

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
FACULDADE DE AGRONOMIA
CURSO DE AGRONOMIA
AGR99006 - DEFESA DE TRABALHO DE CONCLUSÃO**

TRABALHO DE CONCLUSÃO DE CURSO

**Stéfani Catarina Tres Berghahn
00322849**

Aplicações de Agricultura Digital na Prática Acadêmica

PORTO ALEGRE, maio de 2024

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
FACULDADE DE AGRONOMIA
CURSO DE AGRONOMIA

Aplicações de agricultura digital na prática acadêmica

Stéfani Catarina Tres Berghahn

00322849

Trabalho de Conclusão de Curso apresentado como requisito parcial para obtenção do Grau de Engenheiro Agrônomo, Faculdade de Agronomia, Universidade Federal do Rio Grande do Sul.

Supervisor de campo do Estágio: Dr. Guillermo Balboa

Orientador Acadêmico do Estágio: Dr. André Pich Brunes

COMISSÃO DE AVALIAÇÃO

Prof. Alexandre de Mello Kessler Depto de Zootecnia

Prof. José Antônio Martinelli Depto de Fitossanidade

Prof. Sérgio Luiz Valente Tomasini Depto de Horticultura e Silvicultura

Prof. Clésio Gianello Depto de Solos

Profa. Renata Pereira da Cruz Depto de Plantas de Lavoura

Profa. Lucia Brandão Franke Depto de Plantas Forrageiras e Agrometeorologia

PORTO ALEGRE, maio de 2024.

AGRADECIMENTOS

Aos meus pais, Marcela e Ronei Berghahn, e demais familiares por me apoiarem ao longo de toda a vida, muito além de suporte financeiro, mas em todas as decisões e passos que dei em minha jornada sempre sendo porto seguro e exemplos de dedicação e perseverança.

Às instituições que fizeram parte da minha vida acadêmica, Universidade de Passo Fundo, onde ingressei no curso de Agronomia, *Universidad Nacional del Litoral* em Esperanza, Santa Fé, na Argentina, que me acolheu por um semestre e a Universidade Federal do Rio Grande do Sul, que, em meio a uma pandemia mundial, me recebeu e não deixou a chama do ensino se apagar, sendo prova constante do valor do ensino superior e pesquisa brasileiros.

A *University of Nebraska-Lincoln*, por abrir suas portas para estudantes estrangeiros, proporcionando a vivência da agricultura norte americana combinada com a experiência da Universidade estadunidense.

Ao Arthur Galdino, pelo suporte prestado ao longo do processo, pelas longas conversas discutindo temas dos quais não pertenciam a sua realidade, mesmo assim se fez necessário durante a construção do trabalho.

Ao professor André Pich Brunes, o primeiro professor com quem tive contato direto na UFRGS, pois me recebeu proativamente no seu grupo de pesquisa em 2021, quando as aulas ainda eram remotas, facilitando a minha inserção na Universidade.

À equipe da Professora Laila Puntel e do Professor Guillermo Balboa, com os demais estudantes de mestrado, doutorado e estagiários do grupo, pelos ensinamentos e companheirismo durante o intercâmbio.

Aos demais colegas e amigos por partilharem momentos memoráveis na graduação e na vida.

RESUMO

O estágio curricular obrigatório foi desenvolvido na *University of Nebraska-Lincoln*, no estado de Nebraska nos Estados Unidos da América durante os meses de abril a novembro de 2023. Dois trabalhos principais foram desenvolvidos em colaboração com o grupo de Agricultura de Precisão da Universidade e outras instituições parceiras, dos quais as principais linhas de pesquisa aliam tecnologias digitais à agricultura, visando maiores produtividades. O primeiro projeto busca a elaboração de uma plataforma para tomada de decisão para lavouras de soja, através de uma base de dados construída por monitoramentos de pragas, doenças e plantas daninhas durante o ciclo da cultura. O segundo projeto tem como objetivo utilizar aprendizado de máquina para predição de teores de óleo e proteína em lavouras de soja antes da colheita. As atividades de monitoramento e colheita de soja foram realizadas com a finalidade de elaboração da base de dados para ambos os projetos, destacando o envolvimento da Universidade em aproximar as tecnologias digitais da agricultura.

Palavras-chave: soja, agricultura digital, agricultura de precisão.

LISTA DE FIGURAS

	Página
Figura 01. Localização das lavouras monitoradas.....	16
Figura 02. Captura de tela da face do aplicativo OCM.....	17
Figura 03. DA 7250 NIR realizando a leitura qualitativa de grãos de soja..	22
Figura 04. Equipamentos utilizados nas análises de carbono e nitrogênio...	25
Figura 05. Médias de teores de proteína e óleo de soja dos estados do Cinturão de Milho Oeste dos EUA.....	28

LISTA DE TABELAS

	Página
Tabela 01. Porcentagens de óleo e proteína nos campos avaliados.....	23

SUMÁRIO

	Página
1. INTRODUÇÃO.....	8
2. CARACTERIZAÇÃO DO MEIO FÍSICO E SOCIOECONÔMICO DO ESTADO DE NEBRASKA-EUA.....	8
3. CARACTERIZAÇÃO DA INSTITUIÇÃO UNIVERSITY OF NEBRASKA- LINCOLN.....	9
4. REFERENCIAL TEÓRICO.....	10
4.1 Agricultura Digital.....	10
4.2 Conceitos Tecnológicos.....	11
4.2.1 Big Data.....	11
4.2.2 Internet das Coisas.....	12
4.2.3 Machine Learning.....	12
4.3 A Academia e a Agricultura Digital.....	13
5. ATIVIDADES REALIZADAS.....	15
5.1 Monitoramento de lavouras de soja comerciais do Nebraska.....	15
5.1.1 Insetos.....	18
5.1.2 Doenças.....	19
5.1.3 Plantas Daninhas.....	20
5.2 Determinação do teor de proteína e óleo em grãos de soja por <i>Near Infrared Reflectance Spectroscopy</i>	20
5.3 Coletas para experimentos de nitrogênio em milho, soja e trigo.....	23
5.3.1 Processamento e avaliação de biomassa para análise de carbono e nitrogênio.....	24
5.4 Participação em eventos.....	25
5.4.1 Dia de campo SCAL- UNL.....	25
5.4.2 Simpósio de Agricultura digital e Análise Avançada de Dados.....	26
6. DISCUSSÃO.....	26
7. CONSIDERAÇÕES FINAIS.....	28
8. REFERENCIAS.....	29

1. INTRODUÇÃO

No contexto atual, onde a busca pelo constante aumento de produtividade, visando não somente alimentar o mundo, mas tornar o processo rentável e sustentável a agricultura de precisão deve se alinhar cada vez mais com o digital (Basso *et al.*, 2020). A elaboração de ferramentas que cumpram esse papel e, principalmente sejam aplicáveis à rotina agrícola é, em grande parte, desenvolvida nas Universidades, de forma a aproximar o conhecimento científico da agricultura prática.

O estágio foi realizado na *University of Nebraska-Lincoln* (UNL) na modalidade de *Research Scholar* (pesquisador) com o grupo de Agricultura de Precisão no Departamento de Agricultura e Horticultura. Liderado pela professora Dr. Laila Puntel e pelo professor Dr. Guillermo Balboa, o grupo tem como principais atividades estudos relacionados à fertilidade do solo com aplicações de agricultura de precisão, colaborando ainda, no desenvolvimento de pesquisas de outras instituições.

O local da realização do estágio foi definido a partir do interesse pela ampliação dos conhecimentos na área de agricultura de precisão e expansão dos horizontes de aprendizado e práticas agronômicas em outro país. O principal objetivo da escolha foi vivenciar a agricultura no exterior tendo a oportunidade de colocar em prática os conhecimentos adquiridos ao longo do curso de Agronomia.

A experiência ocorreu no período de 23 de abril a 30 de novembro de 2023, com carga horária de 30 horas semanais, totalizando 960 horas de trabalho. As atividades foram realizadas nas dependências da UNL em Lincoln, nos campos experimentais da Universidade e em lavouras comerciais de produtores parceiros distribuídos no estado de Nebraska.

O presente trabalho é constituído pela caracterização do meio físico e socioeconômico de Nebraska, caracterização da instituição de realização do estágio, referencial teórico, relato das atividades realizadas, discussões baseadas nos assuntos desenvolvidos, considerações finais e referências bibliográficas.

2. CARACTERIZAÇÃO DO MEIO FÍSICO E SOCIOECONÔMICO DO ESTADO DE NEBRASKA- EUA

O estado do Nebraska está localizado na região central-norte dos Estados Unidos da América, foi fundado em 1º de março de 1867 e faz fronteira com outros 7 estados: Dakota do Sul ao norte, Kansas ao sul, Colorado ao sul e oeste, Iowa e Missouri ao leste e Wyoming ao oeste. Mesmo com mais de 1.900.000 habitantes concentrados principalmente na capital

Lincoln e em Omaha (maior cidade do estado), é a parte rural que domina a economia do estado, com mais de 44 mil fazendas reportadas, que variam suas atividades entre pecuária e produção de grãos (USDA, 2023).

