy. **Infrared Physics & Technology**, [S.l.], v. 119, p. 103933, dec 2021.
- HUONG, T. T. et al. Water and energy-efficient irrigation based on markov decision model for precision agriculture. **2018 IEEE Seventh International Conference on Communications and Electronics (ICCE)**, [S.l.], p. 51–56, 2018.
- IDRISSI, B. E. et al. RDF/OWL storage and management in relational database management systems: a comparative study. **Journal of King Saud University - Computer and Information Sciences**, [S.l.], oct 2021.
- INC., I. **Pirouette user guide**. Pirouette Multivariate Data Analysis Software - v. 4.5.
- JANARDHANAN, P. Project repositories for machine learning with TensorFlow. **Procedia Computer Science**, [S.l.], v. 171, p. 188–196, 2020.
- JAVAID, N. Integration of context awareness in internet of agricultural things. **ICT Express**, [S.l.], sep 2021.
- JEARANAIWONGKUL, W.; ANDRES, F.; ANUTARIYA, C. A formal model for managing multiple observation data in agriculture. **International Journal of Intelligent Information Technologies**, [S.l.], v. 15, n. 3, p. 79–100, jul 2019.
- JONES, J. N.; SPARROW, G. N.; MILES, J. D. Principles of tobacco irrigation. **Agricultural Research Service - USDA**, Washington, D.C., p. 16, aug 1960.

KALOXYLOS, A. et al. Farm management systems and the future internet era. **Computers and Electronics in Agriculture**, Amsterdam, The Netherlands, v. 89, p. 130–144, nov 2012.

KALOXYLOS, A. et al. A cloud-based farm management system: architecture and implementation. **Computers and Electronics in Agriculture**, Amsterdam, The Netherlands, v. 100, p. 168–179, jan 2014.

KARPATY, A. et al. Large-scale video classification with convolutional neural networks. In: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2014., 2014. **Anais...** IEEE, 2014.

KESHAV, S. How to read a paper. **ACM SIGCOMM Computer Communication Review**, [S.l.], v. 37, n. 3, p. 83–84, jul 2007.

KESWANI, B. et al. Adapting weather conditions based IoT enabled smart irrigation technique in precision agriculture mechanisms. **Neural Computing and Applications**, [S.l.], v. 31, n. S1, p. 277–292, jan 2019.

KETTERINGS, Q. M.; BIGHAM, J. M. Soil Color as an Indicator of Slash-and-Burn Fire Severity and Soil Fertility in Sumatra, Indonesia. **Soil Science Society of America Journal**, [S.l.], v. 64, n. 5, p. 1826–1833, sep 2000.

KLEIN, V. A. **Física do solo**. Passo Fundo/ RS: Universidade de Passo Fundo, 2014. 263 p.

KOTIS, K. I.; VOUIROS, G. A.; SPILIOTOPOULOS, D. Ontology engineering methodologies for the evolution of living and reused ontologies: status, trends, findings and recommendations. **The Knowledge Engineering Review**, [S.l.], v. 35, p. e4, 2020.

KOWALSKI, B. R. Measurement analysis by pattern recognition. **Analytical Chemistry**, [S.l.], v. 47, n. 13, p. 1152A–1162a, Nov. 1975.

KUMAR, P. et al. Micro-climate prediction - multi scale encoder-decoder based deep learning framework. In: ACM SIGKDD CONFERENCE ON KNOWLEDGE DISCOVERY & DATA MINING, 27., 2021. **Proceedings...** ACM, 2021.

LAMY, J.-B. Owlready: ontology-oriented programming in python with automatic classification and high level constructs for biomedical ontologies. **Artificial Intelligence in Medicine**, [S.l.], v. 80, p. 11–28, jul 2017.

LARENTIS, A. V. et al. Ontology-based reasoning for educational assistance in noncommunicable chronic diseases. **Computers**, [S.l.], v. 10, n. 10, p. 128, oct 2021.

LEE, H. chul et al. A study on energy efficient MAC protocol of wireless sensor network for ubiquitous agriculture. In: **Future generation information technology**. [S.l.]: Springer Berlin Heidelberg, 2010. p. 642–650.

LI, M. et al. Quantitative analysis of polycyclic aromatic hydrocarbons in soil by infrared spectroscopy combined with hybrid variable selection strategy and partial least squares. **Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy**, [S.l.], v. 257, p. 119771, aug 2021.

LI, Y.; VIA, B. K.; LI, Y. Lifting wavelet transform for vis-NIR spectral data optimization to predict wood density. **Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy**, [S.l.], v. 240, p. 118566, oct 2020.

LIMA, R. et al. Towards ubiquitous requirements engineering through recommendations based on context histories. **PeerJ Computer Science**, [S.l.], v. 8, p. e794, jan 2022.

LIU, Y. et al. Near-infrared prediction of edible oil frying times based on bayesian ridge regression. **Optik**, [S.l.], v. 218, p. 164950, sep 2020.

LOPES, J. et al. An architectural model for situation awareness in ubiquitous computing. **IEEE Latin America Transactions**, [S.l.], v. 12, n. 6, p. 1113–1119, sep 2014.

LTD, S. Q. P. **Measuring soil texture in the laboratory**. 2021.

MACHADO, S. D. et al. Ambient intelligence based on IoT for assisting people with alzheimer's disease through context histories. **Electronics**, [S.l.], v. 10, n. 11, p. 1260, may 2021.

MAO, S. et al. Ubiquitous computing. In: **Digital health**. [S.l.]: Elsevier, 2021. p. 211–230.

MARTINI, B. G. et al. IndoorPlant: a model for intelligent services in indoor agriculture based on context histories. **Sensors**, [S.l.], v. 21, n. 5, p. 1631, feb 2021.

MCGUINNESS, D.; HARMELEN, F. van. **OWL web ontology language overview**. [S.l.]: W3C, 2004. W3C Recommendation, <https://www.w3.org/TR/2004/REC-owl-features-20040210/>.

MEDICI, M. et al. A web-tool for calculating the economic performance of precision agriculture technology. **Computers and Electronics in Agriculture**, [S.l.], v. 181, p. 105930, feb 2021.

MESHARAM, V. et al. Machine learning in agriculture domain: a state-of-art survey. **Artificial Intelligence in the Life Sciences**, [S.l.], v. 1, p. 100010, dec 2021.

MIRANDA, J. et al. Composição química da solução de solo sob diferentes coberturas vegetais e análise de carbono orgânico solúvel no deflúvio de pequenos cursos de água. **Revista Brasileira de Ciência do Solo**, [S.l.], v. 30, n. 4, p. 633–647, aug 2006.

MORENO-MAROTO, J. M.; ALONSO-AZCÁRATE, J. What is clay? a new definition of “clay” based on plasticity and its impact on the most widespread soil classification systems. **Applied Clay Science**, [S.l.], v. 161, p. 57–63, sep 2018.

MUÑOZ, J. D.; KRAVCHENKO, A. Soil carbon mapping using on-the-go near infrared spectroscopy, topography and aerial photographs. **Geoderma**, [S.l.], v. 166, n. 1, p. 102–110, 2011.

MUSEN, M. A. The protégé project. **AI Matters**, [S.l.], v. 1, n. 4, p. 4–12, jun 2015.

MUÑOZ, A.; SORIANO-DISLA, J. M.; JANIK, L. J. An ontology-based approach for an efficient selection and classification of soils. **Ambient Intelligence and Smart Environments**, [S.l.], v. 22, n. Intelligent Environments 2017, p. 69–78, 2017.

NASH, E.; KORDUAN, P.; BILL, R. Applications of open geospatial web services in precision agriculture: a review. **Precision Agriculture**, [S.l.], v. 10, n. 6, p. 546–560, aug 2009.

- NAWAR, S.; MOUAZEN, A. On-line vis-nir spectroscopy prediction of soil organic carbon using machine learning. **Soil and Tillage Research**, [S.l.], v. 190, p. 120 – 127, 2019.
- NDZI, D. L. et al. Wireless sensor network coverage measurement and planning in mixed crop farming. **Computers and Electronics in Agriculture**, Amsterdam, The Netherlands, v. 105, p. 83–94, jul 2014.
- NIGUSSIE, E. et al. IoT-based irrigation management for smallholder farmers in rural sub-saharan africa. **Procedia Computer Science**, [S.l.], v. 177, p. 86–93, 2020.
- NOY, N.; MCGUINNESS, D. Ontology development 101: a guide to creating your first ontology. **Knowledge Systems Laboratory**, [S.l.], v. 32, p. 26, 01 2001.
- PARISI, E. I. et al. AERIAL PLATFORMS (UAV) SURVEYS IN THE VIS AND TIR RANGE. APPLICATIONS ON ARCHAEOLOGY AND AGRICULTURE. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, [S.l.], v. XLII-2/W11, p. 945–952, may 2019.
- PERERA, C. et al. Context aware computing for the internet of things: a survey. **IEEE Communications Surveys & Tutorials**, [S.l.], v. 16, n. 1, p. 414–454, 2014.
- PETERSEN, K. et al. Systematic mapping studies in software engineering. In: INTERNATIONAL CONFERENCE ON EVALUATION AND ASSESSMENT IN SOFTWARE ENGINEERING, 12., 2008, Swindon, GBR. **Proceedings...** BCS Learning & Development Ltd., 2008. p. 68–77. (EASE'08).
- 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, aug 2015.
- PHAM, V.; WEINDORF, D. C.; DANG, T. Soil profile analysis using interactive visualizations, machine learning, and deep learning. **Computers and Electronics in Agriculture**, [S.l.], v. 191, p. 106539, dec 2021.
- PHILLIPS, A. J. et al. Integrated sensing of soil moisture at the field-scale: measuring, modeling and sharing for improved agricultural decision support. **Computers and Electronics in Agriculture**, Amsterdam, The Netherlands, v. 107, p. 73–88, sep 2014.
- PRADEEP, P.; KRISHNAMOORTHY, S.; VASILAKOS, A. V. A holistic approach to a context-aware IoT ecosystem with adaptive ubiquitous middleware. **Pervasive and Mobile Computing**, [S.l.], v. 72, p. 101342, apr 2021.
- PROJEKT iGreen. **Welcome to the agrordf rdflib lod server**. 2012.
- RAWAT, P. et al. Wireless sensor networks: a survey on recent developments and potential synergies. **The Journal of Supercomputing**, [S.l.], v. 68, n. 1, p. 1–48, jan 2014.
- RODIĆ, L. D. et al. Machine learning and soil humidity sensing: signal strength approach. **ACM Transactions on Internet Technology**, [S.l.], v. 22, n. 2, p. 1–21, may 2022.
- ROSA, J. H. da; BARBOSA, J. L.; RIBEIRO, G. D. ORACON: an adaptive model for context prediction. **Expert Systems with Applications**, Amsterdam, The Netherlands, v. 45, p. 56–70, mar 2016.

