

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM TECNOLOGIAS COMPUTACIONAIS
PARA O AGRONEGÓCIO

VINÍCIUS TESSELE

**APLICAÇÃO DE ALGORITMO *BIO* INSPIRADO
PARA REFINAMENTO DE RECOMENDAÇÃO DE ADUBAÇÃO
PARA ÁREA ESPECÍFICA**

DISSERTAÇÃO

MEDIANEIRA-PR
2018

VINÍCIUS TESSELE

**APLICAÇÃO DE ALGORITMO *BIO* INSPIRADO
PARA REFINAMENTO DE RECOMENDAÇÃO DE ADUBAÇÃO
PARA ÁREA ESPECÍFICA**

Dissertação apresentada ao Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio – PPGTCA – da Universidade Tecnológica Federal do Paraná – UTFPR – Campus Medianeira, como requisito parcial para obtenção do título de Mestre em Tecnologias Computacionais para o Agronegócio / Área de Concentração: Tecnologias Computacionais Aplicadas à Produção Agrícola e Agroindústria.

Orientador: Prof. Dr. Augusto Vaghetti Luchese

Coorientador: Prof. Dr. Arnaldo Candido Junior

MEDIANEIRA-PR

2018

Dados Internacionais de Catalogação na Publicação

T338a Tessele, Vinícius

Aplicação de algoritmo *bio* inspirado para refinamento de recomendação de adubação para área específica. / Vinícius Tessele – 2018.

92 f. : il. ; 30 cm.

Orientador: Augusto Vaghetti Luchese.

Coorientador: Arnaldo Candido Junior.

Dissertação (Mestrado) – Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio. Medianeira, 2018.

Inclui bibliografias.

1. Mineração de dados (Computação). 2. Cultivo. 3. Software - Desenvolvimento. 4. Tecnologias Computacionais - Dissertações. I. Luchese, Augusto Vaghetti, orient. II. Candido Junior, Arnaldo, coorient. III. Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio..IV. Título.

CDD: 004

Biblioteca Câmpus Medianeira
Marci Lucia Nicodem Fischborn 9/1219



TERMO DE APROVAÇÃO

APLICAÇÃO DE ALGORITMO *BIO* INSPIRADO PARA REFINAMENTO DE RECOMENDAÇÃO DE ADUBAÇÃO PARA ÁREA ESPECÍFICA

Por

VINÍCIUS TESSELE

Essa dissertação foi apresentada às oito horas, do dia cinco de julho de dois mil e dezoito, como requisito parcial para a obtenção do título de Mestre em Tecnologias Computacionais para o Agronegócio, Linha de Pesquisa Tecnologias Computacionais Aplicadas à Produção Agrícola, no Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio - PPGTCA, da Universidade Tecnológica Federal do Paraná. O candidato foi arguido pela Banca Examinadora composta pelos professores abaixo. Após deliberação, a Banca Examinadora considerou o trabalho aprovado.

Prof. Dr. Augusto Vaghetti Luchese (Orientador – PPGTCA)

Prof. Dr. Pedro Luiz De Paula Filho (Membro Interno – PPGTCA)

Prof. Dr. Alessandro Jefferson Sato (Membro Externo – UFPR)

A via original com as assinaturas encontra-se na secretaria do programa.

À Deus, aos meus pais e a minha esposa...
companheiros de todas as horas...

AGRADECIMENTOS

Ao Prof. Dr. Orientador Augusto Vaghetti Luchese, braço amigo de todas as etapas deste trabalho.

Ao Prof. Dr. Coorientador Arnaldo Candido Junior, por todas as incansáveis horas de auxílio a realização deste trabalho.

Ao Prof. Egídio um grande amigo e motivador, sempre com palavras de carinho e motivação.

A minha família, pela confiança e motivação.

A minha esposa Adrielly e nossas filhas de pelos Babi e Cherri, pela força e pela vibração e dias ausentes para a realização desta jornada.

Aos professores e colegas de Curso, pois juntos trilhamos uma etapa importante de nossas vidas.

“Se existe uma forma
de fazer melhor, descubra-a”

Thomas Edison

RESUMO

TESSELE, Vinícius. **Aplicação de algoritmo *bio* inspirado para refinamento de recomendação de adubação para área específica**. 2018. 92f. Dissertação (Mestrado em Tecnologias Computacionais para o Agronegócio) - Programa de Pós-Graduação da Universidade Tecnológica Federal do Paraná, 2018.

O manejo do solo é de fundamental importância para o aumento da produtividade. Dentre várias técnicas existentes, a reposição de nutrientes se destaca pela eficiência. Para isso, há a necessidade de conhecer por meio de análise de solo as deficiências presentes no solo, de modo a repor as necessidades nutricionais para os cultivares daquela área. A tecnologia computacional e o ramo da Inteligência Artificial (IA), já presentes no meio rural, vem a contribuir para o aumento da produtividade e lucratividade na agricultura, com diversos dispositivos embarcados e softwares de gestão. Para este estudo, utilizou-se a técnica derivada da IA conhecida como Sistemas Imunológicos Artificiais (SIA). Dentre as suas diversas aplicações, a utilizada neste trabalho é a de otimização utilizando o algoritmo aiNet, para o refinamento de adubação da propriedade estudada. A aplicação deste algoritmo tem por objetivo verificar a sua aderência e apresentar a recomendação de adubação com maior vantagem financeira e produtiva. Para isso, foram realizados experimentos com o cultivo de alfaces, que foi escolhido por ser uma cultura rápida assim possibilitando um maior número de repetições do algoritmo. O algoritmo foi implementado utilizando a linguagem *object pascal* e a plataforma de desenvolvimento utilizada foi a IDE Delphi na versão XE10 que possibilita a criação de aplicativos em multi plataformas. Para a realização do experimento foram formados 80 canteiros com a população inicial e 12 canteiros de controle/testemunha, todos eles com 12 plantas por canteiro, totalizando 1104 pés de alface. Porém, para a entrada de dados, foram selecionados apenas quatro pés centrais de cada um dos 80 canteiros que foram pesados, obtendo assim o valor de sua massa fresca bruta e em uma segunda pesagem, a obtenção de sua massa fresca comercial. Foram realizadas 7 iterações, as quais para cada iteração o aplicativo teve como objetivo principal a otimização do resultado da adubação com o intuito de estabelecer os melhores resultados. Contudo, os resultados obtidos apresentaram uma significativa melhora no desempenho das últimas 3 rodadas, com o aumento dos valores de peso da massa fresca, bem como a redução da quantidade de fertilizante utilizada, a consequência é a obtenção de maior lucro na produção. Outro aspecto positivo foi a diminuição do desvio padrão apresentado nas rodadas de 5, 6 e 7. A menor dispersão dos dados sugere que o algoritmo está sendo eficiente na otimização e busca do refinamento da adubação, e que tem potencial de aplicação na área agrícola.

Palavras-chave: Sistema imunológico artificial. Nutrientes no solo. Aplicativo móvel.

ABSTRACT

TESSELE, Vinícius. **Using of bio-inspired algorithm for fertilizer recommendation refinement for specific area.** 2018. 92f. Dissertação (Mestrado em Tecnologias Computacionais para o Agronegócio) - Programa de Pós-Graduação da Universidade Tecnológica Federal do Paraná, 2018.

Soil management is of fundamental importance for increasing productivity. Among several existing techniques, nutrient replacement is highlighted by efficiency. For this, it is necessary to know by means of soil analysis the deficiencies present in the soil, in order to restore the nutritional needs for the cultivars of that area. Computational technology and the branch of Artificial Intelligence (AI), already present in rural areas, contribute to increase productivity and profitability in agriculture, with several embedded devices and management software. For this study, the technique derived from AI known as Artificial Immunological Systems (SIA) was used. Among its several applications, the one used in this work is the optimization using the aiNet algorithm, for the refinement of fertilization of the studied property. The application of this algorithm aims to verify its adherence and to present the recommendation of fertilization with greater financial and productive advantage. For this, experiments were carried out with lettuce cultivation, which was chosen because it is a fast crop, thus allowing a greater number of replicates of the algorithm. The algorithm was implemented using the object pascal language and the development platform used was the Delphi IDE in the XE10 version that enables the creation of multi-platform applications. 80 seedlings with the initial population and 12 control/control beds were established for the experiment, all with 12 plants per plot, totaling 1104 feet of lettuce. However, for data entry, only four central feet were selected from each of the 80 beds that were weighed, thus obtaining the value of their crude fresh mass and in a second weighing the obtaining of their commercial fresh mass. Seven iterations were performed, which for each iteration the main objective of the application was the optimization of the fertilization result in order to establish the best results. However, the results obtained showed a significant improvement in the performance in the last 3 rounds, with the increase in the weight values of the fresh mass, as well as the reduction of the amount of fertilizer used, the consequence is the obtaining of greater profit in the production. Another positive aspect was the reduction of the standard deviation presented in the rounds of 5.6 and 7. The lower dispersion of the data suggests that the algorithm is being efficient in the optimization and search of the refinement of the fertilization.

Keywords: Artificial immunological system. Nutrients in soil. Mobile application.

LISTA DE FIGURAS

Figura 1 - Mecanismo de defesa e seus mediadores.....	24
Figura 2 - Arquitetura multicamadas do sistema imunológico	25
Figura 3 - O sistema imune adaptativo.....	26
Figura 4 - Seleção clonal.....	29
Figura 5 - Fluxograma do algoritmo de seleção clonal, CLONALG – Problema de otimização	30
Figura 6 - Diagrama Caso uso	42
Figura 7 - Diagrama de Classes.....	43
Figura 8 - Canteiros delimitados e identificados.....	44
Figura 9 - Tela de parâmetros do aplicativo	49
Figura 10 - Fluxograma do algoritmo aplicado no experimento.....	51
Figura 11 - Distribuição dos nutrientes.....	53
Figura 12 - Transplante das mudas de alface ocorrido no dia 6 de novembro de 2016	53
Figura 13 - Colheita no dia 21 de dezembro de 2016	54
Figura 14 - Dispersão dos nutrientes da segunda rodada de cultivo.....	56
Figura 15 - Dispersão dos nutrientes da terceira rodada	58
Figura 16 - Dispersão dos nutrientes da quarta rodada	59
Figura 17 - Dispersão dos nutrientes da quinta rodada de cultivo.....	61
Figura 18 - Dispersão dos nutrientes da sexta rodada de cultivo.....	62
Figura 19 - Dispersão dos nutrientes da sétima rodada de cultivo.....	64
Figura 20 - Simulação da dispersão dos nutrientes da oitava rodada de cultivo.....	65
Figura 21 - Temperatura mínima, máxima e média do período de cultivo	66
Figura 22 - Média de Produção por rodada de plantio	68
Figura 23 - Média dos tratamentos de controle/testemunha	68
Figura 24 - Comparação produtividade MFC com tratamentos de testemunha	69
Figura 25 - Apresenta a somatória dos pesos máximo, média e mínima dos tratamentos bem como a dispersão dos dados com relação à média.....	69
Figura 26 - Desvio padrão por rodada de plantio.	70
Figura 27 - Somatório dos melhores resultados por rodada de plantio.....	71
Figura 28 - Média de Fitness por rodada	72

Figura 29 - Média de Nutrientes por rodada.....	73
Figura 30 - Quantidade de parcelas que superaram 800g de produção	73
Figura 31 - Tela Principal, Tela de Menu, Geração de recomendação	90
Figura 32 - Tela de Recomendação de Adubação	91
Figura 33 - Tela de lançamento de produção.....	91

LISTA DE QUADROS

Quadro 1 - Algoritmo de aprendizado do <i>aiNet</i> com a seleção de anticorpos a partir da afinidade entre antígenos	33
Quadro 2 - Algoritmo aplicado no experimento	90

LISTA DE TABELAS

Tabela 1 - Resultados das análises de solo da propriedade estudada	47
Tabela 2 - Valores utilizado para o 1° Plantio	47
Tabela 3 - Valores utilizados em canteiros de controle/testemunha para o 1° Plantio	48
Tabela 4 - Resultado do sorteio dos nutrientes NPK para o 2° rodada (em gramas)	55
Tabela 5 - Resultado do sorteio dos nutrientes NPK para o 3° rodada (em gramas)	57
Tabela 6 - Resultado do sorteio dos nutrientes NPK para o 4° rodada (em gramas)	59
Tabela 7 - Resultado do sorteio dos nutrientes NPK para o 5° rodada (em gramas)	60
Tabela 8 - Resultado do sorteio dos nutrientes NPK para o 6° rodada (em gramas)	62
Tabela 9 - Resultado do sorteio dos nutrientes NPK para o 7° rodada (em gramas)	63
Tabela 10 – Análise descritiva dos resultados de colheita por rodadas	66
Tabela 11 - Resultado da produção da primeira rodada em Massa fresca comercial (MFC) e Massa fresca bruta (MFB).....	83
Tabela 12 - Análise descritiva do primeiro plantio em Massa fresca bruta (MFB) e Massa fresca comercial (MFC).....	83
Tabela 13 - Resultado da produção para o 2° rodada (em gramas)	84
Tabela 14 - Análise descritiva do segundo plantio	84
Tabela 15 - Resultado da produção para o 3° rodada (em gramas)	85
Tabela 16 - Análise descritiva do terceiro plantio	85
Tabela 17 - Resultado da produção para o 4° rodada (em gramas)	86
Tabela 18 - Análise descritiva do quarto plantio.....	86
Tabela 19 - Resultado da produção para o 5° rodada (em gramas)	87
Tabela 20 - Análise descritiva do quinto plantio	87
Tabela 21 - Resultado da produção para o 6° rodada (em gramas)	88
Tabela 22 - Análise descritiva do sexto plantio	88
Tabela 23 - Resultado da produção para o 7° rodada (em gramas)	89
Tabela 24 - Análise descritiva do sétimo plantio	89

LISTA DE SIGLAS

SIA	Sistema Imunológico Artificial
IA	Inteligência artificial
APP	Aplicativo
MFB	Massa fresca bruta
MFC	Massa fresca comercial
aiNet	Artificial immune network
Nc	Números de células
SI	Sistema Imunológico
UML	Linguagem de Modelagem Unificada

SUMÁRIO

1	INTRODUÇÃO	17
1.1	JUSTIFICATIVA.....	18
1.2	OBJETIVOS.....	19
1.2.1	Objetivo Geral	19
1.2.2	Objetivos Específicos.....	19
2	REVISÃO DE LITERATURA.....	20
2.1	COMPUTAÇÃO EVOLUTIVA	20
2.1.1	Algoritmos Genéticos.....	21
2.1.2	Heurística.....	21
2.1.3	Espaços de buscas.....	22
2.1.4	Diagramas UML.....	22
2.2	SISTEMA IMUNOLÓGICO	23
2.3	SISTEMA IMUNOLÓGICO ARTIFICIAL (SIA).....	27
2.3.1	Seleção Clonal.....	28
2.3.2	Rede Imunológica.....	31
2.3.3	Opt-ainet	31
2.3.4	Aplicação do Sia	34
2.4	FERTILIDADE DO SOLO	35
2.4.1	Nitrogênio (N).....	36
2.4.2	Fósforo (P).....	36
2.4.3	Potássio (K)	37
2.5	ALFACE (<i>Lactuca sativa</i>).....	38
2.5.1	Tipos de Alface	38
3	MATERIAL E MÉTODOS.....	40
3.1	DESENVOLVIMENTO DO SOFTWARE.....	41
3.2	DESENVOLVIMENTO DO EXPERIMENTO.....	44
3.2.1	Delineamento experimental	44
3.2.2	Características avaliadas.....	45
4	RESULTADOS E DISCUSSÃO	47
4.1	INÍCIO DO EXPERIMENTO.....	47

4.2	PARAMETRIZAÇÃO DO SOFTWARE	48
4.3	RODADAS CULTIVO.....	52
4.3.1	Primeira rodada de cultivo	52
4.3.2	Segunda rodada de cultivo	55
4.3.3	Terceira rodada de cultivo.....	56
4.3.4	Quarta rodada de cultivo.....	58
4.3.5	Quinta rodada cultivo	60
4.3.6	Sexta rodada de cultivo	61
4.3.7	Sétima rodada cultivo	63
5	CONCLUSÃO	75
6	CONSIDERAÇÕES FINAIS E SUGESTÕES.....	76
	REFERÊNCIAS.....	77
	APÊNDICE A.....	83
	ANEXO I	92

1 INTRODUÇÃO

Os nutrientes são parte fundamental para o desenvolvimento das plantas. A falta ou a insuficiência deles pode debilitar o crescimento e acarretar em perdas de produtividade. Os solos, que podem ser ricos ou pobres, são responsáveis por armazenar e fornecer água, disponibilizando nutrientes essenciais ao desenvolvimento das plantas. Para isso, a avaliação da disponibilidade dos nutrientes no solo se faz necessário para entender e corrigir possíveis deficiências encontradas, permitindo o aumento da produtividade e maior lucratividade da atividade agrícola.

O Brasil é destaque, em âmbito mundial, como um dos maiores produtores agrícolas. No entanto, é possível aumentar ainda mais a produtividade com o uso massivo de instrumentos tecnológicos nos diversos setores da cadeia de produção nas especificidades das grandes e pequenas empresas.

O uso de recursos computacionais no campo é uma realidade que ultrapassa os computadores pessoais, planilhas e softwares simples de controles de custos. Atualmente, a maioria das pessoas (dentre as quais os empresários do setor agrícola) possui um “*smartphone*” que permite acessar a internet em qualquer lugar com sinal.

Para Fling (2009), esse processo de modernização no uso das tecnologias móveis de acesso à web tende a crescer ainda mais nos próximos anos. As tecnologias de informação e comunicação, assim, tornaram-se uma necessidade no meio rural, tanto quanto já era no urbano, visando atender a demanda constante por conhecimento e informações atualizadas (VIERO; SILVEIRA, 2011).

Sistemas inteligentes podem ser vistos e utilizados na agricultura viabilizando uma série de melhorias no desempenho produtivo, máquinas inteligentes capazes de tomar decisões se tornam realidade no dia-a-dia do campo. A inteligência artificial (IA) é pilar fundamental no desenvolvimento de sistemas inteligentes.

Segundo Massruhá et al. (2008, p.1), esses sistemas são “suporte à decisão, modelagem, previsão, automação, reconhecimento de imagens, mineração de dados/textos e até em áreas como visão computacional”. Os autores ainda complementam dizendo que “Técnicas como lógica difusa e redes neurais têm sido aplicadas em várias áreas da agricultura como diagnóstico e predição de doenças de plantas, modelagem de crescimento de plantas e previsão de mudanças climáticas”

Sistema imunológico artificial (SIA), é uma técnica da inteligência artificial que aplica princípios do sistema imunológico para o desenvolvimento de ferramentas computacionais que atuam nas áreas de reconhecimento de padrões, aprendizado de máquinas, detecção de falhas, anomalias e segurança computacional.

O SIA aplicado a este estudo tem por finalidade o refinamento da adubação para a propriedade estudada, utilizando como base a recomendação padrão de adubação calculada conforme manual de adubação e de calagem para os estados do Rio Grande do Sul e de Santa Catarina (SBCS, 2004).

Neste trabalho, a proposta é o desenvolvimento de um software utilizando o algoritmo opt-aiNet proposto por De Castro e Zuben (2000), de modo que seja feito o refinamento da adubação em uma área específica. Foram feitas alterações pontuais no algoritmo, para atender às necessidades apresentadas no decorrer da pesquisa.

Foram realizadas 7 rodadas, sendo 6 delas obedecendo o resultado da adubação calculada pelo software desenvolvido. No decorrer das rodadas foram avaliados os resultados da produção de cada um dos tratamentos realizados individualmente.

1.1 JUSTIFICATIVA

Solos pobres em nutrientes acarretam na diminuição da produtividade e prejuízo financeiro a todo o setor agrícola. O excesso de alguns nutrientes também pode ocasionar perdas, desta forma, o manejo dos nutrientes de fórmulas e quantidades corretas, que atendam às necessidades nutricionais das plantas, pode trazer benefícios como: aumento da produtividade; economia na aplicação dos insumos; qualidade dos produtos; e equilíbrio ao meio ambiente.