O clima varia de subúmido a semiárido, gradualmente transacionando de leste a oeste. O relevo é majoritariamente plano, característico das Grandes Planícies dos EUA, mas possui pequenas depressões, cânions, vales e dunas, onde podem ser encontrados mais de 31 tipos diferentes de solos, cujo tipo predominante é o Mollissolo (Elder, 1969), caracterizado por profundidade média de 0,8 a 2 metros, boa drenagem e alto teor de matéria orgânica entre 4 e 6%. (Adamchuk *et al.*, 2017). Outro tipo de solo bastante encontrado é o Entisol, com horizontes pouco definidos e grandes teores de areia, em torno de 70%, sendo pouco intemperizados.

Aproximadamente 66% do território do Nebraska está sobre o Aquífero Ogallala, o que viabiliza a irrigação de cerca de 3,4 milhões de hectares, sendo o estado com maior número de pivôs nos EUA (Hrozencik, 2024). Esse fator possibilita que o estado se destaque no cultivo de grãos como milho, soja e trigo e tenha ótimos índices de produtividade na pecuária, principalmente ganadeira. No levantamento realizado pelo USDA (2023), entre 2022 e 2023 o rebanho era composto por cerca de 2.700.000 cabeças de gado, foram produzidos 42 milhões de toneladas de milho, 7.500.000 de toneladas de soja e 700 mil toneladas de trigo. Ainda no mesmo senso, produtos como batatas, feno de alfafa, sorgo, milheto, girassol, ervilhas, beterraba açucareira e aveia ganharam destaque.

O governo do estado de Nebraska juntamente com a *University of Nebraska-Lincoln* e sua Divisão de Pesquisa Agrícola organizou diferentes comitês técnicos, com o objetivo de aproximar produtores, Universidade e o setor administrativo do estado, sendo eles: *NE Corn Board* (para milho), *NE Soybean Board* (para soja), *NE Dry Bean Commission* (para feijão não irrigado), *NE Wheat Board* (para trigo) e *NE Dry Pea and Lentil Commission* (para ervilha e lentilha não irrigadas).

3. CARACTERIZAÇÃO DA INSTITUIÇÃO UNIVERSITY OF NEBRASKA-LINCOLN

Fundada em 1869 a *University of Nebraska-Lincoln* tem seu campus principal localizado na capital do estado, e conta com programas de graduação e pós-graduação em diversas áreas de ensino. Com preocupação local e global, está inserida em todos os distritos do estado, com mais de 3.000 estudantes internacionais de 125 países diferentes engajados em

temas como agricultura e agronegócio, gestão de recursos naturais, nutrição e bem-estar humano, desenvolvimento da juventude e outros tópicos relevantes para a sociedade.

Como a agricultura está fortemente presente no estado, a UNL conta com o *Institute of Agriculture and Natural Resources - IANR* (Instituto de Agricultura e Recursos Naturais), uma divisão composta pela Faculdade de Ciências Agrícolas e Recursos Naturais (*College of Agricultural Sciences and Natural Resources*), pela Divisão de Pesquisa Agrícola (*Agricultural Research Division*) e pelo programa de extensão *NE Extension*.

A Universidade conta com sua principal estrutura de ensino dividida em 3 campi na mesma cidade, sendo eles: *East Campus* (localizado na porção leste de Lincoln), *City Campus* (localizado no centro de Lincoln) e *Innovation Campus* (a oeste na cidade). Possui também 2 estações experimentais: a estação - *South Central Agriculture Laboratory - SCAL* (Laboratório de Agricultura Centro-sul) na cidade de Harvard no condado de *Clay Center*, onde a cada ano mais de 100 estudos são conduzidos nas áreas de manejo de água e irrigação, fertilidade do solo, entomologia, plantas daninhas, sistemas de cultivo, manejo de doenças entre outros temas, e a estação *Eastern Nebraska Research, Extension and Education Center - ENREEC* (Centro de Pesquisa, Extensão e Educação do Leste de Nebraska) com quase 4.000 hectares, que possui mais de 6.000 animais e sítios de pesquisa para estudantes dos programas do IANR.

No Departamento de Agricultura e Horticultura da Universidade inserido no IANR está localizado o laboratório de Agricultura de Precisão, que, na época do estágio (2023), era liderado pela Professora Dr. Laila Puntel e seu assistente, o Professor Dr. Guillermo Balboa, com 1 estudante de doutorado, 3 de mestrado, 1 técnico responsável e 5 estagiários. O grupo desenvolve estudos em modelagem de cultivos, eficiência de uso de nitrogênio e produtividade em três principais cultivos: milho, soja e trigo, além de prestar auxílio em projetos da divisão de extensão da UNL (*NE Extension*).

4. REFERENCIAL TEÓRICO

4.1 Agricultura Digital

Na década de 90 a agricultura teve uma significativa revolução em seus métodos com a introdução da Agricultura de Precisão, definida como: “conjunto de técnicas e metodologias que visam otimizar o manejo de cultivos e a utilização de insumos com máxima eficiência” (Brasil, 2009). Outros conceitos incluem a percepção da variabilidade espacial e temporal dentro da lavoura para basear tomadas de decisão. Com isso, a incorporação de equipamentos tecnológicos vem se tornando rotineira, principalmente para produtores de grãos e cereais.

Esse salto tecnológico impulsionou o que vem sendo apresentado como Agricultura 4.0, Agricultura Digital, ou ainda *Smart Agriculture* (Agricultura Inteligente). Independente da nomenclatura, a produção de alimentos novamente se vê frente a mais um salto tecnológico, cuja incorporação de tecnologias baseadas em computação avançada, como *Big Data*, *Internet of Things* - IoT (Internet das coisas) e *machine learning*, objetivam tornar processos na agricultura mais eficientes e eficazes.

Para que seja possível a aplicação destas tecnologias é primordial a coleta de dados, seja ela realizada pela academia por meio de trabalhos científicos, ou pelos próprios produtores que mantêm registros e controle de suas produções. Sem dados, a tomada de decisão se torna pouco fundamentada e assertiva. Um estudo publicado na revista *Precision Agriculture* em 2021 indicou que a maioria dos agricultores norte-americanos que coletam os seus dados e tomam decisões baseadas neles percebem resultados positivos em sua produtividade (Thompson; DeLay; Mintert, 2021).

A agricultura digital surge não somente para coletar grandes volumes de dados, como também organizá-los e torná-los acessíveis, onde os processos computacionais agem no desenvolvimento de sistemas para gestão agrícola, baseados em dados reais e processos estatísticos complexos, o que torna esta tecnologia consistente e maleável, visando sua adesão no campo (Basso *et al.*, 2020).

4.2 Conceitos Tecnológicos

O meio da computação ainda é algo abstrato para o cotidiano da agricultura, por mais que ele esteja inserido no dia a dia do mundo moderno, muitos conceitos e ferramentas ainda são um mistério para aqueles que usufruem de suas funcionalidades (Wolfert *et al.*, 2017). Portanto, a seguir será apresentado o conceito de alguns termos computacionais que constroem a agricultura digital.

4.2.1 *Big Data*

Big Data, traduzido livremente para grandes dados, compreende conjuntos massivos de dados que podem ser obtidos de diferentes formas, sejam elas sensores remotos, dispositivos móveis ou ainda por conjunto de coletas manuais, mas que pelo seu volume torna-se necessário o uso de sistemas para serem analisados e interpretados (Massrhuá *et al.*, 2020). De Mauro, Greco e Grimaldi (2016) descreveram a importância dos 3 V's que compõe o *Big Data*: volume, velocidade e variedade, reiterando a necessidade de tecnologia para processar grandes

quantidades de dados coletados de diferentes fontes com inúmeras variáveis de forma eficiente e rápida

Na agricultura, *Big Data* está sendo mais aplicado na Europa e na América do Norte. Suas principais aplicações incluem criação de modelos preditivos, para aumentar a produtividade ou diminuir riscos, e manejos de rebanhos com o objetivo de tornar mais eficiente a produção e o consumo de alimentos pelos animais (Wolfert *et al.*, 2017).

A tecnologia na produção de alimentos funcionará como um sistema de puxe e empurre, onde os “puxões” virão daqueles que usarão os métodos, com preocupações direcionadas a segurança alimentar, diminuição de custos e maior produtividade, e os “empurrões” virão desta constante busca por inovações, sempre indagando qual será o próximo avanço (Wolfert *et al.*, 2017).

