

**UFRRJ**

**PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA,  
TECNOLOGIA E INOVAÇÃO EM AGROPECUÁRIA**

**TESE**

**Inteligência Artificial Aplicada na Otimização  
Hídrica para Culturas Agrícolas - OTIMAGRI**

**Manoel Villas Bôas Júnior**

**2023**



**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO  
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA, TECNOLOGIA E  
INOVAÇÃO EM AGROPECUÁRIA**

**INTELIGÊNCIA ARTIFICIAL APLICADA NA OTIMIZAÇÃO  
HÍDRICA PARA CULTURAS AGRÍCOLAS – OTIMAGRI**

**MANOEL VILLAS BÔAS JÚNIOR**

*Sob a Orientação do professor*

**Angel Ramon Sanchez Delgado**

*e Coorientação dos professores*

**Maria Cláudia Rodriguez**

**José Airton Chaves Cavalcante Junior**

Tese submetida como requisito parcial  
para obtenção do grau de **Doutor**, no  
Programa de Pós-graduação em  
Ciência, Tecnologia e Inovação em  
Agropecuária, área de concentração em  
Recursos Naturais e Meio Ambiente.

Seropédica, RJ  
Dezembro de 2023

Universidade Federal Rural do Rio de Janeiro  
Biblioteca Central/Seção de Processamento Técnico

Ficha catalográfica elaborada  
Com os dados fornecidos pelo(a) autor(a)

V484i

Villas Bôas Júnior, Manoel, 1963-  
Inteligência artificial aplicada na otimização hídrica para culturas agrícolas  
- OTIMAGRI/Manoel Villas Bôas Júnior. – Seropédica, 2023.  
67 f. : il.

Orientador: Angel Ramon Sanchez Delgado.  
Tese (Doutorado). – – Universidade Federal Rural do Rio de Janeiro,  
Programa de Pós-Graduação em Ciência, Tecnologia e Inovação em  
Agropecuária, 2023.

1. Agricultura 4.0. 2. Transformação digital. 3. Tecnologia agrícola. I. Delgado,  
Angel Ramon Sanchez, 1956. orient. II. Universidade Federal Rural do Rio de  
Janeiro. Programa de Pós-Graduação em Agronomia-Ciência do Solo. III.  
Título.

É permitida a cópia parcial ou total desta Tese, desde que seja citada a fonte.

**O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de  
Pessoal Nível Superior-Brasil (CAPES) - Código de Financiamento 001.**



**MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA, TECNOLOGIA E  
INOVAÇÃO EM AGROPECUÁRIA**



**HOMOLOGAÇÃO DE TESE DE DOUTORADO Nº 26 / 2023 - PPGCTIA (12.28.01.84)**

**Nº do Protocolo: 23083.083107/2023-11**

**Seropédica-RJ, 15 de dezembro de 2023.**

UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO  
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA, TECNOLOGIA E INOVAÇÃO EM  
AGROPECUÁRIA

**Manoel Villas Boas Junior**

Tese submetida como requisito parcial para obtenção do grau de Doutor, no Programa de Pós-Graduação em Ciência, Tecnologia e Inovação em Agropecuária, área de concentração em Recursos Naturais e Proteção Ambiental.

TESE APROVADA EM 15/12/2023

Angel Ramon Sanchez Delgado. Dr., UFRRJ  
(Orientador)

Edilberto Strauss. Dr., UFRJ

Alan Miranda Monteiro de Lima. Dr., UFRJ

Marinaldo Ferreira Pinto. Dr., UFRRJ

Carlos Andrés Reyna Vera-Tudela. Dr., UFRRJ

**(Assinado digitalmente em 15/12/2023 19:47 )**  
ANGEL RAMON SANCHEZ DELGADO  
PROFESSOR DO MAGISTERIO SUPERIOR  
DeptM (12.28.01.00.00.00.63)  
Matricula: 1219231

**(Assinado digitalmente em 15/12/2023 18:04 )**  
CARLOS ANDRES REYNA VERA TUDELA  
PROFESSOR DO MAGISTERIO SUPERIOR  
DeptM (12.28.01.00.00.00.63)  
Matricula: 2433643

**(Assinado digitalmente em 15/12/2023 19:51 )**  
MARINALDO FERREIRA PINTO  
COORDENADOR CURS/POS-GRADUACAO  
CoordCGEAA (12.28.01.00.00.00.00.35)  
Matricula: 2132414

**(Assinado digitalmente em 16/12/2023 21:24 )**  
ALAN MIRANDA MONTEIRO DE LIMA  
ASSINANTE EXTERNO  
CPF: 004.119.917-01

**(Assinado digitalmente em 18/12/2023 13:01 )**  
EDILBERTO STRAUSS  
ASSINANTE EXTERNO  
CPF: 899.386.667-87

Visualize o documento original em <https://sipac.ufrj.br/public/documentos/index.jsp> informando seu número: **26**, ano: **2023**, tipo: **HOMOLOGAÇÃO DE TESE DE DOUTORADO**, data de emissão: **15/12/2023** e o código de verificação: **4f8d71a896**

## DEDICATÓRIA

*Dedico este trabalho à:*

*Deus me brindou com um presente sem precedentes,  
Rejane, Esposa e Mulher Amada que sempre esteve ao meu lado.  
Um anjo que torna minha vida colorida e feliz,  
nas minhas diversas dificuldades e cansaço  
ela sempre me incentivando e animando, sendo a pessoa mais importante para o término  
deste trabalho.*

*Meus Pais e minha Irmã que muito lutaram por minha educação, tenho certeza de estarem  
felizes com essa conquista, tenho vocês eternamente em meu coração e em minha alma.*

*Ao pequeno e ao mesmo tempo imenso sentido de vida que meus netos oferecem e que me  
inspira a novos objetivos.*

*A minha filha que me proporcionou as imensas alegrias de ter simplesmente nascido, amo  
vocês.*

*A todos da minha família que torcem pelo meu crescimento intelectual e pessoal.*

*A minha sogra e ao meu sogro e toda a família por estarem sempre dispostos a incentivar o  
meu crescimento.*

## AGRADECIMENTOS

A *Deus*, que sempre esteve ao meu lado e que me carregou e carrega em seus braços em todos os vários momentos de tormenta.

Tive a sorte de no caminho percorrido pelo aprendizado, a vida ter me proporcionado conhecer pessoas magníficas, mestres em toda a extensão da palavra, que me guiaram de forma brilhante. Certa vez eu li que sempre devemos ter palavras que expressem o agradecimento sincero, procuro estas palavras para referenciar aos professores Roberto Schirru e Edilberto Strauss. Porém nenhuma delas expressa mais os sentimentos de agradecimento do que um “muito obrigado por tudo”.

Aos amigos Norberto Bellas e Cláudio Latta pelo suporte, frases sábias, ajudas e incentivos constantes.

Ao meu orientador o prof. Angel por toda ajuda recebida nestes anos.

Ao meu coorientador o prof. Airton que tenho a honra de considerar como um amigo, destes que a vida nos oferece por toda ajuda recebida nestes tantos anos.

A minha coorientadora professora Claudia Rodriguez que fez de tudo para uma boa estadia científica.

A todos os professores e funcionários do PPGCTIA que sempre se disponibilizaram a colaborar no que fosse preciso.

A UFRRJ que me acolheu.

Aos amigos diversos que não foram explicitados, mas que estão no coração.

A Los Hermanos Argentinos que yo conocí y mi fueran e son muy importantes.

*"O sucesso nasce do querer. Sempre que o homem aplicar a determinação e a persistência para um objetivo, ele vencerá os obstáculos e, se não atingir o alvo, pelo menos fará coisas admiráveis."*

José de Alencar.

## RESUMO

VILLAS BÔAS JUNIOR, Manoel. **Inteligência artificial aplicada na otimização hídrica para culturas agrícolas - OTIMAGRI**. 2023. 67 f. Tese (Doutorado em Ciência, Tecnologia e Inovação em Agropecuária) Pró-Reitoria de Pesquisa e Pós-Graduação, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2023.

Este trabalho apresenta um sistema de otimização inovador, baseado no algoritmo Otimização por Enxames de Partículas, do inglês *Particle Swarm Optimization* (PSO), projetado para aprimorar a eficiência da agricultura, com ênfase na minimização do consumo de recursos naturais e insumos, incluindo o uso eficiente da água. O principal objetivo é maximizar a receita líquida da produção agrícola, considerando recursos limitados. Uma característica deste sistema é a sua versatilidade, pois pode ser facilmente utilizado em smartphones, tornando-o acessível a um público mais amplo. Além disso, destaca-se pela sua rapidez na obtenção de resultados, tornando a tomada de decisões mais ágil e eficaz. O algoritmo PSO atua como a espinha dorsal deste sistema, permitindo encontrar o equilíbrio entre o consumo de insumos e o rendimento da colheita em culturas agrícolas. Os resultados obtidos foram comparados com dados da literatura, especialmente para culturas como alface americana e meloeiro, e demonstraram ser compatíveis ou, em alguns casos, superiores. Conclui-se que essa ferramenta não apenas oferece suporte confiável para a tomada de decisões econômicas na agricultura, mas também é acessível, rápida e facilmente adaptável a diferentes tipos de insumos e dispositivos móveis e a suporte a introdução rápida de novas funções de produções, independentemente do número de insumos a serem considerados.

**Palavras-chave:** Agricultura 4.0. Transformação digital. Tecnologia agrícola.



## ABSTRACT

VILLAS BÔAS JUNIOR, Manoel. **Artificial intelligence applied in water optimization for agricultural crops - OTIMAGRI**. 2023. 67 p. Thesis (Doctorate in Science, Technology and Innovation in Agriculture). Pró-reitoria de Pesquisa e Pós-Graduação, Universidade Federal Rural do Rio de Janeiro, Seropédica/RJ, 2023

This work presents an innovative optimization system, based on the Particle Swarm Optimization (PSO) algorithm, designed to improve agricultural efficiency, with an emphasis on minimizing the consumption of natural resources and inputs, including the use water efficiency. The main objective is to maximize net income from agricultural production, considering limited resources. A feature of this system is its versatility, as it can be easily used on smartphones, making it accessible to a wider audience. Furthermore, it stands out for its speed in obtaining results, making decision-making more agile and effective. The PSO algorithm acts as the backbone of this system, allowing it to find a balance between input consumption and harvest yield in agricultural crops. The results obtained were compared with data from the literature, especially for crops such as iceberg lettuce and melon, and were shown to be compatible or, in some cases, superior. It is concluded that this tool not only offers reliable support for economic decision-making in agriculture, but is also accessible, quickly and easily adaptable to different types of inputs and mobile devices and supports the rapid introduction of new production functions, regardless of the number of inputs to be considered.

**Key words:** Agriculture 4.0. Digital transformation. Agricultural technology.

## RESUMEN AMPLIADO

VILLAS BÔAS JUNIOR, Manoel. **Inteligencia artificial aplicada en la optimización del agua para cultivos agrícolas - OTIMAGRI**. 2023. 67 h. Tesis (Doctorado en Ciencia, Tecnología e Innovación en Agricultura) Pró-reitoria de Pesquisa e Pós-Graduação, Universidade Federal Rural do Rio de Janeiro, Seropédica/RJ, 2023.

### 1. Introducción

En las últimas décadas, la población mundial ha venido creciendo exponencialmente, lo que nos lleva a la necesidad de producir una mayor cantidad de alimentos y, en consecuencia, aumentar la demanda de recursos naturales, impactando principalmente el agua, pues sabemos que la agricultura, según la FAO, requiere el 70% del agua consumida.

Debido a su esencialidad para el mantenimiento de la vida en el planeta, dos preguntas urgen respuestas: (1) ¿Es posible que la Inteligencia Artificial pueda liderar una revolución agrícola en un momento en que el mundo debe producir más alimentos utilizando menos recursos naturales? y (2) ¿Bajo qué condiciones la Inteligencia Artificial puede cambiar el uso de los recursos naturales?

De esta forma, se debe tener conciencia de que existe un sistema interconectado donde las (n) variables que componen este sistema, influyen y son influidas por las demás. Por ejemplo, el crecimiento demográfico implica un aumento de la producción de alimentos que repercute en el aumento del consumo de agua, y éste en el aumento de la captación, alterando todo un ecosistema.

El desarrollo de tecnologías que ayuden a la planificación de la producción agrícola y a mitigación de los daños ambientales propios de estas actividades, ha despertado el interés de Brasil y Argentina, por el MERCOSUR. Para que el productor aumente o adquiera credibilidad financiera es necesario el asesoramiento técnico y tecnológico, por lo que el suministro de códigos informáticos de fácil acceso técnicas tecnológicas sólidas permitirá al productor adquirir medios para probar la eficacia y viabilidad, además de la técnica de producción de pruebas.

Cabe señalar que el modelo económico productivo en el que se inserta la producción agropecuaria impone la necesidad de obtener modos para mantener el funcionamiento de los agronegocios, y uno de los objetivos de los productores rurales es reducir los costos de producción. Uno de los desafíos es brindarle al productor información relevante para la producción de alimentos, con bajo costo y mínimo desperdicio y degradación de los recursos naturales.

Las funciones de producción expresan una relación funcional en la que demuestran la dependencia de la producción del consumo de agua e insumos. Las funciones de producción pueden ser modeladas matemáticamente y representadas por ecuaciones algebraicas que contemplan las diversas variables de interés que afectan el proceso de producción (suelo, clima, cultura, prácticas culturales). Estas funciones se determinan experimentalmente, con base en fundamentos teóricos y experimentos, y deben representar lo más fielmente posible las relaciones funcionales existentes entre los insumos utilizados y sus efectos en la obtención del resultado final.

Para ayudar a los productores a maximizar sus ganancias y minimizar el uso de insumos y recursos naturales, se desarrolló una aplicación de bajo costo, compuesta en su núcleo por una técnica de inteligencia artificial, denominada Particle Swarm Optimization (PSO), que es un algoritmo de optimización que permitirá ser aplicado a un determinado cultivo utilizando el modelo de una función de producción para los distintos parámetros de

interés, donde los datos se obtienen experimentalmente y otros se obtienen mediante el uso de técnicas matemáticas computacionales.

OTIMAGRI hace uso de técnicas de inteligencia artificial, que en la práctica utiliza un algoritmo que automáticamente realiza una modelación matemática, aprendiendo a describir el comportamiento de la función de producción de uno o varios cultivos, utilizando datos científicos empíricos o ecuaciones y de esta manera, computacionalmente encontrar el valor numérico que corresponde al óptimo de estas funciones en relación con la optimización de insumos (agua, o agua y nitrógeno), y junto con el óptimo de la curva de costes de producción.

## **2. Revisión de La Literatura**

### **2.1 Optimización**

En muchos problemas de optimización, que sean de importancia práctica o teórica, consisten en la búsqueda de la “mejor” configuración de un conjunto de variables para alcanzar determinados objetivos. Estos problemas se dividen en dos categorías: aquellos en los que las soluciones se codifican con variables de valor real (optimización continua), y aquellos en los que las soluciones se codifican con variables discretas (BLUM & ROLI, 2003). En el contexto de la segunda categoría mencionada, se forma la clase de problemas comúnmente llamada Combinatoria - Optimización Combinatoria (OC).

Es común que en los tipos de problemas de OC exista una función objetivo a optimizar y esta función puede considerarse minimizadora o maximizadora.

### **2.2 Inteligencia Artificial**

Por definición, podemos considerar que la IA es la capacidad de una máquina para percibir el entorno que la rodea, razonar, aprender de este entorno y actuar en función de lo aprendido. El caso es que ninguna de estas definiciones es universalmente aceptada, quizás por sus referencias a la palabra "inteligencia", que actualmente se considera abstracta e inconmensurable. En este contexto, la IA se puede definir como la simulación de la inteligencia humana en una máquina, con el fin de hacer que la máquina sea eficiente para identificar y utilizar el "conocimiento". Una máquina que es capaz de resolver un problema, planificar y ejecutar la tarea adecuada en el momento adecuado, se considera racional. Sin embargo, una pequeña reflexión revela que un sistema que puede razonar debe ser un planificador exitoso, ya que la planificación en muchas circunstancias es parte de un proceso de razonamiento. (KONAR, 2000).

#### **2.2.1 El renacimiento de la IA**

Si bien tenemos el concepto de inteligencia artificial formulado desde la década de 1950, su mayor limitación y lo que le impidió crecer y expandirse fue la capacidad de procesamiento de las máquinas disponibles en ese momento. A finales del siglo XX comenzamos a ampliar considerablemente esta capacidad, posibilitando así el procesamiento de grandes volúmenes de datos, lo que junto con la mejora de técnicas y aplicaciones más complejas, promovieron comercialmente su uso. Con la caída constante de los precios del hardware, lo que hace que la informática sea comercialmente barata, además de la capacidad adquirida para analizar grandes volúmenes de datos, lo que se suma al advenimiento de la Internet de las cosas (IoT), y el concepto de sistemas de aprendizaje, tenemos los ingredientes necesarios para unir la gestión de proyectos y la inteligencia artificial.

### **2.2.2 Técnicas de inteligencia artificial**

La observación de diversos fenómenos en la naturaleza es donde la inteligencia artificial normalmente basa sus paradigmas, de esta forma, existen diversas técnicas que se enmarcan en el área denominada Inteligencia Artificial. Un gran conjunto de estas técnicas pueden trabajar juntas, como los sistemas neurofuzzy, donde están involucradas las redes neuronales y la lógica difusa, en esta investigación utilizaremos el algoritmo Optimización del enjambre de partículas (PSO), el cual se inserta dentro de las diversas técnicas de Swarm Intelligence.

## **2.3 Metaheurísticas**

Souza (2005) describe que es ineficiente, o no aplicable, gran parte de las heurísticas para resolver problemas específicos para resolver un objetivo más amplio de problemas reales. La solución de problemas más complejos, a partir del conjunto de conceptos de las áreas de Optimización e IA, dio como resultado la construcción de metaheurísticas.

### **2.3.1 Complejidad computacional**

En complejidad computacional, existen clasificaciones para problemas de los más variados tipos. El área propone el estudio para analizar y categorizar los problemas según su complejidad a resolver, es decir, la cantidad de recursos computacionales necesarios, como tiempo y memoria, para llegar a la solución esperada.

### **2.3.2 - Inteligencia de enjambre**

Swarm Intelligence es una técnica computacional desarrollada a finales de la década de 1980. Según Von Zuben y Castro (2004), se basa en el comportamiento colectivo autoorganizado de sistemas descentralizados formados por un gran número de agentes, con el objetivo de realizar una determinada función. La Inteligencia de Enjambre se puede definir como la subárea de los Sistemas de Inteligencia Artificial donde el comportamiento colectivo de los individuos de una población puede obtener soluciones coherentes.

### **2.3.3 Enjambre de partículas (partícula enjambre optimización - PSO)**

Kennedy y Eberhart (1995), introducen el concepto de enjambre de partículas para la optimización de funciones continuas no lineales, y su base de modelado fue la simulación de grupos sociales simplificados. La basada en poblaciones es una técnica de optimización que, a través de la metáfora del comportamiento social y la interacción de bancos de peces o bandadas de pájaros, lleva a cabo su implementación. En el PSO se simula un enjambre de partículas candidatas a resolver un problema dado, donde en un espacio de búsqueda n-dimensional las partículas son atraídas por regiones de alto valor de adaptación Waintraub (2009).

## **2.4 Función de Producción**

De acuerdo con Frizzzone & Andrade Junior (2005), varios investigadores han desarrollado estudios sobre modelos matemáticos con el objetivo de expresar las funciones de producción de evapotranspiración-cultura. Según Flemming y Gonçalves (2007), para

demostrar las funciones de evapotranspiración-producción de cultura se debe entender uno de los conceptos más fundamentales de las matemáticas, la función matemática; que es básicamente la correspondencia entre conjuntos (FLEMMING y GONÇALVES, 2007).

### **3. Material y Métodos**

#### **3.1 Diferencias entre Aplicación Nativa e Híbrida**

Al planificar la creación de una aplicación, debemos pensar en qué tipo de aplicación se desarrollará, nativa o híbrida. La aplicación debe ofrecer una buena experiencia de usuario, y es necesario analizar qué tipo de desarrollo cubrirá estas necesidades. Sin embargo, las dos opciones tienen diferentes tiempos de desarrollo según el objetivo y el costo. OTIMAGRI fue desarrollado utilizando el lenguaje de desarrollo de tecnología híbrida.

#### **3.2 Equipo Utilizado**

Para el desarrollo del prototipo se utilizó como equipo una computadora MacBook Pro (Retina, 13 pulgadas, Principios de 2015), con procesador Intel Core i5 Dual-Core de 2.9 GHz, 8 GB de RAM DDR3 de 1867 MHz, gráficos Intel Iris Graphics. 6100 1536 MB y macOS Monterey 12.5.1, sistema operativo de 64 bits.

Las pruebas se realizaron en un smartphone moto g10, con 64 GB de almacenamiento y sistema operativo Android.

#### **3.3 Software Desarrollado**

Dado que la administración de actividades agropecuarias requiere de conocimientos técnicos, financieros y de optimización en sus procesos y toma de decisiones, la finalidad como resultado de la innovación tecnológica es involucrarse en la toma de decisiones agropecuarias en las que el objetivo como resultado de la innovación tecnológica es participar en la toma de decisiones agropecuarias en las que el análisis económico y el uso racional de los recursos disponibles son fundamentales.

La aplicación fue desarrollada en lenguaje Xamarin y disponible para teléfonos celulares con el sistema operativo que atiende a la mayor parte del mercado de smartphones: Android de Google y IOS de Apple.

#### **3.4 Modelo PSO**

El modelo PSO, adoptado para ser implementado en el problema de optimización de los ingresos netos de una cultura, corresponde al modelo básico del algoritmo PSO. Cada individuo PSO consta de un vector de 2 posiciones (primera posición correspondiente al agua y la segunda posición correspondiente al nitrógeno), cada posición individual está representada por un valor real, que representa el rango de variables.

### **4. Resultados y Discusión**

Con los resultados obtenidos comprobamos que el modelo OTIMAGRI obtiene resultados con valores del mismo orden de magnitud y mejores que los modelos utilizados para la comparación. El uso de OTIMAGRI tiene ventajas adicionales frente a los modelos anteriores, como el hecho de que el resultado se obtiene en un tiempo muy breve, aproximadamente 6 segundos. El equipo se encuentra fácilmente en el mercado, lo que facilita

el acceso de los usuarios. OTIMAGRI puede trabajar con funciones de producción que no tienen simplemente la forma de paraboloide, pudiendo trabajar con funciones que presentan discontinuidades sin sobrecargar el tiempo, además de trabajar con un número de variables  $n$  - dimensionales sin aumentar su complejidad.

#### **4.1 Optimización de la Producción de Lechuga Americana en dos Dimensiones**

Para maximizar los ingresos netos en la producción de lechuga americana, OTIMAGRI obtuvo valores compatibles e incluso superiores, demostrando la eficiencia del algoritmo. OTIMAGRI obtuvo un valor de productividad máxima de 26.902,71 kg. ha<sup>-1</sup> con 204,35 mm de agua y 239,97 kg. ha<sup>-1</sup> de nitrógeno. Los resultados son compatibles con los obtenidos por Silva (2005), donde se registró una productividad de 26.959,93 kg. ha<sup>-1</sup> con 205,26 mm de agua y 257,14 kg. ha<sup>-1</sup> de nitrógeno.

#### **4.2 Optimización de la Producción de Melón en dos Dimensiones**

Con el objetivo de maximizar el ingreso neto en la producción del cultivo de melón, OTIMAGRI obtuvo valores compatibles e incluso superiores, demostrando la eficiencia del algoritmo. OTIMAGRI obtuvo un valor máximo de productividad de 25.496,08 ha<sup>-1</sup> y una renta neta de R\$ 3.308,46, con 612,12 mm.ha<sup>-1</sup> de agua y 224,44 kg.ha<sup>-1</sup> de nitrógeno. Los resultados también son compatibles con los obtenidos por Monteiro et al. (2008), donde se registró una productividad de 25.384,30 kg. ha<sup>-1</sup> y una renta neta de R\$ 3.353,25 con 609,20 mm de agua y 186,23 kg. ha<sup>-1</sup> de nitrógeno.