A adubação na prática é a reposição dos nutrientes que a planta exige e o que o solo pode fornecer, acrescentando ainda a quantidade perdida. A análise de solo, segundo Chitolina et al. (1999), é a medida mais prática, rápida e barata de se fazer a análise racional da fertilidade do solo. Portanto, é através da análise de solo que se pode determinar a quantidade de reposição dos nutrientes necessários para a produtividade esperada.

A interpretação dos resultados varia por região. Em geral, os estados têm

tabelas de interpretação da fertilidade e de recomendação corretiva para as culturas; haja vista que, segundo Luz, Ferreira e Bezerra (2017), as condições locais, os tipos de solo e o clima influenciam no rendimento das diversas culturas.

Sabendo que o algoritmo de SIA pode ser utilizado no processo de otimização, com seu uso busca-se, no presente trabalho, encontrar a recomendação ideal para reposição dos nutrientes necessários para a produção de alfaces em uma dada área específica.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Estudar o desenvolvimento de uma aplicação que utilize um SIA (sistema imunológico artificial) para área agrícola, a fim de refinar a recomendação de adubação da área estudada.

1.2.2 Objetivos Específicos

Criar um software capaz de receber os dados de produtividade, e realizar o processamento e cálculo de reposição de nutrientes no solo;

Apresentar os resultados do cálculo de nova adubação com base na produção anterior;

Melhorar a capacidade e o desempenho de produtividade com o melhor custo a cada rodada de produção.

2 REVISÃO DE LITERATURA

A tecnologia computacional está presente em diversos setores da economia e no dia a dia das pessoas. As diversas áreas da tecnologia computacional evoluem constantemente, para que problemas do cotidiano sejam resolvidos de forma rápida e confiável (RUSSEL, 2013).

A Inteligência Artificial (IA), segundo Russel (2013), teve seu início após a Segunda Guerra Mundial e seu nome foi proposto em 1956. Atualmente, abrange uma variedade de subcampos. Dentre as áreas, a IA tem, a princípio, o propósito de desenvolver sistemas inteligentes que possam assimilar a inteligência humana e tomar decisões baseadas em seu aprendizado. Diferentes correntes do pensamento da IA têm estudado formas de desenvolver o comportamento inteligente em computadores, as quais dentre elas se estabelece a SIA (Sistema Imunológico Artificial).

Desta forma, Kurzweil (1990, p. 5) define IA como “a arte de criar máquinas que executam funções que exigem inteligência quando executadas por pessoas”. Para Artero (2009, p. 2), “a inteligência artificial é uma forma de simular a inteligência natural”. Os autores concordam que a IA é a tentativa em replicar o comportamento humano nas máquinas.

Para Coppin (2013, p. 5), a “inteligência artificial é o estudo dos sistemas que agem de um modo que a um observador qualquer parecia ser inteligente”. O autor continua: “Poder-se-ia certamente definir inteligência artificial pelas propriedades que ela exhibe: uma capacidade de lidar com novas situações; a capacidade de solucionar problemas, responder a questões, de engendrar planos” (COPPIN, 2013, p. 5).

2.1 COMPUTAÇÃO EVOLUTIVA

A computação evolutiva tem inspiração no princípio da seleção natural e teoria da evolução, de modo a melhorar o desempenho computacional e soluções de problemas complexos. Baseado nas descobertas de Charles Darwin em 1859, a computação evolutiva usa o mecanismo de sua Teoria da Evolução das Espécies, na

qual o mecanismo principal é a seleção natural. Dentro da computação evolutiva, existe uma ampla área de estudo, a qual abrange os algoritmos a seguir:

- Algoritmos genéticos;
- Programação genética;
- Estratégias evolutivas;
- Programação evolutiva;
- Sistemas de classificação.

Todos esses algoritmos possuem características diferentes, porém possuem o mesmo conceito da teoria da evolução de Darwin (PILA, 2015).

2.1.1 Algoritmos Genéticos

Os algoritmos genéticos como parte integrante da computação evolutiva e com base na teoria de Darwin usa uma medida para avaliar a capacidade de indivíduos da população em sobreviver e se reproduzir. Espera-se que estas características dos indivíduos sobreviventes sejam transferidas à próxima geração; e que características dos indivíduos com menores condições de sobrevivência e reprodução sejam perdidas (ARTERO, 2009).

Coppin (2013), afirma que é possível explicar os algoritmos genéticos em comparação à evolução natural, aonde pequenas alterações ocorrem em uma população e, juntamente com a reprodução, tendem a aprimorar a aptidão da população ao longo do tempo.

2.1.2 Heurística

Para Artero (2009), heurísticas são estratégias utilizadas para conduzir a solução de problemas de uma maneira mais rápida do que a experiência de todas as possibilidades de solução. O autor explica, com analogias:

Um exemplo simples de uso de heurística pode ser aquele em que uma pessoa perdida em uma floresta procura encontrar água. Neste caso, ela sempre segue na direção das partes mais baixas do terreno, em geral, lagos e rios são encontrados nestes locais (ARTERO, 2009).

Heurísticas são processos empregados à tomada de decisão não racionais e que são definidas como estratégias, com o objetivo de tornar a decisão mais fácil. Porém, ela poderá ajudar a encontrar soluções “boas”, mas não necessariamente “ótimas” (ARTERO, 2009).

2.1.3 Espaços de buscas

O espaço de busca trata-se de um conjunto que contém todas as soluções do problema a ser resolvido. Este conjunto pode ser finito ou infinito enumerável e é sempre considerado que se tenha apenas soluções viáveis, isto é, aquelas que estejam entre as restrições do problema (BECENERI, 2008).

Dessa forma, para que o software explore o espaço de busca de forma que obtenha soluções de ótima qualidade e consiga explorar áreas ainda não exploradas se necessário, o conceito de diversificação deve ser obedecido.

2.1.4 Diagramas UML

A UML - Linguagem de Modelagem Unificada, linguagem utilizada para modelar softwares, linguagem esta, que se tornou padrão adotada internacionalmente pela engenharia de software. O objetivo é auxiliar os engenheiros de software a definirem as características do sistema, seus requisitos e comportamento (GUEDES, 2018).

O diagrama caso de uso, tem por finalidade permitir a visualização do comportamento de interação entre usuário e o software, e deve apresentar uma visão geral do comportamento do sistema.

Os atores em casos de uso, representam os papéis desempenhados pelos diversos usuários que têm interação com o software, para identificação dos atores, se deve à procura das entidades externas ao sistema, e que terão interação sendo ele humanos ou não, esses atores tem a função de operar o sistema, configurar e lançar resultados (GUEDES, 2018).

O diagrama de classes é considerado uma das representações mais importantes e utilizados da UML. Seu principal enfoque está em permitir a visualização das classes que compõem o sistema e seus respectivos atributos e métodos, além de permitir a demonstração do relacionamento entre suas classes e como transmitem as informações entre si (GUEDES, 2018).

2.2 SISTEMA IMUNOLÓGICO

Ao tentar definir o sistema imunológico artificial, se faz necessário antes conhecer o funcionamento em detalhes do sistema imunológico biológico. Esse sistema é um conjunto de células, tecidos e órgãos que tem a função de defender o organismo contra agentes causadores de doenças. Este sistema possui a capacidade de multiplicação e de reconhecer células patogênicas a fim de eliminar completamente o organismo (KLEIN, 1990).

O sistema imunológico é fundamental para a sobrevivência dos seres vivos e, por isso, precisa atuar de forma eficiente. Existe uma grande quantidade de componentes e mecanismos distintos atuando no sistema imunológico. Alguns destes elementos são otimizados para defender contra um único invasor, enquanto outros são direcionados contra uma grande variedade de agentes infecciosos (DE CASTRO, 2001).

Dasgupta (1998, p. 01) define que “os sistemas imunológicos artificiais são compostos por metodologias inteligentes, inspiradas no sistema imunológico biológico, para a solução de problemas do mundo real”.

De Castro (2001, p. 7) aponta que, existem diversos mecanismos de defesa contra um único invasor e acrescenta que, tanto no ponto de vista “biológico quanto de engenharia, a presença de mecanismos de aprendizagem e memória são características fundamentais do sistema imunológico”. Estes mecanismos de

aprendizagem e memória são capazes de extrair informações dos agentes infecciosos, para que possa disponibilizá-las em caso de novas infecções pelos mesmos agentes ou seus similares.

O sistema imunológico é a principal barreira do organismo contra agentes infecciosos, e pode realizar uma resposta rápida e efetiva contra estes agentes. Ele também pode elaborar outro tipo de resposta igualmente eficaz, entretanto, mais lenta, porém duradoura. Respectivamente, são conhecidos como imunidade inata e imunidade adaptativa (DE CASTRO, 2001), conforme representa a Figura 1.

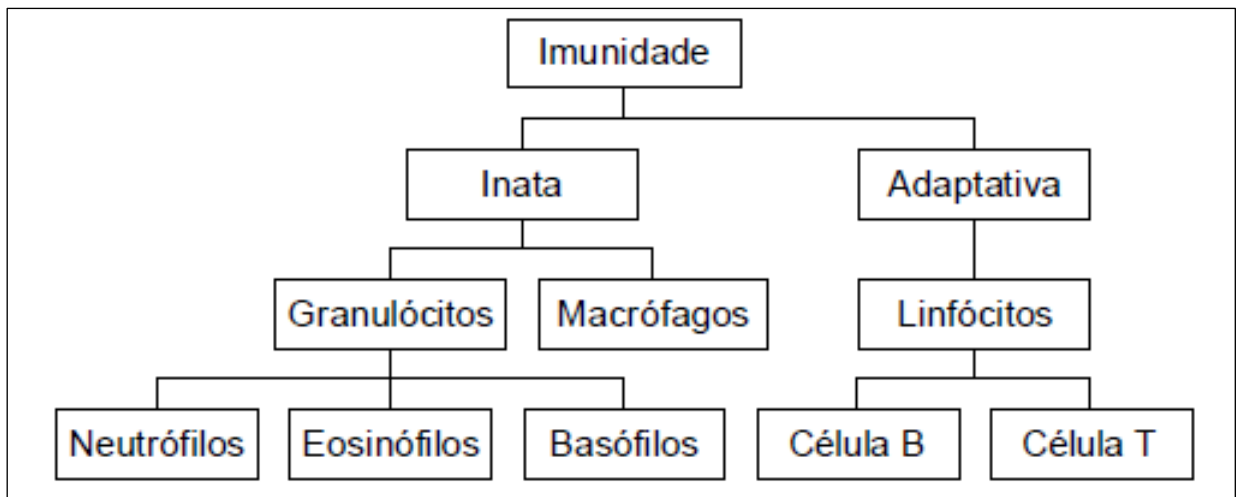


Figura 1 - Mecanismo de defesa e seus mediadores
Fonte: De Castro (2001).

A Figura 2 representa a arquitetura multicamadas do sistema imunológico biológico, e apresenta diferentes tipos de patógenos e a imunidade inata e adaptativa.

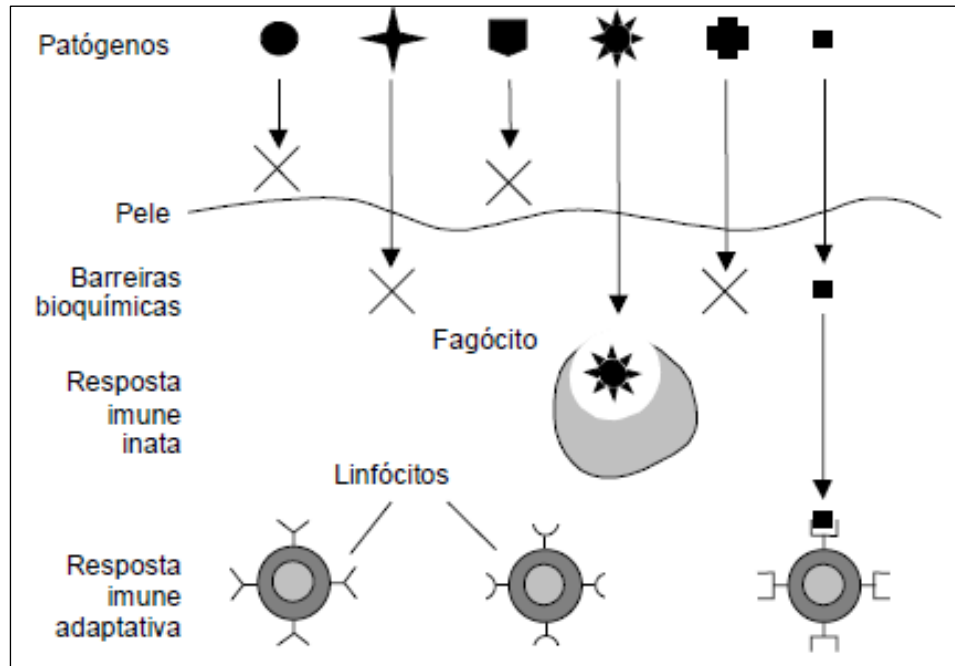


Figura 2 - Arquitetura multicamadas do sistema imunológico
Fonte: De Castro (2001).

A primeira camada de defesa é formada pela pele e pela barreira bioquímica, que inibem alguns agentes patogênicos.

O sistema inato que se caracteriza como a linha de frente dos sistemas de defesa do organismo, reage de maneira semelhante a diferentes patógenos, e sem a necessidade de prévia exposição. Macrófagos, neutrófilos e fagócitos são capazes de ingerir e digerir diversos microrganismos (DE CASTRO, 2001).

As células do sistema imune inato estão imediatamente disponíveis para o combate contra uma ampla variedade de patógenos, sem exigir prévia exposição aos mesmos, e atuam do mesmo modo em todos os indivíduos normais (DE CASTRO, 2001).

O sistema adaptativo é apresentado na Figura 3, a qual ilustra a teoria de seleção clonal que engloba a seleção das células com maior afinidade com o antígeno. Após a seleção, entra o processo de proliferação de clones.




Figura 3 - O sistema imune adaptativo
Fonte: De Castro (2001).

Os antígenos são moléculas que desencadeiam uma resposta imunológica de dois grupos de linfócitos, os linfócitos T e os linfócitos B. Essas moléculas podem ser apenas um fragmento de bactérias ou vírus que invadem o organismo e são interceptados por fagócitos.

Esses últimos são responsáveis pela fagocitose, o ato de destruir as células invasoras. Os fagócitos posteriormente apresentam o fragmento dessa molécula invasora aos linfócitos T. Os linfócitos T são responsáveis por enviar a ordem aos linfócitos B para a criação de anticorpos específicos àquele antígeno (BERBERT, 2008).

Por sua vez, os anticorpos são proteínas produzidas pelos linfócitos B em resposta aos antígenos invasores. Em sua primeira resposta, a produção dessas proteínas é em menor quantidade e de forma lenta, sendo nomeada como resposta primária. Os linfócitos B também são responsáveis pela memória imunológica que visa reconhecer o mesmo estímulo (antígeno) em caso de uma nova infecção e, assim, evitando o ressurgimento da doença (BERBERT, 2008).

As células de memória circulam pelo sangue em vasos linfáticos e tecidos e quando expostas novamente são capazes de produzir novos anticorpos para a proteção do organismo. Este é o processo da metadinâmica e existe uma constante renovação de linfócitos e a morte de elementos que não são mais estimulados (BERBERT, 2008).

Os anticorpos produzidos são capazes de reconhecer apenas um antígeno, porém, a presença deles se dá apenas em um organismo o qual foi exposto aos antígenos causadores da infecção (BERBERT, 2008).

2.3 SISTEMA IMUNOLÓGICO ARTIFICIAL (SIA)

O SIA (Sistema Imunológico Artificial) tem como sua inspiração o sistema imunológico biológico, o qual tem como objetivo proteger todo organismo de microrganismos externos causadores de doenças. O SIA se inspira nas características do sistema imunológico biológico conhecido como adaptativo, por apresentar maturação de afinidade e seleção clonal (DE CASTRO, 2001).

A tentativa de simular um sistema artificial, para resolução de problemas complexos de otimização, surgiu na década de 1990, consistindo em um novo paradigma computacional. O sistema imunológico tem servido como fonte de inspiração para o desenvolvimento de novos algoritmos que possam conter as seguintes propriedades: auto-organização; aprendizagem; adaptação; reconhecimento; robustez; e escalabilidade (DE CASTRO, 2001).

Segundo Timmis e Edmonds (2004), há um paralelo natural entre o sistema imunológico e a otimização; entretanto, o sistema imunológico não é um otimizador e o processo de produção de anticorpos na resposta de um antígeno é de natureza evolutiva.

A área de pesquisa de SIA é extensa. A escolha dos melhores modelos depende do objetivo e das características do problema a ser estudado. As diferentes peculiaridades, funcionalidades, propriedades e mecanismos dos SIAs permitem sua aplicação em diversos problemas. Alguns modelos de SIA são:

Visão Clássica do sistema imunológico: consiste em distinguir células próprias de patógenos que podem causar doenças. Na computação esse modelo pode ser aplicado no reconhecimento de invasão.

Clonal: as células ativas produzem anticorpos através do processo de clonagem e seus clones passam por processo de mutação, o SIA tem a capacidade de distinguir o antígeno com melhor afinidade e excluir os com menor afinidade ao antígeno.

Teoria de rede: supõe-se que as células B formem uma rede, quando a célula é ativada e responde a um antígeno essa célula estimula todas as outras células nos quais está ligada.

Por fim, a escolha dos melhores modelos depende do objetivo e das características do problema a ser estudado.

2.3.1 Seleção Clonal

A seleção clonal é o nome dado para explicar o funcionamento do sistema imune adaptativo que atua sobre os antígenos. Ela é replicada para as células B e T. A diferença é que as células B sofrem hipermutação durante a sua proliferação enquanto as células T não as sofrem (DE CASTRO; TIMMIS, 2002).

Linfócitos B quando reconhecem um antígeno não próprio com maior afinidade e aptidão, são selecionados para proliferar e produzir anticorpos em altos volumes denominados como clones. Esses, sofrem um processo de mutação o qual resulta na obtenção de uma nova geração de células com receptores de alta afinidade com o antígeno.

Esse processo é conhecido como mutação de afinidade da resposta imune, o que significa que os melhores clones com melhores afinidades serão mantidos e evoluem no decorrer do tempo (DE CASTRO; TIMMIS, 2002).

A Figura 4 apresenta a perspectiva da seleção clonal.




Figura 4 - Seleção clonal
Fonte: De Castro (2001).

Durante o processo de geração de clones, existe a possibilidade de geração de resultados indesejados, nos quais os anticorpos não reconhecem como próprio os linfócitos B, dando início a um ataque às próprias células saudias do próprio organismo a fim de eliminá-las (DE CASTRO; TIMMIS, 2002).

Assim, a implementação de algoritmo de seleção clonal tem, a princípio, a função de realizar tarefas de reconhecimento de padrões e problemas de otimização, sendo suas principais características (DE CASTRO; TIMMIS, 2002):

- a) Manutenção de um conjunto de memória específica;
- b) Seleção e clonagem dos anticorpos com maior afinidade;
- c) Morte de anticorpos com menor afinidade;
- d) Maturação por afinidade;
- e) Re-seleção dos clones.

A Figura 5 apresenta o fluxograma da seleção clonal utilizado para sistemas de otimização.