4.2.2 Internet Das Coisas

Outra ferramenta da agricultura digital é a Internet das Coisas (*Internet of Things*- IoT), definida como uma infraestrutura para informação que possibilita a interconexão de informações, existentes ou em construção, de forma física ou virtual, para toda a sociedade (ITU- International Telecommunication Union, 2012). De outra forma, a IoT possibilita que informações sejam compartilhadas entre dispositivos e pessoas via redes de comunicação (internet, seja wifi ou dados móveis, Bluetooth, satélites entre outros), desde que essa possua um endereço de IP (*Internet Protocol*- Protocolo de Internet) (Massrhuá, *et al.*, 2020).

Quy *et al.* (2022) descrevem que o emprego de IoT na agricultura depende de três fatores principais: dispositivos de IoT (sensores de solo, de temperatura e câmeras, que se comuniquem imputando informações), tecnologias de comunicação (incluem os protocolos de comunicação sem fio, espectros de ondas de frequência e a topologia de como o espectro se comunica com o protocolo) e por fim o registro e armazenamento de dados, indicando assim como a agricultura digital pode ser incorporada às propriedades rurais.

4.2.3 Machine Learning

O *machine learning*, em português aprendizado de máquina, implica no aprendizado de computadores a partir do reconhecimento de padrões previamente apresentados, sem serem de fato programados (Murphy, 2012). Pode ser dividido em 2 vertentes: aprendizado supervisionado, no qual há um conjunto de dados rotulados e pretende-se encontrar rótulos que são até então desconhecidos, e aprendizado não supervisionado, onde a identificação de padrões não é específica a partir de dados não rotulados (Massrhuá, *et al.*, 2020).

Modelos computacionais podem ser treinados para reconhecimento de doenças e plantas daninhas, onde existem 2 papéis realizados pela máquina, um gera imagens sintéticas a partir de uma base de dados real e outro discrimina estas imagens. Pode ser empregada em predições de produtividade, na detecção de linhas de semeadura, para sistemas de navegação, identificação de estresses hídricos, para estimar conteúdo de água em tecidos vegetais, assim como pode auxiliar no manejo da irrigação. Ou seja, a partir desta tecnologia, ferramentas podem ser desenvolvidas para auxiliar na manutenção de parâmetros de monitoramento e controle de processo na agricultura (Prema; Veeramani; Sivakumar, 2022).

4.3 A Academia e a Agricultura Digital

Tendo em vista a constante evolução da tecnologia, a academia, como centro gerador de conhecimento, tem o papel fundamental de integrar os conhecimentos de áreas distintas. A integração de conhecimentos da área agrônômica com a computação possibilita os avanços da agricultura digital. Destacam-se trabalhos desenvolvidos pela academia que unem ambas as áreas do conhecimento a fim de tornar as práticas agrícolas mais assertivas, precisas e eficientes.

A dissertação de mestrado de Mazetti Marra (2023) nos campos experimentais da Unesp em Jaboticabal, São Paulo, teve como objetivo identificar quais os melhores recursos e possibilidades de imagens remotas, para que seja possível a predição de produtividade da soja por *machine learning*, através de imagens oriundas de satélites ou de VANTs (Veículos Aéreos não tripulados).

As imagens de Índice de Vegetação utilizadas no estudo foram: NDVI (*Normalized Difference Vegetation Index*- Índice de Vegetação por Diferença Normalizada), GNDVI (*Green Normalized Difference Vegetation Index*- Índice de Vegetação por Diferença Normalizada na cor verde), VARI (*Visible Atmospherically Resistant Index*- Índice de Vegetação Atmosférico Visível), SAVI (*Soil Adjusted Vegetation Index*- Índice de Vegetação Ajustado para o Solo) e EVI (*Enhanced Vegetation Index*- Índice de Vegetação Melhorado) coletando imagens das lavouras de soja nos estádios R4 a R7. Utilizando o modelo de regressão ANN (Redes Neurais Artificiais) com NDVI E GNDVI nos estádios R4 e R5, o autor constatou que estas são as variáveis e recursos mais confiáveis para predições precoces de produtividade (Marra, 2023).

O manejo fitossanitário também é alvo de aplicações da agricultura digital. Em 2016, estudantes da Universidade de Passo Fundo, juntamente com a EMBRAPA e com o Comitê de Ferrugem Asiática da Soja (CAF) (Andreis *et al.*, 2016), desenvolveram um aplicativo para *smartphone* que possibilita a qualquer pessoa do Brasil acessar mapas em tempo real nos quais é possível acompanhar a dispersão da doença.

O aplicativo permite que todos os laboratórios registrados junto ao CAF possam registrar focos de ferrugem da soja em todo o país que, juntamente com dados de pesquisas prévias, são fontes de informação que alimentam o servidor da plataforma. O servidor então produz mapas de dispersão da doença que podem ser acessados pelos seus clientes em diversas cidades brasileiras.

Outra dissertação de mestrado publicada por Alves (2016) pela Universidade Federal de Viçosa buscou analisar, através da abordagem *Big Data*, a ocorrência de espécies quarentenárias brasileiras presentes nos países vizinhos da América do Sul, com o objetivo de prestar auxílio à defesa sanitária brasileira, identificando padrões de invasão das pragas e a possível predição da entrada destas no país.

Os dados para este trabalho vieram de mais de 100 revistas científicas, banco de dados e demais bibliografias nacionais e internacionais. Além de contabilizar as diferentes espécies quarentenárias, o algoritmo desenvolvido elencou o potencial de entrada, de estabelecimento, de dispersão e de dano econômico, concluindo então que 5 espécies de pragas presentes em países vizinhos têm altas chances de entrarem no Brasil e serem de alto risco biológico.

A visão de agricultura digital como ferramenta de auxílio a produtores agrícolas motivou um estudo realizado por Ramos e de Oliveira (2022), com o principal objetivo de utilizar análises de solo e dados de histórico de talhões para prescrição de semeadura com taxa variável em lavouras de milho em Abelardo Luz, Santa Catarina. Através de mapas de fertilidade e constituintes de solo, foi possível ajustar a população de plantas com o auxílio de ferramentas de agricultura digital, constatando assim que esta tecnologia é confiável sendo uma aliada no uso racional de insumos.

O *machine learning* também está presente no desenvolvimento de aplicativos para celular, com o objetivo de facilitar a identificação de pragas na cultura da soja através de fotos tiradas pelo próprio usuário, o projeto desenvolvido por Tonini (2023) no Instituto Federal de Santa Catarina em São José, promete trazer resultados instantâneos para consulta na palma da mão.

O aplicativo será desenvolvido através de um banco de dados com imagens de plantas de soja que apresentam alguma praga devidamente identificada e imagens de plantas saudáveis, em sistema de rede neural profunda, que através de diversas camadas de processamento permite analisar grandes quantidades de dados. Este projeto ainda está em andamento, mas é mais um exemplo de como a sociedade acadêmica está engajada em trazer a tecnologia para auxiliar o dia a dia da produção agrícola.

Portanto as pesquisas e resultados aqui relatados confirmam o que disse Wolfert *et al.* (2017) quando constatou que o homem continuará sendo a fonte intelectual, já a máquina será responsável pelas atividades operacionais, uma vez que desempenha este papel com mais velocidade e precisão.

5. ATIVIDADES REALIZADAS

O estágio curricular obrigatório foi realizado junto ao grupo de pesquisa de Agricultura de Precisão da *University of Nebraska-Lincoln*, no ano de 2023 durante os meses de abril a novembro, onde foram acompanhados os estudos desenvolvidos com as principais culturas do estado de Nebraska: milho, soja e trigo.

5.1 Monitoramento de lavouras de soja comerciais do Nebraska

Durante o período de maio a outubro, foi desenvolvido parte do estudo realizado pelo *North Central Soybean Research Program-NCSRP* (Programa de Pesquisa da Soja Central Norte) intitulado “*Using data-driven knowledge for profitable soybean management systems*” (Uso de conhecimento dado-direcionado para o manejo rentável de sistemas de soja), cujo objetivo é criar uma ferramenta para auxiliar a tomada de decisão e que consequentemente aumente o retorno sobre investimento (ROI) dos produtores de soja.

