UNIVERSIDADE PAULISTA - UNIP
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

APLICAÇÃO DE ALGORITMO METAHEURÍSTICO HÍBRIDO COM MECANISMO PARA ACELERAÇÃO DE CONVERGÊNCIA NA OTIMIZAÇÃO DE PROCESSOS DO AGRONEGÓCIO

Tese apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Paulista- UNIP, para obtenção do título de Doutor em Engenharia de Produção
Orientadora: Dra. Irenilza de Alencar Nääs

MARCO ANTONIO CAMPOS BENVENGA

SÃO PAULO
2022

Benvenga, Marco Antonio Campos.
Aplicação de algoritmo metaheurístico híbrido com mecanismo para aceleração de convergência na otimização de processos do agronegócio / Marco Antonio Campos Benvenga. – 2022.
100 f. : il. color. + CD-ROM.

Tese de Doutorado Apresentada ao Programa de Pós Graduação em Engenharia de Produção da Universidade Paulista, São Paulo, 2022.
Área de concentração: Redes de Empresas e Planejamento da Produção.
Orientadora: Prof.ª Dr.ª Irenilza de Alencar Nääs.

1. Agronegócio. 2. Metaheurística. 3. SAGAC. 4. Aceleração de convergência. 5. Otimização. 6. Inteligência computacional. I. Nääs, Irenilza de Alencar (orientadora). II. Título.

Ficha elaborada pelo Bibliotecário Rodney Eloy CRB8-6450

RESUMO

A aplicação de técnicas metaheurísticas para a solução de problemas com grande quantidade de repostas possíveis (NP-Completos), se mostra mais eficiente que as técnicas determinísticas ou técnicas heurísticas consideradas de busca local. O Algoritmo Genético (GA) é uma destas técnicas metaheurísticas e é consagrada no meio acadêmico e, bastante usada tanto de forma isolada, quanto em algoritmos híbridos implementada em conjunto com outras técnicas. Este projeto implementou o algoritmo metaheurístico híbrido (SAGAC), composto pelas técnicas *Simulated Annealing* (SA) e Algoritmo Genético (GA) com a inclusão de um mecanismo de aceleração de convergência que torne mais eficiente o processo de busca dentro de conjuntos de soluções. Este algoritmo busca acelerar a convergência dos resultados obtidos a cada iteração (geração do GA) processada. O projeto abordou três processos do agronegócio, os quais têm em comum a criação animal para produção de carne. São eles: 1º. Controle ambiental em criadouros de frangos, 2º. Logística de gado de corte e 3º. Planejamento de produção de monogástricos (frangos e suínos) por meio de modelos matemáticos que descrevem suas curvas de crescimento. Para o primeiro processo, aplicou-se o algoritmo metaheurístico para pesquisar uma combinação dos parâmetros ambientais (Temperatura = Tbs (°C), Umidade Relativa do ar = UR (%), Velocidade do vento = Var (m/s), Concentração de Amônia = NH_3 (ppm) e Concentração de gás carbônico = CO_2 (ppm)). O processo de otimização considerou quatro faixas etárias das aves (21, 28, 35, 42 dias) e os resultados obtidos mostraram que houve aumento na taxa de melhoria da ambiência para as quatro faixas etárias, com a maior taxa de melhoria para as aves com 21 dias de idade. Para o segundo processo, aplicou-se o SAGAC para otimizar os parâmetros logísticos (frigorífico, rota, caminhão) do processo de transporte de gado de corte entre o produtor e o frigorífico. Neste caso, haviam resultados obtidos por meio de um algoritmo determinístico (Branch-and-bound) os quais foram comparados com os resultados obtidos pelo SAGAC. Nas 22 duas simulações realizadas, o SAGAC obteve um desempenho médio 0,14% melhor que o algoritmo Branch-and-bound. Para o terceiro processo, utilizou-se o SAGAC para otimizar a combinação dos parâmetros de três modelos de curvas de crescimento (Gompertz, Logistic e Von Bertalanffy) de monogástricos (frangos e suínos) com o intuito de obter o maior coeficiente

de derminação (R^2) que representa a probabilidade de acerto dos dados simulados em relação aos dados reais de crescimento dos animais, indicando, por consequencia, o grau de confiabilidade nos dados do planejamento do processo. Os resultados obtidos apresentaram percentuais de coeficiente de determinação acima de 99% para frangos, com destaque para o modelo Gompertzque apresentou a maior taxa (99,998%) e, acima de 93% para suínos, com destaque para o modelo Logistic que apresentou a maior taxa (97,380%).
Ao final desta pesquisa, verificou-se que o algoritmo (SAGAC) obteve um melhor desempenho que o Algoritmo Genético (GA) tradicional e outros algoritmos, na otimização dos processos do agronegócio abordados.