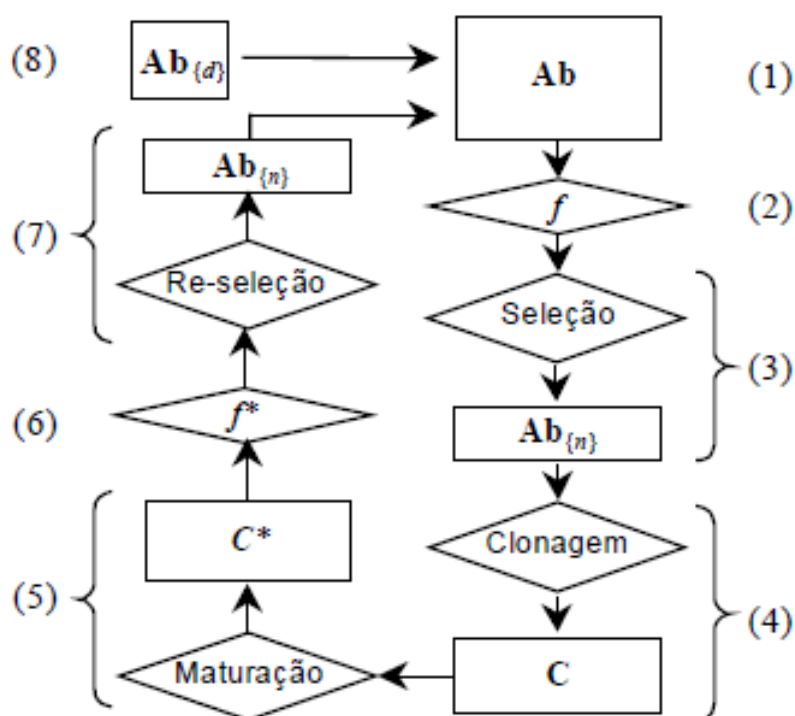


Figura 5 - Fluxograma do algoritmo de seleção clonal, CLONALG – Problema de otimização
 Fonte: De Castro (2001).

O fluxograma apresentado na Figura 5 é descrito da seguinte maneira:

- 1) Inicia-se uma população Ab de anticorpos;
- 2) Um vetor de afinidades f é criado em relação aos anticorpos Ab ;
- 3) São selecionados os melhores anticorpos para que sejam clonados;
- 4) O processo de clonagem dos Ab de anticorpos selecionados é realizado;
- 5) Após o processo de clonagem os novos clones sofrem o processo de maturação por afinidade, dando origem a uma nova célula C^* ;
- 6) É determinado um novo processo de afinidade f^* das células C^* ;
- 7) Re-seleciona-se as melhores células C^* em relação ao antígeno; os anticorpos com melhor afinidade com o antígeno são selecionados como células de memória;
- 8) O resultado de uma nova seleção de indivíduos Ab_d substitui os anticorpos Ab .

2.3.2 Rede Imunológica

A rede imunológica se baseia nos anticorpos que se reconhecem e são reconhecidos no organismo. Neste mecanismo, observa-se um comportamento dinâmico, porém, estes anticorpos permanecem em repouso até que receba algum estímulo de algum antígeno.

Conforme explica Jerne (1974), as células do sistema imunológico possuem estruturas denominadas de idiotopos que permitem que sejam reconhecidas pelos receptores de outras células. Isso torna o sistema uma rede auto organizável de anticorpos que continuamente são reconhecidos pelos seus pares.

De acordo com esta teoria, a rede imunológica permanece em equilíbrio até que seja estimulada por algum antígeno; o que levaria a uma reação imediata e a alteração na quantidade de anticorpos da rede para reestabelecer novamente o equilíbrio do organismo.

2.3.3 Opt-ainet

O Algoritmo aiNet (Artificial Imune NETwork) foi proposto por Castro e Zuben (2000) com o propósito geral de encontrar um modelo reduzido de dados pela eliminação de redundância em um conjunto de dados (STIBOR; TIMMIS, 2007). Esse, é um modelo inspirado na teoria da rede imunológica proposta por Jerne (1974). Foi desenvolvido para uso de valores no espaço de forma euclidiana, entretanto, nada impede o uso de outras formas.

O objetivo do algoritmo aiNet é encontrar anticorpos a partir de sua afinidade, em uma concentração de antígenos no modelo computacional; o qual representa um modelo matemático inspirado na estrutura neural e um organismo inteligente. Esses adquirem conhecimento por meio da experiência (DE CASTRO; ZUBEN, 2000). O aiNet é a evolução do algoritmo de seleção clonal no processo de treinamento da rede.

No aiNet, cada elemento é formado por uma molécula de anticorpo, ou seja, uma rede de elementos gerados aleatoriamente que em seguida são apresentados a

um antígeno de cada vez. A partir disso, são calculadas as afinidades dadas pela distância euclidiana.

Os anticorpos com maior valor de afinidade serão selecionados e clonados; estes clones passarão por um processo de mutação ou maturação, na qual é inversamente proporcional à afinidade. Já os anticorpos com maior afinidade serão mantidos como células de memória, enquanto os de menor afinidade ou abaixo de um limiar serão suprimidos por novas gerações no processo de expansão clonal.

A rede imunológica artificial chamada aiNet, é um grafo com conexões ponderadas, não necessariamente totalmente interconectado, composto por um conjunto de nós, denominados anticorpos, e conjuntos de pares de nós chamados conexões, com um valor característico associado, chamado de peso da conexão ou simplesmente peso (DE CASTRO, 2001).

A otimização do aiNet assume a seguinte terminologia:

- Célula de rede: Indivíduo da população. Neste caso, não é realizada a codificação, cada célula é um vetor;
- Fitness: Consiste na aptidão de uma célula em relação a uma função objetivo para ser otimizado (minimizado ou maximizado). O valor da função quando avaliado para a célula dada;
- Afinidade: Distância euclidiana entre duas células;
- Clone: Células prole que são cópias idênticas de sua célula parental. A prole sofrerá ainda mutação de modo que se tornem variações de seu pai (DE CASTRO; TIMMIS, 2002).

Uma das características do aiNet é que as operações de supressão e adição de novos anticorpos devem ser realizadas somente quando identificada a estagnação de sua população.

É considerada estagnação quando a variação do percentual fitness médio da população entre duas ou mais iterações seja inferior ao valor. Shimo (2012) confirma que o algoritmo opt-aiNet, tem inspirações na teoria de redes imunológicas, e realiza uma etapa de supressão objetivando eliminar soluções semelhantes de modo a aumentar a diversidade populacional.

De Castro e Timmis (2002) resumem o algoritmo descritos no Quadro 1.

Algoritmo de aprendizado do <i>aiNet</i>
<ol style="list-style-type: none"> 1. Gerar anticorpos aleatórios para criação de uma população; 2. Enquanto critério de parada não atendido <ol style="list-style-type: none"> 2.1. Para cada antígeno <ol style="list-style-type: none"> 2.1.1. Determinar a afinidade de cada anticorpo ao antígeno apresentado e selecione os de maior afinidade para uma reprodução em quantidade proporcional à sua afinidade; 2.1.2. Efetuar a mutação de cada clone de tal modo que seja inversamente proporcional à sua afinidade. Selecionar o número de clones com maior afinidade para fazer parte do repertório das células de memória; 2.1.3. Eliminar os clones de memória cuja afinidade com o antígeno seja menor que um limiar específico, desta maneira, os clones de maior afinidade permanecerão no repertório; 2.1.4. Calcular a afinidade entre todos os clones de memória; 2.1.5. Eliminar os clones que tiverem grande afinidade entre si, assim anticorpos de memória muito semelhantes são eliminados; 2.1.6. Inserir os clones de memória referentes ao antígeno apresentado junto aos demais clones da rede; 2.2. Fim Para. 3. Determinar a afinidade entre todos os anticorpos da rede; 4. Eliminar os anticorpos cuja afinidade seja menor que determinado limiar; 5. Inserir novos anticorpos gerados aleatoriamente na rede; 6. Fim Enquanto.

Quadro 1 - Algoritmo de aprendizado do *aiNet* com a seleção de anticorpos a partir da afinidade entre antígenos

Fonte: Adaptado de De Castro e Timmis (2002).

A mutação por afinidade é realizada de acordo com a Equação 1 (DE CASTRO; TIMMIS, 2002, p. 2):

$$c' = c + \alpha N(0,1), \quad (1)$$

$$\alpha = (1 / \beta) \exp(-f^*)$$

Na qual:

c é a célula pai que será clonada;

c' é célula clone após sofrer a mutação;

$N(0,1)$ sendo N uma variável aleatória gaussiana de média zero e desvio padrão $\sigma=1$;

β é o parâmetro que controla o decaimento da inversa exponencial da função;

f^* é a aptidão de um indivíduo normalizada da célula clone.

2.3.4 Aplicação do Sia

Os SIAs estão sendo aplicados em diversas áreas computacionais, os quais Almeida (2007) destaca:

Mineração de dados: processo de análise de conjunto de dados. Seu objetivo é a descoberta de padrões que possam representar informações úteis. Arbex (2010) demonstra a utilização das técnicas de mineração de dados e clusterização hierárquica. Resultam na minimização dos erros na criação de grupos, conforme o desempenho de um rebanho leiteiro, o que não ocorria com a utilização de técnicas manuais;

Busca e otimização: consiste em encontrar uma solução ótima dentro de um conjunto de possibilidades. França (2005) aplica o SIA na otimização dinâmica. Esta técnica tem como propósito solucionar problemas em que a superfície de otimização no espaço de busca sofre variações diversas ao longo do tempo;

Aprendizagem de máquina: corresponde a algoritmos que permitem a uma máquina aprender. Guzella et al. (2008) detalham o uso do sistema imunológico no modelo de aprendizado para tratar do problema de envio de SPAM, que são e-mails indesejados de propagandas ou vírus enviados a uma enorme quantidade de usuários. Nesta proposta, as mensagens são representadas como microrganismos e são divididas em três: título e conteúdo são considerados antígenos; e o remetente é o padrão molecular.

Nesse formato, os componentes do sistema são modelados criando um sistema de proteção em duas camadas. Os e-mails são apresentados como vetores de palavras e cada palavra é formada por uma sequência de caracteres; de tal modo que a detecção de palavras semelhantes seja facilitada através da afinidade existente;

Detecção de falhas e anomalias: é possível identificar possíveis invasores nos sistemas computacionais e/ou defeitos nos sistemas. Berger et al. (2012) utilizam o algoritmo imunológico para detecção de falhas em malha de controle. O trabalho apresenta um método automático de detecção de falhas utilizando SIAs, e não se toma como base padrões estabelecidos de falhas; toma como condição anomalias ou padrões baseados em condições consideradas normais.

2.4 FERTILIDADE DO SOLO

Na agricultura moderna o manejo do solo é parte fundamental do cotidiano agrícola para evitar sua degradação, sendo assim importante para manter ou aumentar a produtividade agrícola (LEPSCH, 2010).

A prática integrante das técnicas de manejo diz respeito à adequação da disponibilidade de nutrientes no solo para o desenvolvimento das plantas. Por isso, conhecer as características do solo é fundamental para que seja feita a reposição dos nutrientes ausentes (LEPSCH, 2010).

A análise de solo tem por objetivo indicar os micros e macro nutrientes presentes e suas quantidades, de modo a fornecer ao agricultor informações sobre as necessidades de reposição nutricional. De acordo com Cardoso, Fernandes e Fernandes (2009, p. 1), “a análise de solos é o único método que permite, antes do plantio, conhecer a capacidade de um determinado solo suprir nutrientes para as plantas”.

O solo é responsável por abrigar diversas espécies vegetais, e exerce um papel fundamental no desenvolvimento e sobrevivência dos seres vivos. Lopes (1998, p. 1) ressalta que “entender a fertilidade do solo é compreender a necessidade básica para produção vegetal”. Ainda conforme este autor, solo fértil é essencial para a produtividade, entretanto, não é o único fator predominante para a produção.

Ademais, fatores como seca, insetos, má drenagem, entre outros, são também limitantes no processo de produção. Lopes (1998) aponta que é importante conhecer as propriedades químicas e físicas e a relação entre solo e planta, a fim de garantir a qualidade do solo e a sua produtividade.

2.4.1 Nitrogênio (N)

O nitrogênio (N) é o nutriente mineral mais exigido em maior quantidade pelas culturas e isso se reflete no consumo mundial deste elemento, o que supera as quantidades utilizadas de fósforo e potássio (RAIJ, 1991).

Esse nutriente é um elemento essencial para o crescimento das plantas, as quais exigem grande quantidade do mesmo. É um dos elementos mais abundantes do planeta, presente em 78% da atmosfera terrestre, conforme explica Gallo (2011, p. 1). Este mesmo autor enfatiza que, “se todo o nitrogênio que é removido do solo não fosse constantemente repostado, praticamente toda a vida neste planeta desapareceria”.

Segundo Leão (2008, p. 3), “para possibilitar o uso do nitrogênio na agricultura há a necessidade de fixação que pode ocorrer por meio de processos biológicos e/ou industriais”. A adição de N ao solo pode ocorrer com a adição de matéria orgânica ou aplicação de adubos orgânicos ou minerais. Já a perda de N no solo se dá pela remoção pelas plantas, lixiviação, erosão e volatilização (LEÃO, 2008).

A ureia, segundo Tasca et al. (2011, p. 2), é o fertilizante nitrogenado mais utilizado do Brasil, sendo de menor custo em relação aos demais adubos nitrogenados. A ureia apresenta 45% de N solúvel em água e absorve com facilidade a umidade do ar (MACHADO, 2017).

O aproveitamento do N disponibilizado para as plantas pela aplicação de ureia é baixo, conforme afirma Cantarella (2007). Isso ocorre devido às perdas por lixiviação e volatilização que podem superar 70%.

2.4.2 Fósforo (P)

Para Taiz e Zeiger (2013) Fósforo é parte importante do metabolismo e desenvolvimento das plantas, como também essencial para transferência de energia das células, e tem função na respiração e fotossíntese. Ele faz parte dos ácidos nucleicos de genes e cromossomos, assim como coenzimas, fosfoproteínas e fosfolipídeos.

As limitações na disponibilidade de P no início do ciclo vegetativo resultam em restrições no desenvolvimento como reduzir a respiração e fotossíntese e o crescimento das células pode ser retardado e potencialmente paralisado, resultando na diminuição da altura da planta, atraso na emergência das folhas, desenvolvimento das raízes entre outros.

Gerando, posteriormente, a não recuperação pela planta, mesmo que seja repostos os níveis adequados de P os quais, conforme Taiz e Zeiger (2013), podem garantir o crescimento adequado da planta.

2.4.3 Potássio (K)

O potássio possui inúmeras funções na planta. Ernani (2007, p. 552) destaca principalmente a “ativação de vários sistemas enzimáticos, muitos deles participantes dos processos de fotossíntese e respiração”. Entretanto, o K também atua na manutenção de água da planta pelo controle de abertura e fechamento dos estômatos e, também, na resistência da planta às pragas e doenças (ERNANI, 2007).

A deficiência de K tende a reduzir o crescimento das plantas, o retardo da frutificação, frutos de menor tamanho e cor menos intensa. Os sintomas de deficiência são normalmente caracterizados por clorose nas bordas das folhas seguida de necrose (ERNANI, 2007).

O cloreto de potássio (KCl) é o fertilizante potássico mais utilizado no mundo, pelo simples fato de ser o mais barato. Ernani (2007, p. 580) afirma que, “como todos os fertilizantes potássicos têm eficiência agrônômica semelhante em termos de suprimento de K às plantas, a opção de compra deve recair sobre aquele de menor custo por unidade de K”.

Esse fertilizante tem um alto índice salino, que pode prejudicar a germinação ou o crescimento inicial, se aplicado muito próximo às sementes. Entretanto, quando aplicadas altas doses, recomenda-se aplicar somente uma parte do adubo junto à sementeira. O restante deverá ser aplicado a lanço, antes da sementeira ou em cobertura (ERNANI, 2007).

2.5 ALFACE (*Lactuca sativa*)

A alface tem sua origem em espécies silvestres que podem ser encontradas em regiões de clima temperado, no Sul da Europa e Ásia ocidental. É uma planta herbácea com caule diminuto, no qual se prendem as folhas que podem ser lisas ou crespas, podendo formar ou não uma cabeça, com coloração em vários tons de verde, ou roxa.

Já as suas raízes são muito ramificadas e superficiais, explorando apenas os 25 cm do solo quando transplantadas. Em sementeiras diretas, a raiz pivotante pode atingir até 60 cm de profundidade (FIGUEIRA, 2007).

A *Lactuca sativa* é uma planta anual, o florescimento se dá sob dias longos e temperaturas quentes; dias longos e temperaturas amenas ou baixas favorecem a etapa vegetativa. A planta se adapta melhor em solos com boa capacidade de retenção de água e de textura média. A faixa de pH 6,0 a 6,8 é a mais propícia e, se necessário, deve-se efetuar a calagem para elevar a saturação por bases para 70% (FIGUEIRA, 2007).

Figueira (2007) apresenta que experimentalmente obteve-se melhores respostas em produtividade com aplicações de N e P, e que aplicações de K não elevam a produção. Para solos de média e baixa fertilidade, sugerem-se as doses de macro nutrientes (kg/ha) de: N=30; P₂O₅=250-400; e K₂O=80-90.

Figueira (2007) ainda explica que, o espaçamento utilizado para canteiros definitivos para transplante seja de 25-30 x 25-30cm. Sua cultura é altamente exigente em água e, portanto, a irrigação deve ser frequente e em abundância, devido à ampla área foliar e a evapotranspiração intensa.

2.5.1 Tipos de Alface

Atualmente existem diversos tipos de alface no mercado nacional, cada qual com sua característica, como por exemplo:

- Repolhuda Lisa;
- Repolhuda crespa ou Americana;

- Solta Lisa;
- Solta Crespa;
- Solta Crespa Roxa;
- Tipo Romana

As alfaces mais conhecidas e consumidas no Brasil são as crespas e as lisas, e algumas delas foram melhoradas para o cultivo de verão ou adaptadas para regiões tropicais, com temperaturas e pluviosidade elevadas (HENZ, SUINAGA, 2009). Segundo Henz e Suinaga (2009), o melhoramento das cultivares nacionais, têm sido feitas principalmente por instituições de ensino e de pesquisa, para ofertar aos produtores cultivares mais adaptadas às condições climáticas do Brasil.

A escolha da alface para o experimento se deu por se tratar de uma cultura de fácil manejo e por ser de ciclo curto entre 55 a 130 após a semeadura que possibilitou a realização de sete rodadas de cultivo.

3 MATERIAL E MÉTODOS

A classificação da pesquisa realizada sobre SIA e o seu algoritmo aiNet é de cunho experimental e de natureza aplicada.

Conforme se expôs anteriormente, o problema que norteia esta pesquisa é a aplicação de algoritmo aiNet para o refinamento da adubação em áreas específicas. A aposta é de que tal algoritmo possa ser aplicado com sucesso na agricultura, maximizando a produtividade e minimizando as despesas inerentes às adubações desnecessárias.

Para iniciar a fase experimental, tornou-se necessário definir algumas ferramentas e técnicas de auxílio para a realização de tais experimentos e construção do produto final.

Para que o experimento tivesse início, foram necessários alguns softwares de apoio bem como materiais para construção dos canteiros descritos a seguir.

Desenvolvimento do Software:

- Computador utilizado para o desenvolvimento do software: Notebook com 4Gb de memória RAM e com processador Intel Core i3 de 1.90GHz e 500gb de HD;
- Dispositivo móvel para realização de testes, com processador de 1.8Ghz, 3GB de memória RAM e 32 GB de armazenamento;
- Delphi Xe10: Ferramenta de desenvolvimento;
- Banco de Dados SQLite: Banco de Dados, versão 3.23.1;
- Lucidchart: Ferramenta de construção de diagramas.

Construção dos canteiros:

- 100 m de tela de sombreamento de 50%;
- 60 m de tela para cerca;
- 200 m de mangueiras;
- 100 aspersores para irrigação;
- 150 m bambu;
- Abraçadeiras, conectores e veda rosca.

3.1 DESENVOLVIMENTO DO SOFTWARE

O algoritmo foi implementado na linguagem *object pascal* utilizando a ferramenta de desenvolvimento *Delphi* na versão Xe10. Esta ferramenta possibilita o desenvolvimento multiplataforma através de seu *framework FireMonkey* (FMX), conforme exposto por Duarte (2015).

O aplicativo por ter características multiplataforma pode ser utilizado em computadores equipados com o sistema operacional *Windows*, ou aparelhos móveis como *smartphones* ou *tablets* que utilizem o sistema operacional *Android*.