### **5. Conclusiones**

Cuando hay asignación de recursos limitados, OTIMAGRI proporciona métodos eficientes que ayudan a optimizar los recursos y la producción. El sistema ayudará a aumentar la productividad, utilizar el agua de forma eficiente y reducir los costes de producción, maximizando así los beneficios de las inversiones en agricultura de regadío. OTIMAGRI todavía se puede usar fácilmente en diferentes tipos de cultivos, además de ser fácilmente manipulable con funciones complejas con  $n$ -dimensiones.

El algoritmo PSO abrirá nuevos enfoques que podrían llevar a los investigadores agrícolas a usarlos más masivamente y como una fuente alternativa, generando incentivos para realizar más experimentos que busquen no solo el agua y el nitrógeno, sino varios otros factores que influyen en la cultura, debido a su facilidad para analizar muchas dimensiones. Los resultados obtenidos demuestran que el sistema cumplió con los objetivos propuestos, indicando que esta herramienta computacional inteligente puede ser utilizada para optimizar el uso de los recursos hídricos e insumos con un incremento en el ingreso neto, habiendo sido probado y validado mediante comparación con los trabajos de Silva (2005), de Monteiro et al (2008), de Delgado et al (2010), de Cavalcante Junior (2013) y Villas Bôas Junior et al (2023) en la optimización de cultivos de lechuga americana y melón.

**Palabras clave:** Agricultura 4.0. Transformación digital. Tecnología agrícola.

## LISTA DE ABREVIACÕES E SIGLAS

ANA	Agência Nacional de Águas
Capes	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
CCTCI	(Câm. Deputados) - Comissão de Ciência, Tecnologia, Comunicação e Informática
CGEE	Centro de Gestão e Estudos Estratégicos
CCT/MCT	Conselho Nacional de Ciência e Tecnologia
CNPq	Conselho Nacional de Desenvolvimento Científico e Tecnológico
C, T&I	Ciência, tecnologia e inovação
Dieese	Departamento Intersindical de Estatísticas e Estudos Socioeconômicos
Embrapa	Empresa Brasileira de Pesquisa Agropecuária
IBM	International Business Machines Corporation
FAO	Food and Agriculture Organization of the United Nations (Organização das Nações Unidas para tratar de assuntos relativos à agricultura e alimentação)
Finep	Financiadora de Estudos e Projetos
GPS	Global Positioning System
IHM	Interface Homem-Máquina
IPCC	Painel Intergovernamental sobre Mudanças Climáticas
MCT	Ministério da Ciência e Tecnologia
MEC	Ministério da Educação
MMA	Ministério do Meio Ambiente
OCDE	Organização para Cooperação e Desenvolvimento Econômico
ONU	Organização das Nações Unidas
PNUMA	Programa das Nações Unidas para o Meio Ambiente
ppm	partes por milhão
RB	Receita bruta
PSO	Particle Swarm Optimization
SSPA	Sistema Solo, Planta e Atmosfera
UFRRJ	Universidade Federal Rural do Rio de Janeiro
Unesco	United Nations Educational, Scientific and Cultural Organization
UNRC	Universidad Nacional de Rio Cuarto

## LISTA DE FIGURAS

<b>Figura 1.</b> Quantidades de água no planeta. Fonte: Reichardt & Timm, 2008. Adaptado por Villas Bôas Junior em 2022.....	3
<b>Figura 2.</b> Funções de custo, receita bruta e ponto de equilíbrio. Fonte: Frizzzone, 2005.....	6
<b>Figura 3.</b> Intervalo para o manejo racional. Fonte: Frizzzone, 2007. ....	7
<b>Figura 4.</b> Representação gráfica tridimensional de soluções ótimas globais. Fonte: <a href="http://www.esteco.com/robust_design.jsp">http://www.esteco.com/robust_design.jsp</a> . Acesso em 2020.....	8
<b>Figura 5.</b> Renascimento da IA no século XXI. Fonte: Villas Bôas Junior, 2021.....	11
<b>Figura 6.</b> Classificação da inteligência artificial. Fonte: Villas Bôas Junior, 2021.....	12
<b>Figura 7.</b> Áreas da inteligência artificial. Fonte: Villas Bôas Junior, 2021.....	13
<b>Figura 8.</b> Aves voando "alinhadas" em busca de alimento. Fonte: Villas Bôas Junior, 2021. ....	17
<b>Figura 9.</b> Atualização de uma partícula. Fonte: Villas Bôas Junior, 2021. ....	17
<b>Figura 10.</b> PSO - Reflexão de uma partícula nas bordas do espaço de busca. Fonte: Villas Bôas Junior, 2021. ....	19
<b>Figura 11.</b> Pseudocódigo genérico do PSO. Fonte: Villas Bôas Junior, 2021. ....	20
<b>Figura 12.</b> Convergência exemplo do PSO. Fonte: Villas Bôas Junior, 2021.....	21
<b>Figura 13.</b> Relação entre conjuntos X e Y. Fonte: Demana, 2009. ....	22
<b>Figura 14.</b> Gráfico de uma função contínua genérica. Fonte: Villas Bôas Junior, 2021.....	22
<b>Figura 15.</b> Funções de custo, receita bruta e ponto de equilíbrio. Fonte: Frizzzone, 2005.....	27
<b>Figura 16.</b> Intervalo para o manejo racional. Fonte: Frizzzone, 2007. ....	30
<b>Figura 17.</b> Custos, receita bruta e receita líquida para a produção do feijoeiro. Fonte: Frizzzone, 2007. ....	32
<b>Figura 18.</b> Diagrama do OTIMAGRI. Fonte: Villas Bôas Junior, 2021. ....	36
<b>Figura 19.</b> Interface OTIMAGRI. Fonte: Villas Bôas Junior, 2021.....	41
<b>Figura 20.</b> Convergência PSO (alface americana). Fonte: Villas Bôas Junior, 2023.....	44
<b>Figura 21.</b> Convergência PSO (meloeiro). Fonte: Villas Bôas Junior, 2023. ....	45
<b>Figura 22.</b> Resultado do PSO com 500 partículas para a alface americana. Fonte: Villas Bôas Junior, 2023. ....	46
<b>Figura 23.</b> Resultado do PSO com 500 partículas para o meloeiro. Fonte: Villas Bôas Junior, 2023. ....	47



## LISTA DE TABELAS

<b>Tabela 1.</b> Resultado exemplo do PSO. ....	20
<b>Tabela 2.</b> Comparativo entre métodos para a alface americana. ....	43
<b>Tabela 3.</b> Comparativo entre métodos para o meloeiro. ....	44
<b>Tabela 4.</b> Comparativo entre métodos para a alface americana. ....	48
<b>Tabela 5.</b> Comparativo entre métodos para o meloeiro. ....	48

## SUMÁRIO

1. INTRODUÇÃO.....	1
2. REVISÃO DE LITERATURA .....	3
2.1 A Questão Hídrica e a Produtividade Agrícola .....	3
2.2 Otimização .....	7
2.3 Inteligência Artificial .....	9
2.3.1 O renascimento da IA .....	10
2.3.2 Técnicas da inteligência artificial.....	13
2.4 Metaheurística.....	14
2.4.1 Complexidade computacional .....	14
2.4.2 Inteligência de enxames .....	15
2.4.3 Enxame de partículas (particle swarm optimization - PSO) .....	16
2.5 Função de Produção .....	21
2.6 Conceitos Econômicos.....	26
2.7 Agricultura 4.0 .....	33
2.8 Desenvolvimento Nativo e Híbrido .....	33
3. MATERIAL E MÉTODOS.....	35
3.1 Descrição da Solução .....	35
3.2 Equipamento Utilizado .....	35
3.3 Software Desenvolvido.....	35
3.4 Modelagem do Aplicativo .....	36
3.5 Interface do Aplicativo .....	39
3.6 Configuração dos Testes do Modelo PSO .....	41
4. RESULTADOS E DISCUSSÃO .....	43
4.1 Otimização da Produção de Alface Americana a Duas Dimensões com 100 Partículas .....	43
4.2 Otimização da Produção do Meloeiro a Duas Dimensões com 100 Partículas .....	44
4.3 Otimização da Produção de Alface Americana a Duas Dimensões com 500 Partículas .....	45
4.4 Otimização da Produção do Meloeiro a Duas Dimensões com 500 Partículas .....	46
4.5 Algoritmo Evolutivo de Aprendizado Incremental Baseado em População (PBIL) .....	47
4.6 Considerações dos Testes .....	48
5. CONCLUSÕES .....	49
6. CONSIDERAÇÕES FINAIS .....	50
7. REFERÊNCIAS BIBLIOGRÁFICAS .....	51
8. ANEXOS .....	55

## 1. INTRODUÇÃO

Nas últimas décadas a população mundial vem crescendo o que nos leva a necessidade de se produzir uma quantidade maior de alimentos e, conseqüentemente, aumentando a demanda dos recursos naturais impactando principalmente o hídrico, pois a agricultura, segundo a Food and Agriculture Organization (FAO), exige 70% da água consumida.

Dada a sua vital importância para a sustentação da vida no planeta, surge a hipótese que a implementação da tecnologia de Inteligência Artificial pode servir como uma ferramenta e recurso valiosos, contribuindo para a redução do consumo de recursos naturais e o aumento da produtividade em culturas agrícolas.

Todo um ecossistema vem sendo alterado devido a este aumento da produção agrícola que pode impactar fortemente na degradação dos solos em especial na água, seja pelo manejo inadequado ou poluição da mesma pelo excesso do uso de fertilizantes e agrotóxicos que altera e desequilibra o ecossistema, aumentando a intranquilidade mundial pela segurança alimentar.

A FAO – Food and Agriculture Organization of the United Nations, instituições oficiais de governos e diversas instituições internacionais, há tempo discutem sobre o tema acerca da produção de alimentos e através de estimativas e previsões, demonstram uma grande preocupação sobre o assunto. Atualmente o Brasil é considerado uma potência mundial em termos de produção de alimentos e como tal deve manter sua luta contra a significativa desigualdade alimentar entre as nações. O desperdício na produção, transporte, armazenamento, e consumo de alimentos também estão associados a fatores relevantes.

O desenvolvimento de tecnologias que auxiliam o planejamento da produção agropecuária e a mitigação de danos ambientais que são próprios destas atividades, tem despertado o interesse do Brasil e da Argentina, através do MERCOSUL. Para que o produtor eleve ou adquira credibilidade financeira se torna necessário um assessoramento técnico e tecnológico, então o fornecimento de códigos computacionais com facilidade de acesso e técnicas eficientes de otimização, irão permitir que o produtor adquira meios para comprovar a eficácia e viabilidade, além da comprovação técnica da produção.

Foi desenvolvido um software com uma interface de uso simples para minimizar as exigências do conhecimento técnico sobre o sistema. O agricultor poderá adicionar uma função de produção e obter a minimização dos insumos relacionados a esta função. Assim se o agricultor usar a quantidade recomendada irá reduzir o desperdício pelo fato de usar o recurso na dose certa, reduzindo o custo de utilização de água, além de minimizar os impactos negativos para o meio ambiente e custos de manutenção dos sistemas de irrigação, energia (elétrica ou combustível fóssil) e mão de obra pela redução do ciclo de trabalho dos sistemas de bombeamento e através do aumento da produção sem aumento dos custos, gerando uma maior receita.

O OTIMAGRI faz uso de técnicas de inteligência artificial, que na prática se utiliza de um algoritmo que faz uma modelagem matemática de forma automática aprendendo a descrever o comportamento da função de produção de uma ou diversas culturas, se utilizando de dados científicos empíricos ou equações e desta forma encontrando computacionalmente o valor numérico que corresponde ao ótimo dessas funções em relação à otimização de insumos (água, ou água e nitrogênio), e em conjunto com o ótimo da curva de custos de produção.

Aprimorar a compreensão e o aprendizado das interações entre o Sistema Solo, Planta e Atmosfera (SSPA) foi crucial para o desenvolvimento do sistema. À medida que aprofundamos esse conhecimento, percebemos que não era essencial conduzir experimentos em campo. Optamos, ao invés disso, por empregar dados amplamente reconhecidos na

literatura, previamente avaliados por especialistas, para obter resultados comparáveis. Essa abordagem eliminou a necessidade de dedicar tempo a experimentos no campo, permitindo que o modelo computacional fosse desenvolvido, refinado e testado com base em informações já consolidadas na literatura e nas orientações recebidas.

Como este projeto é intrinsecamente multidisciplinar, pois possui seu foco no Sistema Solo, Planta e Atmosfera - SSPA, esperamos a continuidade da pesquisa incluindo parcerias acadêmicas em prol da colaboração e formação de grupos com o mesmo interesse comum, em especial a Argentina, onde foi estabelecida esta parceria entre pesquisadores.

Em especial ao produtor agrícola e a população, o trabalho aborda uma ampliação da conscientização quanto a um melhor uso do mais precioso recurso natural – a água. A pretensão do trabalho é propor uma melhor utilização dos recursos naturais de modo a favorecer a produção agrícola, tornando-a mais eficiente e sustentável, ocasionando uma redução dos seus custos operacionais e, conseqüentemente, um maior lucro em suas atividades.

Futuramente, se vislumbra a continuidade da pesquisa, com a proposição de novos modelos matemáticos, devido à obtenção do melhor conhecimento sobre o problema e o aumento da eficiência das irrigações, tendo como consequência a produção de um crescimento na produtividade com o uso racional da água.

Dada a multidisciplinariedade do tema a continuação da pesquisa irá propiciar a formação de grupos de trabalho e estudo multidisciplinares e binacionais com interesses comuns, desta forma fortalecendo a área com impactos na produção científica em revistas especializadas e eventos, inclusive com a colaboração e envolvimento dos parceiros de outros países.

O trinômio Ciência, Tecnologia e Inovação em agropecuária está anexado a nossa abordagem e dada a complexidade do objeto de estudo, ainda não existe uma solução com plena utilização no mercado, ou seja, uma ferramenta computacional que conjugue e resolva com sucesso o problema da quantificação de água e insumos a ser utilizada nas culturas.

Dentro do domínio do problema que nos propomos a estudar, tivemos que recorrer ao diálogo com diversas áreas do saber, dado o caráter inerentemente multidisciplinar da investigação. A literatura pesquisada é muito vasta, existindo uma grande quantidade de informações apontando linhas de pesquisa em várias áreas.


Nos próximos capítulos discorreremos mais detalhadamente sobre estas questões, com base na literatura utilizada, bem como sobre a abordagem matemática/computacional realizada. No capítulo 2 falaremos sobre os conceitos de inteligência artificial, algumas das áreas que compõem a inteligência artificial e as técnicas artificiais que utilizamos para o desenvolvimento do sistema OTIMAGRI, no capítulo 3 será demonstrada a solução proposta para a resolução do problema, no capítulo 4 os resultados obtidos e as considerações comparativas com outros sistemas e finalizando no capítulo 5 com a nossa conclusão e considerações finais.

## 2. REVISÃO DE LITERATURA

Para compreender o OTIMAGRI, apresentamos os conceitos base das técnicas de inteligência artificial que são o cerne do sistema, discorrendo brevemente sobre inteligência artificial, o conceito de inteligência de enxames e o algoritmo de otimização por enxame de partículas, o processo em relação à otimização e função de produção.

### 2.1 A Questão Hídrica e a Produtividade Agrícola

Reichardt & Timm (2008) destacam que as reservas de água disponíveis em nosso planeta são limitadas, conforme ilustrado na Figura 1. Apenas 0,3% desse recurso se encontra prontamente disponível para consumo imediato, e a agricultura absorve uma grande parcela desse consumo.



**Figura 1.** Quantidades de água no planeta. Fonte: Reichardt & Timm, 2008. Adaptado por Villas Bôas Junior em 2022.

Quarenta por cento da população mundial é afetada pela escassez de água e as Nações Unidas e o Banco Mundial estimam que 700 milhões de pessoas correm o risco de se deslocarem até 2030, diversos observadores se preocupam com o que pode vir a acontecer. Segundo Van Der Heijden (2015), “Se não há água, os políticos vão tentar controlar esse recurso e é possível que comecem a brigar por ele”.

O uso mundial de água cresceu de forma avassaladora, por isso devemos nos conscientizar sobre a questão da água e sua utilização racional<sup>1</sup>. Ao longo do século 20, tivemos mais que o dobro da taxa de crescimento populacional. Este desafio está levando várias regiões do mundo, como as cidades de Roma, Cidade do Cabo, Lima e diversos municípios no Brasil, a implementar medidas de racionamento de água.

Dentre os cinco principais desafios globais, a crise hídrica tem consistentemente se destacado na lista de Riscos Globais por Impacto do Fórum Econômico Mundial desde o ano de 2012.

Em 2017, por volta de 20 milhões de pessoas no Oriente Médio e na África se viram obrigadas a abandonar suas casas por causa da escassez de alimentos e os conflitos envolvendo acesso a água. As secas severas neste ano de 2017 proporcionaram a pior crise humanitária desde a Segunda Guerra Mundial.

<sup>1</sup> Com o objetivo de conscientizar para o melhor uso da água o uso racional ou manejo racional é uma política e que pode exigir mudanças culturais da população.

Informações do Pacific Institute, demonstram que a maior parte dos conflitos são relacionados à agricultura. A agricultura representa 70% do uso da água doce do planeta e talvez por isso não seja surpreendente que os conflitos estejam relacionados a ela.

Desta forma, deve haver uma conscientização de que existe um sistema interligado onde as N variáveis que compõem este sistema, influenciam e sofrem influências das demais. Por exemplo, o crescimento populacional implica em um aumento na produção de alimentos que impacta no aumento do consumo de água, e este no aumento da captação, alterando todo um ecossistema.

De acordo com Cavalcante Junior:

É indiscutível a importância da agricultura para o homem, mas sua atividade gera efeitos colaterais indesejáveis que causam vários problemas de cunho ambiental e social. Dentre estes nos preocupamos em especial com os problemas associados ao crescimento da população, à crescente demanda de água para consumo e secundariamente para este trabalho, mas não menos importante à poluição dos recursos hídricos. Esses problemas, dada sua atualidade e amplificação nos últimos anos, apontam para a necessidade de uma resposta efetiva que mitigue seus impactos nocivos, e esclareça a população, e em especial, as autoridades.

Para alcançar estes objetivos, a sensibilização da população e dos governos quanto aos problemas ambientais, cada vez mais ampliados, são o primeiro passo para uma efetiva conscientização, que favoreça a proposição e implementação de políticas públicas, de âmbito local, regional, nacional e mundial, com impactos no uso da água e da energia, de forma racional e consciente, com efeitos positivos na economia em geral e na produção agrícola em particular. Acreditamos que o incentivo às pesquisas no campo da ciência, tecnologia e inovação no que tange a otimização dos recursos hídricos é, portanto, de suma importância. (CAVALCANTE JUNIOR, 2013).

Deve-se salientar que o modelo de produção econômica em que está inserida a produção agrícola, impõe a necessidade de que o lucro seja obtido para manter o funcionamento do agronegócio, e um dos objetivos dos produtores rurais é a redução dos custos da produção. Um dos desafios é suprir o produtor com informações relevantes para a produção de alimentos, com baixo custo e o mínimo de desperdício e degradação de recursos naturais.

De acordo com Cavalcante Junior (2013), verifica-se atualmente que embora os agricultores, em sua grande maioria, apesar do vasto conhecimento empírico que possuem, que muitas vezes são aprimorados ao longo de gerações dedicadas ao cultivo da terra, não dispõem de conhecimentos técnicos mais avançados que lhes permitam mensurar matematicamente o consumo necessário e sem desperdício de água para o desenvolvimento de uma cultura específica ou de várias culturas diversificadas.

Os principais custos do agronegócio derivam de gastos com fertilizantes, eletricidade e uso da água para a irrigação. Ao se utilizar da melhor maneira possível estes e outros insumos, haverá a diminuição dos custos e a utilização apenas da quantidade necessária de cada elemento no processo (CAVALCANTE JUNIOR, 2013).

A produção de culturas agrícolas é dependente de diversos fatores que afetam o processo produtivo tais como: solo, clima, cultura, tratamentos culturais, irrigação e insumos. Para determinar estratégias ótimas de produção, diversos estudos são realizados visando as relações entre a produção dos cultivos e esses fatores por meio de funções de produção que representem a dependência da quantidade de produção de uma determinada cultura em função de uma determinada combinação desses fatores.

No entanto, apenas alguns desses fatores podem ser controlados pelos responsáveis do processo de produção. A otimização dos processos de produção vegetal na agropecuária depende em grande parte da maior ou menor disponibilidade da água e insumos. Assim as funções de produção levam apenas em conta as variáveis de controle sobre as quais podem agir, tais como: irrigação, insumos e implementos agrícolas para as plantas. Estudos realizados procuram determinar as relações entre a produção dos cultivos e os insumos por meio de funções de produção que visam representar a produtividade de uma determinada cultura em função de uma determinada combinação de insumos.

A função de produção desempenha um papel na identificação da eficiência do uso dos recursos no processo produtivo, permitindo discernir entre unidades produtivas eficazes e ineficazes. Dessa forma, é possível descobrir as práticas mais vantajosas e eficazes na utilização dos recursos tecnológicos disponíveis. Essa ferramenta é amplamente aplicada na análise de diversas atividades produtivas, abrangendo desde as práticas primárias até o aprimoramento dos processos de conversão de insumos em produtos acabados, tanto em setores agrícolas quanto industriais. De acordo com Piacenti (2012), estar na vanguarda da eficiência implica que uma unidade organizacional está adotando as melhores práticas dentre todas as unidades, ou seja, está otimizando a utilização de seus recursos para gerar resultados.

As funções de produção, podem ser modeladas matematicamente e serem representadas por equações algébricas contemplando as diversas variáveis de interesse, e que afetam o processo produtivo (solo, clima, cultura, tratos culturais). Essas funções são determinadas experimentalmente, com base em fundamentos teóricos e em experimentos, devendo representar o mais aproximadamente possível as relações funcionais existentes entre os insumos utilizados e os seus efeitos na obtenção do resultado final.

Essas funções podem adotar diversas formas, com algumas das mais comuns incluindo funções quadráticas unidimensionais, funções polinomiais de uma variável, funções quadráticas multidimensionais para culturas que envolvem vários fatores de produção, e funções polinomiais de diferentes graus utilizadas para estimar funções de produção na agricultura irrigada. Essa diversificação de abordagens é justificada pela importância primordial da água como variável, embora outros fatores, como nitrogênio, fósforo e potássio, também desempenhem papéis significativos. Lidar com todas essas variáveis em uma única equação resultaria em uma complexidade para obtenção da formulação e aplicação da função.

Nas práticas voltadas para a gestão dos recursos ambientais, certos elementos desempenham um papel crucial no desenvolvimento das culturas. Entre eles, a água e o nitrogênio são frequentemente destacados, sendo correlacionados com a produção através da função de produção água-nitrogênio-cultura. Se conseguíssemos calcular com precisão essas funções, teríamos a capacidade de determinar com exatidão os níveis ideais de água e nitrogênio para situações específicas. Contudo, diversos fatores, como flutuações climáticas, características físicas do solo e variados insumos, complicam a previsão da produtividade das culturas.


Na literatura, os sistemas matemáticos geralmente operam em duas dimensões, uma vez que calcular funções com pontos de descontinuidade ou quebras pode ser desafiador, especialmente quando esses eventos ocorrem nos pontos ótimos da função. A abordagem matemática clássica utiliza derivadas para identificar os pontos de ótimo (máximos ou mínimos). Entretanto, funções que apresentam comportamentos problemáticos, como descontinuidades ou quebras, tornam difícil a localização desses pontos. Em tais situações, outras técnicas podem ser mais apropriadas, como as técnicas de Inteligência Artificial (IA).