Palavras-chave: Agronegócio, Metaheurística, SAGAC, Aceleração de Convergência, Otimização, Inteligência Computacional

ABSTRACT

Applying metaheuristic techniques to solve problems with many possible answers (NP-Complete) is more efficient than the deterministic techniques or heuristic techniques considered for local search. The Genetic Algorithm (GA) is one of these metaheuristic techniques and is enshrined in academia and is widely used both in isolation and in hybrid algorithms implemented in conjunction with other techniques. This project implemented the hybrid metaheuristic algorithm (SAGAC), composed of Simulated Annealing (SA) and Genetic Algorithm (GA) techniques, with the inclusion of a convergence acceleration mechanism that makes the search process more efficient within solution sets. This algorithm seeks to accelerate the convergence of the results obtained at each iteration (GA generation) processed. The project addressed three agribusiness processes, which have animal husbandry for meat production in common. They are: 1st. Environmental control in chicken farms, 2nd. Beef cattle logistics and 3rd. Production planning of monogastric animals (chickens and pigs) through mathematical models that describe their growth curves. For the first process, the metaheuristic algorithm was applied to search for a combination of environmental parameters (Temperature = Tbs (°C), Relative Air Humidity = RH (%), Wind speed = Var (m/s), Air Ammonia = NH3 (ppm) and Carbon dioxide concentration = CO2 (ppm)). The optimization process considered four age groups of birds (21, 28, 35, and 42 days), and the results showed an increase in the rate of ambiance for the four age groups, with the highest rate of improvement for birds with 21 days old. For the second process, SAGAC was applied to optimize the logistic parameters (slaughterhouse, route, truck) of the beef cattle transport process between the producer and the slaughterhouse. In this case, results were obtained through a deterministic algorithm (Branch-and-bound) compared with the results obtained by SAGAC. In the two 22 simulations performed, SAGAC obtained an average performance of 0.14% better than the Branch-and-bound algorithm. For the third process, SAGAC was used to optimize the combination of parameters from three models of growth curves (Gompertz, Logistic, and Von Bertalanffy) of monogastric animals (chickens and pigs) in order to obtain the highest determination coefficient (R^2) which represents the probability of success of the simulated data concerning the actual data of the animals' growth, indicating, consequently, the degree of reliability in the process planning data. The results

showed percentages of determination coefficient above 99% for chickens, with emphasis on the Gompertz model, which presented the highest rate (99.998%), and above 93% for pigs, with emphasis on the Logistic model, which presented the highest rate. (97.380%). At the end of this research, it was verified that the algorithm (SAGAC) obtained better performance than the traditional Genetic Algorithm (GA) and other algorithms in optimizing the approached agribusiness processes.

Keywords: Agribusiness, Metaheuristics, SAGAC, Convergence Acceleration, Optimization, Computational Intelligence

UTILIDADES

Esta pesquisa é útil ao fornecer benefícios em relação ao processo de otimização pois, apresenta um algoritmo com capacidade de encontrar melhores resultados, em relação a outros algoritmos, para os processos abordados. O primeiro benefício é minimizar o consumo de recursos e, consequentemente tornar os processos mais sustentáveis. O, segundo benefício é pelo fato de o processo necessitar de menos recursos por causa da otimização, seus custos tenderão a cair e consequentemente seus produtos e serviços terão a possibilidade de serem vendidos a preços menores, e isso é socialmente correto porque as pessoas menos favorecidas economicamente poderão ter acesso a esses produtos e serviços. O terceiro benefício é organizacional, ou seja, por minimizar os custos do processo, consequentemente ocorre um aumento da lucratividade que pode desencadear uma sequência de fatos positivos. São eles: 1º. O revinvestimento total ou parcial dos lucros obtidos com a otimização, 2º. O crescimento do negócio devido ao reinvestimento dos lucros, 3º. O aumento do número de vagas de trabalho e/ou da renda do trabalhador devido ao crescimento do negócio, 4º. O aumento da demanda de mercado por causa da abertura de novas vagas de trabalho e/ou do aumento da renda do trabalhador, 5º. O aumento do volume de vendas devido ao aumento da demanda de mercado que, consequentemente gerará mais lucratividade e, finalmente levará de volta ao primeiro (1º.) fato positivo, fechando assim um ciclo virtuoso de “prosperidade”. Esta pesquisa entrega em seus resultados, valores melhores para os parâmetros dos processos abordados, em relação a outras técnicas de otimização, comprovado nos artigos desta tese, proporcionando desta maneira, minimização de custos, consumo de recursos naturais e humanos e, por consequência, aumento de ganhos para os produtores.