As principais funcionalidades da aplicação podem ser destacadas como:

- a) Permitir alteração dos dados de parâmetro e ajustar conforme a necessidade do experimento;
- b) Cadastrar e identificar os tratamentos do experimento;
- c) Efetuar o lançamento da produção por tratamento cadastrado;
- d) Gerar novas recomendações de adubação;
- e) Visualizar recomendações anteriores.

Na tentativa de expor a utilização do software e facilitar a compreensão do mesmo, se faz necessário a utilização de diagramas para facilitar e simplificar a visualização do que se espera da interação entre o usuário e o software. Pensando nisso, a apresentação do modelo é baseada na linguagem UML, linguagem esta que é amplamente utilizada no projeto de softwares. Neste estudo, utilizou-se o diagrama de casos de uso e o diagrama classe.

A Figura 6 representa o caso de uso do software adubSolo, que apresenta o ator que pode ser qualquer pessoa que tenha acesso ao software de modo que possa operar suas funcionalidades e que nesta representação é denominada aqui como usuário e suas interações. Sendo este, responsável por cadastrar os parâmetros, tratamentos, gerar recomendação, lançar produção e visualizar as recomendações geradas.

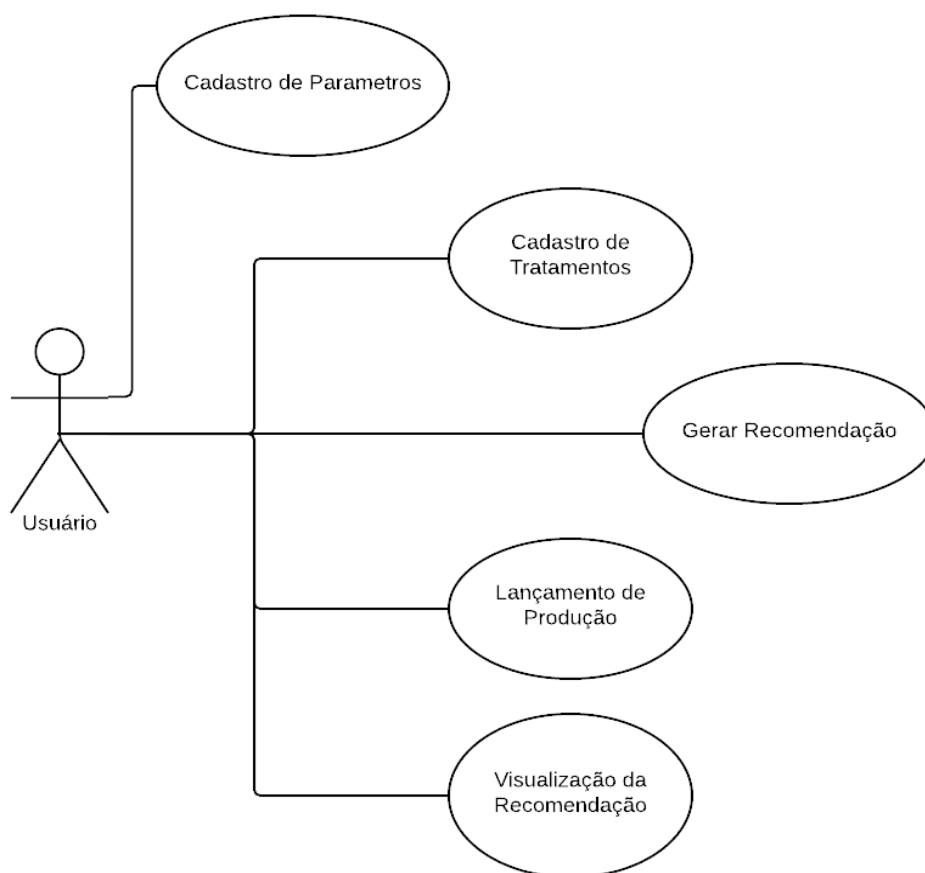


Figura 6 - Diagrama Caso uso
Fonte: Autoria própria (2017).

Para a representação da construção da base de dados BD do software foi utilizado a linguagem padrão a UML de modo a descrever o aspecto físicos e relacionamentos do banco de dados desenvolvido neste trabalho.

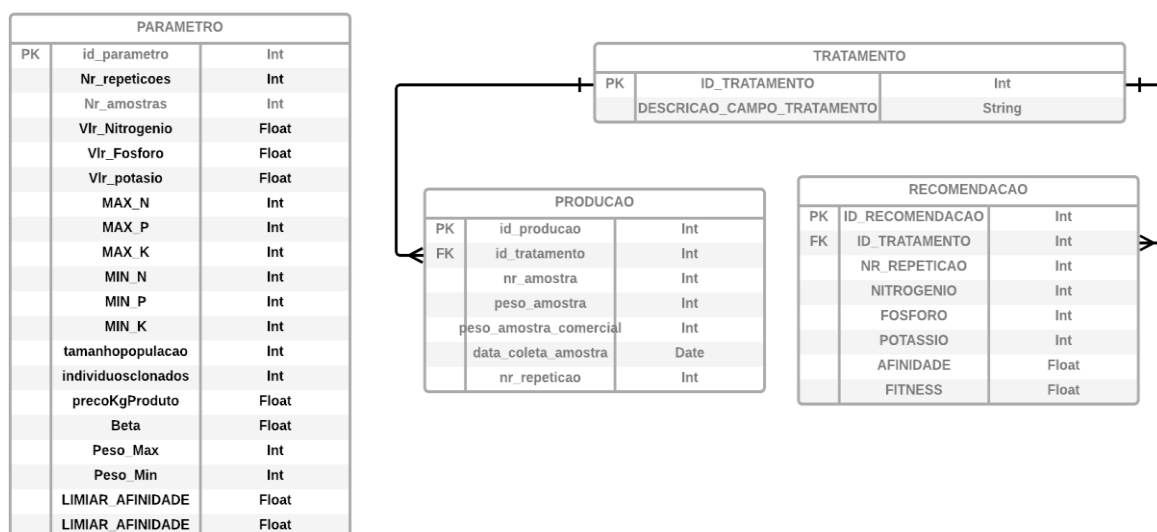


Figura 7 - Diagrama de Classes
Fonte: Autoria própria (2017).

As classes apresentadas na Figura 7 contém também seus atributos necessários para que o software possa compreender e armazenar seus resultados. A classe parâmetro é de suma importância, pois é onde o software tem seus limites de configuração gravados e que devem ser respeitadas no decorrer do processamento em cada uma das rodas para determinar uma nova recomendação de adubação.

As classes de tratamento, produção e recomendação têm o objetivo de armazenar as informações após processamento, servindo, assim, como uma base histórica importante pois as novas recomendações utilizam dessa base para compor as novas recomendações.

Pensando na característica multiplataforma para o armazenamento dos dados de parâmetro, produção e recomendação, foi utilizado o banco de dados SQLite, o que permite a sua utilização tanto em dispositivos moveis quanto em computadores pessoais. Tratando-se de um banco de dados relacional de código aberto, que foi projetado para fornecer um gerenciamento de dados sem sobrecarga e possuir uma característica altamente portátil, fácil de usar, compacto, eficiente e confiável (OWENS; ALLEN, 2010).

3.2 DESENVOLVIMENTO DO EXPERIMENTO

Para este experimento, foi utilizada uma área de aproximadamente 200 m², localizada no distrito rural de Silveirópolis (- 24° 17'38.1" S – 53° 34'10.7" W), na cidade de Assis Chateaubriand, no oeste do estado paranaense.

Para o preparo do solo foi necessário a aração, gradagem e elevação dos canteiros a +- 20cm de altura. As mudas foram obtidas em bandejas multicelulares de 288 células cada. Foram construídos quatro canteiros de 23m de comprimento por 1m de largura, divididos igualmente em 1,2m de comprimento e por 1m de largura, totalizando 92 parcelas de 1,2m².

Do total das 92 parcelas, 12 parcelas foram selecionadas para serem utilizadas testemunhas. Estas parcelas foram utilizadas posteriormente para confronto dos resultados da produção. As parcelas foram identificadas com números de A1 a A20, B1 a B20, C1 a C20 e D1 a D20 e os de controle de 1 a 3. Sendo assim os canteiros formaram uma matriz de 4 linhas e 23 colunas, conforme apresentado na Figura 8.



Figura 8 - Canteiros delimitados e identificados
Fonte: Autoria própria (2017).

3.2.1 Delineamento experimental

Após o preparo do local do experimento, foi necessário estabelecer o espaçamento e quantidade de plantas por parcela, como também a quantidade de plantas a serem selecionadas para a colheita e pesagem. Sendo assim, definiu-se o

seguinte delineamento experimental:

- Realizou-se a análise de solo inicial, de modo a verificar e repor os nutrientes faltantes para a área estudada;
- Definiu-se os compostos para aplicação de cada nutriente os quais foram:
 - N: Ureia;
 - P: Super Fosfato Simples;
 - K: Cloreto de Potássio.
- Definiu-se o plantio de alface do tipo crespa;
- Definido o espaçamento mínimo de 25 cm entre plantas, este espaçamento foi respeitado em todas as iterações do experimento;
- A parcela fora formada por 12 pés de alface. A cada iteração foram plantados no total de 1.104 pés de alface;
- Adquiriu-se mudas do mesmo fornecedor e com no mínimo de 30 dias de germinação;
- De cada parcela, com 12 plantas, foram colhidas as 4 plantas centrais, cortando-as rente ao solo. A massa fresca das plantas foi determinada utilizando-se uma balança com 0,01g de precisão;
- Realizou -se 7 iterações de cultivo de alface.

Após definidos as atividades a serem realizadas no experimento, deu se início a execução do delineamento.

Foram instaladas telas de sombreamento e sistema de irrigação para que as plantas se desenvolvessem com o mínimo de interferências externas. O sombreamento teve a finalidade de diminuir a incidência do sol tornando assim o calor mais ameno. O sistema de irrigação instalado nos canteiros evitou a dependência das chuvas para o desenvolvimento, garantindo assim um ambiente hídrico controlado.

3.2.2 Características avaliadas

As plantas foram colhidas aos 45 dias após os transplantio. Foram coletadas quatro plantas centrais de cada parcela, onde foi tomada a seguinte característica:

- Peso da massa fresca bruta (MFB), que pode ser obtida da parte aérea de cada planta separada das raízes.
- Peso da massa fresca comercial (MFC). A segunda pesagem é realizada após a limpeza, onde foram consideradas as folhas e os caules, como usualmente são vendidos no comércio, removendo-se as folhas danificadas.

4 RESULTADOS E DISCUSSÃO

4.1 INÍCIO DO EXPERIMENTO

A primeira análise de solo composta foi realizada no dia 10 agosto de 2016, na cidade de Palotina – PR pela Universidade Federal do Paraná e obtiveram-se os seguintes valores, apresentados na Tabela 1.

Tabela 1 - Resultados das análises de solo da propriedade estudada

Variável da análise	Valores
pH CaCl ₂	4,72
pH H ₂ O	5,73
K	0,71 cmol _c dm ⁻³
P	16,72 mg dm ⁻³

Fonte: Autoria própria (2017).

Com base na análise de solo descrita na Tabela 1, obteve-se a recomendação de adubação apresentada na Tabela 2 que teve como fonte o Manual de Adubação e de Calagem para os Estados do Rio Grande do Sul e de Santa Catarina (SBCS, 2004). Essa recomendação de adubação foi aplicada igualmente de forma uniforme em 80 parcelas.

Tabela 2 - Valores utilizado para o 1° Plantio

Produtos	Nutrientes	Valores (em g) por parcela
Ureia	N	26
Super Fosfato Simples	P	27
Cloreto de Potássio	K	19

Fonte: Autoria própria (2017).

O objetivo principal da primeira rodada é obter a média de produção e o desvio padrão, que serviu como base inicial e comparativa dos resultados apresentados nas rodadas seguintes. Estes resultados são gerados a partir da segunda rodada de cultivo pela implementação do algoritmo aiNet.

As parcelas denominadas de controle/testemunha receberam adubação diferenciada respeitando os critérios apresentado na Tabela 3.

Tabela 3 - Valores utilizados em canteiros de controle/testemunha para o 1° Plantio

Controles	Nutrientes	N-P-K
A1	0%	0-0-0
B1	0%	0-0-0
C1	0%	0-0-0
D1	0%	0-0-0
A2	50%	13-14-8
B2	50%	13-14-8
C2	50%	13-14-8
D2	50%	13-14-8
A3	100%	26-27-19
B3	100%	26-27-19
C3	100%	26-27-19
D3	100%	26-27-19

Fonte: A autoria própria (2017).

A finalidade dos canteiros de controle/testemunha é de confronto com os resultados de produção. De modo que, se possa observar se a recomendação de adubação calculada pelo algoritmo teve influência no crescimento das plantas, e que eventos externos como adversidades do tempo e temperatura, não tiveram influência significativa.

4.2 PARAMETRIZAÇÃO DO SOFTWARE

A aplicação foi desenvolvida de forma que, possa ser parametrizada e assim, possibilitando que a mesma, seja utilizada em outros experimentos sem que sejam necessárias alterações em seu algoritmo.

Os parâmetros podem ser personalizados conforme o experimento e ajustados durante os testes, com o objetivo de melhorar o desempenho dos resultados.

Os parâmetros são:

- Quantidade de amostras a serem coletadas;
- Quantidade de interações;
- Tamanho da população;
- Quantidade de indivíduos a serem clonados;
- Quantidade de clones gerados por cada indivíduo clonado;

- Para a função de custos, são estabelecidos como parâmetros os preços dos nutrientes e do produto selecionado;
- Valor de beta, que é o fator multiplicativo da equação;
- Limites mínimos e máximos dos nutrientes a serem aplicados. Valores estes que servem como limiar de supressão quando a aplicação apresentar valores fora dos estabelecidos como mínimos e máximos;
- Afinidade, que determina a distância entre o antígeno pai e de seu clone. Este parâmetro também faz parte do limiar de supressão de afinidades parametrizadas, valores superiores aos parametrizados são eliminados e gerado um novo clone.

A tela de parametrização do software é apresentada na Figura 9.

PARAMETRO...	VALORES	MIN MAX
Editar		Salvar
Nr Amostras	4	
Nr Repetições	8	
Tamanho População	80	
Indivíduos Clonados	5	
Qte Clones por Indivíduos	15	
R\$ Nitrogênio Kg	2,00	
R\$ Fósforo Kg	2,00	
R\$ Potássio Kg	2,00	
R\$ Valor Produto Kg	7,64	
Valor de Beta	0,03	
Valor Mão R\$		
Outros Custos R\$		
Mínimo N		0
Mínimo P		0
Mínimo K		0
Máximo N		65
Máximo P		68
Máximo K		48
Peso Max		1000
Peso Min		800
Limiar de Afinidade		5

Figura 9 - Tela de parâmetros do aplicativo
Fonte: Autoria própria (2017).

Os parâmetros estabelecidos para o experimento foram:

1) Nr Amostras: que representa o número de amostras que serão coletadas e pesadas por parcela do experimento. Neste caso, foram delimitados em 4 amostras por parcela.

2) Nr Repetições: Quantidade limite de repetição do experimento. Neste caso, foram feitos 7 plantios (critério de parada).

3) Tamanho da população: Representa o tamanho total das parcelas utilizadas no experimento. Para o experimento apresentado neste trabalho foram delimitados 80 parcelas.

4) Indivíduos clonados: Delimita o número de indivíduos da população que serão clonados no experimento, foi delimitado em 5 parcelas mais produtivas.

5) Quantidade Clones por Indivíduos: A partir das 5 parcelas selecionadas como as mais produtivas no parâmetro indivíduos clonados, o software gera e aplica a mutação sobre 15 clones por parcela como parametrizado.

6) “R\$ Nitrogênio kg”, “R\$ fósforo kg”, “R\$ Potássio kg”: Pode-se estabelecer inicialmente os valores de nitrogênio, fósforo e potássio, e estes valores são utilizados para o cálculo do custo de produção.

7) “R\$ Valor Produto Kg”: O valor do produto é parametrizado por fazer parte do cálculo de custo, no qual pode se obter o valor de lucro.

8) Valor de Beta: É o fator de multiplicação entre [0,1] parametrizado inicialmente como 0,05.

9) Mínimos e máximos de NPK: São os valores estabelecidos como baliza de modo que o software não calcule valores negativos ou valores com quantidades exorbitantes que comprometam o estudo (limiar de morte natural) eliminando os valores que por ventura fiquem fora dos parametrizados.

10) Afinidade: Valor responsável para determinar a aptidão dos clones. Valores maiores que o valor de afinidade parametrizado são suprimidos e são gerados novos clones.

Limites:

Mínimo de N = 0;

Mínimo de P = 0;

Mínimo de K = 0;

Máximo de N = 65 g de ureia;

Máximo de P = 68 g de superfosfato simples;

Máximo de K = 48 g de cloreto de potássio;

Afinidade = 5.

A Figura 10 é a representação do fluxograma adaptado de De Castro (2001), com as adaptações necessárias para que fossem atendidas as necessidades da pesquisa.

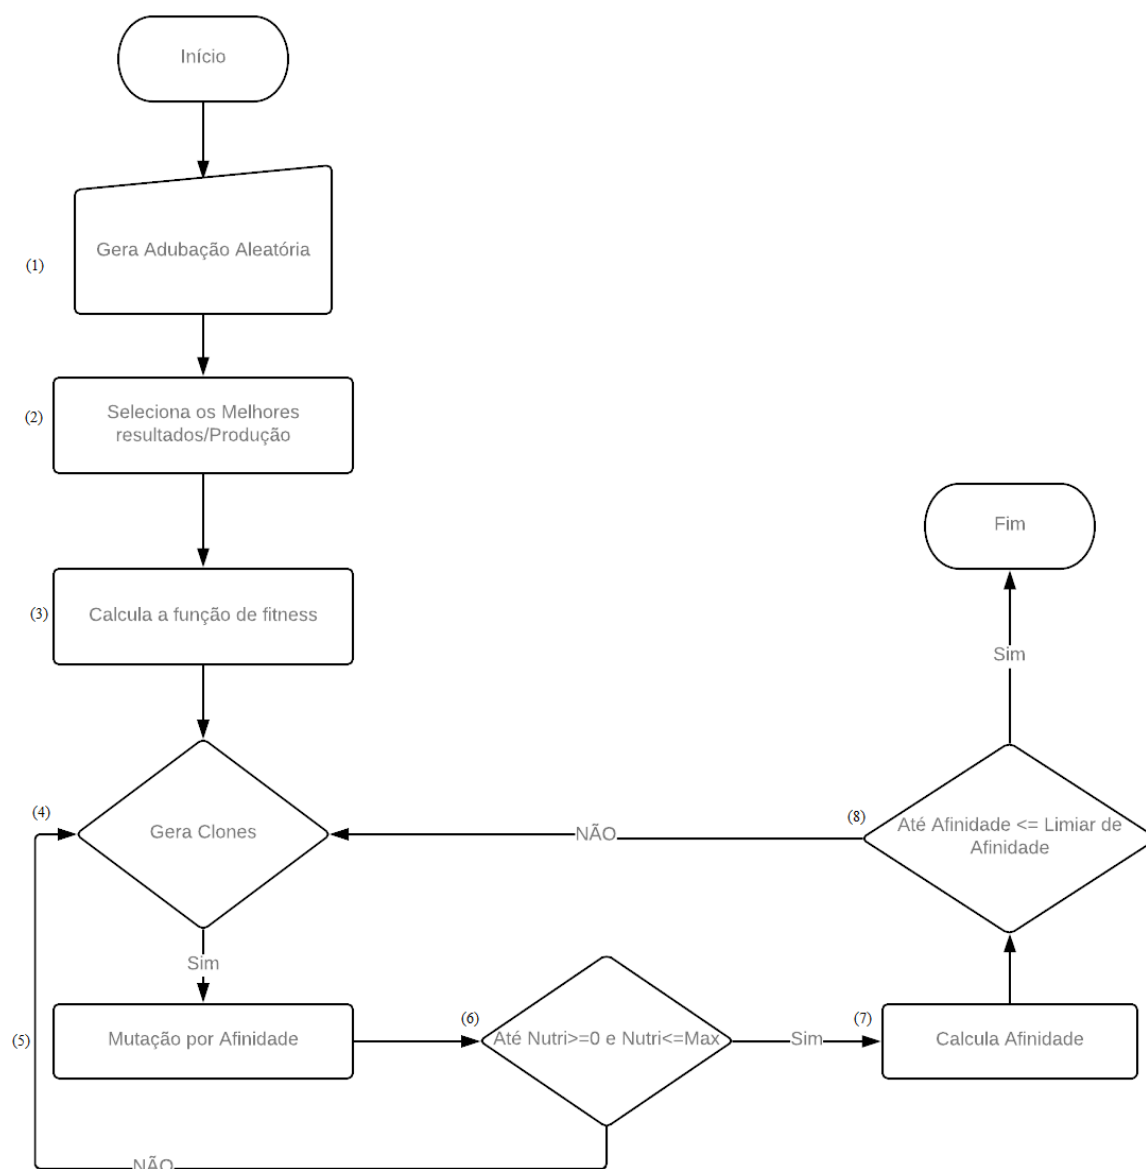


Figura 10 - Fluxograma do algoritmo aplicado no experimento
 Fonte: Adaptado de De Castro (2001).