- ROSA, J. H. et al. A multi-temporal context-aware system for competences management. **International Journal of Artificial Intelligence in Education**, [S.l.], v. 25, n. 4, p. 455–492, jun 2015.
- ROSSEL, R. V. et al. A global spectral library to characterize the world's soil. **Earth-Science Reviews**, [S.l.], v. 155, p. 198–230, apr 2016.
- SABRI, N. et al. Smart prolong fuzzy wireless sensor-actor network for agricultural application. **Journal of Information Science and Engineering**, [S.l.], v. 28, n. 2, p. 295–316, 2012.
- SAMUEL-ROSA, A. et al. The effect of intrinsic soil properties on soil quality assessments. **Revista Brasileira de Ciência do Solo**, [S.l.], v. 37, n. 5, p. 1236–1244, oct 2013.
- SANTOS, R. dos et al. **Manual de descrição e coleta de solo no campo**. 5. ed. Viçosa-MG: Sociedade Brasileira de Ciência do Solo – Centro Nacional de Pesquisa de Solos, 2005. 100 p.
- SANTOS, U. J. L.; ROSA RIGHI, R. da; COSTA, C. A. da. Compreendendo o desempenho de gerenciadores de contexto para internet das coisas. In: SIMPÓSIO BRASILEIRO DE COMPUTAÇÃO UBÍQUA E PERVASIVA (SBCUP), 10., 2018, Porto Alegre, RS, Brasil. **Anais...** SBC, 2018. v. 10.
- SAP AG. **Standardized technical architecture and modeling - conceptual and design level**. http://www.fmc-modeling.org/download/fmc-and-tam/SAP-TAM_Standard.pdf Accessed 23-Jan-2019.
- SATYANARAYANAN, M. Pervasive computing: vision and challenges. **IEEE Personal Communications**, [S.l.], v. 8, n. 4, p. 10–17, 2001.
- SBCS. **Manual de calagem e adubação para os estados do rio grande do sul e de santa catarina**. 11. ed. Porto Alegre-RS: Sociedade Brasileira de Ciência do Solo – Núcleo Regional Sul - Comissão de Química e Fertilidade do Solo, 2016. 376 p.
- SCHILIT, B.; THEIMER, M. Disseminating active map information to mobile hosts. **IEEE Network**, [S.l.], v. 8, n. 5, p. 22–32, sep 1994.
- SCHUSTER, E. W. et al. Machine-to-machine communication for agricultural systems: an XML-based auxiliary language to enhance semantic interoperability. **Computers and Electronics in Agriculture**, Amsterdam, The Netherlands, v. 78, n. 2, p. 150–161, sep 2011.
- SHANKHDHAR, G. K.; SHARMA, R.; DARBARI, M. SAGRO-lite: a light weight agent based semantic model for the internet of things for smart agriculture in developing countries. In: **Semantic IoT: theory and applications**. Cham: Springer International Publishing, 2021. p. 265–302.
- SHAO, J.; MENG, W.; SUN, G. Evaluation of missing value imputation methods for wireless soil datasets. **Personal and Ubiquitous Computing**, [S.l.], v. 21, n. 1, p. 113–123, jan 2017.
- SHARMA, A. et al. Towards trustworthy internet of things: a survey on trust management applications and schemes. **Computer Communications**, [S.l.], v. 160, p. 475–493, jul 2020.
- SHEN, H. et al. Irrigation decision method for winter wheat growth period in a supplementary irrigation area based on a support vector machine algorithm. **Computers and Electronics in Agriculture**, [S.l.], v. 182, p. 106032, mar 2021.

SHEN, Z. et al. When RSSI encounters deep learning: an area localization scheme for pervasive sensing systems. **Journal of Network and Computer Applications**, [S.l.], v. 173, p. 102852, jan 2021.

SHI, H.-L. et al. A task execution framework for cloud-assisted sensor networks. **Journal of Computer Science and Technology**, [S.l.], v. 29, n. 2, p. 216–226, mar 2014.

SILVA, L. G. da et al. ULearnEnglish: an open ubiquitous system for assisting in learning english vocabulary. **Electronics**, [S.l.], v. 10, n. 14, p. 1692, jul 2021.

SILVA, N. M. D.; TADRA, R. M. S. **Geologia e pedologia**. Curitiba: InterSaber, 2017. 320 p.

SIMBEYE, D. S. Deployment of wireless sensor networks for soil macronutrients measurements in farms. **International Journal of ICT Research in Africa and the Middle East**, [S.l.], v. 5, n. 2, p. 25–37, jul 2016.

SIRIN, E. et al. Pellet: a practical OWL-DL reasoner. **Journal of Web Semantics**, [S.l.], v. 5, n. 2, p. 51–53, jun 2007.

SIVAMANI, S.; BAE, N.; CHO, Y. A smart service model based on ubiquitous sensor networks using vertical farm ontology. **International Journal of Distributed Sensor Networks**, [S.l.], v. 9, n. 12, p. 161495, dec 2013.

SIVAMANI, S. et al. A smart service model in greenhouse environment using event-based security based on wireless sensor network. **Concurrency and Computation: Practice and Experience**, [S.l.], v. 30, n. 2, p. e4240, jan 2018.

SOLO SBCS, S. B. de Ciência do. **Cela - sbcs**. 2019.

SOLO SBCS, S. B. de Ciência do. **Sbcs - núcleo região sul**. 2020.

SOLOS, E. **Tecnologia inovadora analisa solos em apenas 30 segundos - portal embrapa**. 2016.

STEINBERGER, G.; ROTHMUND, M.; AUERNHAMMER, H. Mobile farm equipment as a data source in an agricultural service architecture. **Computers and Electronics in Agriculture**, Amsterdam, The Netherlands, v. 65, n. 2, p. 238–246, mar 2009.

STOJANOVIC, V. et al. Streaming and 3d mapping of AGRI-data on mobile devices. **Computers and Electronics in Agriculture**, Amsterdam, The Netherlands, v. 138, p. 188–199, jun 2017.

STRECK, E. V. et al. **Solos do rio grande do sul**. 2. ed. EMATER/RS-ASCAR, FAEPE: UFRGS, 2008. 222 p.

SYMEONAKI, E.; ARVANITIS, K.; PIROMALIS, D. A context-aware middleware cloud approach for integrating precision farming facilities into the IoT toward agriculture 4.0. **Applied Sciences**, [S.l.], v. 10, n. 3, p. 813, jan 2020.

SZEGEDY, C. et al. Going deeper with convolutions. In: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR), 2015., 2015. **Anais...** IEEE, 2015.

TEDESCO, M. et al. **Análise de solo, plantas e outros materiais**. 2. ed. Porto Alegre: UFRGS/Departamento de Solos, 1995. 174 p.

TEIXEIRA, P. C. et al. **Manual de métodos de análise de solo**. 3. ed. Brasília - DF: EMBRAPA, Brasília - DF, 2017. 573 p.

Texas Instruments Incorporated. **Dlp nirscan nano evm user's guide user's guide**. Literature Number: DLPU030G.

TREBOUX, J.; GENOUD, D. Improved machine learning methodology for high precision agriculture. **2018 Global Internet of Things Summit (GIoTS)**, [S.l.], p. 1–6, 2018.

TSAKIRIDIS, N. L. et al. Simultaneous prediction of soil properties from VNIR-SWIR spectra using a localized multi-channel 1-d convolutional neural network. **Geoderma**, [S.l.], v. 367, p. 114208, may 2020.

TZOUNIS, A. et al. Internet of things in agriculture, recent advances and future challenges. **Biosystems Engineering**, Amsterdam, The Netherlands, v. 164, p. 31–48, dec 2017.

VALMORBIDA, W. et al. U-library: an intelligent model for ubiquitous library support. **The Computer Journal**, [S.l.], v. 59, n. 9, p. 1330–1344, nov 2015.

VIANNA, H. D.; BARBOSA, J. L. V. In search of computer-aided social support in non-communicable diseases care. **Telematics and Informatics**, Amsterdam, The Netherlands, v. 34, n. 8, p. 1419–1432, dec 2017.

VIANNA, H. D.; BARBOSA, J. L. V. A scalable model for building context-aware applications for noncommunicable diseases prevention. **Information Processing Letters**, [S.l.], v. 148, p. 1–6, aug 2019.

VIEGAS, F. et al. UFollower: a model for smart cities based on ubiquitous security and surveillance. **IEEE Latin America Transactions**, [S.l.], v. 19, n. 12, p. 2019–2027, dec 2021.

VIJ, A. et al. IoT and machine learning approaches for automation of farm irrigation system. **Procedia Computer Science**, [S.l.], v. 167, p. 1250–1257, 2020.

WEISER, M. The computer for the 21st century. **ACM SIGMOBILE Mobile Computing and Communications Review**, [S.l.], v. 3, n. 3, p. 3–11, jul 1999.

WIEDEMANN, T. et al. SIMCOP: a framework for similarity analysis of context histories. **International Journal of Business Information Systems**, [S.l.], v. 1, n. 1, p. 1, 2020.

WIESMEIER, M. et al. Soil organic carbon storage as a key function of soils - a review of drivers and indicators at various scales. **Geoderma**, [S.l.], v. 333, p. 149–162, jan 2019.

WISE, B. M.; KOWALSKI, B. R. Process chemometrics. In: **Process analytical chemistry**. [S.l.]: Springer Netherlands, 1995. p. 259–312.

ZAHOOR, S.; MIR, R. N. Resource management in pervasive internet of things: a survey. **Journal of King Saud University - Computer and Information Sciences**, [S.l.], v. 33, n. 8, p. 921–935, oct 2021.

ZHANG, X. et al. DeepSpectra: an end-to-end deep learning approach for quantitative spectral analysis. **Analytica Chimica Acta**, [S.l.], v. 1058, p. 48–57, jun 2019.

ANEXO A – REGRAS SEMÂNTICAS - TELLUS-ONTO

Cec_High_Rule: (SoilCEC, ?c) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:greaterThan(?ctc, 15) ∧ swrlb:lessThanOrEqualTo(?ctc, 30) → (Level_of_CEC, ?c, "High")

Cec_Low_Rule: (SoilCEC, ?c) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:lessThanOrEqualTo(?ctc, 7.5) → (Level_of_CEC, ?c, "Low")

Cec_Medium_Rule: (SoilCEC, ?c) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:greaterThan(?ctc, 7.5) ∧ swrlb:lessThanOrEqualTo(?ctc, 15) → (Level_of_CEC, ?c, "Medium")

Cec_VeryHigh_Rule: (SoilCEC, ?c) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:greaterThan(?ctc, 30) → (Level_of_CEC, ?c, "Very High")

Clay_Rule1: (ClayTexture, ?ct) ∧ (clayConcentration, ?ct) ∧ (?clay) ∧ swrlb:greaterThan(?clay, 60) → (Class_of_Clay, ?ct, "Class1")

Clay_Rule2: (ClayTexture, ?ct) ∧ (clayConcentration, ?ct) ∧ (?clay) ∧ swrlb:greaterThan(?clay, 40) ∧ swrlb:lessThanOrEqualTo(?clay, 60) → (Class_of_Clay, ?ct, "Class2")

Clay_Rule3: (ClayTexture, ?ct) ∧ (clayConcentration, ?ct) ∧ (?clay) ∧ swrlb:greaterThan(?clay, 20) ∧ swrlb:lessThanOrEqualTo(?clay, 40) → (Class_of_Clay, ?ct, "Class3")