No que tange aos aspectos acadêmicos referentes às utilidades desta pesquisa, pode-se mencionar o fato de que a inteligência computacional, por meio de algoritmos heurísticos, metaheurísticos e híbridos, como o SAGAC, têm prestado uma importante contribuição à ciência com aplicações para resolução de problemas em tempo computacional viável, nos quais o conjunto de soluções é demasiadamente grande (NP-Completos). Estes tipos de problemas conhecidos como NP-Completos tornam inviável a implementação de aplicações que usam metodologias determinísticas, as quais garantem o retorno da(s) solução(ões)

ótima(s) de um determinado problema, mas, para isto, devem pesquisar todo o conjunto de soluções e isto, demandaria a necessidade de um tempo de processamento também demasiadamente grande, tornando inviável o processo de otimização por estas técnicas. O algoritmo SAGAC, que tem “dentro” de si um algoritmo que aborda a estratégia evolutiva (Algoritmo Genético), utilizado na resolução dos mais variados problemas como, planejamento de produção, análise de dados geoespaciais entre outros, cujo conjunto de soluções possíveis faz parte dos NP-Completos. O Algoritmo metaheurístico híbrido com aceleração de convergência (SAGAC) foi desenvolvido com o objetivo de prover um incremento de desempenho do Algoritmo Genético no processo de busca pela solução ótima em conjuntos de soluções do tipo NP-completos e, encontrar resultados de melhor qualidade que, o Algoritmo Genético original normalmente não encontraria.

LISTA DE FIGURAS

Figura 1 - Justificativa da pesquisa apoiada no conceito de Melhoria Contínua 3
Figura 2 - Justificativa da pesquisa apoiada nos benefícios do processo de otimização 4
Figura 3 - Balança Comercial do Agronegócio – Série Histórica 9
Figura 4 - Exportações Brasileiras do Agronegócio por Mercados 9
Figura 5 - Exportações Brasileiras do Agronegócio por Unidade Federativa – UF 10
Figura 6 - Exportações Brasileiras do Agronegócio por Setores 10
Figura 7 - Participação das exportações de frango, suínos e outras no total de carnes exportadas em 2020 11
Figura 8 - Efetivo de aves no Brasil em 2019 16
Figura 9 - Custos de produção de frango na União Europeia e seis países terceiros em 2017 17
Figura 10 - Efetivo de suínos no Brasil em 2019 20
Figura 11 - Custos de produção de suínos na rede IntergPIG 21
Figura 12 - Fluxograma do Simulated Annealing adaptada de (VASAN e RAJU, 2009) 28
Figura 13 - Esquema cromossômico para três variáveis 29
Figura 14 - Esquema de cruzamento do GA com três genes 30
Figura 15 - Fluxograma do Algoritmo Genético.Adaptado de Linden (2008) 32
Figura 16 - Esquema do funcionamento de um AGAC 34
Figura 17 - Esquema do algoritmo híbrido SAGAC 36
Figura 18 - Algoritmo para implementação, teste e análise de desempenho do SAGAC 37

LISTA DE TABELAS

Tabela 1 - Balanço das exportações, importações e saldo da balança comercial do agronegócio brasileiro em 2019 6
Tabela 2 - Composição dos custos de produção de frango 17
Tabela 3 - Preços e custos de produção de frangos 18
Tabela 4 - Composição dos custos de produção de suínos 21
Tabela 5 - Preços e custos de produção de suínos 22
Tabela 6 - Parâmetros utilizados para definir o EDT 27
Tabela 7 - Resultados parciais da pesquisa publicados em congressos e/ou revistas científicas 42

LISTA DE ABREVIATURAS

GA – Algoritmo Genético

AGAC - Algoritmo Genético com Aceleração de Convergência

SAGAC - Algoritmo Metaheurístico Híbrido – *Simulated Annealing* e Algoritmo Genético com Aceleração de Convergência