O aplicativo recebe os valores de parâmetros pré-definidos, descritos a seguir:

1) A aplicação inicialmente gera um conjunto aleatório de recomendações obedecendo aos valores máximos (MaxN) e mínimos (MinN) para total da população parametrizada (TmPopulacao);

2) Em seguida, o aplicativo seleciona em ordem decrescente os tratamentos com as melhores produtividades, obedecendo a quantidade de células a serem clonadas (NrClone);

3) Cálculo da função de custo (f), para cada um dos tratamentos selecionados;

Para a função de custos é considerado o preço do produto em kg vendido no mercado atual, subtraindo os valores dos nutrientes por kg no mercado atual;

4) Neste passo, a aplicação gera novos clones e permanece no laço de repetição até que o critério de parada definido como número de clones a serem gerados seja atendido (NrClonesGerados);

5) Neste passo, ocorre a mutação proporcional a afinidade que é realizada de acordo com a Equação 1 apresentada anteriormente;

6) Laço de repetição: é responsável em garantir que os nutrientes calculados respeitem os valores de nutrientes parametrizado, tendo como parâmetro de supressão valores menores que 0 e maiores que o MaxN da recomendação. A operação ocorre até encontrar valores diferentes dos mencionados acima, caso contrário, retorna ao passo 4;

7) Ao obter os valores de nutrientes calculados a função de afinidade é responsável por calcular a distância euclidiana dos valores de origem para o seu clone. Neste passo, o programa deve suprimir os valores de afinidades que sejam maiores do que o valor parametrizado;

8) É o laço responsável em suprimir resultados com a afinidade maior que o parametrizado.

4.3 RODADAS CULTIVO

4.3.1 Primeira rodada de cultivo

O plantio ocorreu no dia 6 de novembro de 2016, com mudas de 30 dias de idade. A adubação aplicada pode ser observada na Tabela 2. Em todas as 80 parcelas os fertilizantes foram aplicados uniformemente espalhados por toda área da parcela.

Os fertilizantes foram pesados e condicionados em sacos plásticos com a numeração correspondente a sua parcela de tratamento facilitando assim sua identificação e posteriormente sua aplicação na área estudada.

O processo de pesagem dos fertilizantes ocorreu em todas as fases do experimento conforme a Figura 11.



Figura 11 - Distribuição dos nutrientes
Fonte: Autoria própria (2017).

A Figura 12 apresenta o resultado da construção das parcelas devidamente divididas e identificadas no momento do transplante das mudas de alface.



Figura 12 - Transplante das mudas de alface ocorrido no dia 6 de novembro de 2016
Fonte: Autoria própria (2017).

A colheita ocorreu no dia 21 de dezembro de 2016, decorridos 45 dias após o transplante das mudas, totalizando 75 dias do início da germinação a colheita das alfaces.

No momento da colheita (Figura 13), como definido no delineamento experimental, foram selecionados quatro pés centrais de cada um dos tratamentos, os quais foram pesados da mesma forma que foram colhidos (massa fresca, sem a retirada de folhas mortas, quebradas, amareladas e de baixa qualidade) e nominados como MFB.



Figura 13 - Colheita no dia 21 de dezembro de 2016
Fonte: Autoria própria (2017).

Em seguida, realizou-se a limpeza descartando as folhas mortas, quebradas, amareladas e de baixa qualidade, submetendo-as novamente a pesagem, as quais foram nominadas como MFC. O resultado da parcela é a soma dos 4 pés selecionados e pesados como representados no Anexo I.

Neste primeiro plantio, os resultados apresentados para MFC foram de 536,24 gramas e para MFB foi de 619,99 gramas com desvio padrão de 164,04 gramas e 177,18 gramas, respectivamente.

Como já exposto anteriormente o motivo da primeira rodada sob recomendação padrão calculada pelo manual de adubação e calagem (SBCS, 2004), é de conhecer a média e o desvio padrão da produção da propriedade estudada, para que sirva de parâmetro para novas observações.

4.3.2 Segunda rodada de cultivo

O plantio ocorreu entre 10 fevereiro de 2017 e 27 março de 2017. A partir da segunda rodada do experimento a adubação passou a ser calculada pelo software desenvolvido. Nesta etapa, foram realizados sorteios dos nutrientes aleatoriamente pelo software.

A aleatoriedade é parte inicial do algoritmo implementado e seu objetivo é criar uma diversidade da população. Nesse contexto, a diversidade é a adubação com maior diversidade de formulação de NPK sem que haja repetição da composição.

Entretanto, essa aleatoriedade respeitou apenas os parâmetros definidos de valores mínimos e máximos de cada um dos nutrientes. A parametrização dos limites foram: mínimo de 0 representando a ausência daquele nutriente na aplicação e o valor máximo representando 2,5 vezes a recomendação padrão utilizada na primeira rodada de cada um dos nutrientes.

O resultado do sorteio está apresentado na Tabela 4. Os valores de NPK dizem respeito a quantidade em gramas de Ureia, Super Fosfato Simples e Cloreto de Potássio.

Tabela 4 - Resultado do sorteio dos nutrientes NPK para o 2º rodada (em gramas)

	N	P	K		N	P	K		N	P	K		N	P	K
A1	8	13	26	B1	9	67	34	C1	26	59	5	D1	17	0	44
A2	15	25	0	B2	60	46	33	C2	12	61	20	D2	12	3	38
A3	24	25	45	B3	59	38	25	C3	39	65	28	D3	44	60	41
A4	10	45	30	B4	29	35	42	C4	13	57	42	D4	9	41	25
A5	11	17	22	B5	59	25	23	C5	30	27	25	D5	21	31	33
A6	28	41	37	B6	30	60	18	C6	37	43	45	D6	7	33	29
A7	26	16	10	B7	54	27	22	C7	35	60	24	D7	24	26	38
A8	28	5	10	B8	41	48	12	C8	35	11	18	D8	63	38	39
A9	64	39	3	B9	35	65	12	C9	25	8	4	D9	0	57	2
A10	50	33	22	B10	42	46	4	C10	61	46	10	D10	45	5	33
A11	24	64	12	B11	5	58	30	C11	35	13	11	D11	57	65	14
A12	44	4	34	B12	28	13	7	C12	54	0	0	D12	46	30	11
A13	14	31	37	B13	25	39	11	C13	26	40	28	D13	50	34	4
A14	1	20	25	B14	26	7	44	C14	42	52	19	D14	16	59	0
A15	3	40	1	B15	21	25	2	C15	50	28	33	D15	45	44	37
A16	33	51	13	B16	52	11	32	C16	60	1	19	D16	52	46	24
A17	1	16	42	B17	34	26	1	C17	35	31	34	D17	23	35	47
A18	4	8	33	B18	35	41	1	C18	59	53	5	D18	36	27	45
A19	22	11	1	B19	55	32	32	C19	26	4	19	D19	10	49	12
A20	62	33	27	B20	42	43	31	C20	20	20	20	D20	14	61	12

Fonte: Autoria própria (2017).

Observa-se na Figura 14, a aleatoriedade dos nutrientes que foram gerados pelo algoritmo. A explicação para este fenômeno é que o primeiro passo do algoritmo é a geração de valores aleatórios explorando todo espaço de busca.




Figura 14 - Dispersão dos nutrientes da segunda rodada de cultivo
Fonte: Autoria própria (2017).

Ao final da colheita da segunda rodada de cultivo, obteve-se uma média de 248,29 gramas em peso MFC e 280,36 de peso MFB com um desvio padrão de 153,39 para MFC e 170,66 para MFB.

A produção apresentada nesta rodada é 53% inferior em comparação a primeira rodada. As possíveis causas da diminuição da produção, serão discutidas posteriormente.

4.3.3 Terceira rodada de cultivo

O plantio, referente a terceira rodada, ocorreu entre 10 de abril e 25 de maio de 2017, com mudas de 30 dias de idade.

Os nutrientes Ureia, Super Fosfato Simples e Cloreto de Potássio (NKP) foram aplicados, conforme apresentados na Tabela 5. Para esse cálculo, o software levou em consideração a produção da segunda rodada, selecionando os melhores resultados para a clonagem e mutação (Equação 1) conforme parametrizado.

Tabela 5 - Resultado do sorteio dos nutrientes NPK para o 3° rodada (em gramas)

	N	P	K		N	P	K		N	P	K		N	P	K
A1	41	48	12	B1	47	64	5	C1	29	59	17	D1	23	45	39
A2	46	49	11	B2	34	47	12	C2	60	46	11	D2	7	24	19
A3	40	48	12	B3	41	50	0	C3	46	49	32	D3	51	44	16
A4	39	42	9	B4	25	60	0	C4	60	59	35	D4	62	46	11
A5	42	48	12	B5	24	54	5	C5	21	34	2	D5	59	38	25
A6	41	49	12	B6	44	60	5	C6	19	48	26	D6	53	51	18
A7	42	47	12	B7	33	59	5	C7	31	39	26	D7	5	64	40
A8	39	47	11	B8	46	65	6	C8	2	57	37	D8	15	30	11
A9	36	49	13	B9	47	51	3	C9	29	35	42	D9	22	11	30
A10	43	48	13	B10	28	66	10	C10	58	39	32	D10	38	8	41
A11	44	48	16	B11	20	66	11	C11	62	33	47	D11	25	24	34
A12	43	51	10	B12	31	52	6	C12	34	30	11	D12	30	29	39
A13	41	47	15	B13	30	60	18	C13	57	54	38	D13	5	60	14
A14	43	47	10	B14	19	40	0	C14	24	42	29	D14	40	11	25
A15	41	46	9	B15	42	65	21	C15	48	47	8	D15	37	32	17
A16	41	49	14	B16	33	64	0	C16	59	22	23	D16	62	48	17
A17	35	65	12	B17	30	62	37	C17	49	11	42	D17	3	39	17
A18	25	59	7	B18	20	66	27	C18	49	16	37	D18	34	45	5
A19	32	64	18	B19	42	56	9	C19	23	46	21	D19	63	17	11
A20	51	60	22	B20	14	62	21	C20	48	54	24	D20	39	66	18

Fonte: Autoria própria (2017).

A parametrização, nesse momento do experimento, consiste em selecionar os cinco melhores resultados obtidos na rodada de número dois com no mínimo de 800g e no máximo de 1000g de alface por parcela. Caso o software não encontre nenhuma parcela que se enquadre nesta faixa, ele deve ignorar e buscar os resultados ordenados do maior para o menor, selecionando apenas os cinco primeiros.

Para cada um desses resultados devem ser gerados quinze novos clones. Esses clones passaram pelo processo de maturação conforme Equação 2. O valor de beta nesta rodada fora parametrizado em 0,005.

A dispersão dos nutrientes apresentados na Figura 15, apresenta que o processo de cálculo dos nutrientes até próximo a vigésima parcela manteve um padrão que agruparam os valores de NPK. Entretanto o algoritmo é estimulado a manter a diversidade dos anticorpos.




Figura 15 - Dispersão dos nutrientes da terceira rodada
Fonte: Autoria própria (2017).

Decorrido 45 dias após plantio para a colheita, foram novamente selecionados os 4 pés centrais de cada uma das parcelas sendo feito a pesagem.

O resultado da terceira rodada apresenta em média para MFC de 431,88g e MFB de 476,34g, com o valor do desvio padrão de 216,15 e 240,00 respectivamente.

A terceira rodada de cultivo já apresenta uma melhora com relação à média da segunda rodada, sugerindo assim que o processo de aprendizagem está ocorrendo e o software começou a encontrar melhores resultados.

4.3.4 Quarta rodada de cultivo

A quarta rodada do plantio ocorreu entre 12 de agosto e 26 de setembro de 2017, evitando o período de inverno mais rigoroso. As mudas selecionadas para o plantio possuíam 30 dias de idade.

Os nutrientes foram aplicados, conforme a recomendação calculada pelo software, levando em consideração os resultados da terceira rodada e apresentados na Tabela 6.

Tabela 6 - Resultado do sorteio dos nutrientes NPK para o 4° rodada (em gramas)

	N	P	K		N	P	K		N	P	K		N	P	K
A1	41	48	12	B1	47	64	5	C1	29	59	17	D1	23	45	39
A2	46	49	11	B2	34	47	12	C2	60	46	11	D2	7	24	19
A3	40	48	12	B3	41	50	0	C3	46	49	32	D3	51	44	16
A4	39	42	9	B4	25	60	0	C4	60	59	35	D4	62	46	11
A5	42	48	12	B5	24	54	5	C5	21	34	2	D5	59	38	25
A6	41	49	12	B6	44	60	5	C6	19	48	26	D6	53	51	18
A7	42	47	12	B7	33	59	5	C7	31	39	26	D7	5	64	40
A8	39	47	11	B8	46	65	6	C8	2	57	37	D8	15	30	11
A9	36	49	13	B9	47	51	3	C9	29	35	42	D9	22	11	30
A10	43	48	13	B10	28	66	10	C10	58	39	32	D10	38	8	41
A11	44	48	16	B11	20	66	11	C11	62	33	47	D11	25	24	34
A12	43	51	10	B12	31	52	6	C12	34	30	11	D12	30	29	39
A13	41	47	15	B13	30	60	18	C13	57	54	38	D13	5	60	14
A14	43	47	10	B14	19	40	0	C14	24	42	29	D14	40	11	25
A15	41	46	9	B15	42	65	21	C15	48	47	8	D15	37	32	17
A16	41	49	14	B16	33	64	0	C16	59	22	23	D16	62	48	17
A17	35	65	12	B17	30	62	37	C17	49	11	42	D17	3	39	17
A18	25	59	7	B18	20	66	27	C18	49	16	37	D18	34	45	5
A19	32	64	18	B19	42	56	9	C19	23	46	21	D19	63	17	11
A20	51	60	22	B20	14	62	21	C20	48	54	24	D20	39	66	18

Fonte: Autoria própria (2017).

A quarta rodada também apresenta grande aleatoriedade dos dados calculados, mantendo a diversidade dos anticorpos que pode ser vista na Figura 16.




Figura 16 - Dispersão dos nutrientes da quarta rodada

Fonte: Autoria própria (2017).

O resultado dessa rodada apresenta uma média de 629,98g para MFC e 640,08g para MFB com um desvio padrão de 238,34 e 238,82 respectivamente.

Novamente, a nova rodada do experimento apresentou um resultado médio superior a anterior.

4.3.5 Quinta rodada cultivo

Entre 12 de outubro e 26 de novembro de 2017 ocorreu o plantio das mudas, todas elas com 30 dias de germinação. Os nutrientes foram novamente calculados pelo Software tendo como base os 5 melhores tratamentos da quarta rodada, os quais estão apresentados na Tabela 7.

Tabela 7 - Resultado do sorteio dos nutrientes NPK para o 5° rodada (em gramas)

	N	P	K		N	P	K		N	P	K		N	P	K
A1	27	62	43	B1	24	34	44	C1	29	13	27	D1	13	45	24
A2	6	17	23	B2	62	47	17	C2	5	10	25	D2	52	36	11
A3	39	41	26	B3	53	55	24	C3	28	7	43	D3	25	7	47
A4	34	15	0	B4	23	41	40	C4	18	25	42	D4	3	40	11
A5	12	8	30	B5	0	3	47	C5	35	54	37	D5	17	14	28
A6	19	50	42	B6	28	27	36	C6	9	28	43	D6	24	9	17
A7	28	48	12	B7	21	8	17	C7	54	60	31	D7	58	15	12
A8	50	42	43	B8	22	62	47	C8	45	56	44	D8	23	6	37
A9	55	43	44	B9	49	61	24	C9	61	40	41	D9	18	36	9
A10	46	43	15	B10	53	53	12	C10	38	28	37	D10	51	17	1
A11	11	21	43	B11	59	37	46	C11	21	1	8	D11	12	46	38
A12	55	28	20	B12	27	19	41	C12	40	21	44	D12	48	66	21
A13	2	39	6	B13	64	62	19	C13	55	9	1	D13	5	44	30
A14	11	27	4	B14	28	47	8	C14	40	25	19	D14	26	38	2
A15	46	19	4	B15	17	20	28	C15	7	14	38	D15	48	53	29
A16	64	38	24	B16	13	41	9	C16	29	43	31	D16	30	56	8
A17	35	42	10	B17	52	48	9	C17	5	40	30	D17	31	36	42
A18	1	45	42	B18	0	19	31	C18	22	48	46	D18	21	46	20
A19	18	52	47	B19	35	21	2	C19	20	24	40	D19	16	47	12
A20	46	59	17	B20	45	39	33	C20	0	24	5	D20	64	63	19

Fonte: Autoria própria (2017).

A Figura 17, apresenta grande dispersão dos dados e variando de zero a o máximo parametrizado para cada um dos nutrientes.




Figura 17 - Dispersão dos nutrientes da quinta rodada de cultivo
Fonte: Autoria própria (2017).

O quinto plantio apresenta em média de MFC igual a 573,14g, com desvio padrão de 162,50g e MFB de 643,48g com desvio padrão de 172,39g. Nessa rodada, pode-se observar uma leve queda da média de produção. Também se observa uma diminuição no desvio padrão. Essa diminuição sugere que nessa rodada os tratamentos foram mais uniformes e o aprendizado do algoritmo está ocorrendo.

4.3.6 Sexta rodada de cultivo

A sexta rodada de plantio ocorreu entre 05 de dezembro de 2017 e 19 de janeiro de 2018, com mudas de 30 dias de idade.

Os nutrientes são apresentados na Tabela 8.

Tabela 8 - Resultado do sorteio dos nutrientes NPK para o 6° rodada (em gramas)

	N	P	K		N	P	K		N	P	K		N	P	K
A1	27	19	41	B1	45	50	33	C1	42	17	23	D1	2	0	11
A2	40	63	46	B2	43	61	32	C2	20	54	41	D2	40	16	15
A3	20	59	22	B3	50	2	22	C3	26	48	40	D3	59	60	13
A4	17	12	37	B4	5	4	23	C4	26	11	0	D4	12	32	14
A5	24	19	14	B5	8	7	47	C5	13	41	17	D5	30	56	8
A6	24	14	39	B6	23	36	40	C6	57	20	10	D6	58	59	42
A7	27	21	33	B7	50	5	5	C7	64	7	23	D7	13	22	1
A8	27	38	15	B8	1	2	10	C8	44	15	8	D8	44	40	6
A9	7	14	20	B9	32	33	41	C9	59	37	46	D9	44	33	8
A10	44	8	17	B10	11	6	28	C10	57	22	37	D10	15	66	30
A11	1	13	41	B11	25	42	2	C11	36	49	19	D11	7	5	1
A12	48	10	25	B12	3	8	8	C12	8	47	17	D12	30	1	41
A13	43	50	14	B13	12	46	38	C13	21	56	26	D13	61	6	28
A14	61	56	8	B14	23	58	22	C14	15	67	0	D14	18	3	11
A15	44	9	12	B15	0	44	42	C15	39	12	30	D15	30	65	33
A16	3	60	19	B16	15	45	12	C16	55	35	13	D16	50	37	14
A17	0	3	47	B17	5	32	37	C17	36	42	41	D17	9	45	10
A18	14	65	20	B18	13	17	31	C18	18	9	10	D18	16	26	10
A19	44	9	13	B19	57	16	5	C19	25	40	43	D19	23	44	21
A20	47	14	47	B20	61	0	18	C20	31	65	19	D20	17	51	47

Fonte: Autoria própria (2017).