Clay_Rule4: (ClayTexture, ?ct) ∧ (clayConcentration, ?ct) ∧ (?clay) ∧ swrlb:lessThanOrEqualTo(?clay, 20) → (Class_of_Clay, ?ct, "Class4")

K_High_Rule1: (SoilCEC, ?c) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:lessThanOrEqualTo(?ctc, 7.5) ∧ (SoilPotassium, ?k) ∧ (potassiumConcentration, ?k, ?kc) ∧ swrlb:greaterThan(?kc, 45) ∧ swrlb:lessThanOrEqualTo(?kc, 90) → (Level_of_Potassium, ?k, "High")

K_High_Rule2: (SoilCEC, ?c) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:greaterThan(?ctc, 7.5) ∧ swrlb:lessThanOrEqualTo(?ctc, 15) ∧ (SoilPotassium, ?k) ∧ (potassiumConcentration, ?k, ?kc) ∧ swrlb:greaterThan(?kc, 60) ∧ swrlb:lessThanOrEqualTo(?kc, 120) → (Level_of_Potassium, ?k, "High")

K_High_Rule3: (SoilCEC, ?c) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:greaterThan(?ctc, 15) ∧ swrlb:lessThanOrEqualTo(?ctc, 30) ∧ (SoilPotassium, ?k) ∧ (potassiumConcentration, ?k, ?kc) ∧ swrlb:greaterThan(?kc, 90) ∧ swrlb:lessThanOrEqualTo(?kc, 180) → (Level_of_Potassium, ?k, "High")

K_High_Rule4: (SoilCEC, ?c) \wedge (cecConcentration, ?c, ?ctc) \wedge swrlb:greaterThan(?ctc, 30) \wedge (SoilPotassium, ?k) \wedge (potassiumConcentration, ?k, ?kc) \wedge swrlb:greaterThan(?kc, 105) \wedge swrlb:lessThanOrEqualTo(?kc, 210) \rightarrow (Level_of_Potassium, ?k, "High")

K_Low_Rule1: (SoilCEC, ?c) \wedge (cecConcentration, ?c, ?ctc) \wedge swrlb:lessThanOrEqualTo(?ctc, 7.5) \wedge (SoilPotassium, ?k) \wedge (potassiumConcentration, ?k, ?kc) \wedge swrlb:greaterThan(?kc, 15) \wedge swrlb:lessThanOrEqualTo(?kc, 30) \rightarrow (Level_of_Potassium, ?k, "Low")

K_Low_Rule2: (SoilCEC, ?c) \wedge (cecConcentration, ?c, ?ctc) \wedge swrlb:greaterThan(?ctc, 7.5) \wedge swrlb:lessThanOrEqualTo(?ctc, 15) \wedge (SoilPotassium, ?k) \wedge (potassiumConcentration, ?k, ?kc) \wedge swrlb:greaterThan(?kc, 20) \wedge swrlb:lessThanOrEqualTo(?kc, 40) \rightarrow (Level_of_Potassium, ?k, "Low")

K_Low_Rule3: swrlb:greaterThan(?ctc, 15) \wedge (potassiumConcentration, ?k, ?kc) \wedge (cecConcentration, ?c, ?ctc) \wedge swrlb:lessThanOrEqualTo(?ctc, 30) \wedge (SoilPotassium, ?k) \wedge (SoilCEC, ?c) \wedge swrlb:greaterThan(?kc, 30) \wedge swrlb:lessThanOrEqualTo(?kc, 60) \rightarrow (Level_of_Potassium, ?k, "Low")

K_Low_Rule4: (SoilCEC, ?c) \wedge (cecConcentration, ?c, ?ctc) \wedge swrlb:greaterThan(?ctc, 30) \wedge (SoilPotassium, ?k) \wedge (potassiumConcentration, ?k, ?kc) \wedge swrlb:greaterThan(?kc, 35) \wedge swrlb:lessThanOrEqualTo(?kc, 70) \rightarrow (Level_of_Potassium, ?k, "Low")

K_Medium_Rule1: (SoilCEC, ?c) \wedge (cecConcentration, ?c, ?ctc) \wedge swrlb:lessThanOrEqualTo(?ctc, 7.5) \wedge (SoilPotassium, ?k) \wedge (potassiumConcentration, ?k, ?kc) \wedge swrlb:greaterThan(?kc, 30) \wedge swrlb:lessThanOrEqualTo(?kc, 45) \rightarrow (Level_of_Potassium, ?k, "Medium")

K_Medium_Rule2: (SoilCEC, ?c) \wedge (cecConcentration, ?c, ?ctc) \wedge swrlb:greaterThan(?ctc, 7.5) \wedge swrlb:lessThanOrEqualTo(?ctc, 15) \wedge (SoilPotassium, ?k) \wedge (potassiumConcentration, ?k, ?kc) \wedge swrlb:greaterThan(?kc, 40) \wedge swrlb:lessThanOrEqualTo(?kc, 60) \rightarrow (Level_of_Potassium, ?k, "Medium")

K_Medium_Rule3: (SoilCEC, ?c) \wedge (cecConcentration, ?c, ?ctc) \wedge swrlb:greaterThan(?ctc, 15) \wedge swrlb:lessThanOrEqualTo(?ctc, 30) \wedge (SoilPotassium, ?k) \wedge (potassiumConcentration, ?k, ?kc) \wedge swrlb:greaterThan(?kc, 60) \wedge swrlb:lessThanOrEqualTo(?kc, 90) \rightarrow (Level_of_Potassium, ?k, "Medium")

K_Medium_Rule4: (SoilCEC, ?c) \wedge (cecConcentration, ?c, ?ctc) \wedge swrlb:greaterThan(?ctc, 30) \wedge (SoilPotassium, ?k) \wedge (potassiumConcentration, ?k, ?kc) \wedge swrlb:greaterThan(?kc, 70) \wedge swrlb:lessThanOrEqualTo(?kc, 105) \rightarrow (Level_of_Potassium, ?k, "Medium")

K_Recomm_Rule01: (SoilCEC, ?c) ∧ (cecConcentration, ?c, ?ctc) ∧ (SoilPotassium, ?k) ∧ swrlb:lessThanOrEqualTo(?kc, 15) ∧ swrlb:lessThanOrEqualTo(?ctc, 7.5) ∧ (potassiumConcentration, ?k, ?kc) → (Recommendation_of_Potassium, ?k, "200")

K_Recomm_Rule02: (SoilCEC, ?c) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:greaterThan(?ctc, 7.5) ∧ swrlb:lessThanOrEqualTo(?ctc, 15) ∧ (SoilPotassium, ?k) ∧ (potassiumConcentration, ?k, ?kc) ∧ swrlb:lessThanOrEqualTo(?kc, 20) → (Recommendation_of_Potassium, ?k, "200")

K_Recomm_Rule03: swrlb:greaterThan(?ctc, 15) ∧ (potassiumConcentration, ?k, ?kc) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:lessThanOrEqualTo(?ctc, 30) ∧ swrlb:lessThanOrEqualTo(?kc, 30) ∧ (SoilPotassium, ?k) ∧ (SoilCEC, ?c) → (Recommendation_of_Potassium, ?k, "200")

K_Recomm_Rule04: (SoilCEC, ?c) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:greaterThan(?ctc, 30) ∧ (SoilPotassium, ?k) ∧ (potassiumConcentration, ?k, ?kc) ∧ swrlb:lessThanOrEqualTo(?kc, 35) → (Recommendation_of_Potassium, ?k, "200")

K_Recomm_Rule05: (SoilCEC, ?c) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:lessThanOrEqualTo(?ctc, 7.5) ∧ (SoilPotassium, ?k) ∧ (potassiumConcentration, ?k, ?kc) ∧ swrlb:greaterThan(?kc, 15) ∧ swrlb:lessThanOrEqualTo(?kc, 30) → (Recommendation_of_Potassium, ?k, "160")

K_Recomm_Rule06: (SoilCEC, ?c) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:greaterThan(?ctc, 7.5) ∧ swrlb:lessThanOrEqualTo(?ctc, 15) ∧ (SoilPotassium, ?k) ∧ (potassiumConcentration, ?k, ?kc) ∧ swrlb:greaterThan(?kc, 20) ∧ swrlb:lessThanOrEqualTo(?kc, 40) → (Recommendation_of_Potassium, ?k, "160")

K_Recomm_Rule07: swrlb:greaterThan(?ctc, 15) ∧ (potassiumConcentration, ?k, ?kc) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:lessThanOrEqualTo(?ctc, 30) ∧ (SoilPotassium, ?k) ∧ (SoilCEC, ?c) ∧ swrlb:greaterThan(?kc, 30) ∧ swrlb:lessThanOrEqualTo(?kc, 60) → (Recommendation_of_Potassium, ?k, "160")

K_Recomm_Rule08: (SoilCEC, ?c) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:greaterThan(?ctc, 30) ∧ (SoilPotassium, ?k) ∧ (potassiumConcentration, ?k, ?kc) ∧ swrlb:greaterThan(?kc, 35) ∧ swrlb:lessThanOrEqualTo(?kc, 70) → (Recommendation_of_Potassium, ?k, "160")

K_Recomm_Rule09: (SoilCEC, ?c) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:lessThanOrEqualTo(?ctc, 7.5) ∧ (SoilPotassium, ?k) ∧ (potassiumConcentration, ?k, ?kc) ∧ swrlb:greaterThan(?kc, 30) ∧ swrlb:lessThanOrEqualTo(?kc, 45) → (Recommendation_of_Potassium, ?k, "140")

K_Recomm_Rule10: (SoilCEC, ?c) ∧ (cecConcentration, ?c, ?ctc) ∧ (SoilPotassium, ?k) ∧

swrlb:greaterThan(?ctc, 7.5) \wedge swrlb:lessThanOrEqualTo(?ctc, 15) \wedge (potassiumConcentration, ?k, ?kc) \wedge swrlb:greaterThan(?kc, 40) \wedge swrlb:lessThanOrEqualTo(?kc, 60) \rightarrow (Recommendation_of_Potassium, ?k, "140")

K_Recomm_Rule11: (SoilCEC, ?c) \wedge (cecConcentration, ?c, ?ctc) \wedge swrlb:greaterThan(?ctc, 15) \wedge swrlb:lessThanOrEqualTo(?ctc, 30) \wedge (SoilPotassium, ?k) \wedge (potassiumConcentration, ?k, ?kc) \wedge swrlb:greaterThan(?kc, 60) \wedge swrlb:lessThanOrEqualTo(?kc, 90) \rightarrow (Recommendation_of_Potassium, ?k, "140")

K_Recomm_Rule12: (SoilCEC, ?c) \wedge (cecConcentration, ?c, ?ctc) \wedge swrlb:greaterThan(?ctc, 30) \wedge (SoilPotassium, ?k) \wedge (potassiumConcentration, ?k, ?kc) \wedge swrlb:greaterThan(?kc, 70) \wedge swrlb:lessThanOrEqualTo(?kc, 105) \rightarrow (Recommendation_of_Potassium, ?k, "140")

K_Recomm_Rule13: (SoilCEC, ?c) \wedge (cecConcentration, ?c, ?ctc) \wedge swrlb:lessThanOrEqualTo(?ctc, 7.5) \wedge (SoilPotassium, ?k) \wedge (potassiumConcentration, ?k, ?kc) \wedge swrlb:greaterThan(?kc, 45) \wedge swrlb:lessThanOrEqualTo(?kc, 90) \rightarrow (Recommendation_of_Potassium, ?k, "120")