Neste trabalho, devido a essa complexidade, optou-se por empregar um modelo que utiliza o algoritmo de Otimização por Enxame de Partículas (PSO). Essa escolha permite contornar as limitações associadas à presença de descontinuidades, proporcionando uma abordagem mais eficaz. Além disso, o PSO apresenta a vantagem de ser multidimensional, o

que significa que pode lidar com diversas variáveis, como outros insumos agrícolas, que são de interesse para o produtor. Isso amplia a aplicabilidade do modelo, tornando-o mais robusto e capaz de enfrentar desafios complexos encontrados em cenários agrícolas.

Muito em decorrência das pressões econômicas sobre os agricultores, haverá uma mudança fundamental nas práticas da irrigação nos próximos anos, sendo crescente a competição pelo uso dos recursos e dos impactos ambientais da irrigação. Estes fatores deverão motivar uma mudança do paradigma da irrigação, dando um maior enfoque na eficiência econômica, ao invés da demanda de água das culturas, como peça fundamental para uma agricultura sustentável, (FIGUEIREDO, 2008).

Na Figura 2 podemos visualizar de forma conjunta a função de produção, a reta de custos fixos e o ponto de máximo lucro, os quais são os objetivos da otimização.




**Figura 2.** Funções de custo, receita bruta e ponto de equilíbrio. Fonte: Frizzzone, 2005.

Sendo assim, o objetivo principal é o desenvolvimento de uma ferramenta computacional que efetue o cálculo de forma otimizada às alternativas de produção disponíveis e permita a interação de forma fácil, para que o agricultor escolha, dentre as alternativas de produção disponíveis, a mais eficiente na utilização dos recursos produtivos. Nestas situações em que a tomada de decisão está relacionada com recursos limitados, esta alocação é em função da decisão e da racionalidade do agricultor que depende, por sua vez, de métodos eficientes que o auxiliem na otimização da sua decisão.

Por exemplo, podemos observar pela Figura 3, que no ponto Wel e no ponto Wm a produtividade da cultura é a mesma, porém Wm utiliza uma lâmina de água muito maior, assim ao fazermos esta análise observamos que podemos usar menos água com irrigação para uma mesma produção, ou seja, necessitamos que o sistema consiga encontrar o ponto Wel e assim teremos como ganho a diminuição do consumo de água e os gastos com eletricidade para o bombeamento, isso sem considerarmos outros fatores como manutenção do sistema de irrigação, lixiviação de insumos por excesso da lâmina de água, etc.






**Figura 3.** Intervalo para o manejo racional. Fonte: Frizzzone, 2007.

## 2.2 Otimização

Os problemas de otimização têm por objetivo encontrar o ponto ótimo do problema em um conjunto de variáveis inerentes ao problema, visando alcançar o objetivo principal da busca, que pode ser tanto a maximização quanto a minimização. Esses desafios se dividem em duas categorias distintas: aqueles em que as soluções são representadas por variáveis contínuas, conhecidos como problemas de otimização contínua, e aqueles em que as soluções são descritas por variáveis discretas, conforme destacado por Blum e Roli em 2003. Dentro da segunda categoria, emerge o grupo de problemas frequentemente denominado como Otimização Combinatória do inglês *Combinatorial Optimization* (CO).

É comum que nos tipos de problemas de CO exista uma função objetivo a ser otimizada e esta função pode ser considerada de minimização ou de maximização. Os conceitos que se aplicam a funções objetivo, seja de minimização ou de maximização são idênticos. Por exemplo, se num determinado problema, o objetivo for a diminuição de custos, a função objetivo será de minimização, ou seja, será buscada a melhor solução que leve ao menor custo possível. De forma análoga e inversa, poderemos ter um problema cujo objetivo seja encontrar a solução com o “Maior” ganho possível, a função objetivo será de maximização.

Segundo Papadimitriou e Steiglitz (1982), a solução do problema de CO pode ser vista como um objetivo e é comumente chamado de solução do problema e pode ser considerado um ótimo global ou ótimo local dependendo da posição que essa solução se encontre no espaço de busca. Na Figura 4 é apresentada uma ilustração tridimensional do espaço de busca, onde cada ponto de cor preta no gráfico representa uma possível solução, aquelas localizadas nas áreas vermelhas seriam as melhores soluções do espaço de busca do problema, assim, aquelas pertencentes à área A são as ótimas globais do problema exemplo e aquelas da área B, ótimas locais.



**Figura 4.** Representação gráfica tridimensional de soluções ótimas globais. Fonte: [http://www.esteco.com/robust\\_design.jsp](http://www.esteco.com/robust_design.jsp). Acesso em 2020.

De acordo com Blum e Roli (2003) um problema de CO,  $P = (S, f)$  pode ser definido por:

Um conjunto de variáveis  $X = \{x_1, \dots, x_n\}$ ;

Os domínios das variáveis  $D_1, \dots, D_n$ ;

Restrições entre as variáveis;

Uma função objetivo  $f$  a ser minimizada, onde  $f : D_1 \times \dots \times D_n \rightarrow \mathbb{R}_+$ .

O conjunto de todas as possíveis atribuições viáveis é definido pela Equação 1:

$$S = \{s = \{(x_1, v_1), \dots, (x_n, v_n)\} \mid v_i \in D_i\} \quad (1)$$

Sendo que  $s$  satisfaz todas as restrições.  $S$  é normalmente chamado de espaço de busca, de modo que cada elemento do conjunto é comumente considerado um candidato a solução. Para resolver um problema de otimização combinatória é necessário encontrar uma solução  $s^* \in S$ , tal que o valor da função objetivo para  $s^*$  seja o menor possível (minimização), isto é,  $f(s^*) \leq f(s) \forall s \in S$ . A solução  $s^*$  é chamada de ótimo global de  $(S, f)$  e o conjunto  $S^* \subseteq S$  é chamado de conjunto de soluções ótimas globais (BLUM & ROLI, 2003).

Uma das características distintivas dos problemas de Otimização Combinatória (CO) em relação a outros problemas de otimização está diretamente ligada ao domínio das variáveis, conforme indicado nas observações anteriores. O domínio de uma variável é essencialmente o conjunto de valores discretos que podem ser atribuídos a ela. Além disso, é possível que existam restrições associadas a essas variáveis.

Tomemos como exemplo o problema do caixeiro viajante, que ilustra questões relacionadas a permutações. Neste caso, restrições como a não repetição de cidades são aplicadas, ou seja, uma mesma cidade não pode figurar em duas ou mais posições dentro de

uma única solução. Isso destaca a complexidade e as peculiaridades dos problemas de otimização combinatória, nos quais a manipulação eficiente do domínio das variáveis e o gerenciamento das restrições são fundamentais para encontrar soluções viáveis e eficazes.

Além disso, pode haver regras mais específicas como, por exemplo: num determinado problema nenhuma solução pode ter o valor  $z$  atribuído a uma variável precedente de outra variável com o valor  $y$ , assim, toda solução que tivesse a estrutura  $s = \{ \dots, (xi, z), (xi+1, y), \dots \}$  seria considerada uma solução inválida para este problema.

## 2.3 Inteligência Artificial

A ideia de tornar as máquinas mais inteligentes deu-se com grandes filósofos indianos, chineses e gregos debruçados sobre esse pensamento. Esses filósofos tentaram descrever o pensamento humano como um sistema simbólico. Seus esforços vieram à luz, quando suas ideias foram finalmente aplicadas na década de 1940, na criação de uma máquina baseada nos princípios intelectuais do raciocínio matemático. Essa máquina em questão era o computador digital programável e seus inventores, rapidamente inspiraram outros cientistas ao redor do mundo, que desde então, trabalharam incansavelmente para tornar real o conceito de máquinas inteligentes (BAKER, 2019).

Alan Turing foi o primeiro a ter uma visão conceitual do que viria a ser a área do conhecimento, que hoje chamamos de Inteligência Artificial. Em um artigo publicado em 1950, intitulado *Computing Machinery and Intelligence*, ele discorre sobre o Teste de Turing<sup>2</sup>, Aprendizado de Máquina, Algoritmos Genéticos e Aprendizado por Reforço.

Esse período embrional da Inteligência Artificial ocorreu entre os anos de 1943 e 1955.

Nos anos 50, a IA começou a ganhar terreno como campo de estudo. Durante esse período, grande parte do foco foi no termo Inteligência Artificial Forte, que se concentra no desenvolvimento de uma IA capaz de imitar a mente humana (SULTAN, 2017).

A origem do termo como o conhecemos hoje, "Inteligência Artificial", remonta a Conferência de Dartmouth, realizada em 1956, e foi concebido por McCarthy (1956) sob a ótica comparativa entre a inteligência da máquina e a inteligência do homem. O termo não foi uma unanimidade e ainda hoje existem pessoas, atuantes nessa área do conhecimento, que se opõem a este termo, por considerar que a palavra "artificial" passa o sentido de falso.

Em 1993, Vinge (1993), escreveu um artigo onde ele citava pela primeira vez o termo "singularidade", representando o momento futuro em que a Inteligência Artificial irá exceder a inteligência humana, através da criação de computadores "conscientes".

Por definição, podemos considerar que IA é a capacidade de uma máquina de perceber o ambiente ao seu redor, raciocinar, aprender com este ambiente e agir de acordo com o que foi aprendido. A questão é que, nenhuma dessas definições é universalmente aceita, talvez por causa de suas referências à palavra "inteligência", que atualmente é considerada abstrata e incomensurável. Nesse contexto, IA pode ser definida como a simulação da inteligência humana em uma máquina, de modo a tornar a máquina eficiente para identificar e utilizar o "conhecimento". Uma máquina que seja capaz de solucionar um problema, planejando e executando a tarefa certa, no momento certo, é considerada racional.

---

<sup>2</sup> Alan Turing concebeu um princípio fundamental em sua busca para determinar se as máquinas podem ser consideradas conscientes: "Uma máquina é equivalente a um humano se seu comportamento não puder ser discernido do comportamento humano". Em outras palavras, a máquina adquire uma natureza humana quando seu comportamento se torna indistinguível do de um ser humano. Este postulado ressalta a ideia de que a verdadeira medida da consciência reside na capacidade de uma máquina em imitar, de forma convincente, o comportamento humano, desafiando a distinção entre máquinas e seres humanos. (TEIXEIRA, J. F. **Inteligência artificial (Como ler filosofia)**. Paulus Editora. Edição do Kindle).

Um pouco de reflexão, no entanto, revela que um sistema que pode raciocinar, deve ser um planejador bem-sucedido, pois o planejamento em muitas circunstâncias faz parte de um processo de raciocínio (KONAR, 2000).

Ludwig e Montgomey (2007) definem em seu livro que as principais habilidades que uma máquina inteligente deve ter são:

- Capacidade de realizar inferências e resolver problemas;
- Capacidade de planejamento;
- Capacidade de acumular e manipular conhecimento;
- Compreensão de linguagem natural;
- Capacidade de aprender com ou sem supervisão;
- Capacidade de interpretar estímulos sensoriais.

E que são três os elementos fundamentais de um sistema inteligente:

- Representação do conhecimento;
- Raciocínio e
- Aprendizagem.

### **2.3.1 O renascimento da IA**

Apesar de termos o conceito da Inteligência Artificial formulado desde a década de 1950, seu grande limitador e o que a impedia de crescer e se expandir era a capacidade de processamento das máquinas disponíveis na época.

No final do século XX começamos a ampliar consideravelmente essa capacidade, viabilizando assim o processamento de grandes volumes de dados, que juntamente com o aprimoramento de técnicas e aplicações mais complexas, promoveram comercialmente sua utilização.

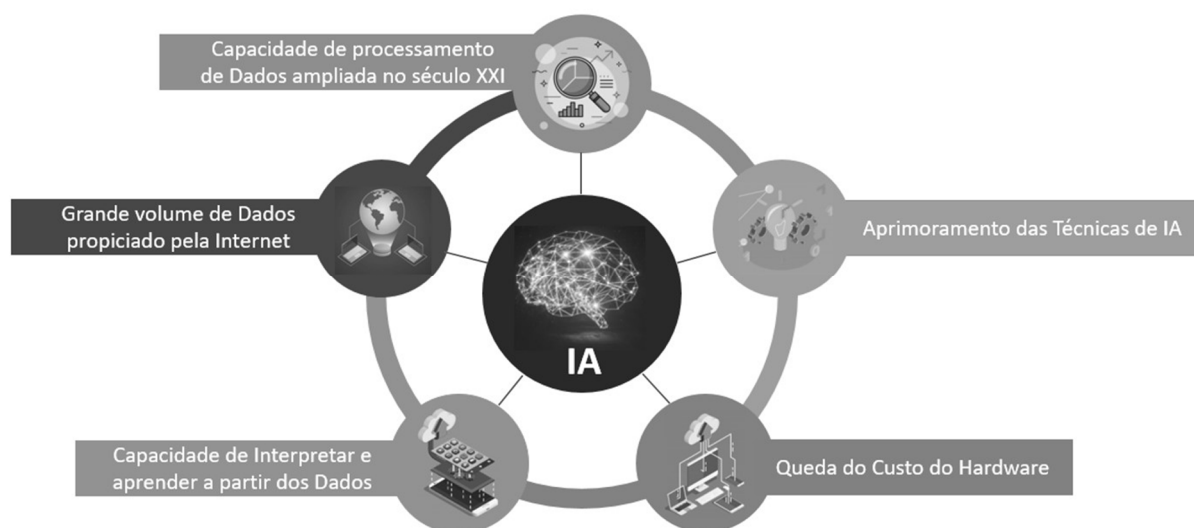
No século XXI a IBM deu um salto quântico com o lançamento do Watson, uma IA capaz de responder perguntas, através do Processamento da Linguagem Natural, do inglês Natural Language Processing - NLP. De acordo com Taurion (2013):

“O Watson foi concebido para entender o sentido da linguagem humana de acordo com o seu contexto, com o objetivo de encontrar a resposta precisa para perguntas complexas. O Watson incorpora uma nova maneira de recuperar informação de forma rápida a partir de imensas quantidades de informação que lhe permitem ter uma profunda capacidade de análise e interpretação. De fato, a capacidade analítica de Watson é de investigar o equivalente a cerca de duzentos milhões de páginas de dados (ou perto de um milhão de livros) permitindo que ele seja capaz de responder a uma pergunta em aproximadamente três segundos. Essa capacidade de lidar com linguagem natural e responder precisamente questões complexas revela um grande potencial de transformar a maneira com que as máquinas interagem com os seres humanos, ajudando-os a conquistar seus objetivos.”

Em 2011 o Watson participou de um famoso jogo americano de perguntas e respostas, chamado Jeopardy<sup>3</sup>. O desafio consistiu numa disputa de conhecimentos gerais, dividido por etapas, e culminou com a vitória do Watson, derrotando os dois maiores campeões da história do programa. Foi um grande feito para uma IA, pois as perguntas feitas no programa não foram elaboradas para serem respondidas por um computador, uma vez que apresentavam regionalismos, gírias, metáforas, ambiguidades, sutilezas e trocadilhos (IBM, 2017).

Essa vitória foi um marco histórico e só foi possível porque houve uma mudança de abordagem, a IBM deixou de usar processamento bruto de informação, para literalmente utilizar máquinas que aprendem. Atualmente o Watson é capaz de interpretar dados, aprender e raciocinar a partir deles.

Com a queda constante nos preços de hardware tornando a computação comercialmente barata, mais a capacidade adquirida de analisarmos grandes volumes de dados, somando ao advento da Internet das Coisas, do inglês Internet of Things - IoT, e do conceito de sistemas de aprendizado, temos os ingredientes necessários para unir gerenciamento de projetos e Inteligência Artificial. A Figura 5 mostra os fatores que contribuíram para o renascimento da Inteligência Artificial no século XXI.



**Figura 5.** Renascimento da IA no século XXI. Fonte: Villas Bôas Junior, 2021.

De acordo com Quaresma (2021), embora possam existir muitos tipos e formas diferentes de IA, uma vez que seu conceito é amplo, é necessário calibrar e classificar o grau de inteligência e capacidade de uso de uma IA. Essa classificação pode abranger desde atividades mais restritas e específicas do uso da "inteligência", até a realização de atividades de cunho intelectual. Dessa forma, podemos classificá-las como Inteligência Artificial Fraca, do inglês Artificial Narrow Intelligence - ANI, que consiste numa IA especializada em uma determinada e única área do conhecimento, operando dentro de uma gama pré-definida e limitada de funções.

Como exemplo podemos citar a Siri, a assistente virtual da Apple, disponível no iPhone, que possibilita a realização de diversas tarefas apenas por comando de voz. A Siri é excelente no que foi programada para realizar, mas incapaz, por exemplo, de jogar uma partida de xadrez. Para essa finalidade, seria necessário a utilização de uma outra IA, programada para tal. Outro exemplo seriam os carros autônomos, que possuem várias ANIs

<sup>3</sup> Jeopardy é um programa de televisão, atualmente exibido nos EUA pela CBS Television Distribution. É um show de perguntas e respostas (quiz) que aborda questões que variam entre história, literatura, cultura e ciências. (<https://pt.wikipedia.org/wiki/Jeopardy!>)

utilizadas de forma coordenada para permitir que o veículo trafegue de forma totalmente autônoma.

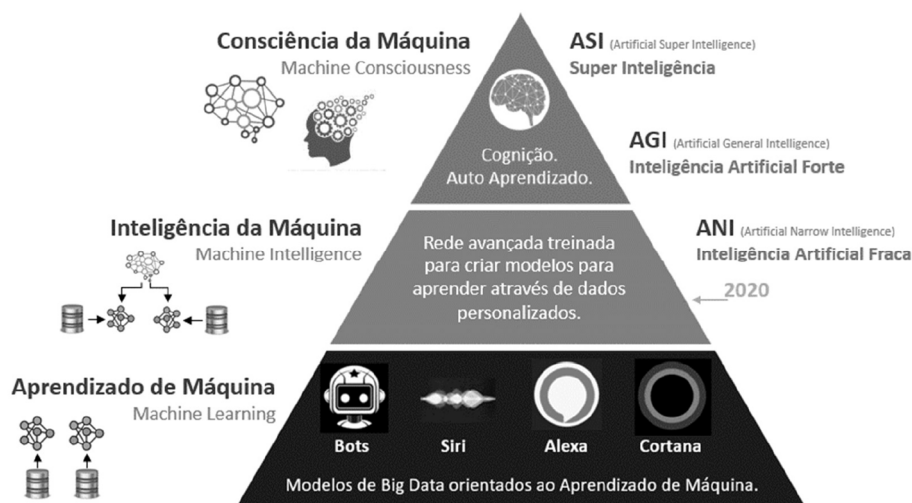
Segundo Quaresma (2021), a Inteligência Artificial Forte, do inglês Artificial General Intelligence - AGI, consiste numa IA capaz de executar qualquer tarefa intelectual que um ser humano seja capaz de realizar. O cérebro humano, com mais de 100 bilhões de neurônios, cada um conectado a milhares de outros neurônios, é o órgão mais complexo do universo conhecido.

A cognição é uma de suas habilidades mais complexas e avançadas, sendo esta a ação mental ou processo de aquisição de conhecimento e entendimento através do pensamento, experiência e sentidos. Abrange a tomada de decisões e a solução de problemas. Gottfredson (1996) descreve nosso cérebro como “possui vasta capacidade mental, podendo raciocinar, planejar, resolver problemas, pensar abstratamente, compreender ideias complexas, aprender rapidamente e aprender com a experiência”.

Criar uma AGI é uma tarefa extremamente difícil e ainda não somos capazes de tal proeza.

A Super Inteligência, do inglês Artificial Super Intelligence – ASI consiste numa IA que teoricamente poderia suplantará a soma de toda a capacidade intelectual da humanidade. Bostrom (2014) cunhou o termo e a define como "um intelecto muito mais inteligente que os melhores cérebros humanos em praticamente todos os campos, incluindo criatividade científica, sabedoria geral e habilidades sociais".

A Figura 6 mostra a pirâmide de classificação e auxilia no entendimento do grau de inteligência de uma IA.



**Figura 6.** Classificação da inteligência artificial. Fonte: Villas Bôas Junior, 2021.

A tecnologia avança exponencialmente e, apesar de ainda não contemplarmos o desenvolvimento de uma AGI e uma ASI, a história nos mostra que quase nada é impossível. Podemos dizer que os problemas impossíveis são somente problemas difíceis para um certo nível de inteligência.

Falar em ASI pode remeter à ficção científica, a fantasia, mas este tema vem chamando a atenção de pesquisadores de todo o mundo, universidades e grandes empresas de tecnologia, que apostam no desenvolvimento de máquinas inteligentes. A cada dia, empresas como Google, Facebook, IBM e OpenAI, apenas citando algumas, lançam novos produtos e serviços utilizando técnicas de Inteligência Artificial.


São nomes como Demis Hassabis, CEO da DeepMind do Google; Yann Lecun, diretor de pesquisas do Facebook; Eric W. Brown, cientista da computação da IBM; Elon Musk, investidor da OpenAI; Geoffrey Hinton, da Universidade de Toronto, um dos grandes nomes nas pesquisas com redes neurais artificiais; Yoshua Bengio, da Universidade de Montreal, um dos maiores evangelistas do machine learning; Nick Bostrom, da Universidade de Oxford, filósofo, mais preocupado com as implicações éticas e morais da adoção em larga escala da IA e seu impacto na sociedade e no futuro da humanidade.

Não é possível citar todos, são muitos os envolvidos em desenvolver essa tecnologia, reduzindo ainda mais a distância entre ficção científica e realidade. Para os céticos, podemos parafrasear Arthur C. Clarke, que foi um grande escritor de ficção científica, "Qualquer tecnologia suficientemente avançada é indistinta de magia". O futuro chegou e estamos vivendo um momento ímpar na história, um momento de grandes e disruptivas descobertas científicas.

### 2.3.2 Técnicas da inteligência artificial

Na observação de vários fenômenos na natureza é onde normalmente a Inteligência Artificial baseia seus paradigmas, desta forma, existem diversas técnicas que se enquadram na área chamada de Inteligência Artificial, sendo algumas das mais importantes demonstradas na Figura 7.

A UFRRJ ainda de forma embrionária está desenvolvendo um Laboratório Virtual de pesquisas nessas áreas da IA, o AIRLab. Ainda que, de forma embrionária, mas já se encontram no seu site as descrições das diversas áreas e subáreas da IA.



**Figura 7.** Áreas da inteligência artificial. Fonte: Villas Bôas Junior, 2021.

Um grande conjunto destas técnicas pode trabalhar em conjunto, como por exemplo, sistemas Neuro-Fuzzy, onde são envolvidas as redes neuronais e lógica nebulosa, nesta pesquisa utilizaremos o algoritmo Otimização por Enxame de Partículas (PSO), que está inserido dentro das diversas técnicas da Inteligência de Enxames.

Utilizamos o PSO para determinação do ponto ótimo das funções de produção, para uma ou mais variáveis (como água e nitrogênio) e receita líquida conjuntamente.

## **2.4 Metaheurística**

Segundo Souza (2005), muitas das heurísticas tradicionais se mostram ineficazes ou inadequadas quando se trata de abordar objetivos mais abrangentes relacionados a problemas do mundo real. A resolução de problemas de maior complexidade, com base nos princípios das áreas de Otimização e Inteligência Artificial, levou ao desenvolvimento de metaheurísticas.

No entanto, não existe ainda uma definição universalmente aceita para o termo. De acordo com Blum e Roli (2003), a conceitualização proposta por Osman e Laporte (1996) emerge como uma das abordagens mais adequadas para solucionar o problema em questão.

“Uma metaheurística é formalmente definida como um processo de geração iterativo, que guia uma heurística subordinada pela combinação de diferentes conceitos inteligentes para explorar o espaço de busca. Estratégias de aprendizagem são usadas para estruturar informações com a finalidade de encontrar, de forma eficiente, soluções próximas do ótimo.”