A dispersão dos dados apresentado na Figura 18, referente a sexta rodada vem se mantendo alta, variando entre zero e o máximo de cada nutriente.




Figura 18 - Dispersão dos nutrientes da sexta rodada de cultivo

Fonte: Autoria própria (2017).

O sexto plantio apresenta em média para MFB de 648,25g com desvio padrão de 153,63g e MFC de 595,19g com desvio padrão de 150,74g. Novamente, a queda no desvio padrão se confirma na sexta rodada e a produção volta a ser superior à da quinta rodada.

4.3.7 Sétima rodada cultivo

O plantio desta rodada de cultivo ocorreu entre 25 de janeiro e 11 de março de 2018, com mudas de 30 dias após germinação.

Os nutrientes foram aplicados, conforme calculado pelo software, cujas quantidades podem ser observadas na Tabela 9.

Tabela 9 - Resultado do sorteio dos nutrientes NPK para o 7º rodada (em gramas)

	N	P	K		N	P	K		N	P	K		N	P	K
A1	19	19	19	B1	19	22	14	C1	19	27	27	D1	20	26	17
A2	19	21	17	B2	23	22	17	C2	19	26	23	D2	24	20	16
A3	16	17	18	B3	14	24	17	C3	16	22	24	D3	24	22	22
A4	20	17	21	B4	18	22	15	C4	19	21	23	D4	26	21	18
A5	19	16	16	B5	20	22	15	C5	21	22	26	D5	23	22	14
A6	23	22	19	B6	18	25	16	C6	18	23	24	D6	23	18	11
A7	18	21	16	B7	18	19	14	C7	18	23	21	D7	25	22	10
A8	16	17	18	B8	14	22	20	C8	21	21	23	D8	22	20	11
A9	15	18	21	B9	15	22	14	C9	22	22	19	D9	19	23	16
A10	22	20	21	B10	15	20	15	C10	23	24	18	D10	26	21	14
A11	20	17	17	B11	17	18	18	C11	23	18	19	D11	27	20	14
A12	20	21	16	B12	14	20	17	C12	24	19	21	D12	25	21	10
A13	21	23	17	B13	19	24	24	C13	26	22	17	D13	25	23	18
A14	22	17	17	B14	19	27	25	C14	23	21	19	D14	26	22	13
A15	20	21	17	B15	18	23	20	C15	22	22	20	D15	21	19	12
A16	20	16	17	B16	22	24	21	C16	24	23	22	D16	25	24	13
A17	18	22	17	B17	18	21	22	C17	22	26	21	D17	27	24	13
A18	15	23	19	B18	15	24	21	C18	21	23	22	D18	23	20	11
A19	16	22	20	B19	18	26	25	C19	18	21	19	D19	24	23	12
A20	19	21	15	B20	18	27	22	C20	25	22	20	D20	26	19	15

Fonte: Autoria própria (2018).

Na sétima rodada de cultivo Figura 19, os nutrientes calculados não apresentaram uma dispersão tão alta em comparação com as rodadas anteriores.




Figura 19 - Dispersão dos nutrientes da sétima rodada de cultivo
Fonte: Autoria própria (2018).

A explicação desse fenômeno é que fora diminuído o valor de Beta que estava parametrizado no valor de 0,05, e para a rodada 7 e 8 fora reduzido para 0,03. A princípio, o valor alto no início é para o algoritmo explorar melhor o espaço de busca. E que, no final a diminuição do valor de beta, é para focar na região no qual é mais provável ter um ótimo global ou local.

Esta rodada apresentou uma média de MFB igual a 807,28g, com desvio padrão de 132,01g e MFC de 786,68g com desvio padrão de 128,87g. Nessa rodada, obteve-se os melhores resultados médios.

Foi realizada uma simulação do cálculo dos nutrientes para a oitava rodada apresentada na Figura 20.




Figura 20 - Simulação da dispersão dos nutrientes da oitava rodada de cultivo
Fonte: Autoria própria (2018).

Observa-se que como na sétima rodada os dados permaneceram com uma dispersão menor se comparada as outras rodadas. Outro ponto a ser observado é que houve uma diminuição na quantidade de nutriente a ser aplicado na maioria das parcelas. A Tabela 10 apresenta a análise descritiva dos resultados obtidos em todas as rodadas.

A Figura 21 apresenta as temperaturas mínimas, máximas e médias diárias. Os dados foram obtidos da estação meteorológica Instituto nacional de meteorologia INMET. Os dados foram agrupados no período em que ocorreram os experimentos.

Tabela 10 – Análise descritiva dos resultados de colheita por rodadas

Descrição	Rodadas													
	1		2		3		4		5		6		7	
	MFC	MFB	MFC	MFB	MFC	MFB	MFC	MFB	MFC	MFB	MFC	MFB	MFC	MFB
Média	536,238	619,988	248,288	280,363	431,875	476,338	629,975	640,075	573,138	643,475	595,188	648,25	786,675	807,275
Desvio Padrão	164,043	177,182	153,395	170,656	216,145	240,000	238,342	238,823	162,504	172,393	150,737	153,631	128,865	132,013
Maior	973	1046	731	809	865	983	1256	1268	978	1056	1048	1053	1068	1104
Menor	245	279	21	27	87	91	214	226	245	279	275	362	516	533
>=800	4	16	0	1	1	4	21	22	9	17	9	14	38	44
Coefficiente de Variação	30,59%	28,58%	61,78%	60,87%	50,05%	50,38%	37,83%	37,31%	28,35%	26,79%	25,33%	23,70%	16,38%	16,35%

Fonte: Autoria própria (2018).




Figura 21 - Temperatura mínima, máxima e média do período de cultivo

Fonte: Dados adaptados do INMET (2018) para Marechal Candido Rondon - PR.

A época de plantio é um fator fundamental no cultivo da alface, por se tratar de uma planta bastante influenciada por condições ambientais, uma vez que se adapta melhor às regiões de clima onde as temperaturas sejam mais amenas.

De acordo com Resende et al. (2017, p. 2 apud SANDERS, 2017), a “cultura é adaptada a temperaturas amenas, sendo que a ideal para o desenvolvimento está na faixa de 15,5 a 18,3°C, apesar de tolerar temperaturas entre 26,6 e 29,4°C, por alguns dias, desde que as temperaturas noturnas sejam baixas”.

Como exposto, os algoritmos SIAs já são amplamente utilizados no processo de otimização. Nesse sentido, a avaliação da efetividade do algoritmo se dará através da análise dos resultados apresentados em cada rodada do experimento. A eficácia da aplicação do algoritmo pôde ser mensurada a fim de se saber se houve melhora significativa nos índices de produção, e uma redução dos custos e consequentemente um aumento no lucro.

Outro ponto a se destacar, é que o software desenvolvido pode ser aplicado em diversas culturas agrícolas por se tratar de um aplicativo parametrizado, sendo possível a alteração dos valores dos nutrientes, do produto a ser cultivado, tamanho da população, quantidade de tratamentos a serem clonados e a quantidade de clones a serem gerados, até mesmos as quantidades de iterações podem ser alteradas.

Porém, para a efetividade do algoritmo SIA, há a necessidade da realização de inúmeras iterações para que o algoritmo possa aprender e apresente resultados satisfatórios.

Os resultados do uso do software serão expostos a seguir ao final da colheita das 7 rodadas de cultivo sendo aplicados os nutrientes calculados e sugeridos pelo software em 6 delas.

A Figura 22 apresenta a média de produção das sete rodadas. Nota-se que na segunda rodada quando o software gerou uma recomendação aleatória da população inicial de nutrientes. A produtividade teve uma acentuada queda, que pode ter ocorrido por inúmeras causas, como por exemplo o vigor das mudas adquiridas, e temperaturas muito altas.

Como pode ser observado na Figura 21, no período de 10 de fevereiro a 27 de março de 2017 ocorreu os maiores índices de temperatura média na região, se comparados aos demais períodos apresentados no experimento.

Na rodada seguinte, o experimento já apresenta uma suave linha de tendência a aumentar a produtividade se aplicado o algoritmo por mais rodadas de cultivo.




Figura 22 - Média de Produção por rodada de plantio
Fonte: Autoria própria (2018).

Observa-se na Figura 23, que os tratamentos relacionados como controle/testemunha também apresentam a tendência de alta. Entretanto, na Figura 24, a comparação entre os tratamentos com adubação sugerida pelo software com as parcelas de controle/testemunha a partir da sexta rodada, os tratamentos gerados pelo software apresentam melhores médias. O que sugere a eficiência do algoritmo.




Figura 23 - Média dos tratamentos de controle/testemunha
Fonte: Autoria própria (2018).




Figura 24 - Comparação produtividade MFC com tratamentos de testemunha
Fonte: Autoria própria (2018).

Na Figura 25, são apresentados os valores máximos, mínimos e a média de cada rodada. É importante verificar, na linha de média do gráfico, a aparente melhora do coeficiente de variação (CV) das amostras em relação as rodadas 3 e 4 que apresentam uma maior dispersão dos pesos.

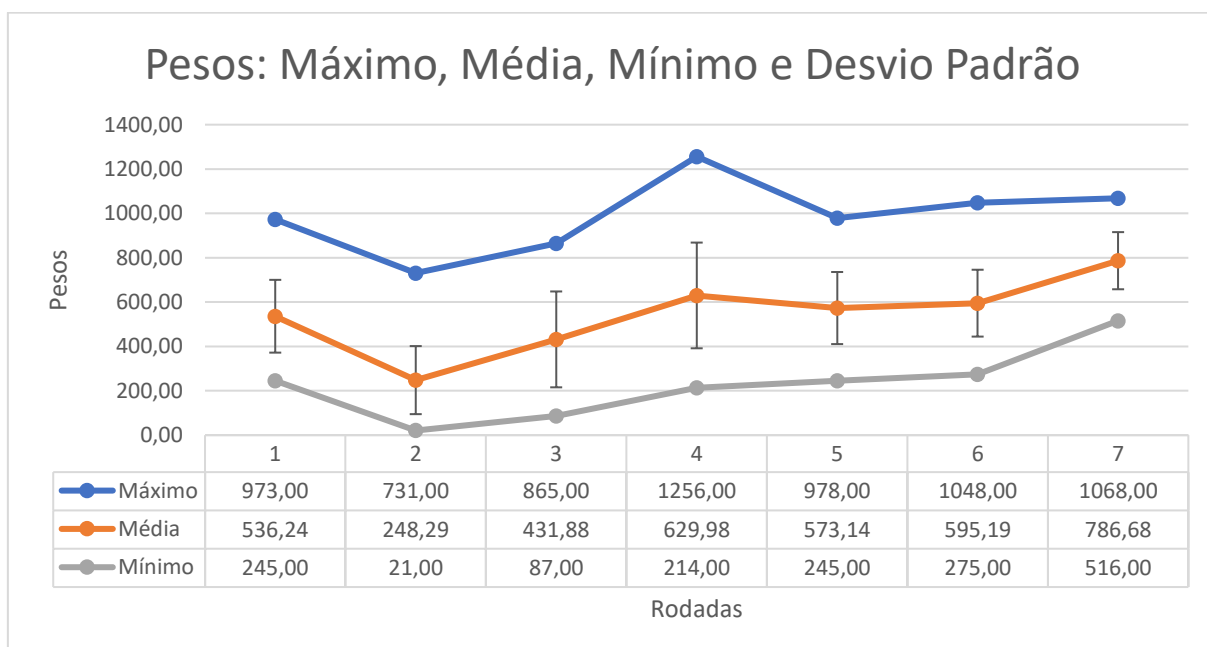


Figura 25 - Apresenta a somatória dos pesos máximo, média e mínima dos tratamentos bem como a dispersão dos dados com relação à média
Fonte: Autoria própria (2018).

Na Figura 26, é apresentado o desvio padrão encontrado a cada rodada. O ponto importante apresentado neste gráfico é a diminuição do desvio padrão, sendo apresentada a partir da quinta rodada e se mantendo em queda na sexta e sétima rodada. A linha de tendência do gráfico confirma a perspectiva de queda.




Figura 26 - Desvio padrão por rodada de plantio.
Fonte: Autoria própria (2018).

Essa informação é muito importante e demonstra que existe uma tendência a diminuição da dispersão dos dados. O CV menor mostra que a média tende a ficar mais próxima dos mínimos do que dos máximos. Uma possível explicação para este fenômeno é que o algoritmo está tentando explorar mais o espaço de busca, ao mesmo tempo mantendo os melhores anticorpos.

O coeficiente de variação é uma medida importante a ser observada em experimentos. Podendo ser útil na definição do delineamento das repetições do ensaio e detecção das diferenças entre médias de tratamentos como com uma dada probabilidade, tendo em vista que os CV estão relacionados ao erro residual nas análises de variância (PIMENTEL-GOMES, 2009).

SCHMILDT et al. (2017, p. 291) salientam que “Na literatura, a maioria dos pesquisadores das diversas áreas da agronomia tem comparado os seus resultados com aqueles sugeridos por Pimentel-Gomes (2009)”. Afirmação aponta que para experimentos de campo com culturas agrícolas considera valores de CV como baixos, quando forem inferiores a 10% e médios, quando estiverem entre 10 e 20%, altos, quando apresentados entre 20 e 30% e valores muito altos, sendo superiores a 30%.

Entretanto, essa classificação, além de se basear em dados agrícolas e de campo, está sendo utilizada para classificar valores de CV de diferentes variáveis indiscriminadamente dentro da experimentação agrícola. Torna-se necessária, portanto, uma nova classificação dos coeficientes de variação, voltados para a realidade das diferentes espécies, das variáveis estudadas, assim como do tipo de experimentação aos quais os dados se referem (SCHMILDT et al., 2017).

Já na Figura 27, são apresentados os melhores resultados divididos em top01 a parcela de melhor resultado, top05 a média dos 5 melhores resultados e top10 a média das 10 melhores parcelas. Esse gráfico observa-se que a diferença entre a melhor parcela e média entre as 10 melhores parcelas tendem a diminuir com a evolução do tempo.




Figura 27 - Somatório dos melhores resultados por rodada de plantio
Fonte: Autoria própria (2018).

Pode se observar uma tendência de aumento da produtividade como já observado em outros gráficos. No entanto, o que chama a atenção nesse caso, é que o mesmo apresenta uma homogeneização dos tratamentos, sugerindo que há uma tendência de melhora de uma forma global, diminuindo a dispersão entre o tratamento com melhor produtividade até o décimo melhor.

Para as rodadas 6 e 7, verifica-se que a diferença entre a melhor parcela com a média das dez melhores foi de 170,3g da sexta rodada, se comparado com a sétima rodada que foi de 84,6g.

Fitness para este experimento é o cálculo de lucro. A Figura 28 apresenta o lucro obtido para a produção, no qual também pode-se observar uma leve tendência de alta, se submetido a novas rodadas. Este valor representa o quão bom é um indivíduo, ou seja, para o experimento o quão rentável pode ser o tratamento.




Figura 28 - Média de Fitness por rodada
Fonte: Autorial própria (2018).

Levou-se em consideração o valor da alface no ponto de venda. Este valor foi parametrizado no software e não levou em consideração as oscilações de preços. Em contrapartida optou-se por considerar apenas os valores dos nutrientes no cálculo do custo de produção.

Nesse contexto, observa-se que houve um aumento no lucro na sétima rodada de R\$0,15 centavos se comparado com a oitava rodada de R\$0,63 centavos. Para a oitava rodada foi realizado o cálculo considerando a produção obtida anteriormente.

Outro ponto importante a se considerar nos resultados obtidos pela aplicação do software e o algoritmo aiNet, é observar que há uma diminuição na quantidade média de fertilizantes aplicados (Figura 29). Essa diminuição é observada a partir da quinta rodada e se mantém em queda nas próximas rodadas.

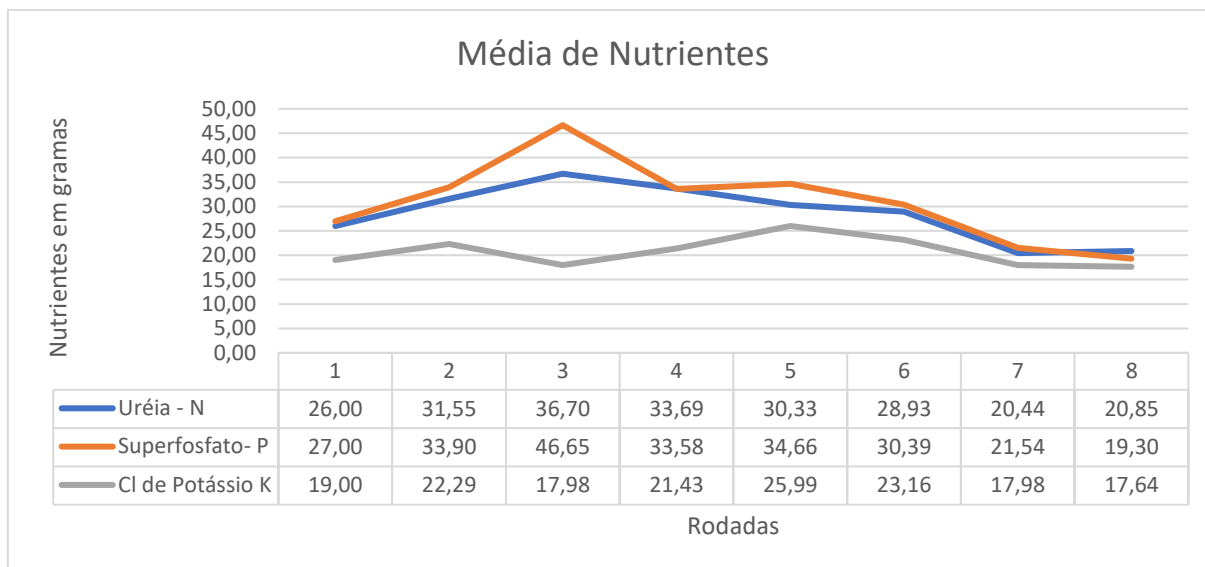


Figura 29 - Média de Nutrientes por rodada.
Fonte: A autoria própria (2018).

Pode-se comparar a Figura 22, onde observa-se que há um aumento de produtividade mesmo reduzindo a aplicação dos nutrientes observada na Figura 29. Isso explica a diminuição do fitness, confirmando assim, um custo menor com a aplicação de NPK e uma maior produtividade.

Outro fator importante a ser avaliado, é a quantidade de parcelas que superaram o parâmetro de peso mínimo estabelecido no software que foi de 800g por tratamento. Estes dados podem ser observados na Figura 30.




Figura 30 - Quantidade de parcelas que superaram 800g de produção
Fonte: A autoria própria (2018).

Após uma queda na quantidade de parcelas, que superariam as 800g que ocorreu na rodada quatro para a cinco e se manteve igual na rodada seis, a rodada sete apresentou 38 parcelas que superaram esse parâmetro.

5 CONCLUSÃO

O experimento mostrou resultados melhores para o algoritmo de SIA aiNet aplicado do que o controle utilizado. Nota-se que é possível obter resultados satisfatórios na otimização de adubação. Entretanto, existe a necessidade de um maior número de iterações e coleta de dados referente a produção da propriedade para fazer testes estatísticos apropriados e verificar a significância do resultado.

Essa coleta de dados de produção fornece o aprendizado ao algoritmo e sem ela não se torna possível sua utilização. Quanto mais informações inseridas no sistema, maiores as chances de os algoritmos apresentarem melhores resultados a cada iteração, e se tornando uma alternativa no uso de referência para aplicação dos nutrientes.

Ademais, é importante frisar que, a característica do algoritmo é de manter uma variabilidade populacional na tentativa de melhorar seus descendentes geração após geração.