K_Recomm_Rule14: (cecConcentration, ?c, ?ctc) \wedge (SoilPotassium, ?k) \wedge swrlb:greaterThan(?ctc, 7.5) \wedge swrlb:greaterThan(?ctc, 15) \wedge (potassiumConcentration, ?k, ?kc) \wedge swrlb:greaterThan(?kc, 60) \wedge swrlb:lessThanOrEqualTo(?kc, 120) \wedge (SoilCEC, ?c) \rightarrow (Recommendation_of_Potassium, ?k, "120")

K_Recomm_Rule15: (SoilCEC, ?c) \wedge (cecConcentration, ?c, ?ctc) \wedge swrlb:greaterThan(?ctc, 15) \wedge swrlb:lessThanOrEqualTo(?ctc, 30) \wedge (SoilPotassium, ?k) \wedge (potassiumConcentration, ?k, ?kc) \wedge swrlb:greaterThan(?kc, 90) \wedge swrlb:lessThanOrEqualTo(?kc, 180) \rightarrow (Recommendation_of_Potassium, ?k, "120")

K_Recomm_Rule16: (SoilCEC, ?c) \wedge (cecConcentration, ?c, ?ctc) \wedge swrlb:greaterThan(?ctc, 30) \wedge (SoilPotassium, ?k) \wedge (potassiumConcentration, ?k, ?kc) \wedge swrlb:greaterThan(?kc, 105) \wedge swrlb:lessThanOrEqualTo(?kc, 210) \rightarrow (Recommendation_of_Potassium, ?k, "120")

K_Recomm_Rule17: (SoilCEC, ?c) \wedge (cecConcentration, ?c, ?ctc) \wedge swrlb:lessThanOrEqualTo(?ctc, 7.5) \wedge (SoilPotassium, ?k) \wedge (potassiumConcentration, ?k, ?kc) \wedge swrlb:greaterThan(?kc, 90) \rightarrow (Recommendation_of_Potassium, ?k, " ≤ 105 ")

K_Recomm_Rule18: (SoilCEC, ?c) \wedge (cecConcentration, ?c, ?ctc) \wedge swrlb:greaterThan(?ctc, 7.5) \wedge swrlb:lessThanOrEqualTo(?ctc, 15) \wedge (SoilPotassium, ?k) \wedge (potassiumConcentration, ?k, ?kc) \wedge swrlb:greaterThan(?kc, 120) \rightarrow (Recommendation_of_Potassium, ?k, " ≤ 105 ")

K_Recomm_Rule19: (SoilCEC, ?c) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:greaterThan(?ctc, 15) ∧ swrlb:lessThanOrEqualTo(?ctc, 30) ∧ (SoilPotassium, ?k) ∧ (potassiumConcentration, ?k, ?kc) ∧ swrlb:greaterThan(?kc, 180) → (Recommendation_of_Potassium, ?k, "≤ 105")

K_Recomm_Rule20: (SoilCEC, ?c) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:greaterThan(?ctc, 30) ∧ (SoilPotassium, ?k) ∧ (potassiumConcentration, ?k, ?kc) ∧ swrlb:greaterThan(?kc, 210) → (Recommendation_of_Potassium, ?k, "≤ 105")

K_VeryHigh_Rule1: (SoilCEC, ?c) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:lessThanOrEqualTo(?ctc, 7.5) ∧ (SoilPotassium, ?k) ∧ (potassiumConcentration, ?k, ?kc) ∧ swrlb:greaterThan(?kc, 90) → (Level_of_Potassium, ?k, "Very High")

K_VeryHigh_Rule2: (SoilCEC, ?c) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:greaterThan(?ctc, 7.5) ∧ swrlb:lessThanOrEqualTo(?ctc, 15) ∧ (SoilPotassium, ?k) ∧ (potassiumConcentration, ?k, ?kc) ∧ swrlb:greaterThan(?kc, 120) → (Level_of_Potassium, ?k, "Very High")

K_VeryHigh_Rule3: (SoilCEC, ?c) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:greaterThan(?ctc, 15) ∧ swrlb:lessThanOrEqualTo(?ctc, 30) ∧ (SoilPotassium, ?k) ∧ (potassiumConcentration, ?k, ?kc) ∧ swrlb:greaterThan(?kc, 180) → (Level_of_Potassium, ?k, "Very High")

K_VeryHigh_Rule4: (SoilCEC, ?c) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:greaterThan(?ctc, 30) ∧ (SoilPotassium, ?k) ∧ (potassiumConcentration, ?k, ?kc) ∧ swrlb:greaterThan(?kc, 210) → (Level_of_Potassium, ?k, "Very High")

K_VeryLow_Rule1: (SoilCEC, ?c) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:lessThanOrEqualTo(?ctc, 7.5) ∧ (SoilPotassium, ?k) ∧ (potassiumConcentration, ?k, ?kc) ∧ swrlb:lessThanOrEqualTo(?kc, 15) → (Level_of_Potassium, ?k, "Very Low")

K_VeryLow_Rule2: (SoilCEC, ?c) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:greaterThan(?ctc, 7.5) ∧ swrlb:lessThanOrEqualTo(?ctc, 15) ∧ (SoilPotassium, ?k) ∧ (potassiumConcentration, ?k, ?kc) ∧ swrlb:lessThanOrEqualTo(?kc, 20) → (Level_of_Potassium, ?k, "Very Low")

K_VeryLow_Rule3: swrlb:greaterThan(?ctc, 15) ∧ (potassiumConcentration, ?k, ?kc) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:lessThanOrEqualTo(?ctc, 30) ∧ swrlb:lessThanOrEqualTo(?kc, 30) ∧ (SoilPotassium, ?k) ∧ (SoilCEC, ?c) → (Level_of_Potassium, ?k, "Very Low")

K_VeryLow_Rule4: (SoilCEC, ?c) ∧ (cecConcentration, ?c, ?ctc) ∧ swrlb:greaterThan(?ctc, 30) ∧ (SoilPotassium, ?k) ∧ (potassiumConcentration, ?k, ?kc) ∧ swrlb:lessThanOrEqualTo(?kc, 35) → (Level_of_Potassium, ?k, "Very Low")

Liming_Rule01: (Liming, ?l) \wedge swrlb:lessThanOrEqual(?smp, 4.4) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "21.0")

Liming_Rule02: (Liming, ?l) \wedge swrlb:Equal(?smp, 4.5) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "17.3")

Liming_Rule03: (Liming, ?l) \wedge swrlb:Equal(?smp, 4.6) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "15.1")

Liming_Rule04: (Liming, ?l) \wedge swrlb:Equal(?smp, 4.7) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "13.3")

Liming_Rule05: (Liming, ?l) \wedge swrlb:Equal(?smp, 4.8) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "11.9")

Liming_Rule06: (Liming, ?l) \wedge swrlb:Equal(?smp, 4.9) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "10.7")

Liming_Rule07: (Liming, ?l) \wedge swrlb:Equal(?smp, 5) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "9.9")

Liming_Rule08: (Liming, ?l) \wedge swrlb:Equal(?smp, 5.1) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "9.1")

Liming_Rule09: (Liming, ?l) \wedge swrlb:Equal(?smp, 5.2) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "8.3")

Liming_Rule10: (Liming, ?l) \wedge swrlb:Equal(?smp, 5.3) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "7.5")

Liming_Rule11: (Liming, ?l) \wedge swrlb:Equal(?smp, 5.4) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "6.8")

Liming_Rule12: (Liming, ?l) \wedge swrlb:Equal(?smp, 5.5) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "6.1")

Liming_Rule13: (Liming, ?l) \wedge swrlb:Equal(?smp, 5.6) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "5.4")

Liming_Rule14: (Liming, ?l) \wedge swrlb:Equal(?smp, 5.7) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "4.8")

Liming_Rule15: (Liming, ?l) \wedge swrlb:Equal(?smp, 5.8) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "4.2")

Liming_Rule16: (Liming, ?l) \wedge swrlb:Equal(?smp, 5.9) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "3.7")

Liming_Rule17: (Liming, ?l) \wedge swrlb:Equal(?smp, 6) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "3.2")

Liming_Rule18: (Liming, ?l) \wedge swrlb:Equal(?smp, 6.1) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "2.7")

Liming_Rule19: (Liming, ?l) \wedge swrlb:Equal(?smp, 6.2) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "2.2")

Liming_Rule20: (Liming, ?l) \wedge swrlb:Equal(?smp, 6.3) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "1.8")

Liming_Rule21: (Liming, ?l) \wedge swrlb:Equal(?smp, 6.4) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "1.4")

Liming_Rule22: (Liming, ?l) \wedge swrlb:Equal(?smp, 6.5) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "1.1")

Liming_Rule23: (Liming, ?l) \wedge swrlb:Equal(?smp, 6.6) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "0.8")

Liming_Rule24: (Liming, ?l) \wedge swrlb:Equal(?smp, 6.7) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "0.5")

Liming_Rule25: (Liming, ?l) \wedge swrlb:Equal(?smp, 6.8) \wedge (smpConcentration, ?l, ?smp) \rightarrow (Recommendation_of_Liming, ?l, "0.3")

Liming_Rule26: (Liming, ?l) \wedge (smpConcentration, ?l, ?smp) \wedge swrlb:Equal(?smp, 6.9) \rightarrow (Recommendation_of_Liming, ?l, "0.2")

Liming_Rule27: $\text{swrlb:greaterThanOrEqual}(?\text{smp}, 7) \wedge (\text{smpConcentration}, ?l, ?\text{smp}) \wedge (\text{Liming}, ?l) \rightarrow (\text{Recommendation_of_Liming}, ?l, "0")$

N_Recomm_Rule1: $\text{swrlb:lessThanOrEqual}(?\text{om}, 1) \wedge (\text{organicMatterConcentration}, ?n, ?\text{om}) \wedge (\text{Nitrogen}, ?n) \rightarrow (\text{Recommendation_of_Nitrogen}, ?n, "160-180")$

N_Recomm_Rule2: $\text{swrlb:greaterThan}(?\text{om}, 1) \wedge (\text{organicMatterConcentration}, ?n, ?\text{om}) \wedge \text{swrlb:lessThanOrEqual}(?\text{om}, 2) \wedge (\text{Nitrogen}, ?n) \rightarrow (\text{Recommendation_of_Nitrogen}, ?n, "140-160")$

N_Recomm_Rule3: $(\text{organicMatterConcentration}, ?n, ?\text{om}) \wedge \text{swrlb:greaterThan}(?\text{om}, 2) \wedge \text{swrlb:lessThanOrEqual}(?\text{om}, 3) \wedge (\text{Nitrogen}, ?n) \rightarrow (\text{Recommendation_of_Nitrogen}, ?n, "120-140")$

N_Recomm_Rule4: $(\text{organicMatterConcentration}, ?n, ?\text{om}) \wedge \text{swrlb:greaterThan}(?\text{om}, 3) \wedge (\text{Nitrogen}, ?n) \wedge \text{swrlb:lessThanOrEqual}(?\text{om}, 4) \rightarrow (\text{Recommendation_of_Nitrogen}, ?n, "110-120")$