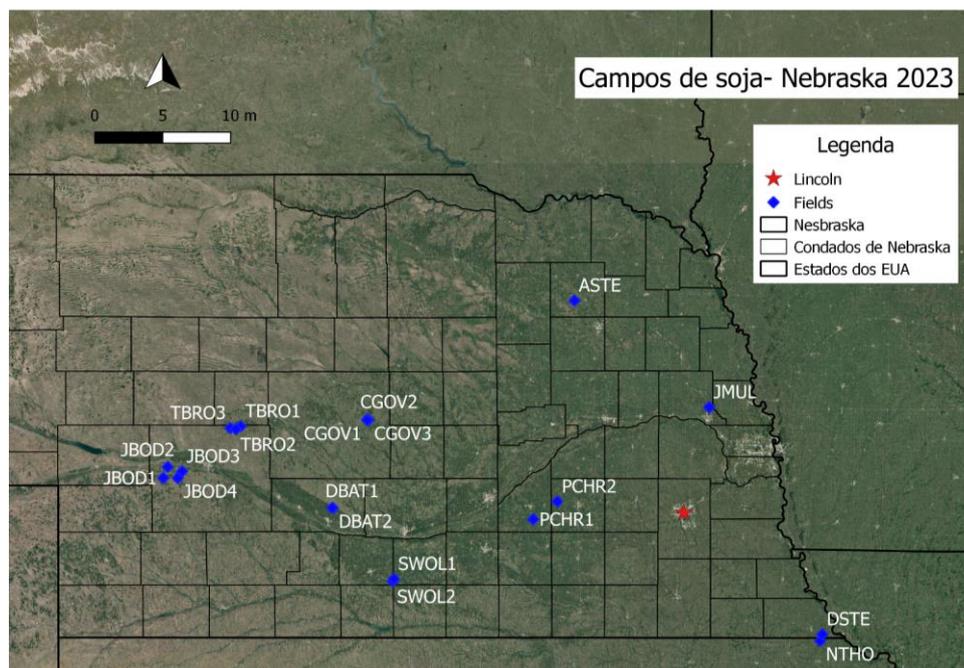
A base de dados para o projeto inclui manejos adotados pelos produtores envolvidos no estudo, fatores bióticos que limitam a produtividade, características físico-químicas do solo, dados climáticos coletados durante o período de cultivo e sensoriamento remoto. A coleta iniciou em 2021 e continua sendo realizada até o presente ano de 2024, sendo liderado pela Universidade de Wisconsin-Madison e Universidade Estadual da Pensilvânia com a colaboração de 6 estados: Ohio, Minnesota, Iowa, Missouri, Nebraska e Dakota do Norte.

Durante os meses de cultivo da soja, foram acompanhadas 20 lavouras comerciais no estado do Nebraska, monitorando periodicamente pragas, doenças, plantas daninhas e estresses abióticos presentes nas lavouras de soja. Os campos pertenciam a agricultores membros do “*Nebraska Soybean Board*” (Comitê da Soja do Nebraska), que se voluntariaram para participar do estudo em parceria com o programa de extensão da UNL.

As vistorias eram realizadas quinzenalmente, de forma a acompanhar o desenvolvimento das plantas. A área das lavouras variou entre 18 a 90 hectares, sendo que para cada nova data de amostragem eram obtidos 5 pontos aleatoriamente distribuídos na área, para que as coletas fossem o mais representativas possível. Os 20 campos foram identificados

conforme o nome de cada produtor, os quais não serão mencionados aqui, tendo assim siglas para a identificação de cada um: ASTE (55ha), CGOV1 (30ha), CGOV2 (48ha), CGOV3 (47ha), DBAT1 (18ha), DBAT2 (58ha), DSTE (26ha), JBOD1 (45ha), JBOD2 (56ha), JBOD3 (41ha), JBOD4 (46ha), JMUL (50ha), NTHO (60ha), PCHR1 (30ha), PCHR2 (57ha), SWOL1 (50ha), SWOL2 (54ha), TBRO1 (90ha), TBRO2 (55,5ha), TBRO3 (47ha). Dos 20 campos que compunham a pesquisa DBAT2, DSTE e NTHO eram os únicos não irrigados.

Figura 01: Localização das lavouras monitoradas.

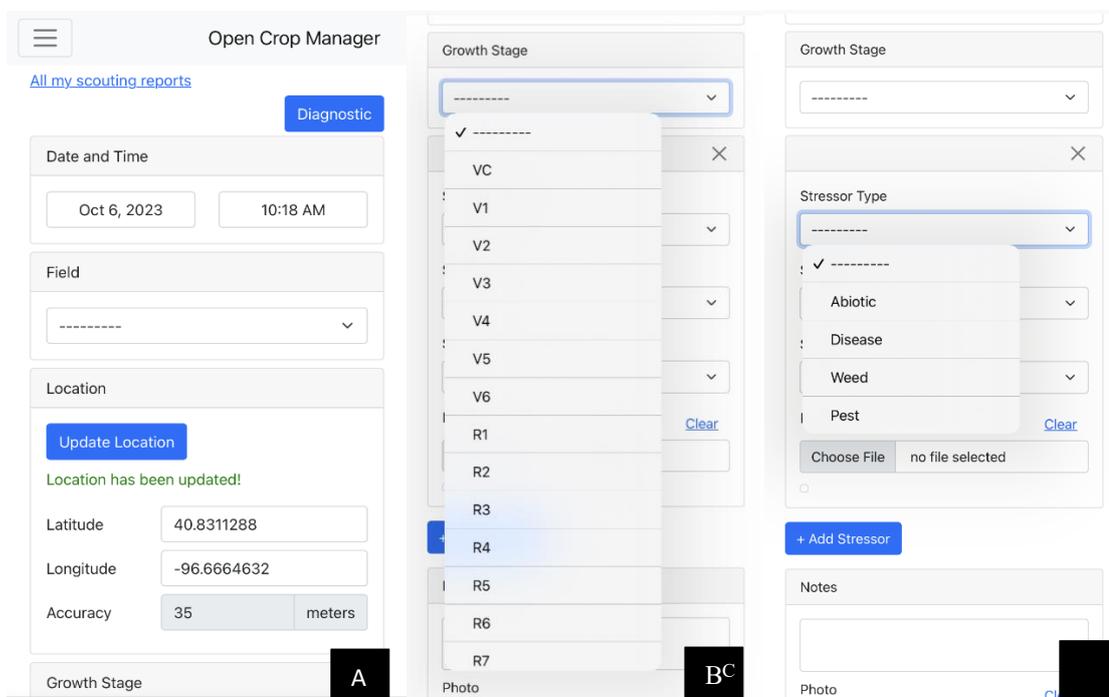


Fonte: elaborado pela autora na plataforma QGIS, 2024.

Utilizando a ferramenta “Avenza Maps” para localização de cada ponto de monitoramento, inicialmente houve contagem do estande de plantas nos estádios V0 e V2 (Fehr e Caviness, 1977), juntamente com o monitoramento de pragas, doenças, daninhas e efeitos abióticos, os quais seguiram sendo coletados e registrados em outra plataforma chamada *Open Crop Manager*- OCM. Cada fator encontrado era reportado individualmente na plataforma, indicando data, hora, coordenada, estágio das plantas, a categoria do agente de estresse, o nome comum (com opções pré-selecionadas na plataforma), grau de severidade e, por fim, uma imagem do que estava sendo reportado.

Figura 02: Captura de tela da face do aplicativo OCM. A) Início do registro com data e hora, identificação do campo, local exato com coordenadas de latitude, longitude e acurácia. B) Estádio de crescimento em que se encontrava a lavoura. C) Tipo de agente estressor: abiótico, doença, planta daninha ou praga. Abaixo se identifica por nome e adiciona-se a imagem do evento estressor.

Fonte: *Open Crop Manager*.



Fonte: Open Crop Manager, 2023.

Para o diagnóstico de pragas, doenças e plantas daninhas no campo, foram disponibilizados dois livros: “*Nebraska Soybean and Corn Pocket Field Guide*” desenvolvido pelo *Nebraska Extension*, juntamente com o *Nebraska Soybean Board* e *Nebraska Corn Board*, o qual contém resumidamente a descrição de estágio e principais características para identificação de pragas, doenças e plantas daninhas, com imagens e indicações de controle para milho e soja. Outro livro utilizado foi o “*A Farmer’s Guide to Soybean Diseases*” com um completo compilado de doenças da soja publicado pela “*The American Phytopathological Society*” em 2016. Quando possível, a internet móvel foi uma grande aliada para identificação e, em casos de incerteza de diagnóstico, amostras eram coletadas e levadas a professores ou profissionais competentes na área necessária.

Ao final das coletas, foi disponibilizada uma planilha na qual constavam todas as entradas registradas no OCM, contendo data, horário, campo e as demais informações sobre pragas, daninhas e doenças encontradas em cada ponto amostral. Uma pasta no drive com todas as imagens carregadas no aplicativo também foi disposta. É importante ressaltar que demais

informações como cultivares, manejos, época de plantio não foram coletadas, pois faziam parte de outra etapa do trabalho.

Análises estatísticas não fizeram parte das atividades desenvolvidas, mas a partir dos dados fornecidos pelo NCRSP, foi possível fazer uma relação de quais estresses tiveram mais aparições nas 494 entradas registradas no OCM. A partir do compilado de relatórios foi elaborada uma descrição dos insetos, doenças e plantas daninhas que se destacaram nos monitoramentos, detalhando as respectivas presenças no total de pontos amostrais, campos e estágio fenológico.