6 CONSIDERAÇÕES FINAIS E SUGESTÕES

A princípio, a aplicação do algoritmo requer um grande volume de interações e dados de entrada para que o refinamento da solução proposta seja de qualidade. Isso irá transformar o experimento muito amplo, porém, há necessidade de novos estudos com quantidades diferentes de iterações e dados de entrada. Esses estudos devem ser explorados para determinar se menores quantidades de dados sejam suficientes para encontrar respostas igualmente satisfatórias.

Ao longo do desenvolvimento do experimento, foram observados a possibilidade de novos trabalhos que possam colaborar com o desenvolvimento de novas ferramentas de SIA.

- **Diminuição de tratamentos:** Estudar se pode obter resultados semelhantes se diminuir os tratamentos de 80 para 50;
- **Utilização de treinamento de rede neural para predição de produção:** Realizar uma pesquisa utilizando de um treinamento de rede neural para predição da produção evitando que o usuário tenha que aguardar todo o ciclo de produção;
- **Estudo do SIA é amplo e com diversos algoritmos que buscam a otimização:** Implementar outros algoritmos a fim de obter a comparação e a apresentação dos algoritmos mais eficientes.

REFERÊNCIAS

ALMEIDA, Carolina Paula de. **Aplicação de sistemas imunológicos artificiais para a predição de estruturas de proteína.** 2007. 80f. Dissertação (Mestrado) Universidade Tecnológica Federal do Paraná, Curitiba, 2007.

ARBEX, Marcio Aarestrup. **Clusterização de grupos contemporâneos com tamanho reduzido para as avaliações genéticas de rebanho leiteiros.** 2010. 168f. Dissertação (Mestrado em Engenharia Civil) – Universidade Federal do Rio de Janeiro. Rio de Janeiro, 2010.

ARTERO, Almir Olivette. **Inteligência artificial: teoria e prática.** São Paulo: Ed. Livraria da Física, 2009.

BECCENERI, José Carlos. **Meta-heurística e otimização combinatória: aplicações em problemas ambientais.** São José dos Campos. INPE. 2008. Disponível em: <http://www.lac.inpe.br/elac13/arquivos/MiniCurso_02ELAC2012.pdf>. Acesso em: 05 fev. 2017.

BERBERT, Priscila Cristina. **Sistema imunológico artificial para otimização multiobjetivo.** 2008. 119f. Dissertação (Mestrado) - Universidade Estadual de Campinas, Campinas, 2008.

BERGER, Marcus André Ramos; DE SOUZA, Cleonilson Protásio; TAVARES, Rhaisa Souza. **Deteção de falhas em malhas de controle utilizando algoritmo imunológico.** Revista Ciência e Tecnologia, [S.l.], v. 14, n. 24/25, mar. 2012.

CANTARELLA, Heitor. **Nitrogênio.** In: NOVAIS, R. F. et al. (Ed.). Fertilidade do solo. SIMPOSIO BRASILEIRO DE CIENCIA DO SOLO, 2007, Viçosa. Anais. Viçosa, 2007.

CARDOSO, Evaldo Luís, FERNANDES, Ana Helena Bergamim, Marozzi; FERNANDES, Fernando Antônio. **Análise de solos: finalidade e procedimentos de amostragem.** Corumbá: Embrapa Pantanal, 2009. 5p. (Embrapa Pantanal. Comunicado Técnico, 79). Disponível em: <<http://www.cpap.embrapa.br/publicacoes/online/COT79.pdf>>. Acesso em: 29 abril 2017.

CHITOLINA, José Carlos; PRATA, Fábio; SILVA, Fábio Cesar; MURAOKA, Takashi; VITTI, Andre Cesar. **Amostragem, acondicionamento e preparo de amostras de solo para análise de fertilidade.** In: SILVA, F. C. Org. Manual de análises químicas de solos, plantas e fertilizantes. Brasília, Embrapa Comunicação para Transferência de Tecnologia. 1999.

COPPIN, Ben. **Inteligência artificial**. Rio de Janeiro: LTC, 2013.

DASGUPTA, Dipankar. **Artificial immune system and their applications**. USA, 1998.

DE CASTRO, Leandro Nunes.; ZUBEN, Fernando. J. **An evolutionary immune network for data clustering**. In: SIMPÓSIO BRASILEIRO DE REDES NEURAIS, 2000, Rio de Janeiro. Anais... Rio de Janeiro: IEEE Computer Society Press, 2000.

DE CASTRO, Leandro Nunes. **Engenharia imunológica: Desenvolvimento e aplicação de ferramentas computacionais inspiradas em sistemas imunológicos artificiais**. 2001. 302f. Tese (Doutorado em Engenharia Elétrica) - Universidade Estadual de Campinas, Campinas, 2001.

DE CASTRO, Leandro Nunes.; TIMMIS, Jonathan. **Artificial immune systems: a new computational intelligence approach**. 1. ed. Springer Science & Business Media. London, 2002.

DUARTE, William. **Delphi para Android e iOS: desenvolvendo aplicativos móveis**. Rio de Janeiro: Brasport, 2015.

ERNANI, Paulo Roberto. **Potássio**. In: NOVAIS, R. F. et al. (Ed.). Fertilidade do solo. SIMPOSIO BRASILEIRO DE CIENCIA DO SOLO, 2007, Viçosa. Anais. Viçosa, 2007.

ERNANI, Paulo Roberto. **Fósforo**. In: NOVAIS, R. F. et al. (Ed.). Fertilidade do solo. SIMPOSIO BRASILEIRO DE CIENCIA DO SOLO, 2007, Viçosa. Anais. Viçosa, 2007.

FRANÇA, Fabrício Olivetti de. **Algoritmos bio-inspirados aplicados à otimização dinâmica**. 2005. 140f. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Estadual de Campinas. Campinas, 2005.

FIGUEIRA, Fernando Antônio Reis. **Novo Manual de olericultura**. 3° Ed. rev, e ampl. Viçosa, MG: Ed. UFV, 2007.

FLING, Brian. **Mobile design and development: practical concepts and techniques for creating mobile sites and web apps**. O' Reilly Media, 2009.

FOX, Daniel. **Building soluitions with the Microsoft.NET compact framework. Architecture and best practices form mobile development.** Boston. Pearson Education, 2003.

GALLO, Luiz Antônio. **O Nitrogênio e o ciclo do nitrogênio.** Disponível em: <<http://docentes.esalq.usp.br/luagallos/nitrogenio.htm>>. Acesso em: 06 abr. 2017.

GIL, Antônio Carlos. **Como elaborar projetos de pesquisa.** 5. ed. São Paulo: Atlas, 2010.

GUZELLA, Thiago. S.; MOTA-SANTOS, Tomas Aroldo.; UCHÔA, Joaquim Quinteiro; CAMINHAS, W. M. **Identification of SPAM messages using an approach inspired on the imune system.** Bio Systems, Elsevier, v. 92, n. 3, 2008.

GUEDES, Gilleanes T. A. **UML 2-Uma abordagem prática.** 3.ed. São Paulo. Novatec editora, 2018.

HENZ, Gilmar. Paludo.; SUINAGA, Fabio. **Tipos de Alface Cultivados no Brasil.** Brasília: Embrapa Hortaliças, 2009.

JERNE, Niels K. **Towards a Network Theory of the Immune System.** Ann. Immunol. 1974.

KLEIN, Jan. **Immunology.** Oxford. Blackwell Scientific Publications, 1990.

KURZWEIL, Ray. **The Age of Spiritual Machines.** The MIT Press, Massachusetts, 1990.

LAUDON, Kenneth C.; LAUDON, Jane Price. **Sistemas de Informação com Internet.** 4. ed. Rio de Janeiro: LTC Livros Técnicos e Científicos, 1999.

LEPSCH, Igo Fernando. **Formação e conservação dos solos.** 2. ed. São Paulo. Oficina de Textos, 2010.

LEÃO, A. F. **Redutores de volatilização do nitrogênio da ureia na cultura do milho safrinha, utilizando coletores semiaberto estático.** 2008. 74f. Dissertação (Mestrado em Agronomia) - Universidade Federal de Goiás, Jataí, 2008.

LOPES, Alfredo Scheid. **Manual internacional de fertilidade do solo. Piracicaba.** São Paulo. Associação Brasileira para pesquisa da potassa e do fosfato. 1998. Disponível em: <[http://brasil.ipni.net/ipniweb/region/brasil.nsf/0/40A703B979D0330383257FA80066C007/\\$FILE/Manual%20Internacional%20de%20Fertilidade%20do%20Solo.pdf](http://brasil.ipni.net/ipniweb/region/brasil.nsf/0/40A703B979D0330383257FA80066C007/$FILE/Manual%20Internacional%20de%20Fertilidade%20do%20Solo.pdf)>. Acesso em: 06 abr. 2017.

LUZ, Maria, J. da S.; FERREIRA, Gilvan. B.; BEZZERA, José, R. C. **Adubação e correção do solo: procedimentos a serem adotados em função dos resultados da análise do solo.** Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/CNPA/19595/1/CIRTEC63.pdf>>. Acesso em: 06 abr. 2017.

INMET. Instituto Nacional de Meteorologia. **Dados de temperatura máximas, médias e mínimas/estação meteorológica de Marechal Candido Rondon.** 2018. Disponível em: <<http://www.inmet.gov.br/>> Acesso em: 06 abr. 2018.

MACHADO, Leonardo O. **Adubação Nitrogenada.** Disponível em: <<http://www.dpv24.iciag.ufu.br/new/dpv24/Apostilas/Monitor%20Leonardo%20-%20Apostila%20Adub.%20Nitrogenada%2002.pdf>>. Acesso em: 06 abr. 2017.

MALAVOLTA, Eurípedes. **Manual de nutrição mineral de plantas.** Piracicaba: Editora Ceres, 2006.

MASSRUHÁ, Silvia Maria F. S.; SOUZA, Kleber Xavier. S. de; MEIRA, Carlos Alberto A.; OLIVEIRA, Stanley Robson. de M.; LIMA, Helano. Povoas. de. **Sistemas computacionais inteligentes na agricultura.** SIMPÓSIO SOBRE INOVAÇÃO E CRIATIVIDADE CIENTÍFICA NA EMBRAPA, 1, 2008, Brasília, DF. Comunicações Seleccionadas. Brasília, DF: Embrapa, 2008. Disponível em: <<http://www.alice.cnptia.embrapa.br/alice/handle/doc/31599>>. Acesso em: 05 set. 2017.

OWENS, Mike; ALLEN, Grant. **The Definitive Guide to SQLite.** Apress LP, 2010.

OLIVEIRA, Edson Lima de. **Sugestão de adubação e calagem para culturas de interesse econômico no Estado do Paraná.** Londrina: IAPAR, 2003.

PIMENTEL-GOMES, Frederico. **Curso de estatística experimental.** 15. ed., Piracicaba: Fealq, 2009, 451 p.

PILA, Adriano D. **História e terminologia a respeito da computação evolutiva**. Revista Ciências Exatas e Tecnologia, Santa Bárbara, v. 1, n. 1, p. 40-50, 2015.

RAIJ, Bernardo. Van. **Fertilidade do solo e adubação**. São Paulo: Ceres, Piracicaba: POTAFOS, 1991.

RAIJ, Bernardo. Van. **Fertilidade do solo e manejo de nutrientes**. International Plant Nutrition Institute. Piracicaba-SP, 2011.

RESENDE, Geraldo, M. de; COSTA, Nivaldo D.; YURI, Jony E.; MOTA, José H. **Adaptação de genótipos de alface crespa em condições semiáridas**. Revista Brasileira de Agricultura Irrigada, Fortaleza, v.11, n.1, p.1145–1154. 2017.

ROMÁN, Fernando; GONZALES-MESONES, Fernando; MARINAS, Ignácio, **Mobile marketing: a revolução multimídia**. São Paulo: Thomson Learning, 2007.

RUSSELL, Stuart. J. **Inteligência artificial**. Rio de Janeiro: Elsevier, 2013.

STIBOR, Thomas.; TIMMIS, Jonathan. **An investigation on the compression quality of aiNet**. IEEE SYMPOSIUM ON FOUNDATIONS OF COMPUTATIONAL INTELLIGENCE, 2007, Honolulu. Proceedings... Honolulu: IEEE Computer Society Press, 2007.

SILVA, Fábio C. da. **Manual de análises químicas de solos, plantas e fertilizantes**. Embrapa Informação Tecnológica; Rio de Janeiro: Embrapa Solos, 2009.

SHIMO, Helder K. **Auto-organização da população em sistemas imunológicos artificiais aplicada ao docking de proteínas**. 2012. 146f. Dissertação (Mestrado em Bioinformática) - Bioinformática, Universidade de São Paulo, Ribeirão Preto, 2012.

SBCS. Sociedade Brasileira de Ciência do Solo. **Manual de adubação e de calagem para os Estados do Rio Grande do Sul e de Santa Catarina**. 10. ed. Porto Alegre, 2004.

SCHMILDT, Edilson R.; SILVA, Wilton; AMBROSIO, Thainá de Jesus; SCHMILDT, Omar; NASCIMENTO, Adriel Lima., FERNANDES, Adriano Alves. **Coefficiente de variação como medida da precisão em experimentos de alface**. Revista Agro@mbiente On-line, Boa Vista, Roraima, v. 11, n. 4, p. 290-295, 2017.

TAIZ, Lincoln; ZEIGER, Eduardo. **Fisiologia vegetal**. 4 eds. Porto Alegre: Artmed, 2013.

TASCA, Francis Alex.; ERNANI, P. R.; ROGERI, D. A.; GATIBONI, L. C. **Volatilização de amônia do solo após a aplicação de ureia convencional ou com inibidor de uréase**. Revista Brasileira de Ciência do solo. v. 35, n. 2, mar/abr. Viçosa. 2011. Disponível em: <<http://www.scielo.br/pdf/rbcs/v35n2/v35n2a18.pdf>>. Acesso em: 06 abr. 2017.

TIMMIS, Jon.; EDMONDS, Camila. A Comment on Opt-AiNET: **An immune network algorithm for optimization**. **Genetic and Evolutionary Computation**. Berlin, 2004.

TOLEDO, Jan Miszura; DEUS, Gilcimar Divino. **Desenvolvimento em smartphones – aplicativos nativos e web**. 7ª Mostra de Produção Científica da Lato Sensu. PUC Goiás. Goiânia – GO. Disponível em: <<http://www.cpgls.ucg.br/7mostra/artigos/agrarias.pdf>>. Acesso em: 05 set. 2016.

VIERO, Veronica; SOUZA, Renato Santos de. **Comunicação rural on-line: promessa de um mundo sem fronteiras - estudo de caso do modelo de monitoramento agrícola do Sistema Irrigada**, Universidade Federal de Santa Maria. XLVI Congresso SOBER. Sociedade Brasileira de Economia, Administração e Sociologia Rural, 46, 2008, Rio Branco, Anais...Rio Branco–Acre, 2008.

VIERO, Veronica Crestani; SILVEIRA, Ada. Cristina. M. **Apropriação de tecnologias de informação e comunicação no meio rural brasileiro**. Cadernos de Ciência & Tecnologia, Brasília, v. 28, n. 1, jan/abr. 2011.

APÊNDICE A

Tabela 11 - Resultado da produção da primeira rodada em Massa fresca comercial (MFC) e Massa fresca bruta (MFB)

Produção 1° Rodada											
	MFC	MFB		MFC	MFB		MFC	MFB		MFC	MFB
A1	570	677	B1	578	645	C1	289	341	D1	513	597
A2	617	694	B2	558	672	C2	566	653	D2	530	621
A3	566	672	B3	696	764	C3	675	826	D3	450	528
A4	796	873	B4	790	898	C4	498	573	D4	419	494
A5	564	625	B5	862	1020	C5	399	476	D5	380	473
A6	658	734	B6	778	842	C6	523	604	D6	275	369
A7	478	550	B7	550	635	C7	351	413	D7	245	279
A8	379	442	B8	663	757	C8	391	462	D8	279	328
A9	398	465	B9	706	755	C9	462	553	D9	374	447
A10	331	410	B10	722	801	C10	664	840	D10	542	626
A11	427	517	B11	716	805	C11	612	727	D11	374	440
A12	466	531	B12	973	1046	C12	538	642	D12	865	983
A13	431	493	B13	637	725	C13	474	568	D13	706	775
A14	354	402	B14	827	906	C14	736	864	D14	446	544
A15	384	452	B15	706	805	C15	476	554	D15	363	409
A16	427	517	B16	698	779	C16	399	483	D16	440	497
A17	455	486	B17	755	863	C17	635	762	D17	779	858
A18	382	474	B18	591	665	C18	704	811	D18	604	662
A19	272	318	B19	407	487	C19	504	612	D19	555	635
A20	258	327	B20	344	422	C20	570	720	D20	524	599

Fonte: Autoria própria (2017).

Tabela 12 - Análise descritiva do primeiro plantio em Massa fresca bruta (MFB) e Massa fresca comercial (MFC)

Descrição	MFC	MFB
Média	536,24	619,99
Erro padrão	18,34	19,81
Mediana	527,00	616,50
Modo	706,00	672,00
Desvio padrão	164,04	177,18
Variância da amostra	26910,01	31393,38
Curtose	-0,52	-0,59
Assimetria	0,34	0,27
Intervalo	728,00	767,00
Mínimo	245,00	279,00
Máximo	973,00	1046,00
Soma	42899,00	49599,00
Contagem	80,00	80,00

Fonte: Autoria própria (2017).

Tabela 13 - Resultado da produção para o 2º rodada (em gramas)

Produção 2º Rodada											
	MFC	MFB		MFC	MFB		MFC	MFB		MFC	MFB
A1	157	180	B1	528	586	C1	294	342	D1	140	163
A2	196	239	B2	514	563	C2	348	381	D2	101	115
A3	274	304	B3	546	608	C3	401	443	D3	76	88
A4	223	253	B4	569	601	C4	371	424	D4	163	184
A5	285	331	B5	434	505	C5	222	252	D5	207	230
A6	255	298	B6	613	661	C6	181	202	D6	56	64
A7	330	358	B7	483	545	C7	75	86	D7	220	252
A8	382	419	B8	731	809	C8	188	215	D8	147	195
A9	174	193	B9	654	787	C9	259	297	D9	104	126
A10	72	80	B10	489	554	C10	145	166	D10	130	141
A11	150	164	B11	337	371	C11	138	160	D11	250	274
A12	149	168	B12	403	438	C12	264	302	D12	329	372
A13	84	98	B13	466	540	C13	284	330	D13	206	239
A14	21	27	B14	250	276	C14	212	246	D14	90	122
A15	77	88	B15	368	418	C15	224	243	D15	262	296
A16	150	164	B16	365	404	C16	113	125	D16	176	200
A17	104	111	B17	398	449	C17	193	218	D17	199	228
A18	155	175	B18	248	281	C18	158	174	D18	203	230
A19	96	111	B19	259	293	C19	120	129	D19	137	158
A20	149	165	B20	187	223	C20	95	107	D20	57	72

Fonte: Autoria própria (2017).

Tabela 14 - Análise descritiva do segundo plantio

	MFC	MFB
Média	248,29	280,36
Erro padrão	17,15	19,08
Mediana	206,50	239,00
Moda	150,00	239,00
Desvio padrão	153,39	170,66
Variância da amostra	23530,00	29123,35
Curtose	0,74	0,86
Assimetria	1,08	1,09
Intervalo	710,00	782,00
Mínimo	21,00	27,00
Máximo	731,00	809,00
Soma	19863,00	22429,00
Contagem	80,00	80,00

Fonte: Autoria própria (2017).