N_Recomm_Rule5: $(\text{organicMatterConcentration}, ?n, ?\text{om}) \wedge \text{swrlb:greaterThan}(?\text{om}, 4) \wedge \text{swrlb:lessThanOrEqual}(?\text{om}, 5) \wedge (\text{Nitrogen}, ?n) \rightarrow (\text{Recommendation_of_Nitrogen}, ?n, "100-110")$

N_Recomm_Rule6: $\text{swrlb:greaterThan}(?\text{om}, 5) \wedge (\text{organicMatterConcentration}, ?n, ?\text{om}) \wedge (\text{Nitrogen}, ?n) \rightarrow (\text{Recommendation_of_Nitrogen}, ?n, "\leq 100")$

OM_High_Rule: $(\text{SoilOrganicMatter}, ?o) \wedge \text{swrlb:greaterThan}(?\text{om}, 5) \wedge (\text{organicMatterConcentration}, ?o, ?\text{om}) \rightarrow (\text{Level_of_OrganicMatter}, ?o, "High")$

OM_Low_Rule: $\text{swrlb:lessThanOrEqual}(?\text{om}, 2.5) \wedge (\text{organicMatterConcentration}, ?o) \wedge (?o) \wedge (\text{SoilOrganicMatter}, ?o) \rightarrow (\text{Level_of_OrganicMatter}, ?o, "Low")$

OM_Medium_Rule: $\text{swrlb:greaterThan}(?\text{om}, 2.5) \wedge (\text{organicMatterConcentration}, ?o) \wedge (?o) \wedge (\text{SoilOrganicMatter}, ?o) \wedge \text{swrlb:lessThanOrEqual}(?\text{om}, 5) \rightarrow (\text{Level_of_OrganicMatter}, ?o, "Medium")$

P_High_Rule1: $(\text{ClayTexture}, ?c) \wedge \text{swrlb:lessThanOrEqual}(?\text{pc}, 9) \wedge (\text{SoilPhosphorus}, ?p) \wedge \text{swrlb:greaterThan}(?\text{clay}, 60) \wedge (\text{clayConcentration}, ?c, ?\text{clay}) \wedge \text{swrlb:greaterThan}(?\text{pc}, 4.5) \wedge (\text{phosphorusConcentration}, ?p) \wedge (?pc) \rightarrow (\text{Level_of_Phosphorus}, ?p, "High")$

P_High_Rule2: (ClayTexture, ?c) \wedge swrlb:greaterThan(?clay, 40) \wedge swrlb:greaterThan(?pc, 6) \wedge (SoilPhosphorus, ?p) \wedge swrlb:lessThanOrEqualTo(?pc, 12) \wedge (clayConcentration, ?c, ?clay) \wedge (phosphorusConcentration, ?p, ?pc) \wedge swrlb:lessThanOrEqualTo(?clay, 60) \rightarrow (Level_of_Phosphorus, ?p, "High")

P_High_Rule3: (ClayTexture, ?c) \wedge swrlb:greaterThan(?pc, 9) \wedge swrlb:lessThanOrEqualTo(?clay, 40) \wedge (SoilPhosphorus, ?p) \wedge (clayConcentration, ?c, ?clay) \wedge swrlb:lessThanOrEqualTo(?pc, 18) \wedge (phosphorusConcentration, ?p, ?pc) \wedge swrlb:greaterThan(?clay, 20) \rightarrow (Level_of_Phosphorus, ?p, "High")

P_High_Rule4: (ClayTexture, ?c) \wedge swrlb:lessThanOrEqualTo(?pc, 30) \wedge (SoilPhosphorus, ?p) \wedge swrlb:lessThanOrEqualTo(?clay, 20) \wedge (clayConcentration, ?c, ?clay) \wedge swrlb:greaterThan(?pc, 15) \wedge (phosphorusConcentration, ?p) \wedge (?pc) \rightarrow (Level_of_Phosphorus, ?p, "High")

P_Low_Rule1: (ClayTexture, ?c) \wedge (SoilPhosphorus, ?p) \wedge swrlb:greaterThan(?clay, 60) \wedge (clayConcentration, ?c, ?clay) \wedge (phosphorusConcentration, ?p, ?pc) \wedge swrlb:greaterThan(?pc, 1.5) \wedge swrlb:lessThanOrEqualTo(?pc, 3) \rightarrow (Level_of_Phosphorus, ?p, "Low")

P_Low_Rule2: (ClayTexture, ?c) \wedge swrlb:greaterThan(?clay, 40) \wedge (SoilPhosphorus, ?p) \wedge (clayConcentration, ?c, ?clay) \wedge swrlb:greaterThan(?pc, 2) \wedge swrlb:lessThanOrEqualTo(?pc, 4) \wedge (phosphorusConcentration, ?p, ?pc) \wedge swrlb:lessThanOrEqualTo(?clay, 60) \rightarrow (Level_of_Phosphorus, ?p, "Low")

P_Low_Rule3: (ClayTexture, ?c) \wedge swrlb:lessThanOrEqualTo(?clay, 40) \wedge (SoilPhosphorus, ?p) \wedge swrlb:greaterThan(?pc, 3) \wedge (clayConcentration, ?c, ?clay) \wedge (phosphorusConcentration, ?p, ?pc) \wedge swrlb:lessThanOrEqualTo(?pc, 6) \wedge swrlb:greaterThan(?clay, 20) \rightarrow (Level_of_Phosphorus, ?p, "Low")

P_Low_Rule4: (ClayTexture, ?c) \wedge swrlb:lessThanOrEqualTo(?pc, 10) \wedge swrlb:greaterThan(?pc, 5) \wedge (SoilPhosphorus, ?p) \wedge swrlb:lessThanOrEqualTo(?clay, 20) \wedge (clayConcentration, ?c, ?clay) \wedge (phosphorusConcentration, ?p) \wedge (?pc) \rightarrow (Level_of_Phosphorus, ?p, "Low")

P_Medium_Rule1: (ClayTexture, ?c) \wedge (SoilPhosphorus, ?p) \wedge swrlb:greaterThan(?clay, 60) \wedge swrlb:greaterThan(?pc, 3) \wedge (clayConcentration, ?c, ?clay) \wedge swrlb:lessThanOrEqualTo(?pc, 4.5) \wedge (phosphorusConcentration, ?p) \wedge (?pc) \rightarrow (Level_of_Phosphorus, ?p, "Medium")

P_Medium_Rule2: (ClayTexture, ?c) \wedge swrlb:greaterThan(?clay, 40) \wedge (SoilPhosphorus, ?p) \wedge swrlb:lessThanOrEqualTo(?pc, 6) \wedge (clayConcentration, ?c, ?clay) \wedge swrlb:greaterThan(?pc, 4) \wedge (phosphorusConcentration, ?p, ?pc) \wedge swrlb:lessThanOrEqualTo(?clay, 60) \rightarrow (Level_of_Phosphorus,

?p, "Medium")

P_Medium_Rule3: (ClayTexture, ?c) ∧ swrlb:lessThanOrEqual(?pc, 9) ∧ swrlb:lessThanOrEqual(?clay, 40) ∧ swrlb:greaterThan(?pc, 6) ∧ (SoilPhosphorus, ?p) ∧ (clayConcentration, ?c, ?clay) ∧ (phosphorusConcentration, ?p, ?pc) ∧ swrlb:greaterThan(?clay, 20) → (Level_of_Phosphorus, ?p, "Medium")

P_Medium_Rule4: (ClayTexture, ?c) ∧ swrlb:greaterThan(?pc, 10) ∧ (SoilPhosphorus, ?p) ∧ swrlb:lessThanOrEqual(?clay, 20) ∧ (clayConcentration, ?c, ?clay) ∧ swrlb:lessThanOrEqual(?pc, 15) ∧ (phosphorusConcentration, ?p) ∧ (?pc) → (Level_of_Phosphorus, ?p, "Medium")

P_Recomm_Rule01: (ClayTexture, ?c) ∧ (clayConcentration, ?c, ?clay) ∧ swrlb:greaterThan(?clay, 60) ∧ (SoilPhosphorus, ?p) ∧ (phosphorusConcentration, ?p, ?pc) ∧ swrlb:lessThanOrEqual(?pc, 1.5) → (Recommendation_of_Phosphorus, ?p, "120")

P_Recomm_Rule02: (ClayTexture, ?c) ∧ (clayConcentration, ?c, ?clay) ∧ swrlb:greaterThan(?clay, 40) ∧ swrlb:lessThanOrEqual(?clay, 60) ∧ (SoilPhosphorus, ?p) ∧ (phosphorusConcentration, ?p, ?pc) ∧ swrlb:lessThanOrEqual(?pc, 2) → (Recommendation_of_Phosphorus, ?p, "120")

P_Recomm_Rule03: (ClayTexture, ?c) ∧ (clayConcentration, ?c, ?clay) ∧ swrlb:greaterThan(?clay, 20) ∧ swrlb:lessThanOrEqual(?clay, 40) ∧ (SoilPhosphorus, ?p) ∧ (phosphorusConcentration, ?p, ?pc) ∧ swrlb:lessThanOrEqual(?pc, 3) → (Recommendation_of_Phosphorus, ?p, "120")

P_Recomm_Rule04: (ClayTexture, ?c) ∧ (clayConcentration, ?c, ?clay) ∧ swrlb:lessThanOrEqual(?clay, 20) ∧ (SoilPhosphorus, ?p) ∧ (phosphorusConcentration, ?p, ?pc) ∧ swrlb:lessThanOrEqual(?pc, 5) → (Recommendation_of_Phosphorus, ?p, "120")

P_Recomm_Rule05: (ClayTexture, ?c) ∧ (clayConcentration, ?c, ?clay) ∧ swrlb:greaterThan(?clay, 60) ∧ (SoilPhosphorus, ?p) ∧ (phosphorusConcentration, ?p, ?pc) ∧ swrlb:greaterThan(?pc, 1.5) ∧ swrlb:lessThanOrEqual(?pc, 3) → (Recommendation_of_Phosphorus, ?p, "80")

P_Recomm_Rule06: (ClayTexture, ?c) ∧ (clayConcentration, ?c, ?clay) ∧ swrlb:greaterThan(?clay, 40) ∧ swrlb:lessThanOrEqual(?clay, 60) ∧ (SoilPhosphorus, ?p) ∧ (phosphorusConcentration, ?p, ?pc) ∧ swrlb:greaterThan(?pc, 2) ∧ swrlb:lessThanOrEqual(?pc, 4) → (Recommendation_of_Phosphorus, ?p, "80")

P_Recomm_Rule07: (ClayTexture, ?c) ∧ (clayConcentration, ?c, ?clay) ∧ swrlb:greaterThan(?clay, 20) ∧ swrlb:lessThanOrEqual(?clay, 40) ∧ (SoilPhosphorus, ?p) ∧ (phosphorusConcentration, ?p, ?pc) ∧ swrlb:greaterThan(?pc, 3) ∧ swrlb:lessThanOrEqual(?pc, 6) → (Recommendation_of_Phosphorus, ?p, "80")

tion_of_Phosphorus, ?p, "80")