5.1.1 Insetos

Uma praga desfolhadora importante para a região norte dos EUA é o *Japanese Beetle*, em português Besouro Japonês (*Popillia japonica*). Apesar de ser polífaga e causar impacto em cultivos de gramíneas, tem grande popularidade na cultura da soja, onde deixa um sintoma característico conhecido como esqueletização da folha. Os besouros têm em torno de 1,2 cm, tórax e cabeça verde metálicos com tufo de pelos nas laterais do abdome. O controle químico é indicado quando se constata 30% de desfolha em estágio vegetativo e 20% em reprodutivo (Wright, *et al.*, 2023). Nas visitas de monitoramento foi constatado a presença do inseto em 14% dos pontos amostrados, em 7 campos diferentes (DSTE, NTHO, PCHR1, PCHR2, DBAT1, DBAT2, JMUL), nos estádios R1 a R6 (Fehr e Caviness, 1977).

O levantamento realizado leva em consideração as 3 espécies mais encontradas de *Stink bugs* (percevejos): *Brown marmorated stink bug* - *Halyomorpha hallis*, *Brown stink bug* - *Euchistus heros* e *Green stink bug* - *Chinavia hilaris* estando presente em 9% de todos os pontos amostrados, com a maior distribuição espacial em 15 dos 20 campos que compunham o estudo (DSTE, TBRO1, SWOL1, SWOL2, PCHR1, PCHR2, DBAT2, JMUL, JBOD1, JBOD2, JBOD3, JBOD4, CGOV1, CGOV2, CGOV3). Estes sugadores são pragas tanto em estágio de ninfa quanto adultos. Ambas as formas foram registradas no período vegetativo em menor quantidade, 4 observações de V2 a V6 (Fehr e Caviness, 1977), e no período reprodutivo tiveram seu pico de aparições, como esperado devido ao ciclo de vida destes insetos. Nos EUA, o controle químico é indicado quando há 1 inseto por linha em 1 pé de comprimento no período reprodutivo ou 3,6 insetos a cada 15 amostras retiradas com pano de batida. (Hunt; Wright; Jarvi, 2015).

Presente na maioria das leguminosas cultivadas, o *Bean leaf Beetle* - *Cerotoma trifurcata*, é praga na soja tanto no estágio larval, quando se alimenta de raízes de plantas por estar no solo, quanto adulto causando desfolha, também podendo ser vetor de viroses

(CropWatch, 2024). Mede em torno de 0,5 cm, sua coloração varia de avermelhada a amarelo, porém a principal característica deste inseto são suas pontuações pretas, 2 em cada asa e uma mancha triangular próxima da cabeça. Foi encontrada ao longo de todo o ciclo em 6% dos pontos amostrais, estando distribuída na metade dos campos observados (TBRO1, TBRO2, NTHO, SWOL1, DBAT1, JMUL, JBOD2, JBOD4, CGOV1, CGOV3).

5.1.2 Doenças

A principal doença encontrada foi *Frogeye leaf spot - Cercospora sojina*, foi reportada em 24% dos pontos amostrais coletados ao longo de todo o ciclo da cultura, sendo que todos os 20 campos apresentaram pelo menos 2 pontos amostrais com a presença de *Cercospora*. O sintoma é facilmente identificado por lesões normalmente circulares de centro esbranquiçado e bordas marrom avermelhadas a arroxeadas. No Nebraska, aparecem em maior quantidade no período reprodutivo, que costuma ter clima mais úmido na região, favorecendo a disseminação do fungo (Mueller, 2016).

O patógeno que ataca as raízes *Fusarium virguliforme* é causador de *Sudden death syndrome*. Ele produz uma toxina que é expressa na parte aérea inicialmente como uma clorose internerval amarelada, que evolui para tecidos mortos, ocasionando a queda do folíolo, de forma com que o pecíolo ainda esteja preso a planta. Em plantas com a doença avançada, um corte longitudinal no caule revela em sua parte lenhosa coloração acinzentada a marrom. Foram encontradas plantas doentes em 8% dos pontos amostrais, distribuídas em 11 dos 20 campos (DSTE, TBRO2, NTHO, SWOL1, SWOL2, PCHR2, JMUL, JBOD1, JBOD2, JBOD3, JBOD4), estando pouco presente em estádios iniciais do período reprodutivo (R2-R3 (Fehr e Caviness, 1977)), onde perdas pela doença são maiores, mas mais presente em R5-R6 (Fehr e Caviness, 1977), causando menor impacto na produtividade. (Mueller, 2016).

Facilmente diagnosticada pela presença de micélio branco do fungo, com estruturas de sobrevivência conhecidas como escleródios pretos presos ao caule da planta, *White mold - Sclerotinia sclerotiorum*, também se manifesta nas folhas como clorose internerval, com eventual morte de folhas ainda presas ao caule (Mueller, 2016). É principalmente observada entre R4 e R6 (Fehr e Caviner, 1977), na época de maior umidade. Esteve presente em 7% dos pontos amostrais, em 12 campos (DSTE, TBRO1, TBRO2, SWOL1, SWOL2, PCHR1, PCHR2, JMUL, JBOD2, JBOD3, CGOV2, CGOV3).

5.1.3 Plantas Daninhas

Mais de 70% das áreas agricultáveis no Nebraska são plantadas com milho resistente a molécula “*glyphosate*” (Jhala; Wright; Chahal, 2015) que, em rotação com soja resistente a mesma molécula, pode ocasionar escapes de milho voluntário, onde este além de competir com a soja, pode ser hospedeiro de pragas comuns às duas culturas. Em 11% dos pontos foram encontradas plantas de milho nas lavouras de soja, distribuídos em 11 campos (DSTE, TBRO1, TBRO2, TBRO3, SWOL1, SWOL2, PCHR1, PCHR2, DBAT2, JMUL, JBOD4), durante todo o ciclo, significando que o problema não foi remediado nos estádios iniciais, onde o controle químico tem a maior eficiência.

Outra planta daninha de grande destaque no estudo são, na verdade, 3 espécies do gênero *Amaranthus*: “*Palmer amaranth*” *Amaranthus palmeri*, “*Redroot pigweed*” *Amaranthus retroflexus* e “*Waterhemp*” *Amaranthus tuberculatus*, sendo encontradas em 9% das amostras monitoradas, presentes em 12 dos 20 campos (TBRO1, PCHR1, PCHR2, DBAT1, DBAT2, JMUL, JBOD2, CGOV1, CGOV2, CGOV3), e em todo o ciclo da soja, o que reitera o grande problema atual enfrentado com este gênero: genótipos resistentes a herbicidas, principalmente à molécula glifosato.

5.2 Determinação do teor de proteína e óleo em grãos de soja por *near infrared reflectance spectroscopy*

Outro trabalho realizado se refere a medições de porcentagem de óleo e proteína em grãos de soja. Os dados coletados fazem parte do projeto de pesquisa da *Kansas State University* (KSU-Universidade Estadual do Kansas), coordenado pelo Professor PhD Ignacio Ciampitti, intitulado “*Mapping Soybean Protein and Oil Quality in Farmer Fields*” (Mapeamento da qualidade de proteína e óleo da soja em lavouras de Agricultores).

O projeto tem como objetivo formar um banco de dados para os 13 estados da região Central Norte dos EUA (Dakota do Norte, Dakota do Sul, Kansas, Minnesota, Iowa, Nebraska, Missouri, Wisconsin, Illinois, Michigan, Indiana, Ohio e Kentucky) que inclua coletas de dados de produtividade e qualidade de sementes de soja, teor de óleo e proteína, relacionando estes fatores a imagens aéreas capturadas durante o desenvolvimento da cultura. A coleta de dados ocorre desde 2021 até 2024, e espera-se disponibilizar em 2025 uma ferramenta online onde os produtores da região possam fazer predições de proteína e óleo em suas lavouras.

Sabendo que a soja é um dos principais ingredientes base da dieta de muitos animais, compradores internacionais e nacionais dos EUA esperam que o conteúdo de proteína e óleo

seja de pelo menos 50% nos grãos, tendo em vista que a produção de farinha de soja tenha pelo menos 48% destes compostos (Durham, 2003), portanto, a preocupação com a qualidade nutricional dos grãos é crescente. Em um estudo realizado por Borja Reis (2022) produtores estadunidenses afirmaram que, caso recebessem algum incentivo, estariam dispostos a investir em manejos para melhorar a qualidade de suas produções. Sendo assim, a pesquisa é impulsionada a aliar novas tecnologias como o *machine learning* para a predição de proteína e óleo dos grãos, como mais uma ferramenta de tomada de decisão para o produtor.