BE - Algoritmo de Busca Exaustiva

BT – Algoritmo Busca Tabu

IBGE – Instituto Brasileiro de Geografia e Estatística

SA – Algoritmo *Simulated Annealing*

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária

FAO – Organização das Nações Unidas para a Alimentação e a Agricultura

IBGE – Instituto Brasileiro de Geografia e Estatistica

MAPA – Ministério da Agricultura, Pecuária e Abastecimento

MDIC – Ministério da Indústria, Comércio Exterior e Serviços

USDA – *United States Department of Agriculture*

CONAB – Companhia Nacional de Abastecimento

UBABEF – União Brasileira de Avicultura

VBP – Valor Bruto da Produção Agropecuária

MVD – *Mediam Volumetric Diameter*

RNA - Rede Neural Artificial

EFC – Capacidade de Campo Efetiva

FC - Taxa de Consumo de Combustível

OEE – Eficiência Energética Geral

SVR – Taxa de Volume do Solo Arado

PLF – Aplicações de Pecuária de Precisão

RSM – Metodologia de Superfície de Resposta

RBF – *Radial Base Function*

CCHP – *Combined Cooling, Heatind and Power*

PES – Economia de Energia Primária

ATCS – Economia Total Anual de Custos

CDER – Redução de Emissão de Dióxido de Carbono

RFID – *Radio Frequency Identification*

EPC – *Environmental Preference Chamber*

CEPEA – Centro de Estudos Avançados em Economia Aplicada

ESALQ – Escola Superior de Agricultura "Luiz de Queiroz"

TE – *Termal Environment*

GEE – Gases de Efeito Estufa

EDT – Esquema de Decaimento da Temperatura

TDS – *Temperature Decline Scheme*

SUMÁRIO

CAPÍTULO I 1
1Introdução 1
1.1 Justificativa 2
1.2 Objetivos 4
1.2.1 Objetivo Geral 4
1.2.2 Objetivos Específicos 4
1.3 Organização da tese 5
CAPÍTULO 2 6
2Referencial teórico 6
2.1 Produção Agropecuária Brasileira 6
2.2 Produção brasileira de carne 6
2.3 Produção animal de Precisão 11
2.4 Aplicação da Otimização de Processos na Agricultura e Pecuária 12
2.4.1 Avicultura 16
2.4.2 Suinocultura 19
2.5 Uso de ferramentas computacionais na produção animal 23
2.6 Algoritmos de Otimização 26
2.6.1 *Simulated Annealing* (SA) 26
2.6.2 Algoritmos Genéticos (GA) 28
2.6.3 Mecanismo de Aceleração de Convergência 32
2.6.4 Esquema básico GA 33
2.6.5 Esquema básico AGAC 33
2.6.6 Esquema básico SAGAC 35
CAPÍTULO 3 37
3Metodologia 37
3.1 Infra-estrutura computacional 38
3.2 Os passos da pesquisa 38
3.3 Realização dos experimentos 38
CAPÍTULO 4 40

4Resultados e Discussão 42
4.1 Artigo 1 43
4.2 Artigo 2 50
4.3 Artigo 3 61
CAPÍTULO 5 74
5Considerações Finais 74
5.1 Conclusões 74
5.2 Recomendações de trabalhos futuros 75

REFERÊNCIAS 76
ANEXOS 87

CAPÍTULO 1

Este capítulo trata da abordagem teórica desta pesquisa, fazendo um apanhado da revisão bibliográfica e apresentando os objetivos desta pesquisa e a organização desta tese.

1 Introdução

Segundo o Governo Federal, a produção agropecuária brasileira teve o melhor desempenho dos últimos 32 anos, com um crescimento real de 17%, alcançando a cifra de R$ 871,3 bilhões.

É sabido que o agronegócio brasileiro tem grande importância econômica para o país e que este, é o setor de negócio que tem maior impacto no Produto Interno Bruto (PIB), na balança comercial e na produtividade (CENTRO DE ESTUDOS AVANÇADOS EM ECONOMIA APLICADA, 2017).

Considerando o mercado global do agronegócio, o Brasil está posicionado como um conhecido e relevante *player*. No que tange aos impactos sociais e ambientais, a sociedade tem observado de perto e com julgamento crítico, o sistemas operativos das companhias que operam neste setor e, avaliando o impacto destes sistemas na sociedade e no meio-ambiente. Após pesquisas realizadas e a divulgação de dados negativos que estas companhias causavam à sociedade e ao meio-ambiente, houve uma mobilização por parte destas no sentido de um voluntariado que promovesse impactos sociais e ambientais mais positivos (DOS SANTOS et al., 2020).