Segundo Gomes (2007), ao utilizar metaheurísticas, um processo de otimização proporciona um equilíbrio dinâmico entre a intensificação da busca e as habilidades de exploração. A intensificação prioriza as buscas em regiões próximas a pontos já visitados e a exploração permite visitar novas regiões do espaço de busca, onde melhores soluções podem eventualmente ser encontradas.

A adaptação dos seres vivos podem ser a inspiração das metaheurísticas, onde os algoritmos agem no conjunto de possíveis soluções para o problema, tendo a sua evolução através da interação entre seus elementos buscando a melhor solução no decorrer das iterações e gerações, sem comprometer a diversidade.

Nos últimos anos, uma grande variedade de metaheurísticas tem sido proposta para a solução de problemas de otimização, a metaheurística da Inteligência Computacional é uma das principais abordagens atualmente empregadas para a solução destes problemas.

### **2.4.1 Complexidade computacional**

Em complexidade computacional, existem classificações para problemas dos mais variados tipos. A área propõe o estudo para analisar e categorizar os problemas de acordo com a sua complexidade para ser resolvido, ou seja, a quantidade de recursos computacionais necessários, como tempo e memória, para se alcançar a solução esperada.

É verdade que muitos problemas de engenharia não podem ser tratados através de métodos analíticos, seja por causa da dificuldade de formulação da modelagem ou do esforço matemático exigido na solução, especialmente quando estão envolvidas funções não diferenciáveis ou descontínuas. Neste sentido, nos últimos tempos, algoritmos bioinspirados baseados em populações e metaheurísticas vêm sendo usados para resolver problemas de busca e otimização em vários domínios de problemas onde soluções robustas são impossíveis ou difíceis de encontrar usando abordagens tradicionais como por exemplo, a programação matemática.

O princípio fundamental desses algoritmos utiliza um método construtivo para a obtenção da população inicial (soluções factíveis iniciais) e uma técnica de busca local para melhorar a solução da população, considerando que os indivíduos (soluções) dessa população são evoluídos de acordo com regras especificadas que consideram o intercâmbio de



informações entre os indivíduos. Esse processo conduz a população em direção à obtenção de uma solução ótima.

Tais algoritmos são conhecidos como algoritmos de computação evolutiva, onde existem duas abordagens evolutivas baseadas em populações que têm se destacado: algoritmos evolutivos e algoritmos de enxames. Os Algoritmos Evolutivos (AE) de forma tradicional incluem os Algoritmos Genéticos (AG) (GOLDBERG, 1989), Programação Genética (PG) (KOZA, 2003), Programação Evolutiva (PE) e Estratégias Evolutivas (EE) (DE JONG, 2006). Mais recentemente foram desenvolvidos algoritmos como Algoritmos Genéticos Competentes (GOLDBERG, 2002) e Algoritmos de Estimação de Distribuição (AED) (PELIKAN, 2006).

Os AEs têm sido amplamente aplicados e intensamente estudados na solução de vários problemas de engenharia e científicos, tais como projeto despacho econômico de sistemas de energia, robótica e problemas de identificação de dobra de proteína, só para mencionar alguns. Devido à sua simplicidade, robustez e flexibilidade estes algoritmos têm desfrutado de sucesso nas aplicações. Os algoritmos atuam sobre uma população de possíveis soluções e aplicam o princípio de sobrevivência de indivíduos mais fortes e bem adaptados ao ambiente e da diversidade destes indivíduos, que se reproduzem através de operadores que imitam os conceitos genéticos, criando descendentes mais fortes que se aproximam da solução do problema.

Este trabalho explora as abordagens evolutivas baseadas em algoritmos de enxames. A Inteligência de Enxames, também referenciada como Inteligência de Colônias ou Inteligência Coletiva, é um conjunto de técnicas baseadas no comportamento coletivo de sistemas auto-organizados, distribuídos, autônomos, flexíveis e dinâmicos.

## **2.4.2 Inteligência de enxames**

A Inteligência de Enxames é uma técnica computacional desenvolvida no final da década de 1980. Segundo Von Zuben e Castro (2004), é baseada no comportamento coletivo auto-organizado de sistemas descentralizados constituídos por um número elevado de agentes, com o objetivo de realizar uma determinada tarefa. A Inteligência de Enxame pode ser definida como a subárea dos Sistemas de Inteligência Artificial onde o comportamento coletivo dos indivíduos em uma população pode obter soluções coerentes.

Como ilustração para o termo enxame ou população, qualquer coleção estruturada de agentes capazes de interagir pode ser genericamente utilizada. Um exemplo clássico é o enxame de abelhas. Outros sistemas de maneira similar também podem ser considerados enxames, como por exemplo, um jogo de futebol onde os agentes são os jogadores, um engarrafamento onde os agentes são os carros, uma revoada de pássaros onde os agentes são os pássaros e até uma colônia de formigas, onde os agentes são as formigas.

A noção de enxame sugere um aspecto de movimento coletivo no espaço, todavia todos os tipos de comportamentos coletivos merecem a atenção e não somente o espacial. As interações coletivas dentro do sistema, muitas vezes levam a algum tipo de comportamento ou inteligência coletiva. Qualquer tentativa de projetar algoritmos ou dispositivos distribuídos de solução de problemas sem ter um controle centralizado, inspirado no comportamento coletivo de agentes sociais e outras sociedades animais podem ser inclusas neste ramo da Inteligência Artificial.

A inteligência coletiva é uma propriedade de sistemas compostos por agentes com capacidade individual limitada que apresentam comportamentos coletivos inteligentes. Tais comportamentos seguem as propriedades descritas abaixo:

- Proximidade: os agentes devem ser capazes de interagir;

- Qualidade: os agentes devem ser capazes de avaliar seus comportamentos;
- Diversidade: o sistema reage a situações inesperadas;
- Estabilidade: as variações ambientais podem afetar o comportamento de um agente;
- Adaptabilidade: capacidade de se adequar as variações ambientais.

O PSO pode ser considerado uma das principais metaheurísticas utilizadas pela Inteligência de Enxame.

### 2.4.3 Enxame de partículas (*particle swarm optimization* - PSO)

Em sua obra de 1995, Kennedy e Eberhart propõem o conceito de enxame de partículas como uma abordagem inovadora para a otimização de funções contínuas não-lineares. A modelagem desse conceito foi fundamentada na simulação de grupos sociais simplificados, especificamente inspirada nas interações observadas em cardumes de peixes ou bandos de pássaros. Essa técnica de otimização, baseada na noção de populações e impulsionada pela metáfora do comportamento social, efetua sua implementação através da simulação de dinâmicas sociais e interações observadas em fenômenos naturais.

Menezes, Machado e Schirru (2008), descreve que na sociologia veem-se discussões sobre a vantagem competitiva de se realizar aprendizado individual a partir do conhecimento de outros componentes do grupo (KENNEDY e EBERHART, 1995). Inclusive nos seres humanos e em diversas espécies, se pode observar esta habilidade, porém com uma diferença, os seres humanos também o aplicam nos campos da abstração cognitiva, enquanto as demais espécies realizam este aprendizado para funções instintivas, como a procura de parceiros e alimentos.

No início da década de 90, foi proposto um novo modelo de movimento com base no aprendizado coletivo (KENNEDY e EBERHART, 1995). Este novo modelo proposto, porém, era similar aos já existentes, mas com um diferencial, os agentes desta nova modelagem, os pássaros, eram atraídos para uma área de pouso ao invés de continuarem em vôo, foi diagnosticado que quando um dos pássaros sobrevoava uma determinada área, este era atraído. Com o aprendizado coletivo e a passagem do tempo, os demais pássaros tenderiam a se movimentar com o intuito de pousar. A capacidade sociocognitiva é fundamental no comportamento do enxame, pois um pássaro ao encontrar uma posição cuja solução pode ser considerada boa sob algum aspecto pode vir a influenciar outros do enxame, fazendo com que caminhem em sua direção, existindo a possibilidade de passarem por alguma posição no espaço de busca ainda melhor. Neste caso, aumentariam as chances de serem descobertos novos e mais eficientes resultados no espaço de busca conforme a evolução do algoritmo.

Levando-se em consideração que características como volume, massa e dimensões dos agentes não são consideradas para a resolução de problemas ou para o processo de otimização, os membros de uma população que procura por soluções de um problema proposto passaram a serem designados pelo termo “partículas”.

A partícula individualmente não consegue avaliar se sua atual posição é boa ou ruim. É necessário que a partícula envie estas coordenadas encontradas para uma função que as avalie quantitativamente, fornecendo um número como resultado. Esta é a chamada função objetivo, ou *fitness*, que é uma medida de aptidão, indicativa de quão boa é uma posição em relação à outra historicamente encontrada pela partícula.

Na busca de resultados no PSO, uma nova posição encontrada deve ser comparada tanto com a melhor posição individual, obtida até o momento pela própria partícula (*pBest*), quanto com a melhor posição de todo o enxame (*gBest*). No entanto, não se devem atribuir


às partículas, individualmente, capacidades cognitivas, já que não possuem cérebros individualizados.

Utilizando uma analogia, o termo “partícula” simboliza os pássaros, como na Figura 8, e representa as possíveis soluções do problema a ser resolvido. O espaço de busca é equivalente a área sobrevoada, e à solução ótima corresponde a encontrar o local com comida.



**Figura 8.** Aves voando "alinhadas" em busca de alimento. Fonte: Villas Bôas Junior, 2021.

No PSO é simulado um enxame de partículas candidatas a solução de um determinado problema, onde em um espaço de busca n-dimensional as partículas são atraídas por regiões de alto valor de adaptação Waintraub (2009), conforme Figura 9.



**Figura 9.** Atualização de uma partícula. Fonte: Villas Bôas Junior, 2021.

A topologia do espaço de busca é dada pela função objetivo do problema, enquanto a posição da partícula representa uma candidata a solução. A cada partícula é atribuída uma velocidade, onde se encontram as informações de direção e taxa de mudança de posição em função do tempo, e o atributo de desempenho ou adequação, obtido pela avaliação da função objetivo na posição da partícula.

A mudança da posição da partícula e de sua velocidade é guiada por sua informação antecedente das regiões já percorridas, boas e ruins, bem como pela observação de seus vizinhos bem-sucedidos. Sejam:

$$\vec{X}_i(t) = \{x_{i,1}(t), \dots, x_{i,n}(t)\} \quad \text{e} \quad \vec{V}_i(t) = \{v_{i,1}(t), \dots, v_{i,n}(t)\}$$

Respectivamente, a posição (o próprio vetor candidato a solução) e a velocidade (sua taxa de mudança) da partícula  $i$  no tempo  $t$ , em um espaço de busca  $n$ -dimensional. Considerando-se também:

$$\vec{pBest}_i(t) = \{pBest_{i,1}(t), \dots, pBest_{i,n}(t)\}$$

A melhor posição já encontrada pela partícula  $i$  até o tempo  $t$ ; e:

$$\vec{gBest}(t) = \{gBest_1(t), \dots, gBest_n(t)\}$$

A melhor posição já encontrada pelo enxame até o tempo  $t$ . As regras de atualização do PSO para a velocidade e posição, no PSO canônico, são dadas pelas Equações 2 e 3:

$$v_{i,j}(t+1) = v_{i,j}(t) + c_1 \cdot r_1 (pBest_{i,j}(t) - x_{i,j}(t)) + c_2 \cdot r_2 (gBest_j(t) - x_{i,j}(t)) \quad (2)$$

$$x_{i,j}(t+1) = x_{i,j}(t) + v_{i,j}(t+1) \quad (3)$$

Onde  $i = \{1, \dots, p\}$  (número total de partículas);

$j = \{1, \dots, n\}$  (dimensão do espaço de busca);

$r_1$  e  $r_2$  são números randômicos uniformemente distribuídos entre 0 e 1;

Os coeficientes  $c_1$  e  $c_2$  são as constantes de aceleração (geralmente chamadas de aceleração cognitiva e social, respectivamente) relativas à:

$$\vec{pBest} \quad \text{e} \quad \vec{gBest} \quad \text{respectivamente.}$$


Dentro da região do ótimo, quando o PSO localiza, ele pode enfrentar dificuldades em ajustar o seu incremento de velocidade para prosseguir em uma busca mais refinada, resultando em uma perda de eficiência do seu método. Para resolver este problema introduz-se um peso para a velocidade anterior da partícula, denominado peso inercial,  $w$ , cuja regra é considerada crítica para a convergência do PSO. Com isto, a equação da velocidade da partícula, anteriormente descrita pela Equação 2, passa a ser na Equação 4:

$$v_{i,j}(t+1) = w \cdot v_{i,j}(t) + c_1 \cdot r_1 (pBest_{i,j}(t) - x_{i,j}(t)) + c_2 \cdot r_2 (gBest_j(t) - x_{i,j}(t)) \quad (4)$$

De acordo com Shi e Eberhart (1998), valores elevados de  $w$  promovem a exploração e prospecção globais, enquanto valores baixos conduzem a uma busca local. Uma aproximação comumente utilizada para aumentar o desempenho do PSO, promovendo um balanço entre a busca global e local, consiste em inicializar  $w$  com um valor alto e ir decrescendo, linearmente ou não, durante a execução do PSO.

Não existe um mecanismo que limite a velocidade de uma dada partícula, fato observado nas Equações 2 e 3. Comparado a outras técnicas de computação evolucionária,

esta falta pode resultar em uma baixa eficiência para o PSO. Valores muito altos de velocidade podem fazer com que a partícula saia do espaço de busca. Neste caso, algumas estratégias podem ser utilizadas, como por exemplo, parar a partícula nos limites do espaço de busca ou, mais natural e eficiente, refletir a partícula para dentro do espaço de busca, conforme ilustrado na Figura 10, que considera busca em duas dimensões:



**Figura 10.** PSO - Reflexão de uma partícula nas bordas do espaço de busca. Fonte: Villas Bôas Junior, 2021.

Este tratamento pode ocasionar a necessidade de várias reflexões em caso de velocidades muito altas, podendo diminuir a eficiência do PSO. Uma limitação do valor da velocidade da partícula em um valor máximo é considerada adequada. A técnica consiste em fixar no valor máximo sempre que a velocidade exceder este limite. No PSO canônico, todas as partículas navegam por um espaço de busca  $n$ -dimensional, delimitado pelos intervalos de variação dos  $n$  parâmetros de otimização. Vizinhança global é a classificação para o enxame, onde todas as partículas são informadas quando um novo melhor ponto de mínimo/máximo é encontrado no espaço de busca.

No algoritmo PSO, o enxame é inicializado randomicamente (posições e velocidades) e enquanto o critério de parada (no caso um número máximo de iterações) não é atingido, executa-se um *loop* contendo os seguintes passos:

1. Partículas são avaliadas de acordo com a função objetivo, e os valores de aptidão de cada partícula são determinados;
2. Valores de  $\vec{pBest}$  e  $\vec{gBest}$  são atualizados;
3. Partículas são movimentadas de acordo com as equações de atualização de velocidade e posição (Equações 2 e 3).

A Figura 11 mostra o pseudocódigo do PSO.

```

Algoritmo PSO
begin
  for i=1 to n_particles do begin
    randomize(Xi); randomize(Vi);
  end;
  for iter=1 to itermax do begin
    for i=1 to n_particles do evaluate (Xi);
    for i=1 to n_particles do update(pBesti,gBest);
    for i=1 to n_particles do begin
      Vi = w*Vi+c1*r1*(pBesti-Xi)+c2*r2*(gBest-Xi);
      Xi = Xi + Vi;
    end;
  end;
end.

```

**Figura 11.** Pseudocódigo genérico do PSO. Fonte: Villas Bôas Junior, 2021.

Segundo Waintraub (2009), existem algumas variações do PSO padrão que visam aumentar a diversidade populacional, fato este que geralmente resulta em melhores resultados.

Para ilustrarmos podemos definir um problema simples onde o objetivo é o de minimizar o resultado. A função objetivo é denotada por  $f(x) = x^2$ , e foi realizado o teste em 20 gerações, para uma população aleatória de 100 indivíduos. O parâmetro  $w = 0.5$ , as constantes  $C_1$  e  $C_2$  foram mantidas fixas e com os valores 2.3 e 1.7 respectivamente. A Tabela 1 mostra o resultado obtido para cada geração e a Figura 12 mostra a convergência do algoritmo.

**Tabela 1.** Resultado exemplo do PSO.


Geração	$\vec{gBest}$
1	12,92
2	10,89
3	9,66
4	9,57
5	9,08
6	8,46
7	8,25
8	8,09
9	7,54
10	7,17
11	6,51
12	6,51
13	6,51
14	6

Continua...

Continuação da Tabela 1.

Geração	$\vec{gBest}$
15	5,93
16	5,93
17	5,93
18	5,81
19	5,59
20	5,18

Fonte: Villas Bôas Junior, 2021.



**Figura 12.** Convergência exemplo do PSO. Fonte: Villas Bôas Junior, 2021.

## 2.5 Função de Produção

De acordo com Frizzzone e Andrade Junior (2005), diversos pesquisadores empreenderam estudos voltados para o desenvolvimento de modelos matemáticos, buscando representar as relações entre as funções de produção e a evapotranspiração da cultura.

Segundo Flemming e Gonçalves (2007), para demonstrar as funções de produção evapotranspiração-cultura um dos mais fundamentais conceitos da matemática deve ser compreendido, o de função matemática; que é basicamente a correspondência entre conjuntos.


Uma função matemática pode ser definida como:

“Uma quantidade é função de outra quando, para cada quantidade da variável independente  $x$ , corresponde a um único valor denominado  $f(x)$ . O conjunto no qual os valores de  $x$  podem ser tomados é chamado de domínio da função, e o conjunto dos valores que  $f$  assume para cada  $x$  é denominado imagem da função.” (FERREIRA, 2005).

Ou seja, é uma associação de elementos de um conjunto a elementos de outro conjunto, ou utilizando a definição mais formal:


“Sejam  $X$  e  $Y$  dois subconjuntos dos  $\mathbb{R}$ . Uma função  $f: X \rightarrow Y$  é uma lei ou regra que a cada elemento de  $X$  faz corresponder um único elemento de  $Y$ .” (FLEMMING e GONÇALVES, 2007).

Na Figura 13 (a) é demonstrado esta definição através do exemplo, e na Figura 13 (b) é mostrado um contraexemplo de uma relação que não é uma função.



**Figura 13.** Relação entre conjuntos  $X$  e  $Y$ . Fonte: Demana, 2009.

Técnicas de cálculo que permitem saber qual o ótimo de uma função existe há tempos. Alguns requisitos devem ser atendidos por tal a função, tais como, ser diferenciável no intervalo  $[x_1, x_2]$  de análise; como demonstrado na Figura 14.



**Figura 14.** Gráfico de uma função contínua genérica. Fonte: Villas Bôas Junior, 2021.

Na Figura 14 a função  $f(x)$  é o que dizemos como bem comportada, isto é, ela é contínua em todo o intervalo  $[x_1, x_2]$ , desta forma podemos em qualquer ponto deste intervalo encontrar a derivada, que é a reta tangente a curva no ponto observado.

Através de técnicas de cálculo diferencial e nesta situação podemos determinar o máximo da função. Porém como não é o objetivo deste trabalho não iremos tecer maiores explicações a esse respeito, somente como encontrá-lo.



Quando a sua derivada primeira da função é zero, pode ser encontrado um ponto de máximo ou de mínimo, desta forma, na Figura 14 no ponto  $x_m$  a derivada da função é igual a zero, o que significa que a reta tangente a função no ponto  $x_m$  tem inclinação zero, isto é, é paralela ao eixo dos  $x$ .

E quando derivarmos novamente (derivada segunda):

$f''(x) > 0$  , ponto de mínimo;

$f''(x) < 0$  , ponto de máximo;

$f''(x) = 0$  , ponto de inflexão;

O problema maior é quando não temos uma função tão comportada assim, ou seja, que tenha pontos de descontinuidade, desta forma não iremos conseguir efetuar a análise se utilizando da forma anteriormente descrita, pois não temos como encontrar a derivada neste ponto. Para resolver o problema vamos utilizar de outra técnica, que neste trabalho é uma técnica de Inteligência Artificial para se achar o ponto de ótimo da função, que é o algoritmo PSO.

As técnicas de Inteligência Artificial também funcionam com funções contínuas, pois também podemos usar a equação da função que representa a função de produção da cultura, que será explicada nos capítulos posteriores.

A produtividade de uma cultura agrícola é dependente de muitos fatores e a maioria destes são pertencentes ao SSPA. Sabemos que para cada cultura as relações entre estes fatores variam muito e desta forma se conseguirmos determinar estas relações para cada cultura, principalmente quanto ao uso de água, que é o objeto deste trabalho, esta pesquisa contribui de forma positiva para insumos agrícolas, como o nitrogênio, um melhor uso de água e gerando aumento da produtividade e receita líquida pela redução dos custos.

Frizzone (2005) demonstra em diversas passagens que o êxito esperado da agricultura irrigada depende de fatores complementares, dentre os quais podem ser reconhecidos de imediato:

- Assistência técnica;
- Capacitação e organização dos agricultores
- Defensivos e herbicidas;
- Disponibilidade de mão de obra;
- Educação ambiental;
- Facilidade de crédito e comercialização dos produtos;
- Fertilizantes;
- Maquinaria e implementos agrícolas adequados;
- Pesquisa aplicada;
- Sementes de bom potencial genético;

Sendo assim é permitido informar que a função de produção é uma relação entre fatores de produção e produtividade, ou ainda, definindo mais explicitamente:

“... relação física entre as quantidades utilizadas de um certo conjunto de insumos e as quantidades físicas máximas que se podem obter do produto para uma dada tecnologia conhecida.” (FRIZZONE, 2005).

Podemos escrever matematicamente (Equação 5) que:

$$Y_{\text{prod}} = Y(U_1, U_2, U_3, \dots, U_n) \quad (5)$$

Isto é, a função de produção  $Y$  é dependente dos vários insumos  $U_s$  participantes do processo.

“Considerando o grande número de variáveis que influencia a produtividade das culturas agrícolas e a complexidade das relações que afetam a quantidade e a qualidade do produto, a produtividade pode ser expressa exclusivamente em função da água utilizada pelo cultivo, contanto que os demais fatores da produção permaneçam fixos, em nível ótimo.” (FRIZZONE, 2005).

Simplificando (Equação 6), vem:

$$Y_{\text{prod}} = Y(W)^4 \quad (6)$$

Onde  $W$  representando que é em função apenas da água.

Segundo Frizzone (2005) é mais interessante ao usuário da irrigação expressar as variáveis da função de produção água-cultura utilizando a lâmina d'água aplicada à parcela, mesmo que apenas parte dela seja utilizada no processo de evapotranspiração.

Frizzone (2005) destaca que por serem empíricas, as aplicações das funções de produção água-cultura são criticadas, pois omite efeitos de outros fatores e sendo específica daquele local, porém sendo defendidas a sua importância por conceituados autores como Vaux, Pruitt e Howell (apud FRIZZONE, 2005, p. 285) entre outros, devido à necessidade de se prever sob certas condições de clima, cultivo e operação as produtividades físicas marginais da água a serem utilizadas nas análises econômicas:

“As funções de produção água-cultura são particularmente importantes às análises de produção agrícola quando a água é escassa. Para o processo de planejamento, essas funções constituem o elemento básico de decisão dos planos de desenvolvimento e, relativamente à operação de projetos de irrigação, permitem tomar decisões sobre planos ótimos de cultivo e ocupação de área para produção econômica com base na água disponível.” (FRIZZONE, 2005).

A importância da gestão da irrigação é subestimada, especialmente em regiões com acesso abundante à água. No entanto, é fundamental recordar, como mencionado anteriormente, que não podemos subestimar a relevância da irrigação. Ignorar essa questão pode resultar em escolhas inadequadas de métodos de irrigação, com consequências negativas tanto para o meio ambiente quanto para a economia.

A relação entre a água e a produção agrícola é complexa e fundamental. A função de produção água-cultura representa uma ferramenta de análise essencial, pois auxilia os tomadores de decisão a compreenderem os fatores envolvidos e a tomar decisões informadas. Isso, por sua vez, permite um planejamento mais eficaz e a otimização da produção agrícola, levando em consideração as implicações ambientais e econômicas.