Em agosto de 2023, uma parte da avaliação dos resultados desta pesquisa foi publicada por Hernandez (2023) na qual 47 campos de soja do Kansas e Iowa fizeram parte. Avaliou-se diferentes bandas espectrais que indicam índice de clorofila, índice de área foliar, conteúdo de água e biomassa total, e 6 diferentes modelos de aprendizado de máquina: ElasticNet, Random Forest, XGBoost, LightGBM, CatBoost e um conjunto de todos os anteriores, onde 70% dos campos foram utilizados para treinar os modelos e 30% para testá-los.

Os resultados obtidos confirmaram que a melhor época para treinar os modelos de predição de qualidade da semente é após o pico do índice de clorofila. Entre as 6 ferramentas de “*machine-learning*” testadas, XGBoost se destacou, verificando uma margem de erro de 1,8% para proteína e 1,04% para teor de óleo em suas predições. Estes parâmetros se aproximaram mais dos teores reais quando comparados com os coletados a campo e analisados por NIR.

Na safra de 2023, realizou-se a colheita manual dos grãos de soja de 19 campos que fizeram parte do projeto citado, assim como coleta de amostras de solo para serem enviadas à KSU. O protocolo para a realização desta tarefa foi providenciado pela Universidade responsável. Mapas gerados pela plataforma Google Earth foram enviados indicando as coordenadas de cada ponto de amostragem. As amostras de grão foram colhidas ao longo de 21 polegadas (53 cm) na linha de plantio, sendo que o número de linhas variou de acordo com o espaçamento de plantio de cada lavoura (30 polegadas (76 cm) entre linhas: 1 linha, 15 polegadas (38 cm): 2 linhas e 7,5 polegadas (19 cm) polegadas: 4 linhas), de modo a aproximar-se de 100.000 plantas/acre (em torno de 400.000 plantas/ha), cada campo tinha entre 6 e 9 pontos amostrais. Já as amostras de solo foram obtidas para caracterização do solo, sendo de 0-24 polegadas (0-60 cm), retiradas nos mesmos locais das colheitas, mas agrupadas em até 3 *clusters* de acordo com imagens de satélite analisadas pela KSU.

As vagens coletadas no estádio R8 (Fehr e Caviness, 1977) no campo foram secadas por 5 dias em estufas de ventilação com ar forçado à temperatura próxima de 40°C. Após esse período, foram trilhadas e, previamente ao envio das amostras de grãos para a KSU, foram

realizadas leituras para teor de óleo e proteína utilizando o equipamento DA 7250 NIR (*Near Infrared Reflectance Spectroscopy*- Espectroscopia de reflectância no Infravermelho Próximo) da empresa PerkinElmer.

Figura 03: DA 7250 NIR realizando a leitura qualitativa de grãos de soja.



Fonte: a autora, 2023.

As amostras consistiram de 80g de grãos inteiros de soja cuja leitura era realizada pelo equipamento que leva em média 6 segundos para analisar cada amostra de modo não destrutivo. Os parâmetros qualitativos analisados incluíram teor de óleo e de proteína, ambos expressos em porcentagem (%). Com estes dados foi possível realizar uma breve apresentação sobre os trabalhos desenvolvidos junto ao grupo de pesquisa.

A Tabela 01 traz as médias de porcentagens para proteína e óleo de cada campo, constatadas a partir da análise das amostras pelo equipamento DA 7250 NIR. A média geral de todos os campos avaliados foi de 38,3% para teor de proteína e, para óleo, a média de todos os campos foi de 20,6%.

Tabela 01: Porcentagens de óleo e proteína nos campos avaliados

Campo	Proteína (%)	Óleo (%)
ASTE	39,53	21,5
CGOV1	40,63	18,8
CGOV2	40,0	18,9
CGOV3	37,5	20,2
DBAT1	37,6	21,1
DBAT2	38,0	21,2
DSTE	37,7	22,2
JBOD1	36,6	20,7
JBOD2	35,2	21,2
JBOD3	39,3	19,8
JBOD4	38,4	20,5
JMUL	39,1	20,3
NTHO	37,3	21,2
PCHR1	39,3	21,2
PCHR2	39,9	20,5
SWOL1	37,5	21,7
SWOL2	38,2	21,6
TBRO2	37,1	20,3
TBRO3	38,0	19,2
Médias	38,3	20,6

5.3 Coletas para experimentos de nitrogênio em milho, soja e trigo

O grupo de pesquisa em Agricultura de Precisão estava conduzindo diferentes estudos relacionados à aplicação de doses de nitrogênio em soja, milho e trigo, utilizando modelagem de culturas para buscar melhor eficiência no uso deste nutriente e conseqüentemente maiores produtividades.

Os experimentos foram conduzidos nas dependências da Universidade, localizadas nas cidades de Clay Center e Midge, e em áreas comerciais de produtores parceiros distribuídas em todo o estado de Nebraska. Os experimentos eram conduzidos pelos estudantes de doutorado e mestrado do grupo, juntamente com o apoio dos professores orientadores. Os estagiários eram responsáveis pelas coletas a campo, as quais eram realizadas seguindo as orientações dos pesquisadores competentes.

Nas atividades realizadas em campos experimentais de milho, as coletas eram realizadas idealmente a cada 2 estádios de desenvolvimento que a cultura atingia, sendo elas em V3, V6,

V9, R1, R3, R6 (Ritchie; Hanway; Benson, 1993) e, ao final, quando atingiram ponto de maturidade para colheita em R8. As coletas incluíam dados de altura de plantas (cm), obtida com fita métrica, diâmetro de colmo (mm), medido com paquímetro, índice de área foliar determinado com o equipamento LAI-2200 da empresa LI-Cor, que permite realizar as medições de forma não destrutiva, índice de clorofila, medido através do aparelho SPAD-550 da empresa Konica Minolta, mensurado diretamente nas folhas sem cortá-las, biomassa fresca e biomassa seca (g). Esses dados foram utilizados para acompanhar o crescimento da cultura ao longo do ciclo, sendo correlacionados com a produtividade. Os campos experimentais contavam com áreas de milho lado a lado irrigadas e não irrigadas, possibilitando a comparação de resultados entre estes tratamentos.

Nas lavouras de soja, as coletas foram menos frequentes, pois os campos experimentais estavam localizados em Clay Center, cerca de 150 km da sede da equipe, o que dificultava o planejamento para coletas. Foi possível acompanhar as coletas realizadas no período reprodutivo e no enchimento de grãos, onde somente a biomassa fresca (g) foi coletada.

Por fim, nos experimentos de trigo, duas coletas de dados foram realizadas pela equipe, ambas com pontos de coleta definidos a partir de imagens de satélite que indicam índices de vegetação. A primeira série de amostragens ocorreu no emborrachamento da cultura no mês de maio, na qual foram coletados índices de fechamento de dossel com o aplicativo de celular “Canopeo”, biomassa verde e amostras de solo para análise química. A última coleta de dados foi realizada previamente à colheita das lavouras, no início de julho, obtendo-se somente as espigas e amostras de solo. As espigas foram secas em estufas de ar forçado a 40°C e posteriormente trilhadas e analisadas em equipamento NIR, com metodologia não destrutiva, para verificação de teor de proteína nos grãos de trigo.

5.3.1 Processamento e avaliação de biomassa para análise de carbono e nitrogênio

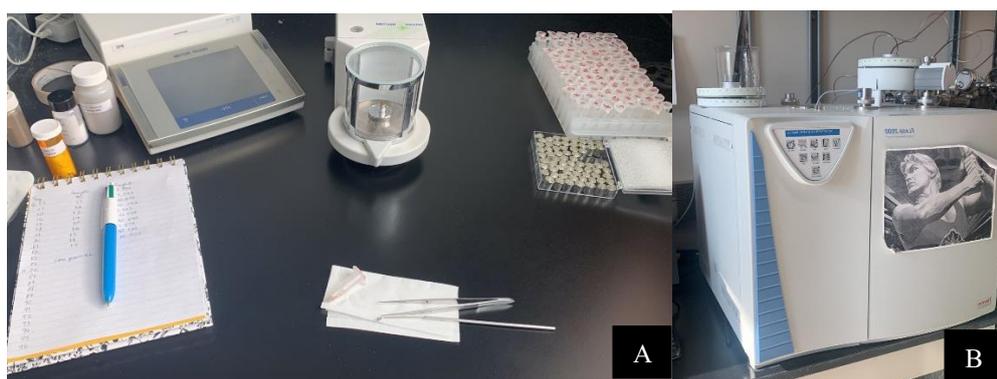
Além da coleta dos dados supracitados, nas lavouras de soja e milho, foram coletadas amostras de tecido particionadas em caules, folhas e estruturas reprodutivas, para determinação do conteúdo de carbono e nitrogênio por método destrutivo de combustão em equipamento apropriado. Em 2023 foram conduzidas análises de Carbono e Nitrogênio das amostras retiradas em 2022 e parte das amostras coletadas em 2023.