O sistema agrícola brasileiro é uma corrente de suprimentos cujos elos, ligados entre si, são produtores, consumidores e importadores de outros países. Estes elos da corrente estão bem estruturados e com gestão moderna e competitiva. Este conjunto de características estão presentes nos produtores de grãos, oleaginosas, carne, açúcar, biocombustíveis, frutas e vegetais (PESSÔA e SIMÕES, 2020).

Ser um *player* competitivo globalmente é um desafio não só para o Brasil mas para todos os países. Desta forma, há uma maneira de superar este desafio que é, ter conhecimento da dinâmica do comércio global, e alinhar a sua pauta de exportação com a demanda mundial (CHRIST et al., 2021).

A adoção de métodos de otimização para a melhoria de previsão de séries e desempenho dos processos produtivos é uma das estratégias adotadas para tornar o agronegócio brasileiro competitivo. Dentre métodos aditados pode-se citar os algoritmos de otimização, o *machine learning*, técnicas de Inteligência Artifical como as Redes

Neurais Artificiais, entre outros (PUCHALSKY et al., 2018; BENVENGA & NÄÄS, 2021; DE ARRUDA SILVA et al., 2020)

Segundo o site do Governo Federal (GOV, 2020) o Valor Bruto da Produção Agropecuária (VBP) do Brasil de 2020, alcançou a cifra de R$ 871,3 bilhões, tornando-se o maior valor da série histórica dos últimos 32 anos, representando um crescimento real de 17%. As lavouras tiveram faturamento de R$ 580,5 bilhões, alta de 22,2%, e a pecuária, R$ 290,8 bilhões, incremento de 7,9%. De acordo com nota técnica da Secretaria de Política Agrícola, do Ministério da Agricultura, Pecuária e Abastecimento (MAPA, 2021), os produtos que mais contribuíram para o resultado foram o milho, com crescimento real de 26,2%; soja, com 42,8%; carne bovina, com 15,6%; e carne suína, 23,7%.

O faturamento da soja, milho e carne bovina foi de R$ 243,7 bilhões, R$ 99,5 bilhões e R$ 126,3 bilhões, respectivamente. Destaca-se ainda a contribuição positiva da produção de ovos em 2020. Os resultados relacionados acima são possíveis não somente devido ao clima favorável ou ao vasto território brasileiro, mas, também ao desenvolvimento de tecnologias que proporcionam a melhoria dos processos produtivos do agronegócio. Graças a estas tecnologias, pode-se aumentar a produtividade e melhorar a qualidade dos produtos oriundos da agropecuária brasileira a cada ano, sem desmatar mais áreas nativas ou consumir mais recursos naturais. Alguns exemplos podem ser apresentados a seguir.

Entretanto, muitos processos utilizados na produção pecuária e agrícola podem ser otimizados com o auxílio de algoritmos desenvolvidos para tal função, ou ainda adaptados para isto.

1.1 Justificativa

Como todo processo de otimização, que faz parte da área de Pesquisa Operacional, na Engenharia de Produção, a otimização de processos de produção de aves, suínos e bovinos para consumo por meio de algoritmos de otimização, visa utilizar algoritmos heurísticos, metaheurísticos ou híbridos para maximizar benefícios como, rendimento dos processos, qualidade dos produtos, lucratividade, etc. ou, minimizar custos desses processos como, consumo de insumos, energia, mão-de-obra. O principal benefício advindo do processo de otimização, além dos benefícios já relacionados neste parágrafo, é o aumento do potencial competitivo desses produtores,

podendo oferecer para o consumidor, produtos de melhor qualidade, a preços mais vantajosos, ou seja, a melhor relação Preço x Qualidade possível.

O desenvolvimento de técnicas de otimização cada vez mais eficientes se faz necessário, devido ao crescente aparecimento de problemas cada vez mais complexos. Em problemas complexos de Job Shop, por exemplo, o GA não consegue encontrar uma solução satisfatória (SREEKARA REDDY et al., 2017). Daí advém a justificativa da pesquisa por melhorias de desempenho no GA e em outros algoritmos de otimização também.