---

<sup>4</sup> Na maior parte dos testes foi utilizado somente água, porém em algumas ocasiões trabalhamos também com nitrogênio, desta forma, a equação simplificada passa a ser escrita como:  $Y_{\text{prod}} = Y(W, N)$ .

Portanto devemos reconhecer que a gestão adequada da irrigação desempenha um papel na promoção da sustentabilidade, maximização da produção e tomada de decisões informadas no que diz respeito ao cultivo e uso da área de produção.

“Na agricultura irrigada, o fator água deve ser otimizado possibilitando, sem maiores riscos, aumentar a utilização dos demais fatores de produção e, por consequência, obterem-se maiores produtividades com uma melhor combinação dos insumos empregados. Para tanto, o conhecimento das funções de produção ou superfícies de resposta é fundamental para auxiliar nas decisões, uma vez que estas funções possibilitam a interação entre os diversos fatores que afetam a produtividade, e escolher as soluções mais condizentes com a realidade regional, permitindo assim o manejo racional da irrigação em bases técnicas e econômicas.” (BERNARDO, 2010).

Howell e Hiler (1975), Stewart (1977) e Howell (1990), trabalharam com modelos onde a relação era linear entre a produção da matéria seca com a transpiração, e muitos outros modelos existem para tentar descrever a função de produção de uma cultura. Em nossa pesquisa os modelos não são totalmente prioritários, pois estamos utilizando como ferramenta de tracejamento da curva da função de produção o PSO, porém devemos destacar modelos considerados clássicos como os de Dewit (1958), que visava a identificação dos fatores da relação transpiração-produção das culturas, Arkley (1963) que inseriu um fator de correção para o clima na equação de Dewit, o modelo de Hanks (1974) que também tem como base o modelo de Dewit, relacionando a transpiração relativa e produtividade relativa de matéria seca e Doorenbos e Kassan (1979) que baseado no modelo anterior desenvolvem um método para estimar a relação entre água e rendimento das culturas.

Frizzone (2005) demonstra ao planejar uma análise econômica das funções de produção para se definir estratégias ótimas de irrigação nos depararemos com três correntes:

- i. Objetivando o rendimento máximo estabelecendo o nível de água utilizada para tal – água em abundância não sendo ela um fator limitante;
- ii. Objetivando maximizar a eficiência do uso de água em relação ao rendimento da cultura – a água é fator limitante;
- iii. Objetivando que a água utilizada seja selecionada no ponto de região econômica de produção em que a produtividade marginal da água seja igual ao seu preço – a terra é o fator limitante.

Podemos dividir e classificar os custos de produção em quatro categorias:

- i. Custos fixos que não dependem da quantidade de água aplicada como preparação do solo e plantio;
- ii. Custos que dependem indiretamente da quantidade de água aplicada como fertilizantes, controle de pragas e doenças;
- iii. Custos que dependem diretamente da quantidade de água aplicada como custo da água, mão-de-obra para irrigar e eletricidade;
- iv. Custos que dependem diretamente da quantidade produzida como colheita, manuseio, transporte.

## 2.6 Conceitos Econômicos

A seguir iremos demonstrar alguns conceitos econômicos, iniciando com o de receita bruta para posteriormente fazer a junção de água e receita.

Receita bruta (RB) é o valor monetário que obtemos a partir de uma transação comercial, isto é, decorrente da venda de bens e/ou serviços em um dado período, no nosso caso, o valor total que recebemos pela venda dos produtos agrícolas (Equação 7).

$$\text{Receita bruta} = P.D \quad (7)$$

Onde: P = Preço;

D = Demanda, também chamado de Número de Unidades Vendidas.

A relação entre preço e demanda (Equação 8) é uma relação linear da forma:

$$P = a - b.D \quad (8)$$

Para  $0 \leq D \leq a/b$  e  $a$  e  $b > 0$  onde:

$a$  = ponto de interseção com o eixo dos preços;

$b$  = quantidade onde a demanda aumenta para cada unidade de decréscimo no preço.

Assim podemos reescrever a Equação anterior como a Equação 9 a seguir:

$$D = \frac{a - P}{b}, \text{ com } b \neq 0, \quad (9)$$

E que (Equação 10):

$$RB = (a - bD) D = aD - bD^2 \quad (10)$$

Para  $0 \leq D \leq a/b$  e  $a$  e  $b > 0$ .

Pela teoria de máximos e mínimos, para obtermos a demanda máxima  $D^*$ , sua derivada tem de ser igual a zero, então (Equação 11):

$$\frac{dRB}{dD} = a - 2bD = 0 \quad (11)$$

Assim (Equação 12):

$$D^* = \frac{a}{2b} \quad (12)$$

A derivada da receita bruta em relação à demanda, chamamos de receita marginal, ainda pelo cálculo diferencial deveremos ter esta derivada negativa, desta forma, derivando novamente vem (Equação 13):

$$\frac{d^2RB}{dD^2} = -2b \quad (13)$$

O outro conceito é o custo e estes podem ser fixos ou variáveis.

- 1) Custos fixos - são aqueles fixos em relação ao processo, ou seja, não sofrem alteração em decorrência do aumento ou da diminuição da produção, como por exemplo: aluguel, vigilância, etc...
- 2) Custos variáveis - são aqueles que dependem diretamente do volume produzido ou volume de vendas efetivado num determinado período, como por exemplo: Comissões, Matérias-Primas, Insumos produtivos como água, eletricidade, etc...


E definimos custo total como sendo a soma dos custos fixos + custos variáveis (Equação 14).

$$C_T = C_F + C_v \quad (14)$$

Sendo o custo variável o produto do custo variável unitário (cv) pela demanda, isto é (Equação 15):

$$C_v = cv.D \quad (15)$$

Observando o gráfico da Figura 15, que junta estes conceitos, podemos finalizar a análise com as equações a seguir.



**Figura 15.** Funções de custo, receita bruta e ponto de equilíbrio. Fonte: Frizzzone, 2005.

Os pontos chaves da análise são:

- PE1, que é o ponto de equilíbrio inferior, que é o ponto onde para se ter lucro devemos aumentar a demanda;
- PE2, que é o ponto de equilíbrio superior, é exatamente o contrário, isto é, para se ter lucro devemos diminuir a demanda;

- E o ponto de máximo lucro  $D^*$ .

Finalmente o interesse de todos é o lucro líquido máximo; sabendo: o lucro total – LT é igual a receita total menos os custos totais (Equação 16):

$$LT = RB - C_T \quad (16)$$

Podemos reescrever como (Equação 17):

$$LT = (aD - bD^2) - (C_f - c_v.D) \quad (17)$$

Rearrmando os termos (Equação 18):

$$LT = -C_F + (a - c_v)D - bD^2 \quad (18)$$

Desta forma, para obtermos lucro teremos que satisfazer duas condições, já que a nossa equação é do segundo grau e teremos duas raízes:

- 1)  $(a - c_v) > 0$ : O preço unitário para demanda zero tem que ser maior que o custo variável unitário para evitar que a demanda seja negativa; e
- 2) A receita bruta tem que ser maior que o custo total no período observado.

Novamente nos valendo do cálculo para obter o lucro máximo vem (Equação 19):

$$\frac{dLT}{dD} = a - c_v - 2bD = 0 \quad (19)$$

Então o valor que maximiza o lucro é (Equação 20):

$$D^* = \frac{a - c_v}{2b} \quad (20)$$

E derivando novamente para verificar que a segunda derivada seja negativa vem (Equação 21):

$$\frac{d^2LT}{dD^2} = -2b \quad (21)$$

Até o momento, em nossas investigações, não conseguimos identificar uma solução viável para a irrigação uniforme em toda a área cultivada. Portanto, a maximização da produtividade em toda a extensão da área de cultivo permanece um desafio não resolvido.

A busca pela irrigação ideal, que asseguraria o máximo potencial de produção, está fundamentada na premissa de uma distribuição uniforme de água por toda a área cultivada. Contudo, na prática, a consecução desse ideal muitas vezes se depara com desafios consideráveis. Aspectos como a topografia do terreno, a disponibilidade de água, os custos associados à instalação de sistemas de irrigação uniforme e outras variáveis complexas frequentemente tornam difícil ou inviável a obtenção de uma irrigação homogênea em toda a extensão da área cultivada.

Como resultado, em áreas onde a irrigação não pode ser uniforme, algumas partes da plantação podem receber mais água do que o necessário, enquanto outras podem receber menos. Essa variação na disponibilidade de água pode afetar o crescimento e o rendimento das culturas de maneira desigual, resultando em uma produção subótima em algumas partes da área cultivada.

Portanto, apesar de ser desejável atingir o máximo potencial de produção em toda a área, na prática, a variabilidade na irrigação pode levar a limitações na produtividade. Isso destaca a importância de estratégias de gestão de irrigação eficazes e da otimização do uso de recursos hídricos para obter o melhor desempenho possível nas condições disponíveis.

Uma análise matemática típica é feita considerando  $w_m$  como a lâmina de água aplicada (mm) capaz de promover a maior produtividade média e a função de produção  $Y$ , sendo uma relação funcional entre os vários insumos ( $U$ ) e produto, considerará apenas a água e desta forma, poderemos escrever que  $y(w)$  é a função de produção água-cultura por unidade de área ( $\text{kg.ha}^{-1}$ ).

Retornando ao conceito de máximos e mínimos do cálculo diferencial, temos (Equação 22):

$$\frac{\partial y(w)}{\partial w} = 0 \quad (22)$$

E considerando que a função  $y(w)$  é um polinômio de 2º grau (Equação 23):

$$y(w) = r_0 + r_1 w + r_2 w^2 \quad (23)$$

Assim (Equação 24):


$$\frac{\partial y(w)}{\partial w} = r_0 + r_1 w + 2 r_2 w \rightarrow w_m = - r_1 / 2 r_2 \quad (24)$$

Substituindo (Equação 25):

$$y(w_m) = r_0 - \frac{r_1^2}{4r_2} \quad (25)$$

“A receita bruta da unidade técnica é igual à produção da cultura multiplicada pelo preço do produto. Assim, as funções de produção água-cultura e de receita bruta tem a mesma forma geral. Portanto a quantidade de água que maximiza a produção por unidade de área ( $w_m$ ) também maximiza a receita bruta. Neste ponto, a eficiência marginal da utilização de água é zero, uma vez que a aplicação de um volume adicional de água não produz acréscimo na produção” (FRIZZONE, 2007).

Então, se a quantidade de água for inferior a  $w_m$ , a eficiência marginal de um incremento de água será maior que zero, e irá produzir um incremento de produção, ou seja, a eficiência marginal é inversamente proporcional a quantidade de água aplicada.



**Figura 16.** Intervalo para o manejo racional. Fonte: Frizzzone, 2007.

Frizzzone diz que: “A relação entre a quantidade de água aplicada e o custo total de produção denomina-se função custo e pode ser representada por uma linha reta.” Assim podemos reescrever a função custo total de produção em relação a água como sendo (Equação 26):

$$c(w) = c_o + h(w) + c_w.w \quad (26)$$

Onde:

$c_o$  = custos fixos de produção por unidade de área ( $R\$.ha^{-1}$ );

$h(w)$  = custos que dependem indiretamente da quantidade de água aplicada ( $R\$.ha^{-1}$ );

$c_w$  = custos que dependem diretamente da quantidade de água aplicada ( $R\$.m^{-3}$ );

$w$  = volume de água aplicada por unidade de área ( $m^3.ha^{-1}$ ).

Considerando fixos os custos  $c_o$  e  $h(w)$  constantes (Equação 27):

$$c(w) = c_f + c_w.w \quad (27)$$

E que a receita líquida com área irrigada  $x$  pode ser expressa da seguinte forma (Equação 28):

$$Z(w) = x(py(w) - c_o - h(w) - c_w.w) \quad (28)$$

Assim (Equação 29):

$$Z(w) = x(py(w) - c_f - c_w.w) \quad (29)$$

Para maximizar a receita líquida, Frizzzone (1986), utilizou uma aproximação analítica para otimizar a irrigação. Foi utilizada a receita líquida por área e determinada a lâmina de



água que maximiza  $Z(w)$ , isto é, temos a derivada primeira igual a zero, resultando em (Equação 30):

$$\frac{\partial y(w)}{\partial w} = \frac{c_w}{p} \quad (30)$$

Observamos a utilização do insumo água como única variável.

Visualizando a receita líquida maximizada de  $w^*$ , que é inferior a  $w_m$ , obtemos a declividade da reta de custo igual a declividade de custo da receita bruta.

Para uma quantidade de água maior que  $w^*$ , a reta de custo tem uma declividade (reta tangente ao ponto) maior que a curva de receita bruta.

Conforme Figura 16, ao observar o intervalo entre  $w^*$  e  $w_m$ , vemos a possibilidade da redução de custos, devido a menor quantidade de água, reduzindo o capital e alguns custos fixos e variáveis tais como eletricidade para as bombas de irrigação ou o diesel dos geradores elétricos.

Então (Equação 31):

$$\max Z(w) = x(py(w) - c_f - c_w \cdot w) \quad (31)$$

Sendo este o objetivo do produtor, assim uma estratégia de maximização de lucro irá permitir se utilizar menos água por unidade de área que a de maximização da produção. A quantidade ótima de água representa somente um ponto sobre a curva de produção, tendo pouco significado na prática. Na busca pela eficiência na produção agrícola, é comum delinear uma faixa específica de lâmina de irrigação. Este intervalo visa maximizar a produtividade, resultando em uma receita líquida superior à obtida em condições de ausência de irrigação.

Pesquisas indicam que em determinadas situações, as economias advindas do déficit de irrigação estão associadas ao aumento da eficiência na irrigação, à redução dos custos de irrigação e aos custos oportunos da água (ENGLISH, et al. 1990). Dessa forma, ao empregar uma quantidade menor de água, os produtores têm a oportunidade de diminuir os custos de capital e outros custos fixos. Na prática, a experiência demonstra que, quando a disponibilidade de terra é um fator limitante para a produção, a utilização de irrigação com déficit pode resultar em retornos econômicos superiores em comparação com a irrigação plena (DELGADO, et al. 2010).

Isto pode ser visualizado na Figura 17, onde observamos que existe um intervalo de lâmina de água onde a irrigação com déficit é mais rentável que a irrigação plena. O limite inferior é nomeado  $w_{el}$  o qual resulta numa receita líquida equivalente a produzida por uma quantidade de água  $w_m$ .

Uma análise adicional que podemos fazer é que no intervalo entre  $w_m$  e  $w_{el}$ , se a amplitude é muito grande, o risco associado à decisão é relativamente pequeno, e um intervalo pequeno implica que tem de ser tomado um grande cuidado no manejo da irrigação, e o valor ótimo neste intervalo é nomeado por  $w^*$  e é obtido pela Equação 32:

$$\left( \frac{dy}{dw} p \right) = c_w \quad (32)$$

Se utilizarmos o mesmo polinômio de segundo grau que representa a função de produção água-cultura (Equação 33):

$$r_1 + 2r_2w = \frac{c_w}{p} \rightarrow w^* = \frac{cw - p.r_1}{2r_2.p} \quad (33)$$

Qualquer que seja a quantidade de água entre  $w_{el}$  e  $w_m$  irá produzir uma receita líquida por unidade de área maior que a obtida pela irrigação plena. O valor de  $w_{el}$ , para o qual a receita líquida é igual aquela que se consegue com  $w_m$ , é obtido pela solução do seguinte conjunto das Equações 34 e 35:

$$Z(w_{el}) = x(py(w_{el}) - c_f - c_w.w_{el}) \quad (34)$$


$$Z(w_m) = x(py(w_m) - c_f - c_w.w_m) \quad (35)$$

Substituindo  $y(w_m)$  e  $y(w_{el})$  nas equações anteriores, a quantidade de água  $w_{el}$  é encontrada para  $Z(w_{el}) = Z(w_m)$  o que resulta em (Equação 36):

$$pr_2w_{el}^2 + (pr_1 - c_w)w_{el} + \left(\frac{pr_1^2}{4r_2} - \frac{c_w r_1}{2r_2}\right) = 0 \quad (36)$$

Usando a formula de Báskara temos os coeficientes a, b c da seguinte forma (Equação 37):

$$a = pr_2, b = (pr_1 - c_w), c = \left(\frac{pr_1^2}{4r_2} - \frac{c_w r_1}{2r_2}\right) \quad (37)$$



**Figura 17.** Custos, receita bruta e receita líquida para a produção do feijoeiro. Fonte: Frizzzone, 2007.

## 2.7 Agricultura 4.0

A Agricultura 4.0 refere-se a uma revolução tecnológica na agricultura que incorpora avanços digitais e tecnológicos para otimizar os processos agrícolas. Essa abordagem busca integrar as tecnologias da informação e comunicação (TIC) na produção agrícola, visando aumentar a eficiência, a sustentabilidade e a rentabilidade.

Alguns dos principais elementos da Agricultura 4.0 incluem:

1. Internet das Coisas (IoT): Sensores e dispositivos conectados coletam dados em tempo real sobre condições do solo, clima, culturas e máquinas agrícolas;
2. Big Data: Análise de grandes conjuntos de dados para obter insights valiosos sobre padrões climáticos, práticas agrícolas, otimização de culturas, entre outros;
3. Inteligência Artificial (IA): Sistemas de IA podem processar dados, fazer previsões e recomendar decisões para melhorar a gestão agrícola;
4. Automatização e Robótica: Uso de drones, tratores autônomos e robôs para realizar tarefas agrícolas de forma mais eficiente e precisa;
5. Agricultura de Precisão: Aplicação de insumos agrícolas (água, fertilizantes, pesticidas) de maneira precisa e personalizada, com base em dados detalhados;
6. Blockchain: Rastreabilidade e garantia de qualidade dos produtos agrícolas, proporcionando maior transparência na cadeia de suprimentos.

A Agricultura 4.0 visa criar sistemas agrícolas mais sustentáveis, reduzir o desperdício, aumentar a produtividade e melhorar a resiliência das atividades agrícolas diante de desafios como mudanças climáticas e escassez de recursos. Essa abordagem busca transformar a agricultura tradicional em um setor mais conectado, eficiente e inovador.

## 2.8 Desenvolvimento Nativo e Híbrido

Ao se planejar a criação de um aplicativo devemos pensar qual o tipo de aplicativo será desenvolvido, nativo ou híbrido. O aplicativo deve oferecer uma boa experiência com o usuário, sendo necessário analisar qual o tipo de desenvolvimento vai suprir tais necessidades. No entanto, as duas opções apresentam tempos diferentes de desenvolvimento de acordo com o objetivo e custo.

Segundo Madureira (2017), o aplicativo nativo é codificado na linguagem de cada sistema operacional, onde cada uma das plataformas apresenta seus elementos e ferramentas de interface. O aplicativo nativo é desenvolvido para utilização em uma plataforma específica, como iOS ou Android, sendo capaz de explorar todas as potencialidades da plataforma para a qual foi criado, conseguindo ter acesso a todos os recursos disponíveis dos aparelhos como GPS, câmera, calendário, lista de contatos etc... É importante frisar que os desenvolvedores respeitam a um padrão de design, que são oferecidos para cada sistema operacional, como um guia.

“Não é aprovada a ideia de ter que repetir todo o trabalho mais de uma vez em linguagens de programação diferentes. Além da perda de tempo em fazer o trabalho, falhas encontradas posteriormente provavelmente também terão que ser corrigidas mais de uma vez.” (MADUREIRA, 2017, n. p.).

A criação de um aplicativo nativo implica a necessidade de desenvolvimento específico para cada plataforma, demandando a produção de códigos distintos. Adicionalmente, a reutilização de códigos é inviável, uma vez que cada plataforma exige uma

abordagem única para o desenvolvimento do aplicativo. Isso resulta em custos mais elevados, já que a linguagem de programação é própria e específica para cada plataforma, aumentando a complexidade do processo de desenvolvimento.

O desenvolvimento de um aplicativo com tecnologia híbrida é mais rápido e tem um custo menor devido o código ser desenvolvido somente uma vez e poder ser distribuído em várias plataformas.

O aplicativo híbrido pode ser construído utilizando diversas linguagens e frameworks como as linguagens HTML5, CSS e JavaScript ou ainda frameworks como IONIC ou FLUTTER assim como um site mobile. A manutenção também possui um custo menor, pois a mão de obra é mais genérica e mais fácil de ser encontrada no mercado.

Uma das características que mais diferenciam o aplicativo nativo do aplicativo híbrido é justamente o seu processo de desenvolvimento. Para desenvolver uma aplicação nativa, como mencionado na definição, temos que ter em mente que cada dispositivo tem seu próprio processo de desenvolvimento exclusivo. Em contrapartida para desenvolver uma aplicação híbrida, o desenvolvimento é iniciado com uma única implementação, essa implementação é testada e compilada de forma única, e atribuída simultaneamente às plataformas existentes no mercado.

O OTIMAGRI foi desenvolvido com a linguagem de desenvolvimento Xamarin, de tecnologia híbrida. O aplicativo foi avaliado através de trabalhos científicos, como os de culturas alface americana (SILVA, 2005) e meloeiro (MONTEIRO, et al. 2008).

Devido ao fato de termos acesso a estes dados economizamos tempo na execução destes experimentos pois não houve a necessidade de implementarmos nossos próprios experimentos *in loco*, para teste da ferramenta OTIMAGRI.

### **3. MATERIAL E MÉTODOS**

Neste capítulo é descrito os material e métodos utilizados para o desenvolvimento da pesquisa e a elaboração da ferramenta computacional inteligente – OTIMAGRI.

#### **3.1 Descrição da Solução**

Para ajudar os produtores a maximizar o seu lucro e minimizar a utilização de insumos e recursos naturais, foi desenvolvido um aplicativo, de baixo custo, composto em seu núcleo (core) de uso de uma técnica da inteligência artificial, denominada Otimização por Enxame de Partículas (PSO), que é um algoritmo de otimização que será aplicado para uma determinada cultura, se utilizando para tal o modelo de uma função de produção para os diversos parâmetros de interesse, onde se encontram disponíveis dados obtidos experimentalmente e outros obtidos através do uso de técnicas matemáticas computacionais. Dentre esses métodos, destacamos o experimental e o Método de Barreira Logarítmica (DELGADO et al., 2010), Pontos Interiores (CARVALHO, et al., 2009), além do modelo INTELIAAGRI (CAVALCANTE JUNIOR, 2013) que utiliza duas outras técnicas de Inteligência Artificial (as redes neurais e algoritmos genéticos) que serão usados para confrontar com os resultados obtidos neste trabalho.

O aplicativo foi projetado com uma abordagem híbrida, o que o coloca em posição de atender às necessidades dos dois principais protagonistas de Sistema Operacional (SO) de smartphones do mercado atual. Essa abordagem permite que uma ampla gama de usuários potenciais possa utilizá-lo com facilidade. No que se refere ao cadastramento das funções de produção, os usuários desfrutem de uma considerável flexibilidade para criar e armazenar várias funções em seu banco de dados. Essa característica confere ao aplicativo uma notável versatilidade, sendo aplicável em diversas áreas do conhecimento.

#### **3.2 Equipamento Utilizado**

Para o desenvolvimento do protótipo foi utilizado como equipamento um computador MacBook Pro (Retina, 13-inch, Early 2015), com processador 2,9 GHz Intel Core i5 Dual-Core, memória RAM de 8 GB 1867 MHz DDR3, gráficos Intel Iris Graphics 6100 1536 MB e sistema operacional macOS Monterey 12.5.1, 64 bits.