Para realização de tal tarefa, as amostras são moídas manualmente ou em moedores mecânicos, para que atinjam granulometria semelhante à farinha de trigo. No estágio vegetativo, as plantas foram processadas inteiras, a partir do estágio reprodutivo, estruturas

reprodutivas, vegetativas e grãos foram moídas separadamente, possibilitando analisar os compostos de cada estrutura individualmente.

O conteúdo de de C e N foi obtido por leitura no equipamento “*Flash 2000 Organic Elemental Analyzer*” da empresa ThermoFischer Scientific, que, através de combustão, determina os parâmetros citados. Para tal, foi pesado 10 mg de cada amostra uma em balança de precisão, envolvendo este conteúdo em cápsulas de papel alumínio para leva-lo à máquina. O equipamento deve ser calibrado a cada 48h, seguindo as instruções do fabricante, sendo que cada espécie vegetal tem sua curva de calibração e amostra padrão para controle de qualidade. Após a calibração, as amostras podem ser analisadas, levando em torno de 6 minutos para cada uma. Ao final, uma planilha é produzida com os resultados da análise, assim como uma curva de C:N para cada amostra lida.

Figura 04: Equipamentos utilizados nas análises de carbono e nitrogênio. A) Materiais utilizados na preparação de amostras para leitura de carbono e nitrogênio. B) *Flash 2000 Organic Elemental Analyzer*.



Fonte: a autora, 2023.

5.4 Participação em Eventos

5.4.1 Dia de campo SCAL- UNL

No dia 1 de agosto de 2023 a unidade experimental “*South Central Agricultural Laboratories- SCAL*” sediou seu dia de campo anual, o qual foi possível prestigiar juntamente aos colegas de laboratório. No evento, foram abordados os seguintes temas:

- a) Manejo de nutrientes- demonstração de fertirrigação e tecnologias de agricultura de precisão para manejo de nutrientes;
- b) Manejo de doenças- atualizações sobre doenças de soja e milho;
- c) Manejo de insetos- atualizações sobre pragas de soja e milho;
- d) Manejo de irrigação- tecnologias para agendamento de irrigação;
- e) Manejo de daninhas- culturas de cobertura para supressão de daninhas em soja e milho: plantio verde e consorciação.

O dia de campo acolheu toda a comunidade acadêmica assim como produtores locais que participam ativamente do programa de extensão da Universidade. Os tópicos foram de extrema relevância, visto que as principais culturas (soja e milho) estavam permeando metade de seu ciclo, sendo uma ótima estratégia para aproximar produtores das novas tecnologias e estratégias de manejo perante cenários vivenciados na safra passada.

5.4.2 Simpósio de agricultura digital e análise avançada de dados

A Universidade Estadual do Kansas (*Kansas State University*- KSU) em conjunto com o programa de simpósios da Corteva (*Corteva Symposia Series*), ofereceu seu primeiro Simpósio de Agricultura digital e Análise Avançada de Dados, o qual foi prestigiado no dia 23 de outubro de 2023 pelos estagiários do grupo de Agricultura de Precisão da UNL.

O simpósio contou com palestrantes locais e internacionais das seguintes instituições: NASA Acres, Universidade de Illinois, Universidade Estadual do Arizona, Instituto Nacional Francês de Agricultura, Alimentos e Meio Ambiente e da empresa Corteva, que abordaram temas como sensoriamento remoto, “*Big Data*” e inteligência artificial, máquinas para agricultura de precisão, robótica e análise estatística e de riscos na agricultura.

6. DISCUSSÃO

A Universidade, juntamente com o grupo de extensão e o laboratório de Agricultura de Precisão, participa de uma importante etapa no avanço da pesquisa tecnológica. Ambos os projetos relacionados à cultura da soja demonstram a constante busca pela inserção do digital na agricultura, permitindo que as instituições estejam inseridas no meio rural e cumpram seu papel aliando a pesquisa com a prática agrícola.

Como o objetivo final do projeto de pesquisa é montar uma plataforma que os produtores da região norte dos EUA possam acessar e, assim, manter-se a par dos históricos de seus respectivos condados e receber previsões sobre as próximas safras, a compilação dos dados coletados se torna de extrema importância para a produção da plataforma final.

A execução dos monitoramentos é exemplo de como a agricultura digital ampara o meio agrícola nos Estados Unidos, uma vez que a reunião dos dados do projeto de monitoramento da soja só foi possível graças ao OCM. O aplicativo, além de determinar precisamente a localização em que cada inseto, doença ou daninha foi encontrada, facilita o processo de monitoramento por estar na palma da mão do usuário, podendo ser acessado *in loco* ou após visita a campo.

Cabe salientar que, se por um lado o aplicativo de celular utilizado facilita a coleta de informações a campo, a ausência de informação como o nome científico dos organismos no software dificulta a identificação correta de agentes estressores. Apesar de haver espaço para adição de comentários pelo usuário, estas informações não foram compiladas na planilha oferecida ao final do monitoramento. Espera-se que esta questão seja solucionada pelo NCSRП para confecção dos resultados finais.

As análises de dados e os resultados finais são altamente tecnológicos, porém é importante ressaltar que os meios de coleta descritos nas atividades realizadas também são uma porta para introdução de novas tecnologias. Um exemplo disso é o emprego de robôs como o BoniRob que é capaz de realizar atividades de fenotipagem em plantas (Biber, 2012), a ferramenta ainda é incipiente, mas é promissora para a substituição da mão-de-obra, podendo estendê-la a outras atividades como o reconhecimento de pragas e doenças.

É possível constatar também, através da participação nos monitoramentos, o comprometimento da comunidade envolvida com a produção de soja nos EUA. Unidos as principais redes que suportam o projeto: o NCSRП, a UNL, com seu grupo de extensão que busca aproximar as tecnologias ao campo, estão os produtores, que engajam com as instituições, disponibilizando suas lavouras para a pesquisa.

A colheita dos campos para leituras de teores de óleo e proteína foi realizada em 19 dos 20 campos monitorados, sendo que TBRO1 não foi colhido por desencontro de agenda com o produtor. As amostras foram enviadas a KSU que fará o processamento dos dados, e o grupo de Agricultura de Precisão poderá obter uma prévia da qualidade das sementes através de análise NIR.

O método não destrutivo, utilizado para leitura da qualidade de semente durante o estágio, é o mesmo utilizado por Hernandez (2023) para o processo de *machine learning* na primeira publicação fruto do projeto. Além de rápido, o equipamento não requer nenhuma preparação prévia das amostras e quando comparado a outras metodologias é preciso, apresentando replicabilidade em suas análises (Honigs, 2021).

A predição de teores de proteína e óleo através de aprendizado de máquina baseado em leituras de sensoriamento remoto é um projeto que visa dar liberdade de negociação de preço para produtores de soja com mercados que buscam características de qualidade específicas. Essa possibilidade de barganha pode se tornar realidade em grandes mercados como o da China, que, em 2023, substituiu alguns padrões para importação de soja, determinando que alto índice de óleo seria considerado superior a 20% e alto índice de proteína não inferior a 40% (China, 2023).

Os resultados médios para teores de óleo e proteína apresentados nas atividades realizadas foram de 20,6% e 38,3% respectivamente, se aproximando dos valores médios para qualidade de soja reportados por Naeve e Christenson (2023) na mesma safra, como é possível observar na Figura 05.

Figura 05: Médias de teores de proteína e óleo de soja dos estados do Cinturão de Milho

Oeste dos EUA.

Region	State	Number of Samples	Protein (%)*	Std. Dev.	Oil (%)*	Std. Dev.
Western	Iowa	161	33.7	1.1	20.0	0.8
Corn Belt (WCB)	Kansas	49	34.1	1.4	19.2	1.1
	Minnesota	170	33.5	1.1	19.7	0.9
	Missouri	61	33.6	0.9	20.1	0.9
	Nebraska	86	34.2	1.1	19.1	1.0
	North Dakota	71	33.1	1.2	19.1	0.8
	South Dakota	68	34.0	1.2	19.1	0.7

Fonte: Adaptado de Naeve e Christenson (2023).

Portanto, os resultados aqui apresentados sobre ambos os projetos são apenas uma pequena porção de todos os dados que constituirão a base final para a inserção de mais estas possibilidades de agricultura digital. Os próximos passos serão realizados pelas instituições competentes e acompanhados à distância pela estudante que contribuiu na construção dos projetos.

7. CONSIDERAÇÕES FINAIS

A realização do estágio em uma Universidade estadunidense possibilitou experienciar a agricultura norte-americana através de uma perspectiva de construção de conhecimento para a comunidade agrícola. Através da participação de pesquisas, que aliam os conhecimentos práticos à tecnologia da agricultura de precisão e digital, foi possível aplicar os aprendizados agronômicos adquiridos durante a formação, adicionando as práticas vivenciadas ao longo do estágio.