O algoritmo genético embora seja um método de otimização consagrado ainda não tem um desempenho satisfatório em problemas de otimização com alto grau de complexidade, a menos que seja implementado em conjunto com outras técnicas. Por este motivo, e considerando o método de otimização do Algoritmo Genético como um processo, justifica-se a proposição de melhorias com o objetivo de obtenção um ganho de eficiência. As Figuras 01 e 02 apresentan os diagramas que traduzem graficamente a justificativa deste projeto, explicada nos parágrafos anteriores.

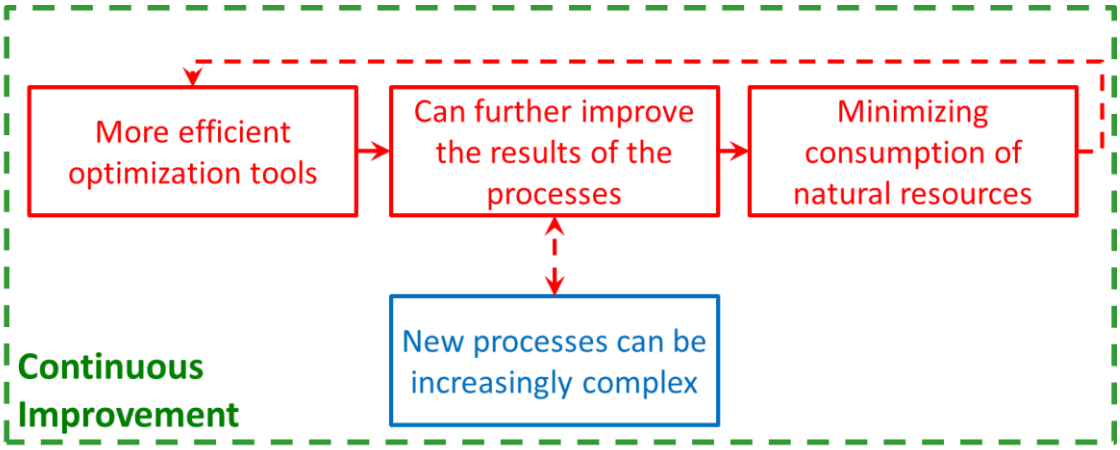

Figura 1 - Justificativa da pesquisa apoiada no conceito de Melhoria Contínua

A Figura 01 apresenta as razões pertinentes ao conceito de gestão da qualidade, na qual tem como um de seus objetivos a melhoria contínua dos processos e, por concequência, dos produtos e serviços. Já a Figura 02, por sua vez, apresenta os aspectos complementares da justificativa deste projeto, nos quais são apresntados os possíveis benefícios oriundos dos processo de otimização.

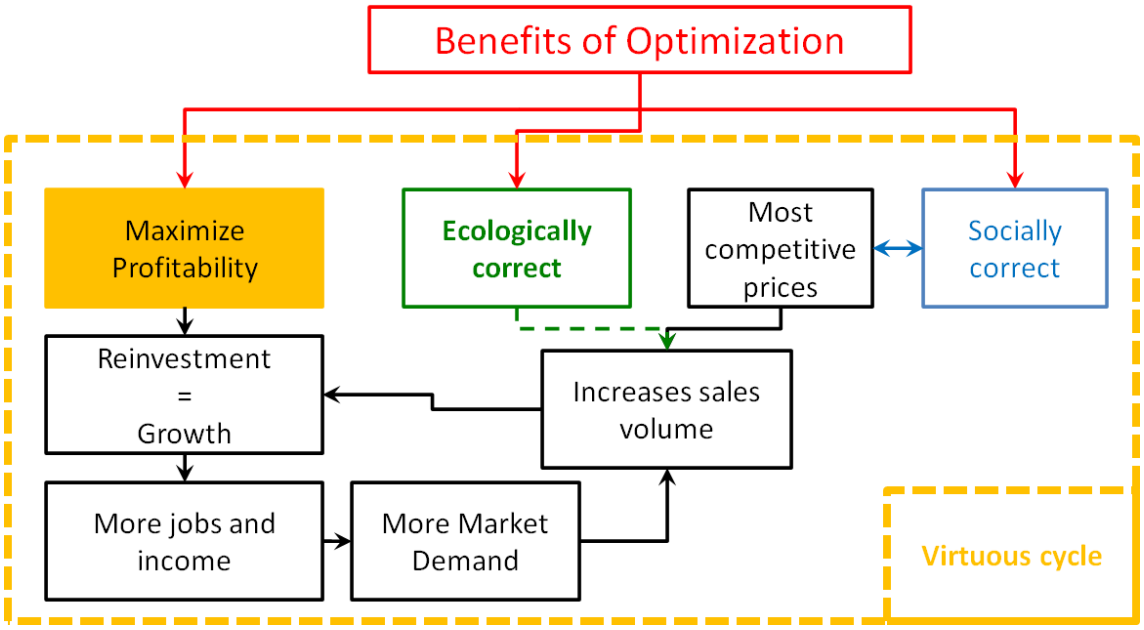

Figura 2 - Justificativa da pesquisa apoiada nos benefícios do processo de otimização