Tabela 15 - Resultado da produção para o 3º rodada (em gramas)

Produção 3º Rodada											
	MFC	MFB		MFC	MFB		MFC	MFB		MFC	MFB
A1	197	215	B1	247	261	C1	422	460	D1	548	631
A2	165	174	B2	172	181	C2	576	273	D2	450	524
A3	165	180	B3	163	167	C3	401	569	D3	428	520
A4	151	163	B4	91	96	C4	722	742	D4	380	473
A5	124	138	B5	150	168	C5	530	585	D5	275	369
A6	101	109	B6	143	147	C6	566	637	D6	275	369
A7	120	126	B7	714	729	C7	615	723	D7	579	628
A8	149	160	B8	712	724	C8	671	775	D8	570	720
A9	124	135	B9	601	613	C9	579	654	D9	368	440
A10	87	91	B10	651	719	C10	542	597	D10	542	626
A11	224	233	B11	680	773	C11	544	555	D11	706	775
A12	157	166	B12	536	663	C12	540	556	D12	446	544
A13	204	222	B13	446	523	C13	474	568	D13	865	983
A14	206	213	B14	571	581	C14	757	814	D14	604	662
A15	238	258	B15	647	668	C15	468	514	D15	555	636
A16	224	233	B16	424	431	C16	424	473	D16	524	599
A17	244	255	B17	599	624	C17	647	748	D17	355	409
A18	254	265	B18	664	678	C18	710	799	D18	440	497
A19	141	149	B19	676	737	C19	518	616	D19	779	858
A20	116	127	B20	786	847	C20	717	797	D20	374	447

Fonte: Autoria própria (2017).

Tabela 16 - Análise descritiva do terceiro plantio

	MFC	MFB
Média	431,88	476,34
Erro padrão	24,17	26,83
Mediana	448,00	523,50
Moda	165,00	233,00
Desvio padrão	216,15	240,00
Variância da amostra	46718,82	57599,97
Curtose	-1,27	-1,25
Assimetria	-0,08	-0,13
Intervalo	778,00	892,00
Mínimo	87,00	91,00
Máximo	865,00	983,00
Soma	34550,00	38107,00
Contagem	80,00	80,00

Fonte: Autoria própria (2017).

Tabela 17 - Resultado da produção para o 4º rodada (em gramas)

Produção 4º Rodada											
	MFC	MFB		MFC	MFB		MFC	MFB		MFC	MFB
A1	382	391	B1	676	682	C1	882	895	D1	428	453
A2	636	644	B2	419	426	C2	893	904	D2	587	599
A3	336	347	B3	283	288	C3	499	513	D3	556	568
A4	339	348	B4	627	635	C4	456	464	D4	466	475
A5	333	344	B5	402	411	C5	688	700	D5	536	545
A6	363	369	B6	482	489	C6	438	446	D6	545	554
A7	556	564	B7	443	461	C7	344	348	D7	361	377
A8	413	421	B8	494	502	C8	745	756	D8	874	880
A9	410	418	B9	681	685	C9	936	950	D9	984	993
A10	529	534	B10	783	788	C10	879	891	D10	1048	1053
A11	578	586	B11	984	996	C11	1013	1026	D11	1256	1268
A12	692	699	B12	903	914	C12	781	798	D12	872	876
A13	727	735	B13	439	449	C13	854	866	D13	966	980
A14	245	251	B14	808	822	C14	734	749	D14	1056	1076
A15	467	476	B15	597	613	C15	703	716	D15	935	942
A16	578	586	B16	470	486	C16	633	647	D16	887	891
A17	214	226	B17	896	904	C17	459	471	D17	978	984
A18	343	348	B18	374	389	C18	569	583	D18	960	973
A19	598	606	B19	265	272	C19	799	810	D19	785	798
A20	515	523	B20	235	244	C20	788	797	D20	710	719

Fonte: Autoria própria (2017).

Tabela 18 - Análise descritiva do quarto plantio

	MFC	MFB
Média	629,98	640,08
Erro padrão	26,65	26,70
Mediana	592,00	602,50
Moda	556,00	348,00
Desvio padrão	238,34	238,82
Variância da amostra	56806,96	57036,32
Curtose	-0,78	-0,77
Assimetria	0,29	0,29
Intervalo	1042,00	1042,00
Mínimo	214,00	226,00
Máximo	1256,00	1268,00
Soma	50398,00	51206,00
Contagem	80,00	80,00

Fonte: Autoria própria (2017).

Tabela 19 - Resultado da produção para o 5° rodada (em gramas)

Produção 5° Rodada											
	MFC	MFB		MFC	MFB		MFC	MFB		MFC	MFB
A1	590	610	B1	598	645	C1	309	341	D1	530	621
A2	660	685	B2	594	681	C2	566	653	D2	450	528
A3	676	745	B3	740	805	C3	725	826	D3	405	490
A4	796	863	B4	800	898	C4	404	476	D4	380	473
A5	654	755	B5	884	1014	C5	496	573	D5	485	566
A6	758	801	B6	808	857	C6	523	604	D6	245	279
A7	668	700	B7	572	648	C7	345	407	D7	279	328
A8	559	592	B8	699	784	C8	391	462	D8	374	447
A9	598	645	B9	610	655	C9	462	543	D9	542	626
A10	431	480	B10	602	671	C10	744	851	D10	368	440
A11	627	688	B11	848	919	C11	662	727	D11	865	983
A12	531	578	B12	978	1056	C12	538	642	D12	706	775
A13	561	608	B13	677	755	C13	474	568	D13	456	544
A14	333	362	B14	827	906	C14	733	865	D14	495	521
A15	421	441	B15	706	805	C15	477	554	D15	462	491
A16	627	688	B16	698	779	C16	401	483	D16	845	911
A17	465	493	B17	565	663	C17	837	939	D17	701	724
A18	477	574	B18	491	565	C18	718	811	D18	585	646
A19	570	618	B19	318	387	C19	514	612	D19	558	609
A20	263	314	B20	374	452	C20	524	597	D20	623	757

Fonte: Autoria própria (2017).

Tabela 20 - Análise descritiva do quinto plantio

	MFC	MFB
Média	573,14	643,48
Erro padrão	18,17	19,27
Mediana	565,50	634,00
Moda	598,00	755,00
Desvio padrão	162,50	172,39
Variância da amostra	26407,54	29719,21
Curtose	-0,50	-0,38
Assimetria	0,16	0,17
Intervalo	733,00	777,00
Mínimo	245,00	279,00
Máximo	978,00	1056,00
Soma	45851,00	51478,00
Contagem	80,00	80,00

Fonte: Autoria própria (2017).

Tabela 21 - Resultado da produção para o 6° rodada (em gramas)

Produção 6° Rodada											
	MFC	MFB		MFC	MFB		MFC	MFB		MFC	MFB
A1	808	857	B1	882	895	C1	545	554	D1	808	857
A2	572	648	B2	893	904	C2	361	377	D2	572	648
A3	699	784	B3	499	513	C3	874	880	D3	699	784
A4	610	655	B4	456	464	C4	984	993	D4	610	655
A5	602	671	B5	688	700	C5	1048	1053	D5	602	671
A6	598	645	B6	428	453	C6	570	677	D6	566	637
A7	594	681	B7	587	599	C7	617	694	D7	615	723
A8	740	805	B8	556	568	C8	566	672	D8	671	775
A9	800	898	B9	466	475	C9	796	873	D9	579	654
A10	884	1014	B10	536	545	C10	564	625	D10	542	597
A11	482	489	B11	548	631	C11	613	661	D11	647	661
A12	443	461	B12	450	524	C12	483	545	D12	572	581
A13	494	502	B13	428	520	C13	731	809	D13	563	567
A14	681	685	B14	380	473	C14	654	787	D14	491	496
A15	783	788	B15	275	369	C15	489	554	D15	550	568
A16	482	489	B16	275	369	C16	627	688	D16	778	842
A17	514	563	B17	579	628	C17	531	578	D17	550	635
A18	546	608	B18	570	720	C18	561	608	D18	663	757
A19	569	601	B19	368	440	C19	333	362	D19	706	755
A20	434	505	B20	542	626	C20	421	441	D20	722	801

Fonte: Autoria própria (2017).

Tabela 22 - Análise descritiva do sexto plantio

	MFC	MFB
Média	595,19	648,25
Erro padrão	16,85	17,18
Mediana	571,00	641,00
Moda	572,00	857,00
Desvio padrão	150,74	153,63
Variância da amostra	22721,55	23602,62
Curtose	0,68	-0,10
Assimetria	0,57	0,41
Intervalo	773,00	691,00
Mínimo	275,00	362,00
Máximo	1048,00	1053,00
Soma	47615,00	51860,00
Contagem	80,00	80,00

Fonte: Autoria própria (2018).

Tabela 23 - Resultado da produção para o 7º rodada (em gramas)

Produção 7º Rodada											
	MFC	MFB		MFC	MFB		MFC	MFB		MFC	MFB
A1	673	687	B1	663	687	C1	715	730	D1	814	843
A2	1068	1104	B2	942	968	C2	684	701	D2	685	705
A3	980	1016	B3	775	795	C3	730	749	D3	780	804
A4	862	879	B4	822	841	C4	690	706	D4	813	835
A5	664	678	B5	988	1017	C5	805	824	D5	585	599
A6	755	777	B6	707	737	C6	827	850	D6	617	641
A7	594	601	B7	851	872	C7	929	946	D7	793	810
A8	877	891	B8	732	754	C8	805	814	D8	976	993
A9	516	533	B9	718	737	C9	914	932	D9	847	871
A10	983	1005	B10	924	945	C10	768	789	D10	660	673
A11	860	877	B11	845	872	C11	885	909	D11	556	571
A12	962	991	B12	623	634	C12	817	839	D12	615	621
A13	760	789	B13	848	864	C13	997	1031	D13	750	774
A14	785	811	B14	842	858	C14	797	822	D14	789	821
A15	750	772	B15	950	965	C15	759	779	D15	761	780
A16	979	1010	B16	910	928	C16	919	935	D16	701	730
A17	847	866	B17	808	830	C17	930	945	D17	901	937
A18	650	659	B18	634	650	C18	618	635	D18	528	551
A19	938	964	B19	780	803	C19	951	974	D19	724	747
A20	638	652	B20	870	889	C20	520	538	D20	606	620

Fonte: Autoria própria (2018).

Tabela 24 - Análise descritiva do sétimo plantio

	MFC	MFB
Média	786,68	807,28
Erro padrão	14,41	14,76
Mediana	791,00	812,50
Moda	750,00	687,00
Desvio padrão	128,87	132,01
Variância da amostra	16606,22	17427,44
Curtose	-0,68	-0,65
Assimetria	-0,12	-0,11
Intervalo	552,00	571,00
Mínimo	516,00	533,00
Máximo	1068,00	1104,00
Soma	62934,00	64582,00
Contagem	80,00	80,00

Fonte: Autoria própria (2018).

Quadro 2 - Algoritmo aplicado no experimento

Algoritmo de aprendizado do <i>aiNet</i> aplicado no experimento	
Parâmetros de entrada NrClones, NrClonesGerados, VlrN, VlrP, VlrK, VlrProduto, Beta, MinN, MinP, MinK, MaxN, MaxP, MaxK, TmPopulacao, LimiarAfinidade	
1.	Gerar adubação aleatória para criação de uma população inicial de igual tamanho de TmPopulacao.
2.	Obter NrClones dos melhores resultados de produção
2.1.	Para 1 até NrClones faça
2.1.1.	$F := QteA * VlrProduto - QteN * VlrN - QteP * VlrP - QteK * VlrK;$ FimPara
2.2.	Para 1 até NrClonesGerados faça
2.2.1.	Repita
2.2.1.1.	Repita
2.2.1.2.	$\alpha = (1 / \beta) \exp(-F *)$ $c' = c + \alpha N(0,1)$
2.2.1.3.	até que nutrienteN >-1 e nutriente < MaxN Repita
2.2.1.4.	$\alpha = (1 / \beta) \exp(-F *)$ $c' = c + \alpha N(0,1)$ até que nutrienteP >-1 e nutriente < MaxP Repita
2.2.1.4.	$\alpha = (1 / \beta) \exp(-F *)$ $c' = c + \alpha N(0,1)$ até que nutrienteK >-1 e nutriente < MaxK
2.2.2	AfinidadeCalculada
2.2.3	Até que AfilidadeCalculada <= LimiarAfinidade
2.3	FimPara

Fonte: Adaptado de De Castro e Timmis (2002).



Figura 31 - Tela Principal, Tela de Menu, Geração de recomendação
Fonte: Autoria própria (2018).

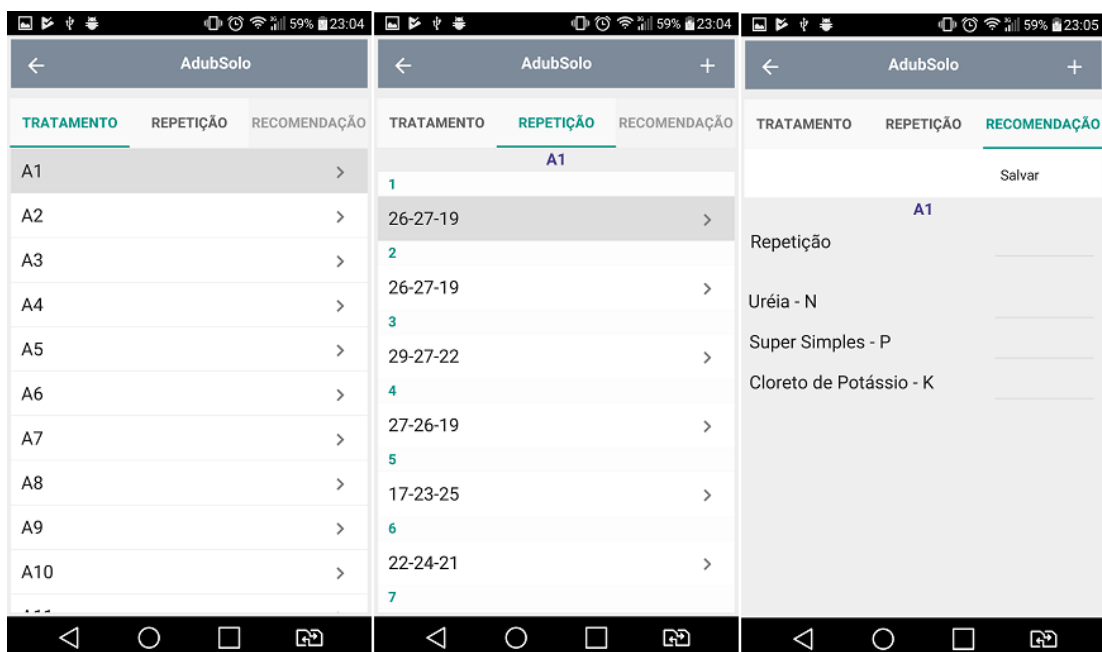


Figura 32 - Tela de Recomendação de Adubação
Fonte: Autoria própria (2018).

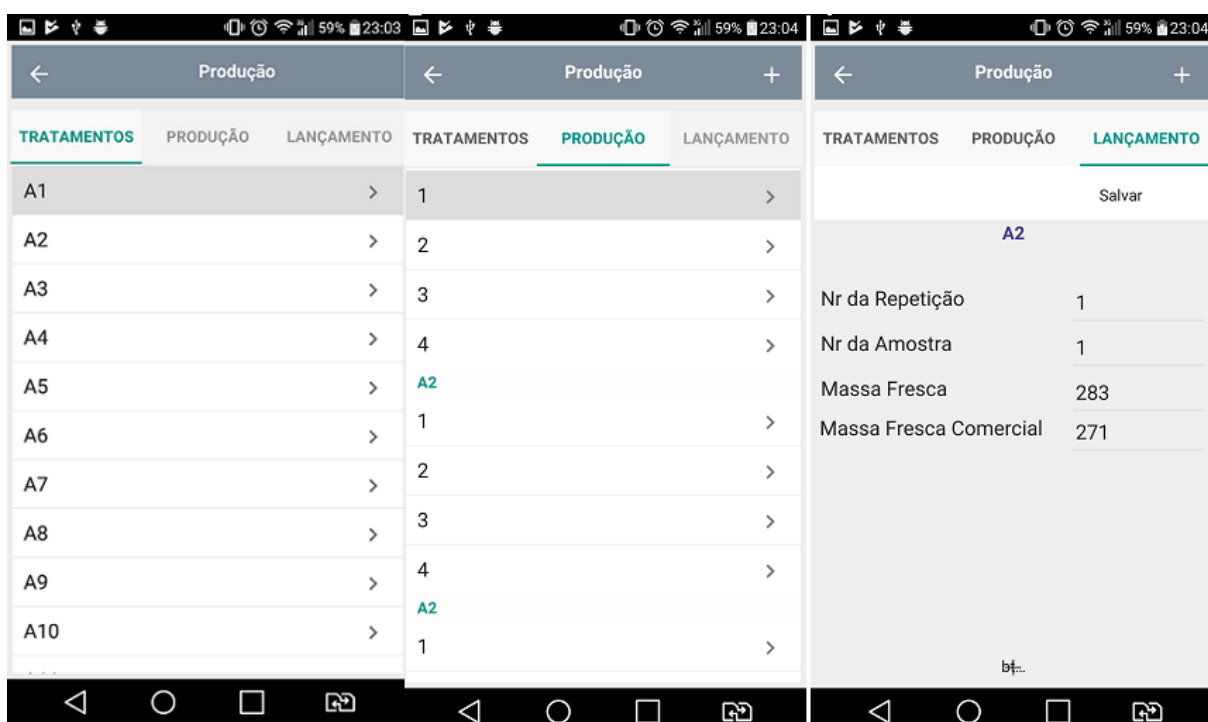


Figura 33 - Tela de lançamento de produção
Fonte: Autoria própria (2018).

ANEXO I

Nome:	Amostra 5	Município:	Palotina
Entidade:	Mestrado-luchese	Localidade:	Amostra Mestrado Vinicius
Nº Laboratório:	0	Nº Amostra:	5
		Local/Taihão:	0

Resultado da Análise de Rotina

Unidade	Elemento	Teor	Nível
	pH CaCl ₂	4,72	baixo
	pH H ₂ O	5,73	
cmol _c dm ⁻³	Alumínio (Al ³⁺)	0,00	baixo
	pH SMP	5,77	
cmol _c dm ⁻³	Acidez Potencial (H ⁺ + Al ³⁺)	5,87	
cmol _c dm ⁻³	Cálcio + Magnésio (Ca ²⁺ + Mg ²⁺)	4,10	
cmol _c dm ⁻³	Cálcio (Ca ²⁺)	2,70	médio
cmol _c dm ⁻³	Magnésio (Mg ²⁺)	1,40	alto
cmol _c dm ⁻³	Potássio (K ⁺)	0,71	alto
cmol _c dm ⁻³	Soma de Bases (SB)	4,81	
cmol _c dm ⁻³	Capacidade de Troca Catiônica (CTC)	10,68	
g dm ⁻³	Carbono Orgânico (C)	15,45	alto
g dm ⁻³	Matéria Orgânica (MO)	26,63	alto
mg dm ⁻³	Fósforo (P)	16,72	alto
%	Saturação por Bases (V%)	45,06	
mg dm ⁻³	Enchofre (S-SO ₄ ²⁻)	0	

Necessidade de Calagem (PRNT = 100%)	
V%	Calcário t ha ⁻¹
50	0,53
55	1,06
60	1,60
65	2,13
70	2,66
75	3,20
80	3,73
85	4,27

Participação na CTC		
Elemento	Teor	Ideal
Ca ²⁺	25,3	50-70%
Mg ²⁺	13,1	10-15%
K ⁺	6,7	3-5%
Al ³⁺	0,0	0%

Relações Nutricionais		
Relação	Valor	Ideal*
Ca ²⁺ /Mg ²⁺	1,93	2-5
Ca ²⁺ /K ⁺	3,78	4-16
Mg ²⁺ /K ⁺	1,96	2-4

* Valores considerados ideais dentro de uma faixa de V% de 40-70%

P, K (Mehlich-1)
Ca, Mg, Al (KCl 1 mol L⁻¹)
Carbono (Walkley-Black)
pH (CaCl₂ 0,01 mol L⁻¹)
H+Al (pH SMP)

Dr Augusto Vaghetti Luchese
Este laudo foi realizado para atender projetos de pesquisa e extensão
não devendo ser utilizado para finalidades comerciais

Palotina: 10 agosto, 2016

Laudo da análise de rotina de amostra de solo encaminhada pelo proprietário