A participação em estudos com a cultura da soja reiterou a percepção da importância de se disponibilizarem meios digitais para a incrementação de produtividade e qualidade de grãos. Ambos os projetos de maior envolvimento tiveram como objetivo facilitar a tomada de decisão dos produtores, utilizando a tecnologia como ferramenta de auxílio para a rotina da lavoura.

Acompanhar a fase de coleta de dados com a finalidade de um objetivo maior de inovação é uma oportunidade enriquecedora, permitindo a valorização do trabalho dos pesquisadores para a elaboração destes conteúdos e também consolidando a participação da academia na evolução da agricultura

REFERENCIAS

ADAMCHUK, V. *et al.* Tools for Proximal Soil Sensing. *In: SOIL SURVEY MANUAL*. Washington, DC: United States Department of Agriculture, 2017. p. 355–395.

ALVES, G. A. **Uso de Ferramentas de Análise de “Big Data” na Identificação de Ameaças e Fatores de Risco Fitossanitários**. 2016. Dissertação (Mestrado) —Universidade Federal de Viçosa, Viçosa, MG, 2016.

ANDREIS, J. H. *et al.* Mobile Application for Asian Soybean Rust Tracking in Brazil. *In: WORKSHOP DE COMPUTAÇÃO APLICADA À GESTÃO DO MEIO AMBIENTE E RECURSOS NATURAIS (WCAMA)*, 7, 2016, Porto Alegre. **Anais [...]**. Porto Alegre: Sociedade Brasileira de Computação, 2016. p. 1903-1916. Disponível em: <https://doi.org/10.5753/wcama.2016.9550>. Acesso em fevereiro 2024.

BASSOI, L. H. *et al.* Agricultura de precisão e agricultura digital. **TECCOGS: Revista Digital de Tecnologias Cognitivas**, n. 20, 26 maio 2020. Disponível em: <https://revistas.pucsp.br/teccogs/article/view/48542>. Acesso em março de 2024.

BIBER, P. B. *et al.* **Navigation System of the Autonomous Agricultural Robot “BoniRob”**, 2012. Disponível em: <https://www.cs.cmu.edu/~mbergerm/agrobotics2012/01Biber.pdf>. Acesso em março 2024.

BORJA REIS, *et al.* Soybean management for seed composition: The perspective of U.S. farmers. **Agronomy Journal**, v. 114, p. 2608–2617, 2022. Disponível em: <https://doi.org/10.1002/agj2.21082>. Acesso em fevereiro 2024.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. **Agricultura de precisão**. Brasília: Mapa/ACS, 2009. 31 p.

CHINA. **GB 1352-2023**. [2023]. Disponível em: <https://www.chinesestandard.net/PDF/English.aspx/GB1352-2023>. Acesso em: março 2024

CROPWATCH. **Bean Leaf Beetle Identification**. [2024]. Disponível em: <https://cropwatch.unl.edu/insect/beanleafbeetleid> . Acesso em fevereiro 2024.

DE MAURO, A.; GRECO, M.; GRIMALDI, M. A formal definition of Big Data based on its essential features. **Library Review**, v. 65, n. 3, p. 122–135, 4 abr. 2016.

DURHAM, D. The United Soybean Board’s Better Bean Initiative: Building United States Soybean Competitiveness from the Inside Out. **AgBioForum**, p. 23–26, 2003. Disponível em: https://agbioforum.org/wp-content/uploads/2021/02/AgBioForum_6_12_23.pdf. Acesso em março 2024.

ELDER, J. A. **Soils of Nebraska**. Lincoln, NE: University of Nebraska Conservation and Survey Division. Maio 1969.

FEHR, W.R.; CAVINESS, C.E. **Stages of soybean development**. Ames, Iowa State University of Science and Technology, 1977.

HERNANDEZ, C. M. *et al.* On-farm soybean seed protein and oil prediction using satellite data. **Computers and Electronics in Agriculture**, v. 212, 1 set. 2023. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169923004842?via%3Dihub>. Acesso em fevereiro 2024.

HONIGS, D. **Better Barley Malt Analysis Using NIR**. Springfield, Illinois. PerkinElmer, 2021. Disponível em: https://resources.perkinelmer.com/lab-solutions/resources/docs/APP_Barley_malt_A_DA7200.pdf. Acesso em março 2024.

HROZENCIK, A. **USDA ERS - Irrigation & Water Use**. [2024]. Disponível em: <https://www.ers.usda.gov/topics/farm-practices-management/irrigation-water-use/>. Acesso em março 2024.

HUNT, T.; WRIGHT, B.; JARVI, K. **Stink Bugs Reported in Corn and Soybeans**. 2015 Disponível em: <https://cropwatch.unl.edu/stink-bugs-reported-corn-and-soybeans>. Acesso em fevereiro 2024.

ITU- International Telecommunication Union. **Recomendação ITU-T Y.2060**. 2012. Disponível em: <https://www.itu.int/en/ITU-T/gsi/iot/Pages/default.aspx>. Acesso em março 2024.

JHALA, A.; WRIGHT, B.; CHAHAL, P. **Volunteer Corn in Soybean: Impact and Management**. 2015. Disponível em: <https://cropwatch.unl.edu/volunteer-corn-soybean-impact-and-management>. Acesso em fevereiro 2024.

MARRA, T. M. **Abordagem para predição de soja por índices de vegetação e modelos de machine learning**. 2023. Dissertação (Mestrado), Universidade Estadual Paulista (Unesp), Jaboticabal, SP. 2023. Disponível em: <http://hdl.handle.net/11449/250211>. Acesso em fevereiro 2024.

MASSRHUÁ, S. M. F. S. *et al.* **Agricultura digital: pesquisa, desenvolvimento e inovação nas cadeias produtivas**. Brasília, DF: Embrapa, 2020.

MUELLER, D. **A farmer's guide to soybean diseases**. St. Paul, Minnesota, U.S.S The American Phytopathological Society, 2016.

MURPHY, K. P. **Machine learning: a probabilistic perspective**. Cambridge (Ma): Mit Press, 2012.

NAEVE, S. L.; CHRISTENSON, J. **United States Soybean Quality Anual Report 2023**. Saint Paul, MN: USDA, 2023.

PREMA, N. P.; VEERAMANI, N. A.; SIVAKUMAR, N. T. Machine Learning Applications in Agriculture. **Journal of agriculture research and technology**, v. Special, n. 01, p. 126–129, 1 jan. 2022.

QUY, V. K. *et al.* IoT-Enabled Smart Agriculture: Architecture, Applications, and Challenges. **Applied Sciences**, Basel, v. 12, n. 7, p. 3396, 27 mar. 2022.

RAMOS, F. P. L.; DE OLIVEIRA, J. P. M. Agricultura digital como ferramenta de auxílio em tomadas de decisões dos produtores rurais do Brasil. **Anais de Agronomia**, Chapecó, RS, v. 2, n. 1, p. 1 - 13, abril 2022. Disponível em: <https://uceff.edu.br/anais/index.php/agronomia/article/view/313>. Acesso em março 2024.

RITCHIE, S.W.; HANWAY, J.J.; BENSON, G.O. **How a corn plant develops**. Iowa State University of Science and Technology Cooperative Extension Service, Ames, 1993.

THOMPSON, N.M.; DELAY, N.D.; MINTERT, J.R. Understanding the farm data lifecycle: collection, use, and impact of farm data on U.S. commercial corn and soybean farms. **Precision Agric.** v. 22, p. 1685–1710, 2021. Disponível em: <https://doi.org/10.1007/s11119-021-09807-w>. Acesso em fevereiro 2024.

TONINI, V. F. **Desenvolvimento de um sistema de detecção de pragas em soja utilizando técnicas de aprendizado de máquina**. Trabalho de Conclusão de Curso (Graduação). Instituto Federal de Santa Catarina, São José, SC, dezembro 2023, p. 25.

USDA/NASS 2023 **State Agriculture Overview for Nebraska**. Disponível em: https://www.nass.usda.gov/Quick_Stats/Ag_Overview/stateOverview.php?state=NEBRASKA. Acesso em fevereiro 2024

WOLFERT, S. *et al.* **Big Data in Smart Farming – A review**. *Agricultural Systems*, v. 153, p. 69–80, maio 2017. Disponível em: <https://doi.org/10.1016/j.agsy.2017.01.023>. Acesso em fevereiro 2024.

WRIGHT, R. *et al.* **Japanese Beetles Emerging: Scout Corn and Soybean Fields**. 2023. Disponível em: <https://cropwatch.unl.edu/2019/japanese-beetles>. Acesso em fevereiro 2024.