Outro aspecto do processo de otimização refere-se aos benefícios que podem ser obtidos. Estes benefícios poder-se-iam ser subdivididos em três categorias, sejam elas: a categoria de benefícios organizacionais, a categoria dos benefícios ambientais e a categoria dos benefícios sociais.

1.2 Objetivos

A presente pesquisa busca apresentar um algoritmo metaheurístico híbrido de otimização como uma ferramenta viável para os processos de produção de proteína animal, melhorando a eficiência desses processos e também da qualidade de seus produtos.

1.2.1 Objetivo Geral

O objetivo deste trabalho é investigar o desempenho do metaheurístico híbrido SAGAC, que é composto do algoritmo *Simulate Annealing* (SA) e do Algoritmo Genético (GA) com a inclusão de uma nova heurística que torne mais eficiente o processo de busca no conjunto de soluções de um problema.

1.2.2 Objetivos Específicos

1. Avaliar o desempenho do algoritmo SAGAC na otimização de processos de criação de animais de corte;
2. Analisar o desempenho de algoritmos de otimização no abate de suínos de corte

1.3 Organização da tese

Esta tese está dividida em cinco capítulos, da seguinte forma:

1º. Capítulo - é apresentada uma introdução com suas considerações iniciais incluindo justificativa e objetivos da pesquisa.

2º. Capítulo – fala sobre a produção agropecuária brasileira, dados sobre o balanço das exportações, comparações entre a produção de carne e outras culturas do agronegócio, como esta produção de carne é distribuída entre os estados da federação e também sobre a produção animal de precisão. Descreve alguns aspectos sobre aplicação da otimização de processos na agricultura e pecuária, o uso de ferramentas computacionais na produção animal e da aplicação de algoritmos de otimização dentro destes processos de otimização. Detalhes dos algoritmos envolvidos nesta pesquisa também são apresentados.

3º. Capítulo - são apresentados os materiais e métodos utilizados neste trabalho. Desde a implementação, testes e análise de resultados do algoritmo SAGAC até a calibração dos algoritmos de cada técnica de otimização.

4º. Capítulo - são apresentados os resultados obtidos com a implementação do algoritmo SAGAC, e análises comparativas dos resultados.

5º. Capítulo – é a conclusão do trabalho com base nos resultados obtidos e, apresentação de sugestões de trabalhos que podem ser desenvolvidos a partir da implementação do algoritmo SAGAC.

CAPÍTULO 2

2 Referencial teórico

2.1 Produção Agropecuária Brasileira

O Brasil é uma potência agrícola e boa parte de sua produção, seja da agricultura ou da pecuária ajuda a saciar a fome de populações ao redor do mundo. O balanço das exportações, importações e saldo da balança comercial do agronegócio brasileiro tem auxiliado nosso país a fechar a conta positivamente. A Tabela 01 apresenta a balança do agronegócio do Brasil em 2019 por setores em bilhões de dólares.

Tabela 1 - Balanço das exportações, importações e saldo da balança comercial do agronegócio brasileiro em 2019

BALANÇA COMERCIAL			
	EXPORTAÇÕES	IMPORTAÇÕES	SALDO
Outros	100,29	123,96	-23,67
Agronegócio	84,94	13,63	71,31
Total	185,23	137,59	47,64

Pode-se notar na Tabela 01, a diferença de desempenho na balança comercial entre o agronegócio brasileiro e outros setores produtivos no ano de 2019. Com US$ 84,94 bi de produtos exportados (45,85% do total) e US$13,63 bi de produtos importados (9,91% do total), o agronegócio apresentou um saldo de US$ 71,31 bi que, com o saldo apresentado dos demais setores de US$ -23,66 bi, fez com que o saldo da balança comercial do país fechasse o ano positivamente.