P_Recomm_Rule08: (ClayTexture, ?c) ∧ (clayConcentration, ?c, ?clay) ∧ swrlb:lessThanOrEqualTo(?clay, 20) ∧ (SoilPhosphorus, ?p) ∧ (phosphorusConcentration, ?p, ?pc) ∧ swrlb:greaterThan(?pc, 5) ∧ swrlb:lessThanOrEqualTo(?pc, 10) → (Recommendation_of_Phosphorus, ?p, "80")

P_Recomm_Rule09: (ClayTexture, ?c) ∧ (clayConcentration, ?c, ?clay) ∧ swrlb:greaterThan(?clay, 60) ∧ (SoilPhosphorus, ?p) ∧ (phosphorusConcentration, ?p, ?pc) ∧ swrlb:greaterThan(?pc, 3) ∧ swrlb:lessThanOrEqualTo(?pc, 4.5) → (Recommendation_of_Phosphorus, ?p, "60")

P_Recomm_Rule10: (ClayTexture, ?c) ∧ (clayConcentration, ?c, ?clay) ∧ swrlb:greaterThan(?clay, 40) ∧ swrlb:lessThanOrEqualTo(?clay, 60) ∧ (SoilPhosphorus, ?p) ∧ (phosphorusConcentration, ?p, ?pc) ∧ swrlb:greaterThan(?pc, 4) ∧ swrlb:lessThanOrEqualTo(?pc, 6) → (Recommendation_of_Phosphorus, ?p, "60")

P_Recomm_Rule11: (ClayTexture, ?c) ∧ (clayConcentration, ?c, ?clay) ∧ swrlb:greaterThan(?clay, 20) ∧ swrlb:lessThanOrEqualTo(?clay, 40) ∧ (SoilPhosphorus, ?p) ∧ (phosphorusConcentration, ?p, ?pc) ∧ swrlb:greaterThan(?pc, 6) ∧ swrlb:lessThanOrEqualTo(?pc, 9) → (Recommendation_of_Phosphorus, ?p, "60")

P_Recomm_Rule12: (ClayTexture, ?c) ∧ (clayConcentration, ?c, ?clay) ∧ swrlb:lessThanOrEqualTo(?clay, 20) ∧ (SoilPhosphorus, ?p) ∧ (phosphorusConcentration, ?p, ?pc) ∧ swrlb:greaterThan(?pc, 10) ∧ swrlb:lessThanOrEqualTo(?pc, 15) → (Recommendation_of_Phosphorus, ?p, "60")

P_Recomm_Rule13: (ClayTexture, ?c) ∧ (clayConcentration, ?c, ?clay) ∧ swrlb:greaterThan(?clay, 60) ∧ (SoilPhosphorus, ?p) ∧ (phosphorusConcentration, ?p, ?pc) ∧ swrlb:greaterThan(?pc, 4.5) ∧ swrlb:lessThanOrEqualTo(?pc, 9) → (Recommendation_of_Phosphorus, ?p, "40")

P_Recomm_Rule14: (ClayTexture, ?c) ∧ (clayConcentration, ?c, ?clay) ∧ swrlb:greaterThan(?clay, 40) ∧ swrlb:lessThanOrEqualTo(?clay, 60) ∧ (SoilPhosphorus, ?p) ∧ (phosphorusConcentration, ?p, ?pc) ∧ swrlb:greaterThan(?pc, 6) ∧ swrlb:lessThanOrEqualTo(?pc, 12) → (Recommendation_of_Phosphorus, ?p, "40")

P_Recomm_Rule15: (ClayTexture, ?c) ∧ (clayConcentration, ?c, ?clay) ∧ swrlb:greaterThan(?clay, 20) ∧ swrlb:lessThanOrEqualTo(?clay, 40) ∧ (SoilPhosphorus, ?p) ∧ (phosphorusConcentration, ?p, ?pc) ∧ swrlb:greaterThan(?pc, 9) ∧ swrlb:lessThanOrEqualTo(?pc, 18) → (Recommendation_of_Phosphorus, ?p, "40")

P_Recomm_Rule16: (ClayTexture, ?c) ∧ (clayConcentration, ?c, ?clay) ∧ swrlb:lessThanOrEqualTo

$?clay, 20) \wedge (\text{SoilPhosphorus}, ?p) \wedge (\text{phosphorusConcentration}, ?p, ?pc) \wedge \text{swrlb:greaterThan}(?pc, 15) \wedge \text{swrlb:lessThanOrEqual}(?pc, 30) \rightarrow (\text{Recommendation_of_Phosphorus}, ?p, "40")$

$\text{P_Recomm_Rule17}: (\text{ClayTexture}, ?c) \wedge (\text{clayConcentration}, ?c, ?clay) \wedge \text{swrlb:greaterThan}(?clay, 60) \wedge (\text{SoilPhosphorus}, ?p) \wedge (\text{phosphorusConcentration}, ?p, ?pc) \wedge \text{swrlb:greaterThan}(?pc, 9) \rightarrow (\text{Recommendation_of_Phosphorus}, ?p, "\leq 20")$

$\text{P_Recomm_Rule18}: (\text{ClayTexture}, ?c) \wedge (\text{clayConcentration}, ?c, ?clay) \wedge \text{swrlb:greaterThan}(?clay, 40) \wedge \text{swrlb:lessThanOrEqual}(?clay, 60) \wedge (\text{SoilPhosphorus}, ?p) \wedge (\text{phosphorusConcentration}, ?p, ?pc) \wedge \text{swrlb:greaterThan}(?pc, 12) \rightarrow (\text{Recommendation_of_Phosphorus}, ?p, "\leq 20")$

$\text{P_Recomm_Rule19}: (\text{ClayTexture}, ?c) \wedge (\text{clayConcentration}, ?c, ?clay) \wedge \text{swrlb:greaterThan}(?clay, 20) \wedge \text{swrlb:lessThanOrEqual}(?clay, 40) \wedge (\text{SoilPhosphorus}, ?p) \wedge (\text{phosphorusConcentration}, ?p, ?pc) \wedge \text{swrlb:greaterThan}(?pc, 18) \rightarrow (\text{Recommendation_of_Phosphorus}, ?p, "\leq 20")$

$\text{P_Recomm_Rule20}: (\text{ClayTexture}, ?c) \wedge (\text{clayConcentration}, ?c, ?clay) \wedge \text{swrlb:lessThanOrEqual}(?clay, 20) \wedge (\text{SoilPhosphorus}, ?p) \wedge (\text{phosphorusConcentration}, ?p, ?pc) \wedge \text{swrlb:greaterThan}(?pc, 30) \rightarrow (\text{Recommendation_of_Phosphorus}, ?p, "\leq 20")$

$\text{P_VeryHigh_Rule1}: (\text{ClayTexture}, ?c) \wedge \text{swrlb:greaterThan}(?pc, 9) \wedge (\text{SoilPhosphorus}, ?p) \wedge \text{swrlb:greaterThan}(?clay, 60) \wedge (\text{clayConcentration}, ?c, ?clay) \wedge (\text{phosphorusConcentration}, ?p) \wedge (?pc) \rightarrow (\text{Level_of_Phosphorus}, ?p, "Very High")$

$\text{P_VeryHigh_Rule2}: (\text{ClayTexture}, ?c) \wedge \text{swrlb:greaterThan}(?clay, 40) \wedge (\text{SoilPhosphorus}, ?p) \wedge (\text{clayConcentration}, ?c, ?clay) \wedge (\text{phosphorusConcentration}, ?p, ?pc) \wedge \text{swrlb:lessThanOrEqual}(?clay, 60) \wedge \text{swrlb:greaterThan}(?pc, 12) \rightarrow (\text{Level_of_Phosphorus}, ?p, "Very High")$

$\text{P_VeryHigh_Rule3}: (\text{ClayTexture}, ?c) \wedge \text{swrlb:lessThanOrEqual}(?clay, 40) \wedge (\text{SoilPhosphorus}, ?p) \wedge (\text{clayConcentration}, ?c, ?clay) \wedge \text{swrlb:greaterThan}(?pc, 18) \wedge (\text{phosphorusConcentration}, ?p, ?pc) \wedge \text{swrlb:greaterThan}(?clay, 20) \rightarrow (\text{Level_of_Phosphorus}, ?p, "Very High")$

$\text{P_VeryHigh_Rule4}: (\text{ClayTexture}, ?c) \wedge (\text{SoilPhosphorus}, ?p) \wedge \text{swrlb:lessThanOrEqual}(?clay, 20) \wedge (\text{clayConcentration}, ?c, ?clay) \wedge (\text{phosphorusConcentration}, ?p, ?pc) \wedge \text{swrlb:greaterThan}(?pc, 30) \rightarrow (\text{Level_of_Phosphorus}, ?p, "Very High")$

$\text{P_VeryLow_Rule1}: (\text{ClayTexture}, ?c) \wedge \text{swrlb:lessThanOrEqual}(?pc, 1.5) \wedge (\text{SoilPhosphorus}, ?p) \wedge \text{swrlb:greaterThan}(?clay, 60) \wedge (\text{clayConcentration}, ?c, ?clay) \wedge (\text{phosphorusConcentration}, ?p) \wedge (?pc) \rightarrow (\text{Level_of_Phosphorus}, ?p, "Very Low")$

P_VeryLow_Rule2: (ClayTexture, ?c) ∧ swrlb:greaterThan(?clay, 40) ∧ (SoilPhosphorus, ?p) ∧ swrlb:lessThanOrEqualTo(?clay, 60) ∧ (clayConcentration, ?c, ?clay) ∧ swrlb:lessThanOrEqualTo(?pc, 2) ∧ (phosphorusConcentration, ?p, ?pc) → (Level_of_Phosphorus, ?p, "Very Low")

P_VeryLow_Rule3: (ClayTexture, ?c) ∧ swrlb:lessThanOrEqualTo(?clay, 40) ∧ (SoilPhosphorus, ?p) ∧ swrlb:lessThanOrEqualTo(?pc, 3) ∧ (clayConcentration, ?c, ?clay) ∧ (phosphorusConcentration, ?p, ?pc) ∧ swrlb:greaterThan(?clay, 20) → (Level_of_Phosphorus, ?p, "Very Low")

P_VeryLow_Rule4: (ClayTexture, ?c) ∧ (SoilPhosphorus, ?p) ∧ swrlb:lessThanOrEqualTo(?clay, 20) ∧ swrlb:lessThanOrEqualTo(?pc, 5) ∧ (clayConcentration, ?c, ?clay) ∧ (phosphorusConcentration, ?p, ?pc) → (Level_of_Phosphorus, ?p, "Very Low")

Rule_Clay: swrlb:lessThanOrEqualTo(?sand, 45) ∧ swrlb:lessThan(?silt, 40) ∧ (siltConcentration, ?t, ?silt) ∧ swrlb:greaterThanOrEqualTo(?clay, 40) ∧ (clayConcentration, ?t, ?clay) ∧ (SoilTexture, ?t) ∧ (sandConcentration, ?t, ?sand) ∧ swrlb:lessThanOrEqualTo(?clay, 60) → (Category_of_BrazilianSoil, ?t, "Clay")