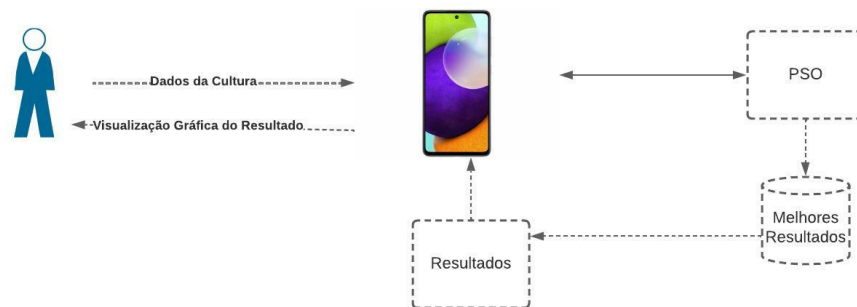
Os testes foram efetuados em um smartphone moto g10, com 64 GB de armazenamento e sistema operacional Android.

#### **3.3 Software Desenvolvido**

Considerando que a administração de atividades agropecuárias requer de conhecimentos técnicos, financeiros e de otimização em seus processos e tomada de decisão, foi concebido dentro da filosofia da Agricultura 4.0 o aplicativo OTIMAGRI, cuja finalidade como produto de inovação tecnológica é participar nas tomadas de decisões agrícolas, onde a análise econômica e o uso racional dos recursos disponíveis são relevantes.

O aplicativo foi desenvolvido utilizando-se a forma híbrida, na linguagem de programação Xamarin e disponibilizado para celulares com o sistema operacional que atendem a maior fatia do mercado de smartphone: Android da empresa Google e IOS da empresa Apple. Além disso, o aplicativo foi concebido com o pensamento de ser um mecanismo generalista, isto é, o usuário poderá utilizar para verificar o algoritmo com qualquer função que desejar. Desta forma, fica extremamente simples implementar novas

funções que levem em consideração diversos outros insumos. A Figura 18 representa o diagrama macro do sistema OTIMAGRI proposto.



**Figura 18.** Diagrama do OTIMAGRI. Fonte: Villas Bôas Junior, 2021.

### 3.4 Modelagem do Aplicativo

Para documentação do desenvolvimento do aplicativo foi utilizado a metodologia de orientação a objetos e foram produzidos os seguintes artefatos:

Diagrama de Casos de Uso: O diagrama de casos de uso identifica os principais atores (usuários ou sistemas externos) e os casos de uso que descrevem as principais funcionalidades do sistema. Para a criação do aplicativo, temos três atores principais:

- I) Usuário: Representa o usuário do sistema;
- II) Sistema Externo: Representa um sistema externo que pode interagir com o sistema;
- III) Algoritmo PSO: Representa o algoritmo de otimização PSO.

Os casos de uso principais são:

#### a) Incluir função matemática

Ator Principal: Usuário

Breve Descrição: Este caso de uso permite que o usuário insira uma nova função matemática no sistema. O usuário fornece um nome e uma expressão matemática para a função que deseja adicionar. O sistema valida os dados inseridos e armazena a função matemática para uso posterior.

#### b) Alterar função matemática

Ator Principal: Usuário

Breve Descrição: Este caso de uso permite que o usuário faça alterações em uma função matemática existente no sistema. O usuário seleciona a função que deseja modificar, faz as alterações necessárias na expressão ou nome da função, e o sistema atualiza os dados da função no sistema.

### **c) Consultar função matemática**

Ator Principal: Usuário

Breve Descrição: Este caso de uso permite que o usuário pesquise e visualize informações sobre funções matemáticas armazenadas no sistema.

### **d) Remover função matemática**

Ator Principal: Usuário

Breve Descrição: Este caso de uso permite que o usuário exclua uma função matemática do sistema. O usuário seleciona a função que deseja remover, confirma a ação e o sistema exclui permanentemente a função do banco de dados.

### **d) Otimizar com PSO**

Ator Principal: Usuário

Breve Descrição: Este caso de uso envolve a otimização de uma função matemática específica usando o algoritmo Particle Swarm Optimization (PSO). O usuário seleciona a função alvo e configura os parâmetros relevantes para a otimização. O sistema utiliza o algoritmo PSO para encontrar um valor otimizado para a função, e o resultado é apresentado ao usuário.

Esses casos de uso representam as principais funcionalidades do sistema e descrevem como os atores (usuário, sistema externo e algoritmo PSO) interagem com o sistema para realizar diferentes tarefas relacionadas às funções matemáticas e à otimização com o algoritmo PSO. Cada caso de uso pode ser detalhado com cenários específicos, pré-condições, pós-condições e exceções, conforme necessário para uma documentação completa do sistema.

Diagrama de Classes: O diagrama de classes descreve as classes no sistema, seus atributos e relacionamentos.

Este diagrama de classes representa as principais classes do sistema, seus atributos e relacionamentos.

### **a) Classe Função Matemática**

Atributos:

Nome (string): O nome atribuído à função matemática.

Expressão (string): A expressão matemática associada à função.

Variáveis (int): Indica o número de insumo que a função possui.

Restrição (string): Indica as restrições que a fórmula matemática possui.

Relacionamentos: nenhum relacionamento direto com outras classes, mas é referenciada por outras classes para manipulação e consulta.

### **b) Classe Sistema:**

Atributos: nenhum atributo específico, pois esta classe é responsável por operações com funções matemáticas.

Métodos: IncluirFuncaoMatematica (nome: string, expressao: string): Realiza a inclusão de uma nova função matemática no sistema.

**AlterarFuncaoMatematica** (nome: string, novaExpressao: string): Realiza a alteração de uma função matemática existente.

**ConsultarFuncaoMatematica** (nome: string): Permite a consulta de uma função matemática com base em seu nome.

**RemoverFuncaoMatematica** (nome: string): Remove uma função matemática do sistema com base em seu nome.

**Relacionamentos:** associação com a classe Função Matemática para operações de inclusão, alteração, consulta e remoção de funções matemáticas.

## **b) Classe Algoritmo PSO:**

**Atributos:** nenhum atributo específico, pois esta classe é responsável pela execução do algoritmo PSO.

**Métodos:** **Otimizar** (funcao: FuncaoMatematica, parametros: ParametrosOtimizacao): Executa o algoritmo PSO para otimizar uma função matemática específica com base nos parâmetros fornecidos.

**Relacionamentos:** associação com a classe Função Matemática para indicar a função alvo da otimização.

## **c) Classe Parâmetros Otimização:**

**Atributos:** parâmetros específicos do algoritmo PSO, como número de partículas, número de iterações, coeficientes de inércia, limites de busca, etc.

**Relacionamentos:** pode ser utilizado pela classe AlgoritmoPSO para configuração da otimização.

### **Diagrama de Sequência (Otimização com PSO):**

O diagrama de sequência mostra a interação entre objetos em um cenário específico, neste caso, a otimização com o algoritmo PSO. Neste exemplo de diagrama de sequência, podemos ver a interação entre as classes "Sistema" e "AlgoritmoPSO" para otimizar uma função matemática. O processo começa com o usuário solicitando a otimização de uma função específica. O sistema interage com a classe "AlgoritmoPSO" para executar a otimização, que envolve várias iterações até que um resultado otimizado seja alcançado.

Abaixo a descrição dos passos do diagrama de sequência que mostra a interação entre os objetos e as mensagens trocadas durante o processo de otimização com o algoritmo PSO.

### **Título do Diagrama de Sequência: Otimização com PSO**

#### **Participantes:**

- Ator Principal: Usuário
- Objeto 1: Sistema
- Objeto 2: AlgoritmoPSO

#### **Descrição do Diagrama de Sequência:**

I. O usuário inicia o processo de otimização selecionando a função matemática alvo e configurando os parâmetros da otimização. Isso é representado por uma mensagem (seta vertical) do usuário para o objeto Sistema, indicando a solicitação de otimização.



II. O objeto Sistema recebe a solicitação do usuário e encaminha a função matemática selecionada para o objeto AlgoritmoPSO, juntamente com os parâmetros de configuração. Isso é representado por uma mensagem do objeto Sistema para o objeto AlgoritmoPSO, incluindo os dados relevantes.

III. O objeto AlgoritmoPSO começa o processo de otimização, utilizando o algoritmo Particle Swarm Optimization (PSO). O algoritmo PSO executa várias iterações para encontrar a solução otimizada.

IV. Durante cada iteração, o objeto AlgoritmoPSO atualiza o estado das partículas e calcula o valor otimizado da função. Isso é representado por mensagens de ida e volta entre o objeto AlgoritmoPSO e ele mesmo, indicando as iterações do algoritmo.

V. Após a conclusão do processo de otimização, o objeto AlgoritmoPSO retorna o resultado da otimização (valor otimizado da função) para o objeto Sistema. Isso é representado por uma mensagem do objeto AlgoritmoPSO para o objeto Sistema, transmitindo o resultado.

VI. O objeto Sistema apresenta o resultado da otimização ao usuário, que pode visualizar o valor otimizado da função. Isso é representado por uma mensagem do objeto Sistema para o usuário, comunicando o resultado da otimização.

VII. O usuário recebe o resultado da otimização e o processo é concluído.

Este diagrama de sequência descreve a interação entre o usuário, o sistema e o objeto AlgoritmoPSO durante o processo de otimização com o algoritmo PSO. Ele ilustra como as mensagens são trocadas entre os participantes e como o algoritmo PSO é executado para encontrar a solução otimizada da função matemática selecionada.

### **3.5 Interface do Aplicativo**

A interface do usuário (UI) é a parte do sistema com a qual o usuário interage para realizar tarefas, inserir dados, visualizar informações e receber feedback do sistema. No contexto do sistema, que envolve funções matemáticas e otimização com o algoritmo PSO, a interface do usuário desempenha um papel importante em facilitar a interação do usuário com o software. Abaixo, são descritas algumas características e elementos que podem estar presentes na interface do usuário:

#### **1. Página Inicial:**

A interface do usuário começa com uma página inicial que fornece uma visão geral do sistema.

#### **2. Menu de Navegação:**

Um menu de navegação permite que o usuário acesse diferentes partes do sistema, como “Tela Principal”, “Cadastrar Função” e “Otimizar com PSO”. Cada opção de menu leva a uma página ou tela correspondente.

#### **3. Formulários de Entrada:**

Para incluir ou alterar funções matemáticas, a UI apresenta formulários de entrada onde o usuário pode inserir o nome e a expressão da função.

#### 4. Lista de Resultados:

Após a pesquisa, uma lista de resultados é exibida, mostrando as funções matemáticas correspondentes. Cada item na lista pode ser clicável para exibir detalhes completos da função.

#### 5. Botões de Ação:

Para ações como "Incluir Função", "Alterar Função" e "Remover Função", botões de ação podem ser apresentados na interface para permitir que o usuário execute essas ações.

#### 6. Configuração de Parâmetros:

Na tela de otimização com PSO, a UI inclui campos para que o usuário configure os parâmetros relevantes para a otimização, como o número de partículas, número de iterações etc.

#### 7. Botão de Início de Otimização:

Um botão "Iniciar Otimização" ou equivalente é fornecido para iniciar o processo de otimização com base nos parâmetros configurados.

#### 8. Exibição de Resultados de Otimização:

Após a conclusão da otimização, a interface exibe o valor otimizado da função e outras métricas relevantes.

#### 9. Feedback e Mensagens de Erro:

A UI fornece feedback claro ao usuário após a execução de ações, indicando sucesso ou mensagens de erro, quando apropriado.

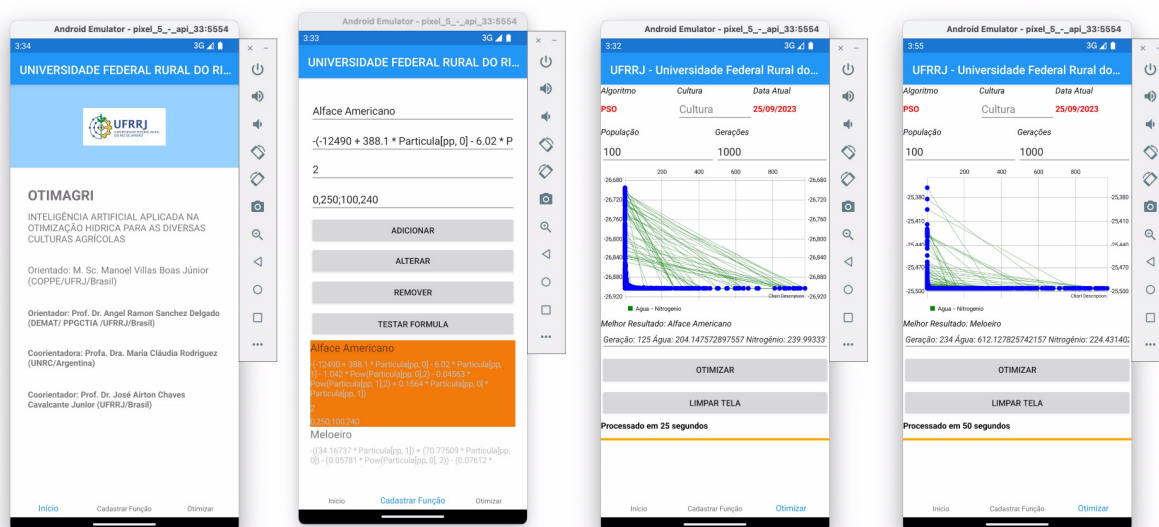
#### 10. Layout Responsivo:

A interface do usuário foi projetada para ser responsiva, ou seja, deve funcionar bem em diferentes dispositivos.

#### 11. Design de Interface Atraente:

Foi definido um design de interface atraente e intuitivo, sendo importante para a usabilidade do sistema, incluindo o uso de cores, ícones e layout que tornem a interação agradável e eficiente.

A Figura 19 demonstra a interface desenvolvida para ser utilizada no aplicativo OTIMAGRI.



**Figura 19.** Interface OTIMAGRI. Fonte: Villas Bôas Junior, 2021.

### 3.6 Configuração dos Testes do Modelo PSO

O modelo do PSO, adotado para ser implementado no problema de otimização do lucro líquido de uma cultura corresponde ao modelo básico do algoritmo do PSO. Cada indivíduo do PSO consiste em um vetor de 2 posições (primeira posição correspondente a água e a segunda posição correspondente a nitrogênio), cada posição do indivíduo é representada por um valor real no intervalo, que representa o intervalo das variáveis.

Na implementação do PSO a função objetivo (fitness), que serve para medir a capacidade daquele indivíduo de resolver um determinado problema, foi implementada utilizando o seguinte método: foram selecionadas as culturas alface americana (SILVA, 2005) (Equação 38) e meloeiro (MONTEIRO et al., 2008) (Equação 39).

$$y(w,n) = -12.490 + 388,1w - 6,02n - 1,042w^2 - 0,04563n^2 + 0,1564wn \quad (38)$$

Onde:  $y(w,n)$  = Produtividade da alface americana em  $kg.ha^{-1}$ ;

$r^2 = 0,8311$ ;

$w$  = Lâmina de água, em mm;

$n$  = Dose de nitrogênio, em  $kg.ha^{-1}$ ;

Em que o domínio de  $w$  e  $n$  está restrito à caixa bidimensional  $[0, 250] \times [100, 240]$  e:

$$y(w,n) = 34,16737n + 70,77509w - 0,05781w^2 - 0,07612n^2 \quad (39)$$

Onde:  $y(w,n)$  = produtividade de meloeiro em  $kg.ha^{-1}$ ;

$r^2 = 0,9962$ .

Em que o domínio de  $w$  e  $n$  está restrito à caixa bidimensional  $[0, 700] \times [0, 350]$ .

O preço adotado para alface americana foi de R\$ 0,80  $kg^{-1}$ . O custo para água de R\$ 0,44  $mm \cdot ha^{-1}$  e para nitrogênio R\$2,09  $kg^{-1}$ . Já para o melão foi calculado um preço de R\$

0,40 kg<sup>-1</sup> e de R\$ 0,134 mm\*ha<sup>-1</sup> para água. Na época, o preço do nitrogênio era R\$ 2,33 kg<sup>-1</sup>. Note que o coeficiente de determinação ( $r^2$ ) da alface americana indica que 83,11% da variação do rendimento em função dos níveis de água e nitrogênio podem ser explicadas pela Equação 38. Analogamente para a cultura do melão, a Equação 39 indica 99,62% de ajuste.

Os parâmetros do PSO foram utilizados variando da seguinte forma:

- População: 100 e 500
- Gerações: 1000
- Semente: 42
- C1 (constante Pb): 0.1 até 3.9
- C2 (constante Gb): 3.9 até 0.1

Onde  $C1 + C2 = 4$  e W (inercia) variando de 0.5 até 0.9.

## 4. RESULTADOS E DISCUSSÃO

Nesta seção, o objetivo é avaliar o desempenho do OTIMAGRI quando aplicado ao problema da maximização da receita líquida na produção agrícola. Uma atenção especial deve ser dada aos valores a serem aplicados aos parâmetros  $w$ ,  $C_1$  e  $C_2$  do PSO, pois os mesmos influenciam diretamente o desempenho do algoritmo.

Os valores dos parâmetros  $C_1$  e  $C_2$  são abordados em várias pesquisas reportadas na literatura sugerem a adoção de valores diferentes para os parâmetros  $C_1$  e  $C_2$  desde que satisfaçam  $C_1 + C_2 = 4.0$ . Durante a fase de validação do aplicativo foi executado vários testes com diversos valores para os parâmetros  $C_1$  e  $C_2$ , não encontrando nenhum resultado que indicasse contradição em utilizar os valores já referenciados na literatura.

Com relação ao parâmetro  $w$  foram efetuados testes de sensibilidade do comportamento do algoritmo, principalmente no intervalo 0.5 e 0.9 com variação de 0.005, onde os valores altos de  $w$  favorecem a exploração global e os baixos a exploração local.

Outro parâmetro da configuração que influi no comportamento do PSO é o número de partículas (população) e dentro desta ótica todos os testes realizados foram feitos com populações de 100 e 500 partículas. Estes valores foram selecionados em função da comparação com os resultados já existentes na literatura.

### 4.1 Otimização da Produção de Alface Americana a Duas Dimensões com 100 Partículas

Os valores de comparação utilizados baseiam-se no estudo conduzido por Silva (2005).

Para maximização da produtividade na produção da cultura alface americana, o OTIMAGRI obteve valores compatíveis e até superiores, como mostra a Tabela 2, demonstrando a eficiência do algoritmo. O OTIMAGRI obteve um valor da produtividade máxima de 26.902,71 kg. ha<sup>-1</sup>, com 204,35 mm de água e 239,97 kg. ha<sup>-1</sup> de nitrogênio.

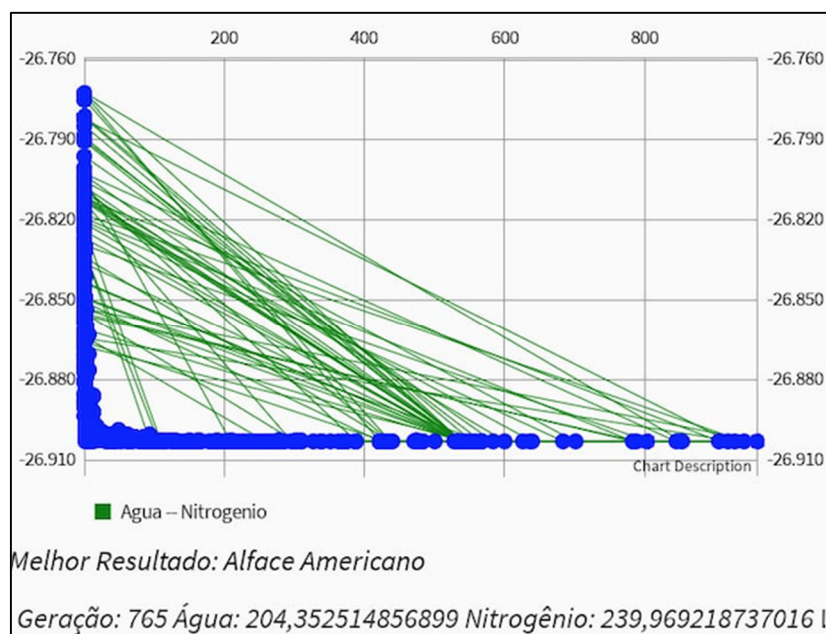
Os resultados são compatíveis com os obtidos em Silva (2005), onde foi registrada uma produtividade de 26.959,93 kg. ha<sup>-1</sup> com 205,26 mm de água e 257,14 kg. ha<sup>-1</sup> de nitrogênio.

**Tabela 2.** Comparativo entre métodos para a alface americana.

	OTIMAGRI	INTELIAGRI	MBL	PS
Água (mm.ha <sup>-1</sup> )	204,35	199,55	204,99	205,26
Nitrogênio (kg.ha <sup>-1</sup> )	239,97	234,96	249,99	257,14
Produtividade (kg.ha <sup>-1</sup> )	26.902,71	26.903,00	26.903,00	26.959,93

Fonte: Villas Bôas Junior, 2023.

Nos algoritmos de otimização, a função fitness é uma função matemática que atribui um valor numérico para cada indivíduo em um algoritmo de otimização, com base em quão bem ele se adequa ao objetivo do problema. Essa função é usada para avaliar o processo de aprendizado e comparar a qualidade das soluções candidatas em um processo de otimização. Assim, foi gerado o gráfico apresentado na Figura 20 mostrando o valor do melhor fitness encontrado em cada geração ao longo do tempo. Isso permite visualizar a melhoria do fitness ao longo das gerações e identificar se o algoritmo está convergindo para uma solução ótima.



**Figura 20.** Convergência PSO (alface americana). Fonte: Villas Bôas Junior, 2023.

#### 4.2 Otimização da Produção do Meloeiro a Duas Dimensões com 100 Partículas

Os valores de comparação utilizados baseiam-se no estudo conduzido por Monteiro et al. (2008).

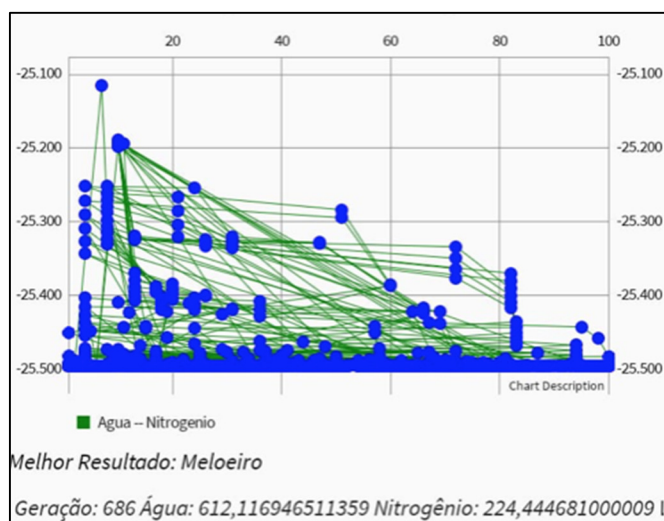
Para maximização da receita líquida na produção da cultura do meloeiro, o OTIMAGRI obteve valores compatíveis e até superiores, como mostra a Tabela 3, demonstrando a eficiência do algoritmo. O OTIMAGRI obteve um valor da produtividade máxima de 25.496,08 ha<sup>-1</sup> e uma receita líquida de R\$ 3.308,46, com 612,12 mm.ha<sup>-1</sup> de água e 224,44 kg.ha<sup>-1</sup> de nitrogênio. Os resultados também são compatíveis com os obtidos em Monteiro et al. (2008), onde foi registrada uma produtividade de 25.384,30 kg. ha<sup>-1</sup> e uma receita líquida de R\$ 3.353,25 com 609,20 mm de água e 186,23 kg. ha<sup>-1</sup> de nitrogênio.

**Tabela 3.** Comparativo entre métodos para o meloeiro.

	OTIMAGRI	INTELIAGRI	MBL	PS
Água (mm.ha <sup>-1</sup> )	612,12	630,11	612,30	609,20
Nitrogênio (kg.ha <sup>-1</sup> )	224,44	234,97	224,30	186,23
Produtividade (kg.ha <sup>-1</sup> )	25.496,08	25.467,00	25.469,00	25.384,30

Fonte: Villas Bôas Junior, 2023.