Rule_ClayLoam: swrlb:lessThanOrEqualTo(?sand, 45) ∧ swrlb:greaterThanOrEqualTo(?clay, 27) ∧ swrlb:greaterThan(?sand, 20) ∧ (clayConcentration, ?t, ?clay) ∧ swrlb:lessThan(?clay, 40) ∧ (SoilTexture, ?t) ∧ (sandConcentration, ?t, ?sand) → (Category_of_BrazilianSoil, ?t, "Clay-Loam")

Rule_HeavyClay: swrlb:lessThanOrEqualTo(?sand, 40) ∧ (SoilTexture, ?t) ∧ (siltConcentration, ?t, ?silt) ∧ swrlb:greaterThan(?clay, 60) ∧ (clayConcentration, ?t, ?clay) ∧ swrlb:lessThanOrEqualTo(?silt, 40) ∧ (sandConcentration, ?t, ?sand) → (Category_of_BrazilianSoil, ?t, "HeavyClay")

Rule_Loam: swrlb:greaterThanOrEqualTo(?silt, 28) ∧ (siltConcentration, ?t, ?silt) ∧ (clayConcentration, ?t, ?clay) ∧ swrlb:lessThanOrEqualTo(?sand, 52) ∧ swrlb:greaterThanOrEqualTo(?clay, 7) ∧ swrlb:lessThan(?silt, 50) ∧ (SoilTexture, ?t) ∧ swrlb:lessThan(?clay, 27) ∧ (sandConcentration, ?t, ?sand) → (Category_of_BrazilianSoil, ?t, "Loam")

Rule_LoamySand: (siltConcentration, ?t, ?silt) ∧ (SoilTexture, ?t) ∧ swrlb:greaterThanOrEqualTo(?resultOne, "15) ∧ swrlb:lessThan(?resultTwo, 30) ∧ swrlb:add, ?resultOne) ∧ (?silt) ∧ (?mOne) ∧ swrlb:multiply, ?mTwo) ∧ (?clay, 2) ∧ (clayConcentration, ?t, ?clay) ∧ swrlb:multiply, ?mOne) ∧ (?clay, 1.5) ∧ swrlb:add(?resultTwo, ?silt, ?mTwo) → (Category_of_BrazilianSoil, ?t, "LoamySand")

Rule_Sand: (siltConcentration, ?t, ?silt) ∧ swrlb:lessThan(?result, "15) ∧ (clayConcentration, ?t, ?clay) ∧ swrlb:multiply, ?m, ?clay, 1.5) ∧ swrlb:add, ?result, ?silt, ?m) ∧ (SoilTexture, ?t)

→ (Category_of_BrazilianSoil, ?t, "Sand")

Rule_SandyClay: swrlb:greaterThan(?sand, 45) ∧ (clayConcentration, ?t, ?clay) ∧ (SoilTexture, ?t) ∧ swrlb:greaterThanOrEqual(?clay, 35) ∧ (sandConcentration, ?t, ?sand) → (Category_of_BrazilianSoil, ?t, "SandyClay")

Rule_SandyClayLoam: swrlb:lessThan(?silt, 28) ∧ swrlb:lessThan(?clay, 35) ∧ (siltConcentration, ?t, ?silt) ∧ swrlb:greaterThan(?sand, 45) ∧ swrlb:greaterThanOrEqual(?clay, 20) ∧ (clayConcentration, ?t, ?clay) ∧ (SoilTexture, ?t) ∧ (sandConcentration, ?t, ?sand) → (Category_of_BrazilianSoil, ?t, "SandyClayLoam")

Rule_SandyLoam: swrlb:add, ?result, ?silt, ?m) ∧ (siltConcentration, ?t, ?silt) ∧ (sandConcentration, ?t, ?sand) ∧ swrlb:lessThan(?clay, 20) ∧ (clayConcentration, ?t, ?clay) ∧ (SoilTexture, ?t) ∧ swrlb:multiply, ?m, ?clay, 2) ∧ swrlb:greaterThanOrEqual(?clay, 7) ∧ swrlb:greaterThan(?sand, 52) ∧ swrlb:greaterThanOrEqual(?result, "30) → (Category_of_BrazilianSoil, ?t, "SandyLoam")

Rule_SandyLoam2: swrlb:add, ?result, ?silt, ?m) ∧ (siltConcentration, ?t, ?silt) ∧ (clayConcentration, ?t, ?clay) ∧ swrlb:lessThan(?clay, 7) ∧ (SoilTexture, ?t) ∧ swrlb:multiply, ?m, ?clay, 2) ∧ (sandConcentration, ?t, ?sand) ∧ swrlb:lessThan(?silt, 50) ∧ swrlb:greaterThanOrEqual(?result, "30) → (Category_of_BrazilianSoil, ?t, "SandyLoam")

Rule_Silt: (siltConcentration, ?t, ?silt) ∧ swrlb:greaterThanOrEqual(?silt, 80) ∧ (clayConcentration, ?t, ?clay) ∧ (SoilTexture, ?t) ∧ swrlb:lessThan(?clay, 12) → (Category_of_BrazilianSoil, ?t, "Silt")

Rule_SiltLoam: swrlb:greaterThanOrEqual(?clay, 12) ∧ (siltConcentration, ?t, ?silt) ∧ (clayConcentration, ?t, ?clay) ∧ swrlb:lessThan(?clay, 27) ∧ swrlb:greaterThanOrEqual(?silt, 50) ∧ (SoilTexture, ?t) → (Category_of_BrazilianSoil, ?t, "SiltLoam")

Rule_SiltLoam2: (siltConcentration, ?t, ?silt) ∧ swrlb:greaterThanOrEqual(?silt, 50) ∧ (clayConcentration, ?t, ?clay) ∧ (SoilTexture, ?t) ∧ swrlb:lessThan(?silt, 80) ∧ swrlb:lessThan(?clay, 12) → (Category_of_BrazilianSoil, ?t, "SiltLoam")

Rule_SiltyClay: (siltConcentration, ?t, ?silt) ∧ swrlb:greaterThanOrEqual(?clay, 40) ∧ (clayConcentration, ?t, ?clay) ∧ (SoilTexture, ?t) ∧ swrlb:greaterThanOrEqual(?silt, 40) → (Category_of_BrazilianSoil, ?t, "SiltyClay")

Rule_SiltyClayLoam: swrlb:greaterThanOrEqual(?clay, 27) ∧ swrlb:lessThanOrEqual(?sand, 20) ∧ (clayConcentration, ?t, ?clay) ∧ swrlb:lessThan(?clay, 40) ∧ (SoilTexture, ?t) ∧ (sand-

Concentration, ?t, ?sand) → (Category_of_BrazilianSoil, ?t, "SiltyClayLoam")

Type1_Rule1: (SoilTexture, ?t) ∧ (clayConcentration, ?t, ?clay) ∧ swrlb:lessThan(?clay, 15) ∧ swrlb:greaterThanOrEqualTo(?clay, 10) → (Type_of_BrazilianSoil, ?t, "Type 1")

Type1_Rule2: swrlb:greaterThanOrEqualTo(?sand, 60) ∧ (clayConcentration, ?t, ?clay) ∧ (sandConcentration, ?t, ?sand) ∧ swrlb:lessThan(?clay, 10) ∧ (SoilTexture, ?t) → (Type_of_BrazilianSoil, ?t, "Type 1")

Type1_Rule3: (SoilTexture, ?t) ∧ (clayConcentration, ?t, ?clay) ∧ (sandConcentration, ?t, ?sand) ∧ swrlb:greaterThanOrEqualTo(?clay, 15) ∧ swrlb:subtract, ?result) ∧ (?sand) ∧ (?clay) ∧ swrlb:greaterThanOrEqualTo(?result, "50) → (Type_of_BrazilianSoil, ?t, "Type 1")

Type1_Rule4: (SoilTexture, ?t) ∧ (sandConcentration, ?t, ?sand) ∧ swrlb:greaterThanOrEqualTo(?sand, 90) → (Type_of_BrazilianSoil, ?t, "Type 1")

Type2_Rule: (SoilTexture, ?t) ∧ (clayConcentration, ?t, ?clay) ∧ (sandConcentration, ?t, ?sand) ∧ swrlb:greaterThanOrEqualTo(?clay, 15) ∧ swrlb:lessThan(?clay, 35) ∧ swrlb:subtract, ?result) ∧ (?sand) ∧ (?clay) ∧ swrlb:lessThan(?result, "50) → (Type_of_BrazilianSoil, ?t, "Type 2")

Type3_Rule: (SoilTexture, ?t) ∧ (clayConcentration, ?t, ?clay) ∧ swrlb:greaterThanOrEqualTo(?clay, 35) → (Type_of_BrazilianSoil, ?t, "Type 3")

ANEXO B – EXPLICAÇÕES DA INFERÊNCIA PARA AMOSTRA S03T

A inferência ilustrada na Figura 31 apresenta a situação onde a instância s03-T possui concentração de matéria orgânica igual à 2.0%, pertencendo ao domínio "SoilOrganicMatter" que por sua vez contém uma regra de equivalência onde concentrações que forem menores ou iguais a 2.5% são classificadas como MO de nível "Baixo".

Figura 31 – Inferência para nível de OM - amostra S03T.

Explanation 1 Display laconic explanation

Explanation for: 's03 - T' Level_of_OrganicMatter "Low"^^xsd:string

organicMatterConcentration Domain SoilOrganicMatter

's03 - T' organicMatterConcentration 2.0

lessThanOrEqual(?om, 2.5), organicMatterConcentration(?o, ?om), SoilOrganicMatter(?o)

-> Level_of_OrganicMatter(?o, "Low"^^xsd:string)

Fonte: Elaborado pelo autor.

A inferência ilustrada na Figura 32 apresenta a situação onde a instância s03-T possui concentração de CTC igual à 7.9%, pertencendo ao domínio "SoilCEC" que por sua vez contém uma regra de equivalência onde concentrações maiores que 7.5% e menores ou iguais a 15% são classificadas como CTC de nível "Médio".

Figura 32 – Inferência para nível de CTC - amostra S03T.

Explanation 1 Display laconic explanation

Explanation for: 's03 - T' Level_of_CEC "Medium"^^xsd:string

cecConcentration Domain SoilCEC

SoilCEC(?c), cecConcentration(?c, ?ctc), greaterThan(?ctc, 7.5), lessThanOrEqual(?ctc, 15) -> Level_of_CEC(?c, "Medium"^^xsd:string)

's03 - T' cecConcentration 7.9

Fonte: Elaborado pelo autor.

A inferência ilustrada na Figura 33 apresenta a situação onde a instância s03-T possui concentração de CTC igual à 9.1% e concentração de Potássio igual à 478% pertencendo aos domínios "SoilCEC" e "SoilPotassium" que por sua vez contém uma regra de equivalência onde concentrações de CTC maiores que 7.5% e menores ou iguais a 15% e concentrações de Potássio maiores que 120% são classificadas como Potássio de nível "Muito Alto".

A inferência ilustrada na Figura 34 apresenta a situação onde a instância s03-T possui concentração de argila igual à 18% e concentração de Fósforo igual à 94.1% pertencendo aos domínios "ClayTexture" e "SoilPhosphorus" que por sua vez contém uma regra de equivalência onde concentrações de Argila menores ou iguais à 20% e concentrações de Fósforo maiores que 30% são classificadas como Fósforo de nível "Muito Alto".