A Figura 21 demonstra o gráfico de aprendizado do algoritmo para o experimento do meloeiro ao longo das gerações, através da evolução do melhor fitness a cada geração.




**Figura 21.** Convergência PSO (meloeiro). Fonte: Villas Bôas Junior, 2023.

#### 4.3 Otimização da Produção de Alface Americana a Duas Dimensões com 500 Partículas

Os valores de comparação utilizados baseiam-se no estudo conduzido por Silva (2005).

Para maximização da produtividade na produção da cultura alface americana utilizando o PSO com 500 partículas, o OTIMAGRI obteve um valor de 204,41 mm de água e 239,99 kg. ha<sup>-1</sup> de nitrogênio.

O OTIMAGRI obteve valores muito próximos aos encontrados quando da utilização do PSO com 100 partículas, desta forma, indica que a diferença não produz um efeito que mereça ser levado em consideração, como mostra a Figura 22. Os resultados são compatíveis com os obtidos na literatura.



**Figura 22.** Resultado do PSO com 500 partículas para a alface americana. Fonte: Villas Bôas Junior, 2023.

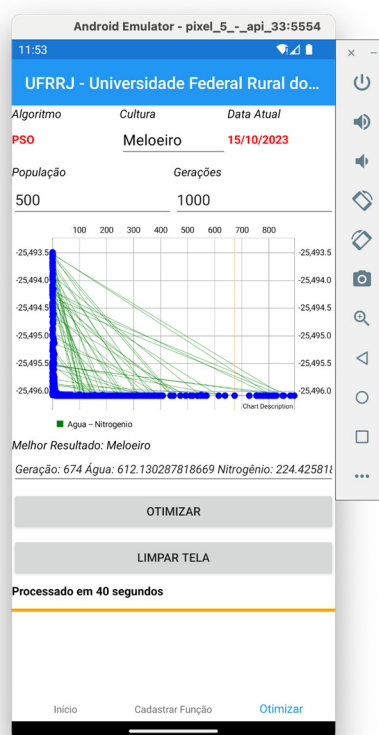
#### 4.4 Otimização da Produção do Meloeiro a Duas Dimensões com 500 Partículas

Os valores de comparação utilizados baseiam-se no estudo conduzido por Monteiro et al. (2008).

Para maximização da receita líquida na produção do meloeiro usando o PSO com 500 partículas, o OTIMAGRI obteve o valor de 612,13 mm de água e 224,42 kg. ha<sup>-1</sup> de nitrogênio.

O OTIMAGRI obteve valores muito próximos aos encontrados quando da utilização do PSO com 100 partículas, desta forma, indica que a diferença não produz um efeito que mereça ser levado em consideração, como mostra a Figura 23. Os resultados são compatíveis com os obtidos na literatura.





**Figura 23.** Resultado do PSO com 500 partículas para o meloeiro. Fonte: Villas Bôas Junior, 2023.

#### 4.5 Algoritmo Evolutivo de Aprendizado Incremental Baseado em População (PBIL)

O uso da inteligência artificial (IA) em pesquisas vem se destacando na resolução de problemas complexos, como a otimização do uso de insumos agrícolas. O estudo conduzido por Villas Bôas Junior (2022), que utilizou o algoritmo PBIL em conjunto com técnicas de IA para resolver o problema de otimização do uso de água e nitrogênio em culturas de alface americana e meloeiro, demonstra bons resultados.

Comparar os resultados obtidos pelo OTIMAGRI com os resultados de outras pesquisas que também utilizam IA, como PBIL e INTELIAGRI, é uma abordagem interessante para avaliar a eficácia do método. Isso fornece uma base sólida para analisar o desempenho relativo dos diferentes algoritmos e técnicas empregados na resolução desse desafio específico.

Os dados e informações apresentados nas Tabelas 4 e 5, que demonstram os resultados para a alface americana e o meloeiro, respectivamente, são valiosos para a comunidade acadêmica e a indústria agrícola. Essas comparações podem ajudar a identificar quais métodos se destacam na otimização do uso de insumos agrícolas, contribuindo para práticas mais eficientes e sustentáveis no setor.

Essa abordagem de pesquisa demonstra o potencial da IA na agricultura e como ela pode ser aplicada para resolver problemas complexos, promovendo a eficiência e a sustentabilidade na produção de alimentos. Continuar a explorar e aprimorar essas técnicas é um avanço da agricultura moderna.

**Tabela 4.** Comparativo entre métodos para a alface americana.

	<b>OTIMAGRI</b>	<b>INTELIAGRI</b>	<b>PBIL</b>
Água (mm.ha-1)	204,35	199,55	203,72
Nitrogênio (kg.ha-1)	239,97	234,96	239,80
Produtividade (kg.ha-1)	26.902,71	26.903,00	26.901,77

Fonte: Villas Bôas Junior, 2023.

**Tabela 5.** Comparativo entre métodos para o meloeiro.

	<b>OTIMAGRI</b>	<b>INTELIAGRI</b>	<b>PBIL</b>
Água (mm.ha-1)	612,12	630,11	611,58
Nitrogênio (kg.ha-1)	224,44	234,97	224,04
Produtividade (kg.ha-1)	25.496,08	25.467,00	25.496,10

Fonte: Villas Bôas Junior, 2023.

#### 4.6 Considerações dos Testes

Neste capítulo foi demonstrado os resultados obtidos pelo OTIMAGRI que são confrontados com cinco outros métodos, pelo método que utiliza programação separável (PS) (SILVA, 2005; MONTEIRO et al, 2008), com o resultado obtido pelo Método de Barreira Logarítmica – MBL (DELGADO et al, 2010), INTELIAGRI (CAVALCANTE JUNIOR, 2013) e Algoritmo Evolutivo de Aprendizado Incremental Baseado em População (PBIL) para Otimização Hídrica na Produção Agrícola (VILLAS BÔAS JUNIOR et al., 2023), que se utiliza de técnicas de Inteligência Artificial, na otimização do uso de dois insumos – água e nitrogênio, nas culturas de alface americana e do meloeiro, devido ao fato de termos os dados disponíveis na literatura destes quatro métodos para as referidas culturas, porém se deve salientar que o OTIMAGRI pode trabalhar com qualquer cultura a diversas variáveis, e não apenas a água e nitrogênio. Com os resultados obtidos, comprovamos que o modelo OTIMAGRI obtém resultados com valores na mesma ordem de grandeza e compatíveis com os modelos utilizados para comparação. A utilização do OTIMAGRI apresenta vantagens adicionais em comparação com os modelos citados, como o fato do usuário poder manter uma base funções. O equipamento (smartphones) é facilmente encontrado no mercado, o que facilita o acesso ao usuário. O OTIMAGRI tem a capacidade de lidar com funções de produção que não se restrinjam a forma paraboloide. Isso significa que o algoritmo é flexível para resolver problemas onde haja funções que exibam descontinuidades sem que isso resulte em aumento significativo do tempo de processamento. Além disso, sua eficácia não é comprometida mesmo quando se trabalha em configurações n-dimensionais pois não é acrescentado complexidade excessiva ao processo.

## 5. CONCLUSÕES

A finalidade do OTIMAGRI, como inovação tecnológica é o desenvolvimento de uma ferramenta computacional, de simples uso e que sirva de apoio a decisão do produtor rural nas tomadas de decisões agrícolas onde são relevantes o uso racional dos recursos disponíveis (água e insumos) e a análise econômica.

O aplicativo desenvolvido pode ser utilizado em diversas marcas de smartphones proporcionando uma grande abrangência entre os produtores rurais, sejam pequenos, médios ou grandes e proporcionando o acesso a um sistema de fácil utilização, o que favorece a inclusão digital no campo associada à otimização dos recursos, além de ser um aplicativo genérico sob o ponto de vista das funções matemáticas que podem ser testadas de forma simples.

Os resultados obtidos demonstram que o sistema atendeu aos objetivos propostos, indicando que essa ferramenta computacional inteligente pode ser utilizada para a otimização do uso de recursos hídricos e insumos com o aumento da receita líquida, tendo sido testado e validado através de comparação com outros trabalhos.

Desta forma fica demonstrado que a implementação da tecnologia de Inteligência Artificial serve como uma ferramenta e recurso valiosos, contribuindo para redução do consumo de recursos naturais e o aumento da produtividade em culturas agrícolas.

## 6. CONSIDERAÇÕES FINAIS

Quando há alocação de recursos limitados, o OTIMAGRI disponibiliza métodos eficientes que o auxiliam na otimização dos recursos e da produção. O sistema ajuda a aumentar a produtividade, com uso da água de forma eficiente e diminuição dos custos de produção, desta forma, maximizando os benefícios dos investimentos na agricultura irrigada.

O OTIMAGRI ainda pode ser facilmente utilizado com diversos tipos de culturas, além de ser facilmente manipulado com funções complexas com n-dimensões.

O algoritmo do PSO abrirá novas abordagens o que poderá levar a pesquisadores agrícolas a utilizá-los de forma mais maciça e como uma fonte alternativa, gerando incentivo para serem feitos mais experimentos observando não apenas água e nitrogênio, e sim diversos outros fatores que influenciam na cultura, devido sua facilidade na análise a muitas dimensões.

Diversas novas possibilidades de continuidade dos estudos e aplicação do OTIMAGRI serão abertas a partir deste trabalho, para a sua utilização pelos produtores rurais em parceria com centros de pesquisa e universidades, como é o caso da UNRC - Argentina.

Neste trabalho exploramos a Inteligência de Enxames, através da capacidade do algoritmo de Otimização por Enxame de Partículas (PSO), mostrando a viabilidade deste algoritmo como método de otimização para utilização de recursos limitados e proporcionando um menor desperdício em insumos e água e uma maior produtividade da cultura. O mesmo foi responsável por encontrar o melhor resultado que maximiza o lucro líquido e minimiza o consumo dos insumos, demonstrando robustez e eficiência na solução do problema.

O aplicativo desenvolvido pode ser usado em várias marcas de smartphones proporcionando grande abrangência entre os produtores rurais, sejam pequenos, médios ou grandes e proporcionando o acesso a um sistema de fácil utilização, o que favorece a inclusão digital no campo associada à otimização dos recursos, além de ser um aplicativo genérico sob o ponto de vista das funções matemática que podem ser testadas de forma simples.

Os resultados obtidos demonstram que o sistema atendeu aos objetivos propostos, indicando que essa ferramenta computacional inteligente pode ser utilizada para a otimização do uso de recursos hídricos e insumos com o aumento da receita líquida, tendo sido testado e validado através de comparação com os trabalhos de Silva (2005), Monteiro et al (2008), Delgado et al (2010), Cavalcante Junior (2013) e Villas Bôas Junior et al (2023), na otimização das culturas da alface americana e do meloeiro.

Nesse sentido, o OTIMAGRI atende aos objetivos propostos, sendo uma ferramenta computacional inteligente que pode ser utilizada para a otimização do uso de recursos hídricos e aumento da receita líquida em culturas como testado, comparado e validado. Vale ressaltar que no desenvolvimento foi utilizado dados oriundos de experimentos científicos no Brasil, desta forma, sem a necessidade de fazer experimentos em campo, pois os dados que serão utilizados já estão consagrados na literatura, sendo seus resultados avaliados e verificados pelos seus pares, sendo assim eliminado o ônus do tempo.

Como trabalhos futuros pretende-se realizar experimentos com outras culturas levando em conta um número maior de insumos e a determinação dos parâmetros desses insumos para o ponto de produção ótima.

## 7. REFERÊNCIAS BIBLIOGRÁFICAS

- BAKER, C. **Artificial Intelligence:** Learning automation skills with Python (2 books in 1: Artificial Intelligence a modern approach & Artificial Intelligence business applications). Independently Published. 290p. ISBN: 1692995707, 2019.
- BERNARDO, S. Produção agrícola e uso da água. In: GOMES, M. A. F.; PESSOA, M. C. P. Y. **Planejamento ambiental do espaço rural com ênfase para microbacias hidrográficas – Manejo de recursos hídricos, ferramentas computacionais e educação ambiental.** Brasília, DF: Editora Embrapa Informação Tecnológica, pp. 13-33. 2010.
- BERNARDO, S.; SOARES, A. A.; MANTOVANI, E. C.; **Manual de Irrigação**, 8ª edição, ed. UFV, Viçosa, 625p. 2006.
- BLUM, C.; ROLI, A. Metaheuristics in Combinatorial Optimization: Overview and Conceptual Comparison. **ACM Computing Surveys (CSUR)**, 35, 268-308. <https://doi.org/10.1145/937503.937505> 2003.
- BOSTROM, N. **Super intelligence:** Paths, Dangers, Strategies. Great Clarendon Street, OX2 6DP, United Kingdom. ISBN 0199678111. 2014.
- BROWNSTON, L.; FARREL, R.; KANT, E.; MARTIN, N. **Programming Expert Systems in OPS5.** Addison-Wesley Publishing Company, Inc., 475 p. 1986.
- CAMPOS, M. M., SAITO, K. **Sistemas Inteligentes em Controle e Automação de Processos**, Rio de Janeiro: Editora Ciência Moderna, 235 p. 2004.
- CARVALHO, D. F.; DELGADO, A. R. S.; OLIVEIRA, R. F.; SILVA, W. A.; FORTE, V. L. Maximização da produção e da receita agrícola com limitações de água e nitrogênio utilizando pontos interiores. **Eng. Agric. Jaboticabal**, v. 29, n. 2, p. 321-327, abr/jun 2009.
- CAVALCANTE JUNIOR, J. A. C. **Ferramenta computacional inteligente aplicada à otimização do uso de recursos hídricos e aumento da receita líquida na agricultura – INTELIAGRI.** Tese (Doutorado) – UFRJ. Seropédica-RJ. 128 p. 2013.
- CAVALCANTE JUNIOR, J. A. C. **Sistema especialista em OPS5 para o processamento inteligente de alarmes em usinas nucleares.** Dissertação (Mestrado COPPE) – UFRJ. Rio de Janeiro-RJ. 126 p. 1997.
- DARTMOUTH CONFERENCE Artificial Intelligence – John McCarthy proposes the term “artificial intelligence” and Newell, Simon and Shaw demonstrate the first working AI program, the Logic Theorist. **Annals...** Hanover, 1956.
- DE JONG, K. A. **Evolutionary Computation:** A Unified Approach. New York: MIT Press. 2006.
- DELGADO, A. R. S.; DUARTE, W. S.; LIMA, V. N.; CARVALHO, D. F. Otimização da Produção e Renda de Melão e Melancia com Restrições de Água e Nitrogênio, **Irriga, Botucatu**, v. 15, n. 1, p. 1-9, 2010.
- DELGADO A. R. S.; RODRIGUES, P. C. P.; CARVALHO, D. F.; LEAL V. F.; O Problema Inverso de Otimização na Produção Agrícola com Restrições Hídricas. **Rev. Univ. Rural: Série Ciência Exatas e da Terra**, Seropédica, RJ: EDUR, v. 26, n. 1-2, p.01-11, 2007.

- DELGADO, A. R. S.; VENTURA, S. D.; CARVALHO, D. F.; SANTOS, R. D. Determinação de intervalos ótimos de irrigação utilizando a barreira logarítmica. **Revista Brasileira de Agricultura Irrigada**, v. 4, p. 128-138, 2010.
- ENGLISH, M. J. Deficit irrigation. I: Analytical Framework. **Journal of the Irrigation and Drainage Engineering of ASCE**, New York, v. 116, n. 3, p. 399-412, 1990.
- ENGLISH, M. J.; RAJA, S. N. Perspectives on deficit irrigation. **Agricultural Water Management**, v. 32, p. 1-14. 1996.
- ENGLISH, M. J.; SOLOMON, K. H.; HOFFMAN, G. J. A paradigm shift in irrigation management, **Journal of Irrigation and Drainage Engineering**, New York, v. 128, n. 5, p. 267-277, 2002.
- FERREIRA, A. B. H. **Novo Dicionário Aurélio da Língua Portuguesa**. Novo Dicionário Eletrônico Aurélio versão 5.0. Curitiba, Paraná: Editora Positivo, Positivo Informática, n. p. 2004.
- FERREIRA, R. S. **Matemática Aplicada às Ciências Agrárias: Análise de Dados e Modelos**, 3ª ed., Viçosa, MG: Editora UFV, 333p. 2005.
- FIGUEIREDO, G. M.; FRIZZONE, J. A.; PITELLI, M. M.; REZENDE, R. Lâmina ótima de irrigação do feijoeiro, com restrição de água, em função do nível de aversão ao risco do produtor. **Acta Sci. Agron.**, Maringá, v. 30, n. 1, p. 81-87, 2008.
- FLEMMING, D. M.; GONÇALVES, M. B. **Cálculo A – Funções, limite, derivação e integração**, 6ª ed., São Paulo, SP: Editora Pearson Prentice Hall, 449 p. 2006.
- FRIZZONE, J. A. Planejamento da irrigação com uso de técnicas de otimização. **Revista Brasileira de Agricultura Irrigada** v. 1, n. 1, p. 24-49, Fortaleza, CE, INOVAGRI, 2007.
- FRIZZONE, J. A. **Programação Matemática Aplicada a Projetos Hidroagrícolas**. Viçosa, MG: Sociedade Brasileira de Engenharia Agrícola-SBEA. 29 p. 1995.
- FRIZZONE, J. A.; ANDRADE JÚNIOR, A. S. **Planejamento de irrigação: análise de decisão de investimento**. Brasília: Embrapa Informação Tecnológica, 626 p. 2005.
- FRIZZONE, J. A.; TEODORO, R. E. F.; PEREIRA, A. S.; BOTREL, T. A. Lâminas de água e doses de nitrogênio na produção de aveia (*Avena sativa* L.) para forragem. **Scientia Agrícola, Piracicaba**, v. 52 n. 3, p. 578-586, 1995.
- GOLDBERG, D. E. **Genetic algorithms in search, optimization and machine learning**. USA: Addison Wesley Publishing Company, 1989.
- GOLDBERG, D. E. **The Design of Innovation: Lessons from and for competent genetic algorithms**, USA: Kluwer Academic Publishers, Norwell, MA. 2002.
- GOMES, M. M. R. C. **Aplicação das Metaheurísticas PSO e AG na estimação de parâmetros de um modelo de secagem em leite fluidizado**, Dissertação de Mestrado, pp. 34-50. 2007.
- GOTTFREDSON, L. **The General Intelligence Factor**. Scientific American Presents. University of Delaware Newark, DE 19716. 1996.

HOFFMAN, G. J.; HOWELL, T. A.; SOLOMON, K. H. **Management of farm irrigation systems**. St. Joseph: American Society of Agricultural Engineers, p. 93-122. 1992.

HOWELL, T. A.; CUENCA, R. H.; SOLOMON, K. H., Crop yield response. In: HOFFMAN, G. J.; HOWELL, T. A.; SOLOMON, K. H. **Management of farm irrigation systems**. St. Joseph: American Society of Agricultural Engineers, p. 93-122. 1992.

IBM. **Official Site**. <https://www.ibm.com/blogs/watson/2017/06/why-it-matters-that-ai-is-better-than-humans-at-their-own-games/> 2017.

KENNEDY J.; EBERHART R. C. Particle Swarm Optimization. Proc IEEE International Conference on Neural Net Works, **Annals...** pp. IV: 1942-1948, Perth, Australia. 1995.

KENNEDY J.; EBERHART R. C.; SHI, Y. **Swarm Intelligence**. Morgan Kaufmann, San Francisco, CA. Publishers Inc. 2001.

KONAR, A. **Artificial Intelligence and Soft Computing - Behavioral and Cognitive Modeling of the Human Brain**. Department of Electronics and Telecommunication Engineering Jadavpur University, Calcutta, India. CRC Press LLC, N. W. Corporate Blvd. 2000.

KOZA, J. R.; KEANE, M. A.; STREETER, M. J.; MYDLOWEC, W. **Genetic Programming IV: Routine Human-Competitive Machine Intelligence**. New York: Springer Science Business Media. 2003.

MADUREIRA, D. **Aplicativo nativo, web App ou aplicativo híbrido?**. Disponível em: <<https://usemobile.com.br/aplicativo-nativo-web-hibrido/>>. Acesso em: 10 out, 2017.

MCCORDUCK, P. **Machines Who Think**. 2nd ed., p. 13. Natick, MA: A. K. Peters, Ltd., OCLC 52197627 - ISBN 1-56881-205-1. 2004.

MENEZES, A. A. M.; MACHADO, M. D.; SCHIRRU, R. **Particle Swarm Optimization applied to the nuclear reload problem of a Pressurized Water Reactor. Progress in Nuclear Energy**, In Press, Corrected Proof. 2008.

MONTEIRO, R. O. C.; COSTA, R. N. T.; LEÃO, M. C. S.; AGUIAR, J. V. Eficiência do uso da água e nitrogênio na produção de melão. **Irriga, Botucatu**, v. 13, n. 3, p. 367-377, 2008.

OSMAN, I. H.; LAPORTE, G. Metaheuristics in combinatorial optimization: Overview and conceptual comparison. **ACM Computing Surveys**, v. 35, n. 3, p. 268-308. 1996.

OSWALDO JUNIOR, L.; MONTGOMERY, E. **Redes Neurais: fundamentos e aplicações com programas em c**. Rio de Janeiro: Ed. Ciência Moderna Ltda. 2007.

PAPADIMITRIOU, C. H.; STEIGLITZ, K. **Combinatorial Optimization: algorithms and complexity**. Upper Saddle River, NY: Prentice-Hall Inc. 1982.

PELIKAN, M.; SASTRY, K.; CANTÚ-PAZ, E. (eds.) Scalable Optimization via Probabilistic Modeling. **Studies in Computational Intelligence**, Vol. 33, Springer. 2006.

PIACENTI, C. A. Indicadores de modernização tecnológica. In: PIACENTI, C. A.; LIMA, J. F. **Análise Regional: metodologias e indicadores**. Curitiba: Camões, p. 35-40. 2012.

QUARESMA, A. **Weak artificial intelligence and computational brute strength**, n 1, vol 10. <https://doi.org/10.37467/gka-revtechno.v10.2815>. 2021.

REICHARDT, K.; TIMM, L. C. **Solo, Planta e Atmosfera**. Barueri, SP: Ed. Manole, 478 p. 2008.

SILVA, P. A. M. **Análise técnica e econômica da aplicação de água e nitrogênio na cultura da alface americana**. Tese (Doutorado em Engenharia Agrícola) – Universidade Federal de Lavras (UFLA). Lavras-MG. 93 p. 2005.

SHI, Y.; EBERHART, R. C. Empirical Study of Particle Swarm Optimization. Congress of Evolutionary Computation. **Annals...** Vol. 3, 1945-1950. 1998.

SOUZA, M. J. F. **Inteligência Computacional para Otimização**. Notas de aula, FOP, Ouro Preto, MG. 2005.

SULTAN, S. **Artificial Intelligence: Volume I (AI Course Book 1)**. Expert of Course Publishing. Edição do Kindle. 2017.

TAURION, C. **Big Data**. Brasport. Edição do Kindle. 2013.

VAN DER HEIJDEN, K.; OTTO, B.; MADDOCKS, A. **Beyond conflict, water stress contributed to Europe's migration crisis**. 2015. Disponível em: <https://www.wri.org/insights/beyond-conflict-water-stress-contributed-europes-migration-crisis>. Acesso em: 28 mar. 2022.

VILLAS BÔAS JUNIOR, M.; DELGADO A. R. S.; CAVALCANTE JUNIOR, J. A. C.; COSTA, M. S. Algoritmo evolutivo de aprendizado incremental baseado em população (PBIL) para otimização hídrica na produção agrícola. **Revista Projectus**, v. 7, n. 3. UNISUAM. <https://doi.org/10.15202/25254146.2022v7n3p32>. 2023.

VINGE, V. The Coming Technological Singularity: How to survive in the post-human era. department of mathematical sciences San Diego State University. Symposium sponsored by NASA Lewis Research Center and the Ohio Aerospace Institute. **Annals...** 1993.