Figura 33 – Inferência para nível de K - amostra S03T.

Explanation 1 Display laconic explanation

Explanation for: 's03 - T' Level_of_Potassium "Very High"^^xsd:string

```

cecConcentration Domain SoilCEC
sample004 cecConcentration 9.1
potassiumConcentration Domain SoilPotassium
SoilCEC(?c), cecConcentration(?c, ?ctc), greaterThan(?ctc, 7.5), lessThanOrEqual(?ctc, 15), SoilPotassium(?k), potassiumConcentration(?k, ?kc), greaterThan(?kc, 120)
-> Level_of_Potassium(?k, "Very High"^^xsd:string)
's03 - T' potassiumConcentration 478

```

Fonte: Elaborado pelo autor.

Figura 34 – Inferência para nível de P - amostra S03T.

Explanation 1 Display laconic explanation

Explanation for: 's03 - T' Level_of_Phosphorus "Very High"^^xsd:string

```

phosphorusConcentration Domain SoilPhosphorus
sample005 clayConcentration 18
ClayTexture(?c), SoilPhosphorus(?p), lessThanOrEqual(?clay, 20), clayConcentration(?c, ?clay), phosphorusConcentration(?p, ?pc), greaterThan(?pc, 30)
-> Level_of_Phosphorus(?p, "Very High"^^xsd:string)
clayConcentration Domain ClayTexture
's03 - T' phosphorusConcentration 94.1

```

Fonte: Elaborado pelo autor.

A inferência ilustrada na Figura 35 apresenta a situação onde a instância s03-T possui concentração de argila igual à 18%, concentração de silte igual à 11% e concentração de areia igual à 71% pertencendo aos domínios "ClayTexture" e "SoilTexture" são classificadas Solo Brasileiro do tipo "Franco Arenoso".

Figura 35 – Inferência para categoria de solo - amostra S03T.

Explanation 1 Display laconic explanation

Explanation for: 's03 - T' Type_of_BrazilianSoil "SandyLoam"^^xsd:string

```

's03 - T' clayConcentration 18
ClayTexture(?ct), clayConcentration(?ct, ?clay), lessThanOrEqual(?clay, 20) -> Class_of_Clay(?ct, "Class4"^^xsd:string)
's03 - T' siltConcentration 11
clayConcentration Domain ClayTexture
Class_of_Clay Domain SoilTexture
add(?result, ?silt, ?m), siltConcentration(?t, ?silt), lessThan(?clay, 20), greaterThan(?sand, 52), clayConcentration(?t, ?clay), greaterThanOrEqual(?clay, 7), SoilTexture(?t), multiply(?m, ?clay, 2), sandConcentration(?t, ?sand), greaterThanOrEqual(?result, 30)
-> Type_of_BrazilianSoil(?t, "SandyLoam"^^xsd:string)
's03 - T' sandConcentration 71

```

Fonte: Elaborado pelo autor.

A inferência ilustrada na Figura 36 apresenta a situação onde a instância s03-T possui concentração de argila igual à 18% pertencendo ao domínio "ClayTexture" que por sua vez contém uma regra de equivalência onde concentrações de Argila menores ou iguais à 20% são classificadas como Textura de "Classe 4".

A inferência ilustrada na Figura 37 apresenta a situação onde a instância s03-T possui concentração de matéria orgânica igual à 2.0% pertencendo ao domínio "Nitrogen" recomenda a quantidade de Nitrogênio entre 140 e 160 kg de N/ha.

Figura 36 – Inferência para classe de argila - amostra S03T.

Explanation 1 Display laconic explanation

Explanation for: 's03 - T' Class_of_Clay "Class4"^^xsd:string

```
's03 - T' clayConcentration 18
ClayTexture(?ct), clayConcentration(?ct, ?clay), lessThanOrEqual(?clay, 20) -> Class_of_Clay(?ct, "Class4"^^xsd:string)
clayConcentration Domain ClayTexture
```

Fonte: Elaborado pelo autor.

Figura 37 – Inferência para recomendação de N - amostra S03T.

Explanation 1 Display laconic explanation

Explanation for: 's03 - T' Recommendation_of_Nitrogen "140-160"^^xsd:string

```
organicMatterConcentration Domain Nitrogen
's03 - T' organicMatterConcentration 2.0
greaterThan(?om, 1), organicMatterConcentration(?n, ?om), lessThanOrEqual(?om, 2), Nitrogen(?n)
-> Recommendation_of_Nitrogen(?n, "140-160"^^xsd:string)
```

Fonte: Elaborado pelo autor.

A inferência ilustrada na Figura 38 apresenta a situação onde a instância s03-T possui concentração de argila igual à 20% e concentração de Fósforo igual à 94.1% pertencendo aos domínios "ClayTexture" e "SoilPhosphorus" recomendam a quantidade de Fósforo menor ou igual à 20 kg de P₂O₅/ha.

Figura 38 – Inferência para recomendação de P - amostra S03T

Explanation 1 Display laconic explanation

Explanation for: 's03 - T' Recommendation_of_Phosphorus "<=20"^^xsd:string

```
phosphorusConcentration Domain SoilPhosphorus
sample004 clayConcentration 20
ClayTexture(?c), clayConcentration(?c, ?clay), lessThanOrEqual(?clay, 20), SoilPhosphorus(?p), phosphorusConcentration(?p, ?pc), greaterThan(?pc, 30)
-> Recommendation_of_Phosphorus(?p, "<=20"^^xsd:string)
clayConcentration Domain ClayTexture
's03 - T' phosphorusConcentration 94.1
```

Fonte: Elaborado pelo autor.

A inferência ilustrada na Figura 39 apresenta a situação onde a instância s03-T possui concentração de CTC igual à 12.2% e concentração de Potássio igual à 478% pertencendo aos domínios "SoilCEC" e "SoilPotassium" recomendam a quantidade de Potássio menor ou igual à 105 kg de K₂O/ha.

A inferência ilustrada na Figura 40 apresenta a situação onde a instância s03-T possui índice SMP igual à 7.1 pertencendo ao domínio "Liming" recomenda a quantidade de Calcário igual à 0 kg de CaCO₃/ha.

Figura 39 – Inferência para recomendação de K - amostra S03T

Explanation 1 Display laconic explanation

Explanation for: 's03 - T' Recommendation_of_Potassium "<= 105"^^xsd:string

```

cecConcentration Domain SoilCEC
sample002 cecConcentration 12.2
SoilCEC(?c), cecConcentration(?c, ?ctc), greaterThan(?ctc, 7.5), lessThanOrEqual(?ctc, 15), SoilPotassium(?k), potassiumConcentration(?k, ?kc), greaterThan(?kc, 120)
-> Recommendation_of_Potassium(?k, "<= 105"^^xsd:string)
potassiumConcentration Domain SoilPotassium
's03 - T' potassiumConcentration 478

```

Fonte: Elaborado pelo autor.

Figura 40 – Inferência para recomendação de calagem - amostra S03T

Explanation 1 Display laconic explanation

Explanation for: 's03 - T' Recommendation_of_Liming "0"^^xsd:string

```

smpConcentration Domain Liming
's03 - T' smpConcentration 7.1
greaterThanOrEqual(?smp, 7), smpConcentration(?l, ?smp), Liming(?l) -> Recommendation_of_Liming(?l, "0"^^xsd:string)

```

Fonte: Elaborado pelo autor.

ANEXO C – ALGORITMOS

Figura 41 – Algoritmo para classificação do solo – triângulo textural

```

1 def getTextureClass(sand, clay, silt):
2     texture = 'Undefined'
3     if ((silt + 1.5*clay) < 15):
4         texture = 'Sand'
5     elif ((silt + 1.5*clay >= 15) and (silt + 2*clay < 30)):
6         texture = 'Loamy Sand'
7     elif ((clay >= 7 and clay < 20) and (sand > 52) and ((silt + 2*clay) >= 30) or
8           (clay < 7 and silt < 50 and (silt+2*clay)>=30)):
9         texture = 'Sandy Loam'
10    elif ((clay >= 7 and clay < 27) and (silt >= 28 and silt < 50) and (sand <= 52)):
11        texture = 'Loam'
12    elif ((silt >= 50 and (clay >= 12 and clay < 27)) or ((silt >= 50 and silt < 80) and clay < 12)):
13        texture = 'Silt Loam'
14    elif (silt >= 80 and clay < 12):
15        texture = 'Silt'
16    elif ((clay >= 20 and clay < 35) and (silt < 28) and (sand > 45)):
17        texture = 'Sandy Clay Loam'
18    elif ((clay >= 27 and clay < 40) and (sand > 20 and sand <= 45)):
19        texture = 'Clay Loam'
20    elif ((clay >= 27 and clay < 40) and (sand <= 20)):
21        texture = 'Silty Clay Loam'
22    elif (clay >= 35 and sand > 45):
23        texture = 'Sandy Clay'
24    elif (clay >= 40 and silt >= 40):
25        texture = 'Silty Clay'
26    elif (clay >= 40 and sand <= 45 and silt < 40):
27        texture = 'Clay'
28    return texture

```

Fonte: Elaborado pelo autor.

ANEXO D – ARTIGOS PUBLICADOS

HELPER, G. A. et al. Ubiquitous computing in precision agriculture: a systematic review. **Agris on-line Papers in Economics and Informatics**, [S.l.], v. 11, n. 4, p. 3–13, Dec. 2019.

HELPER, G. A. et al. A model for productivity and soil fertility prediction oriented to ubiquitous agriculture. In: XXV SIMPÓSIO BRASILEIRO DE SISTEMAS MULTIMÍDIA E WEB, 2019, Porto Alegre, RS, Brasil. **Anais...** SBC, 2019. p. 489–492.

HELPER, G. A. et al. A computational model for soil fertility prediction in ubiquitous agriculture. **Computers and Electronics in Agriculture**, [S.l.], v. 175, p. 105602, 2020.

HELPER, G. et al. 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. **Anais...** Sociedade Brasileira de Computação - SBC, 2019.

HELPER, G. et al. Tellus-onto: uma ontologia para classificação e inferência de solos na agricultura de precisão. In: XVII SIMPÓSIO BRASILEIRO DE SISTEMAS DE INFORMAÇÃO, 2021, Porto Alegre, RS, Brasil. **Anais...** SBC, 2021.

Artigos publicados derivados da tese e outras contribuições

HELPER, G. A. et al. Multispectral cameras and machine learning integrated into portable devices as clay prediction technology. **Journal of Sensor and Actuator Networks**, [S.l.], v. 10, n. 3, p. 40, June 2021.

MARTINI, B. G. et al. IndoorPlant: a model for intelligent services in indoor agriculture based on context histories. **Sensors**, [S.l.], v. 21, n. 5, p. 1631, Feb. 2021.

COSTA, A. da et al. PhotoMetrix UVC: a new smartphone-based device for digital image colorimetric analysis using PLS regression. **Journal of the Brazilian Chemical Society**, [S.l.], 2021.

HELPER, G. A. et al. The application of parallel processing in the selection of spectral variables in beer quality control. **Food Chemistry**, [S.l.], v. 367, p. 130681, Jan. 2022.