VON ZUBEN, F. J.; CASTRO, L. N. **Recent developments in biologically inspired computing**. Chapter 4, v. 1. US: IGI Global. 2004.

WAINTRAUB, M. M. D.; SCHIRRU, R. **Algoritmos paralelos de otimização por enxame de partículas em problemas nucleares**. In Press, Corrected Proof. 2009.



## 8. ANEXOS

### 8.1 Anexo I - Código Fonte do PSO

```
using System;
using System.Collections.Generic;

using SkiaSharp;

using UltimateXF.Widget.Charts.Models;
using UltimateXF.Widget.Charts.Models.Formatters;
using UltimateXF.Widget.Charts.Models.LineChart;

namespace UFRRJ
{
    public class PSO
    {

        private double[,] PopulacaoParticula;
        private double[,] PopulacaoVelocidade;
        private double[,] PopulacaoPBest;

        private int Npop = 0; // Tamanho da Populacao
        private int Dimensao = 1;

        private double bestfitnessglobal = 0;
        public double[] bestfitnesspessoal;
        private double[] Fitness;
        private double[] Gbest;

        private double W = 0.9;
        private double C1 = 0.1;
        private double C2 = 3.9;
        private double[] XMin;
        private double[] XMax;
        //private double[] XMinSalvo;
        //private double[] XMaxSalvo;

        private int Interacao = 0;
        private int Semente = 42;
        private string objetivo;
        private string PROBLEM;

        public void Processa(double _W, double _C1, double _C2, int _Populacao, int _Semente, int
        _Interacao, List<EntryChart> entries, List<Geral._Resultados> Resultados,string problema,string
        fitness,int dimensao, double[] xmin, double[] xmax)
        {
```

```

// Inicializa as variaveis do PSO
Npop = _Populacao;
W = _W;
C1 = _C1;
C2 = _C2;
Semente = _Semente;
Interacao = _Interacao;
bestfitnesspessoal = new double[Npop];
Fitness = new double[Npop];

PROBLEM = problema;
Dimensao = dimensao;
//PreencheDimensaoAsync(PROBLEM);
PopulacaoParticula = new double[Npop, Dimensao + 1];
PopulacaoVelocidade = new double[Npop, Dimensao + 1];
PopulacaoPBest = new double[Npop, Dimensao + 1];

//PreencheDominioAsync(problema);
XMax = new double[Dimensao + 1];
XMin = new double[Dimensao + 1];
XMin = xmin;
XMax = xmax;

Gbest = new double[Dimensao + 1];

objetivo = fitness;
OTIMIZACAO(entries, Resultados);
}

private double GetRandomNumber(Random random, double minimum, double maximum)
{ return random.NextDouble() * (maximum - minimum) + minimum; }

private void PreencheDimensaoAsync(string formula)
{
    // Inicializa as variaveis do PSO
    List<Funcao> registro = new List<Funcao>();

    registro = App.Database.GetPeopleAsync();
    foreach (Funcao element in registro)
    {
        if (formula.ToUpper().Trim() == element.Name.ToUpper().Trim())
        {
            Dimensao = Convert.ToInt16(element.Dimensao);
            Dimensao = Dimensao - 1;
            break;
        }
    }
}

private void PreencheDominioAsync(string formula)

```

```

{
    // Inicializa as variaveis do PSO
    List<Funcao> registro = new List<Funcao>();
    string virgula = ",";
    string pontoevirgula = ";";

    int index;
    int index2;
    string aux;
    int jj;
    bool achou = false;

    for (jj = 0; jj <= Dimensao; jj++)
    {
        XMin[jj] = 0;
        XMax[jj] = 100;
    }

    //XMin[0] = 0;
    //XMax[0] = 100;

    //XMin[1] = 250;
    //XMax[1] = 240;
    //return;

    jj = 0;
    registro = App.Database.GetPeopleAsync();
    foreach (Funcao element in registro)
    {
        achou = true;
        if (formula.ToUpper().Trim() == element.Name.ToUpper().Trim())
        {
            bool b = element.Dominio.Contains(pontoevirgula);

            if (b)
            {
                while (element.Dominio != "")
                {
                    index = element.Dominio.IndexOf(pontoevirgula);
                    if (index >= 0)
                    {
                        aux = element.Dominio.Substring(0, index);
                        index2 = aux.IndexOf(virgula);
                        if (index2 >= 0)
                        {
                            //XMinSalvo[jj] = Convert.ToDouble(aux.Substring(0, index2));
                            //XMaxSalvo[jj] = Convert.ToDouble(aux.Substring(index2 + 1));
                            XMin[jj] = Convert.ToDouble(aux.Substring(0, index2));
                            XMax[jj] = Convert.ToDouble(aux.Substring(index2 + 1));
                            element.Dominio = element.Dominio.Substring(index + 1);
                            jj += 1;
                        }
                    }
                }
            }
        }
    }
}

```

```

        }
        else { break; }

    }
    else
    {

        aux = element.Dominio;
        index2 = aux.IndexOf(virgula);
        if (index2 >= 0)
        {
            //XMinSalvo[jj] = Convert.ToDouble(aux.Substring(0, index2));
            //XMaxSalvo[jj] = Convert.ToDouble(aux.Substring(index2 + 1));
            XMin[jj] = Convert.ToDouble(aux.Substring(0, index2));
            XMax[jj] = Convert.ToDouble(aux.Substring(index2 + 1));
            element.Dominio = "";
            jj += 1;
        }

        break;
    }
}
else
{
    for (jj = 0; jj <= Dimensao; jj++)
    {
        //XMin[jj] = XMinSalvo[jj];
        //XMax[jj] = XMaxSalvo[jj];
    }
}

break;
}
}
if (achou == false)
{
    for (jj = 0; jj <= Dimensao; jj++)
    {
        //XMin[jj] = XMinSalvo[jj];
        //XMax[jj] = XMaxSalvo[jj];
    }
}
}
}

```

```

private void INICIARPOPULACAO()
{
    Random GeradorDeNumerosAleatorios = new Random(Semente);
    Random GeradorDeNumerosAleatoriosW = new Random(Semente);
}

```

```

Random GeradorDeNumerosAleatoriosN = new Random(Semente);
double Randomico = 0;
int ii, jj = 0;

for (ii = 0; ii < Npop; ii++)
{
    for (jj = 0; jj <= Dimensao; jj++)
    {

        Randomico = GetRandomNumber(GeradorDeNumerosAleatoriosW, XMin[jj],
XMax[jj]);

        // Inicializar x(i,j) randomicamente.
        PopulacaoParticula[ii, jj] = Randomico;

        // Inicializar v(i,j) randomicamente.
        PopulacaoVelocidade[ii, jj] = (XMin[jj] +
(GetRandomNumber(GeradorDeNumerosAleatorios, 0, 1) * (XMax[jj] - XMin[jj]))) / 10;

    }
}

// Avaliar a xi (0)
FITNESS();

for (ii = 0; ii < Npop; ii++) { bestfitnesspeessoal[ii] = Fitness[ii]; }

// Inicializar pbest(i,j) como uma cópia de x(i,j).
for (ii = 0; ii < Npop; ii++)
{
    for (jj = 0; jj <= Dimensao; jj++)
    { PopulacaoPBest[ii, jj] = PopulacaoParticula[ii, jj]; }

}

// Inicializar gbest(j) com x(i,j) da partícula i de menor fitness.
for (ii = 0; ii < Npop; ii++)
{
    if (bestfitnesspeessoal[ii] < bestfitnessglobal)
    {
        // If bestfitnesspeessoal(ii) > bestfitnessglobal Then
        bestfitnessglobal = bestfitnesspeessoal[ii];
        for (jj = 0; jj <= Dimensao; jj++) { Gbest[jj] = PopulacaoParticula[ii, jj]; }
    }
}

}

private void FITNESS()
{

```

```

        string aux="";
        string pobjetivo = objetivo;
        int pp = 0;
        for (pp = 0; pp < Npop; pp++)
        {
            Fitness[pp] = 0;
            pobjetivo = objetivo;
            try
            {
                for (int i = 0; i < 9; i++)
                {
                    aux = "Particula[pp, " + i.ToString().Trim() + "]";
                    if (pobjetivo.Contains(aux)) { pobjetivo = pobjetivo.Replace(aux,
PopulacaoParticula[pp, i].ToString());}

                    aux = "Particula[pp, " + i.ToString().Trim() + "]";
                    if (pobjetivo.Contains(aux)) { pobjetivo = pobjetivo.Replace(aux,
PopulacaoParticula[pp, i].ToString()); }
                }
                if (pobjetivo != "")
                {
                    NCalc.Expression evaluator = new NCalc.Expression(pobjetivo);
                    var evoluir = evaluator.Evaluate();
                    Fitness[pp] = Convert.ToDouble(evoluir);
                }
            }
            catch (Exception ex)
            {
                _ = App.Current.MainPage.DisplayAlert("Alerta", ex.Message, "OK");
            }
        }

        //fitness
        //Fitness[pp] = -(-12490 + 388.1 * PopulacaoParticula[pp, 0] - 6.02 * PopulacaoParticula[pp,
1] - 1.042 * Math.Pow(PopulacaoParticula[pp, 0], 2) - 0.04563 * Math.Pow(PopulacaoParticula[pp,
1], 2) + 0.1564 * PopulacaoParticula[pp, 0] * PopulacaoParticula[pp, 1]);
    }

}

private void OTIMIZACAO(List<EntryChart> entries, List<Geral._Resultados> Resultados)
{

    try
    {
        int pp = 0;
        int jj = 0;
        int kk = 0;
        Random GeradorDeNumerosAleatorios = new Random(Semente);
        Random GeradorDeNumerosAleatoriosW = new Random(Semente);
        Random GeradorDeNumerosAleatoriosN = new Random(Semente);
        double Randomico = 0;

```

```

// Redimensionamento de Variaveis
// -----
bestfitnesspessoal = new double[Npop];
Fitness = new double[Npop];
PopulacaoParticula = new double[Npop, Dimensao + 1];
PopulacaoVelocidade = new double[Npop, Dimensao + 1];
PopulacaoPBest = new double[Npop, Dimensao + 1];

Gbest = new double[Dimensao + 1];

bestfitnessglobal = 9999999999;
//bestfitnessglobal = -9999999999;
// -----

//Seja P o número total de partículas.
//Seja x(i,j) a posição x da i-ésima partícula, representando uma solução candidata.
//Seja fitness(i) a função objetivo f (x)
//Seja v(i,j) a velocidade v da partícula i.
//Seja gbest(j) a melhor posição global gbest j.
//Seja bestfitnessglobal a melhor fitness, encontrada a partir de gbest (j).
//Seja pbest(i,j) a melhor posição pbest i,j a i-ésima partícula.
//Seja bestfitnesspessoal(i) a melhor fitness da partícula i, encontrada a partir de pbest (i,j).
//Passo(1(Inicialização))
// Inicializar x(i,j) randomicamente.
INICIARPOPULACAO();

//Passo 2: Repetir até que algum critério seja satisfeito.
for (kk = 0; kk < Interacao; kk++)
{
    // 2.4. Avaliar fitness (i)
    FITNESS();
    for (pp = 0; pp < Npop; pp++)
    {
        // 2.1. Para cada partícula i: se fitness(i) < bestfitnesspessoal, então pbest(j) = x (i,j)
        if (Fitness[pp] < bestfitnesspessoal[pp])
        {
            bestfitnesspessoal[pp] = Fitness[pp];
            for (jj = 0; jj <= Dimensao; jj++)
            {
                PopulacaoPBest[pp, jj] = PopulacaoParticula[pp, jj];
            }
        }
    }

    // 2.2. Para cada partícula i: se bestfitnesspessoal(i) < bestfitnessglobal, então, gbest
    = pbest (i,j)
    if (Fitness[pp] < bestfitnessglobal)
    {
        bestfitnessglobal = Fitness[pp];
        Geral._Resultados ResultadoAuxiliar = new Geral._Resultados();
    }
}

```

```

ResultadoAuxiliar.Agua = PopulacaoParticula[pp, 0];
ResultadoAuxiliar.C1 = C1;
ResultadoAuxiliar.C2 = C2;
ResultadoAuxiliar.Fitness = bestfitnessglobal;
ResultadoAuxiliar.Geracao = kk;
ResultadoAuxiliar.Nitrogenio = PopulacaoParticula[pp, 1];
ResultadoAuxiliar.W = W;
ResultadoAuxiliar.Dados = "Geração: " + Convert.ToString(kk + 1) + " Água: " +
Convert.ToString(PopulacaoParticula[pp, 0]) + " Nitrogênio: " +
Convert.ToString(PopulacaoParticula[pp, 1]) + " W: " + Convert.ToString(W) + " C1: " +
Convert.ToString(C1) + " C2: " + Convert.ToString(C2) + " GBest: " +
Convert.ToString(bestfitnessglobal);
Resultados.Add(ResultadoAuxiliar);

for (jj = 0; jj <= Dimensao; jj++) { Gbest[jj] = PopulacaoParticula[pp, jj]; }

}

}

// 2.3. Para cada partícula i: atualizar x(i,j) e v(i,j) de acordo com as equações (I) e (II).
double Vk = 0;
double Xk = 0;

for (pp = 0; pp < Npop; pp++)
{
    for (jj = 0; jj <= Dimensao; jj++)
    {
        Vk = (W * PopulacaoVelocidade[pp, jj]) +
            (C1 * GetRandomNumber(GeradorDeNumerosAleatorios, 0, 1) *
            (PopulacaoPBest[pp, jj] - PopulacaoParticula[pp, jj])) +
            (C2 * GetRandomNumber(GeradorDeNumerosAleatorios, 0, 1) * (Gbest[jj] -
            PopulacaoParticula[pp, jj]));
        Xk = PopulacaoParticula[pp, jj] + Vk;

        // Verifica Extrapolação do Espaço de Busca
        Randomico = GetRandomNumber(GeradorDeNumerosAleatoriosW, XMin[jj],
XMax[jj]);

        if (Xk > 0)
        {
            if (Xk > XMax[jj])
            {
                Xk = Randomico;
                Vk = (XMin[jj] + (GetRandomNumber(GeradorDeNumerosAleatorios, 0, 1) *
(XMax[jj] - XMin[jj]))) / 10;
            }
            else
            {
                if (Xk < XMin[jj])
                {

```



```

        Xk = Randomico;
        Vk = 0;
    }
}

PopulacaoParticula[pp, jj] = Xk;
PopulacaoVelocidade[pp, jj] = Vk;
}

}

}

}
catch (Exception ex)
{
    _ = App.Current.MainPage.DisplayAlert("Alerta", ex.Message, "OK");
}

}

}
}

```

## 8.2 Anexo II – Modelos Desenvolvidos para Funções de Produção (FRIZZONE, 2005)

### 8.2.1 DeWit (1958)

Desenvolveu um método para prever a produtividade das culturas a partir da água consumida. Os primeiros experimentos foram conduzidos em vasos com o objetivo de identificar os fatores que determinam a relação transpiração-produção das culturas. Encontrou uma relação linear entre a produção de matéria seca (MS) e a razão transpiração (T) / evaporação de tanque (Eo) para regiões áridas e semi-áridas como se segue (Equação 40):

$$MS = m \left( \frac{T}{E_o} \right) \quad (40)$$

MS	–	Quantidade de matéria seca total acumulada	–	(kg/vaso)
T	–	Transpiração total no mesmo período de tempo	–	(kg/vaso)
Eo	–	Evaporação média na estação de crescimento	–	(mm/dia)
m	–	Coeficiente de proporcionalidade	–	(mm/dia)

O coeficiente m depende da disponibilidade de água do solo da espécie e variedade cultivada (valores típicos são: para sorgo 0,0252; trigo 0,0139 e alfafa 0,00662 mm/dia).

O valor de m no campo tem que ser reduzido em 10%.

Para regiões de clima temperado, sob condições não limitantes de água, a relação T/Eo não varia consideravelmente, de forma que a equação de MS pode ser reescrita como (Equação 41):

$$MS = nT \quad (41)$$

Dado que em Kg/Kg e dependente da espécie vegetal.

Obs. n é o inverso da razão de transpiração  $\frac{m}{E_o}$  denominada de eficiência de transpiração  $\frac{MS}{T}$ .

### 8.2.2 Arkley (1963)

Postulou que a produção das culturas e a transpiração são relacionadas, mas a advecção pode afetar essa relação. Analisando os mesmos fatores de DeWit foi introduzido um fator de correção climático para substituir Eo baseado na umidade relativa média mensal. Ele também investigou a relação entre produção de matéria seca, transpiração e déficit de pressão de vapor. Isso possibilitou combinar os resultados de produção e transpiração das áreas úmidas e áridas e ainda obter um alto coeficiente de correlação. A Equação proposta (Equação 42) foi:

$$MS = \frac{KT}{(100-UR)} = 0,001 KT \left( \frac{e_o}{e_o - e_a} \right) \quad (42)$$

### 8.2.3 Hanks (1974)

Utilizou a equação de DeWit e desenvolveu um modelo relacionado a transpiração relativa e produtividade relativa de matéria seca. Considerou que para uma determinada cultura e época, os valores de  $m$ ,  $K$ ,  $UR$ ,  $E_o$ ,  $(e_o - e_a)$ ; são praticamente constantes sendo válida a relação (Equação 43):

$$\frac{MS}{MS_m} = \frac{T}{T_m} \quad (43)$$

- $MS$  – Produtividade de matéria seca
- $T$  – Transpiração acumulada durante o ciclo da cultura
- $MS_m$  – Produtividade de matéria seca máxima
- $T_m$  – Transpiração máxima (quando não há restrição hídrica para a planta)

A Equação acima assume que  $TR$  é constante e não afetada pela irrigação.

Tem-se demonstrado que a relação  $T/T_m$  é melhor que  $ET/ET_m$  como indicador das respostas relacionadas a fotossíntese e transpiração.

A transpiração relativa é um claro indicador das quantidades relativas de trocas gasosas ( $CO_2$  e  $H_2O$ ) que ocorrem na superfície das folhas através dos estômatos.

A utilização de valor relativo  $T/T_m$  ou  $ET/ET_m$  ao invés de  $T$  ou  $ET$  facilita a generalização dos modelos de função de produção permitindo um certo grau de transferibilidade das mesmas.

### 8.2.4 Stewart et al (1977)

O grupo mostra uma relação linear entre redução do rendimento das culturas e déficit estacional de evapotranspiração.

O coeficiente angular  $b$  de tal função é uma medida da sensibilidade da cultura ao déficit hídrico, mas difere muito entre culturas e também entre variedades, sendo constante para uma dada variedade. Valores típicos de  $b$  são 2,34 – feijão; 1,26 – milho e 0,98 – sorgo, isso indica que o feijão é 85% mais sensível ao déficit de  $ET$  que o milho e este 25% mais sensível que o sorgo.

Embora a relação linear tenha representado bem a redução do rendimento relativo em função do déficit de evapotranspiração relativa, os autores destacam a necessidade de cuidados para a extrapolação de resultados (Equação 44):

$$\frac{Y}{Y_m} = 1 - \beta ET_d \quad (44)$$

- $Y$  – Rendimento atual
- $Y_m$  – Rendimento máximo
- $\beta$  – coeficiente angular da reta  $Y/Y_m$  versus  $ET_d$  (indicando a sensibilidade da cultura ao déficit hídrico)
- $ET_d$  – Déficit de evapotranspiração relativa –  $ET_d = 1 - \frac{ET}{ET_m} = \frac{ET_m - ET}{ET_m}$

Reescrevemos como (Equação 45):

$$1 - \frac{Y}{Y_m} = \beta \left( 1 - \frac{ET}{ET_m} \right) \quad (45)$$

$$(1 - (Y/Y_m)) = (Y_m - Y)/Y_m \quad - \quad \text{A redução do rendimento relativo}$$

$$(1 - (ET/ET_m)) = (ET_m - ET)/ET_m \quad - \quad \text{Déficit de evapotranspiração relativa}$$

O problema no uso da Equação 45 deve-se a necessidade de determinar o valor de experimentos de campo.

Uma relação semelhante a Equação 45 (Equação 46) foi proposta para a produção de matéria seca (HANKS-RAMUSSEN, 1982):

$$\frac{MS}{MS_m} = \left[ 1 - \beta^* \left( 1 - \frac{ET}{ET_m} \right) \right] \quad (46)$$

$\beta^*$  é o fator de proporcionalidade entre  $(1 - (MS/MS_m))$  e  $(1 - (ET/ET_m))$ , indicando a partição de ET em E (evap. de água do solo) e T (transpiração). Esses valores podem ser estimados pelas Equações 47 e 48:

$$E = ET_m \left[ 1 - \left( \frac{1}{\beta^*} \right) \right] \quad (47)$$

$$T_m = \frac{ET_m}{\beta^*} \quad (48)$$

$$\beta^* = 1 \text{ significa que } E = 0 \text{ e conseqüentemente } T_m = ET_m$$

$$\beta^* = 1,5 \text{ tem-se } E = 0,33 ET_m \text{ e } T_m = 0,67 ET_m$$

Os resultados obtidos pelas Equações 47 e 48 são específicos para o método e o manejo de irrigação utilizado, sendo também influenciados pelo método de cálculo de  $ET_m$ .

### 8.2.5 Doorenbos & Kassan (1979)

Utilizaram o modelo de Stewart para desenvolver um método para estabelecer a relação entre água e rendimento das culturas. Propuseram que o cálculo de  $Y_m$  fosse realizado pela aproximação de DeWit, modificada com alguns fatores de correção e o cálculo de  $ET_a$  e  $ET_m$  pelos métodos de Doorenbos & Pruitt. Nesse modelo o efeito do suprimento de água sobre o rendimento das culturas é quantificado pelo fator de resposta da cultura:

$$Ky = \frac{\left( 1 - \frac{Y}{Y_m} \right)}{\left( 1 - \frac{ET}{ET_m} \right)}$$

Um déficit hídrico pode ocorrer tanto de forma contínua durante todo o período de crescimento da cultura quanto de qualquer uma das fases específicas do crescimento: fase de estabelecimento, vegetativa, floração, formação da colheita e maturação.

Geralmente as culturas são mais sensíveis ao déficit hídrico durante a emergência, a floração e na fase inicial de formação da colheita, do que durante o período vegetativo, após o estabelecimento e maturação.

Isto mostra que a programação do momento de aplicação da água é tão importante quanto o nível de suprimento de água durante o período total de crescimento.

O Planejamento do suprimento estacional deve considerar o fornecimento ótimo de água a cultura durante as fases do ciclo fenológico.

Em termo de manejo de água isto significa que para um suprimento hídrico limitado, a dotação de água deve atender as necessidades hídricas da cultura durante as fases mais sensíveis ao déficit hídrico, em vez de atender parcialmente as necessidades da cultura de maneira uniforme durante todo o período de crescimento.

Os valores de  $K_y$  para a maioria das culturas foram determinados supondo que a relação entre o rendimento relativo ( $Y/Y_m$ ) e a evapotranspiração relativa ( $ET/ET_m$ ) é linear e válida para um déficit hídrico de 50%, isto é:

$$\left(1 - \frac{ET}{ET_m}\right) = 0,5 \quad (\text{valores baseados em análise de dados experimentais})$$

#### **8.2.6 Para estádios fenológicos**

Os efeitos do deficit hídrico sobre o rendimento das culturas variam com a espécie e o estágio fenológico que ocorre. Existem estádios mais sensíveis que outros.

Estádios - Fase, período, época, estação.

Fenologia - Parte da botânica que estuda vários fenômenos periódicos das plantas, como a brotação, a floração e a frutificação, marcando-lhes as épocas e os caracteres.

#### **8.2.7 Estudo das relações dos processos biológicos periódicos com o clima**

As culturas respondem negativamente ao déficit hídrico em determinado estágio fenológico; outras podem responder positivamente, aumentando o rendimento ou a qualidade do produto colhido (algodão, soja, abacaxi e cana). A natureza da dependência entre estádios relativamente ao efeito do déficit ainda não foi claramente explicada.