Abreu et al. (2020) usaram uma Rede Neural Artificial para predizer os valores da temperatura de ambientes envolvidos na criação de frangos de corte com o objetivo de proporcionar maior conforto aos animais.

Dias et al. (2020) usaram as técnicas Planejamento Fatorial, Análise de Variância e Cálculos de Regressão com o objetivo de avaliar e modelar o equilíbrio higroscópico e as curvas de calor isotérmico do pericarpo e tecidos do endosperma do café arábica com o objetivo de alcançar o valor de equilíbrio de água contida na fruta com a água do ambiente. Diel et al. (2020) realizaram um estudo de viabilidade econômica da geração de eletricidade por meio de biorreatores que usam dejetos de suínos em fazendas de criação objetivando contribuir para a sustentabilidade ambiental com a redução da poluição.

Strathe et al. (2009) compararam quatro funções de crescimento e métodos de análise de dados, particularmente um que considera medições não-lineares repetidas para analisar modelos de predição do peso de mercado de suínos maximizando o retorno sobre os custos de criação. Dados foram coletados de um experimento com 40 porcos mantidos desde o nascimento até a maturidade.

Tavanti et al. (2020) investigaram a variabilidade espacial e sua correlação com outros atributos físicos e químicos do solo para gerar uma função de pedotransferência para estimar o índice “S”. Os resultados obtidos pela pesquisa indicaram que o índice “S” e correlacionado com a porosidade, estoques de carbono, capacidade de troca catiônica e frações de tamanho de partícula.

Almeida et al. (2020) avaliaram o efeito das concentrações de glifosato sobre o risco potencial da dispersão de gotículas, tensão superficial de solução de pulverização e ângulo de contato das gotas nas superfícies. Foram conduzidos 3 experimentos e avaliado o potencial de dispersão pela mediana do diâmetro volumétrico (*mediam volumetric diameter* - MVD), porcentagem de volume de gotas com diâmetro menor que 100 µm (% V <100 µm) e coeficiente de uniformidade (Span), com 12 repetições.

Petry et al. (2020) modelaram o rendimento, balanço da água no solo e o retorno econômico da soja sob níveis diferentes de déficit de água. Foram avaliados os impactos do estresse hídrico na produtividade das lavouras e comparadas alternativas de manejo da irrigação com o objetivo de garantir um retorno econômico. Já Oliveira et al. (2020) analisaram a caracterização de aspectos específicos do gerenciamento de solo usando correlação espacial e linear entre o rendimento do feijão comum irrigado e as propriedades químicas do solo.

Schinckel et al. (2009) avaliaram o impacto do peso ao desmame e do crescimento pós-desmame precoce de porcos para o crescimento final tardio quando alimentados com dietas à base de farinha de milho e soja ou dietas com baixa excreção de nutrientes. Os resultados mostraram que, em ambos os tratamentos dietéticos, os porcos com maior índice BW de crescimento ao desmame e maior índice ADG pós-desmame precoce necessitaram de menos dias para atingir o índice BW alvo de mercado.

Baldacci et al. (2014) usaram um algoritmo interativo orientado pela abordagem de Lagrangean que, é uma técnica de busca local, associado à uma heurística, para resolver o problema de encaixe de formas para corte em superfícies, com o objetivo de minimizar as sobras.

Arcoverde et al. (2020) calcularam a influência da intensificação do tráfego de tratores nos atributos físicos do solo e nos componentes de rendimento da soja. O estudo ocorreu orientado por um planejamento fatorial durante 10 anos, em solo com plantio direto subdividido em blocos aleatórios, com cinco intensidades de tráfego de tratores (0, 2, 4, 6, 8 e 12 passes) e com cinco réplicas. Os cálculos mostraram que, após 12 passagens, mesmo com a mudança dos atributos físicos do solo, não houve limitação da produtividade do plantio da soja que, apresentou maior diâmetro do caule, número de vagens por planta, peso de grão por planta e rendimento de grão após 12 passagens.

Wulantuya et al. (2020) realizaram uma análise e estudo experimental sobre o processo de transporte de materiais de fibras agrícolas por transportadores de parafusos com o objetivo de melhorar a eficiência e a estabilidade do transportador helicoidal. Os fatores envolvidos neste processo que fizeram parte do estudo foram: os métodos de alimentação, as condições de funcionamento e características de fluxo dos materiais. Os resultados dos experimentos mostraram que, mudanças no ângulo das hélices e na forma de alimentação do material a ser transportado podem promover uma melhor estabilidade no transportador.

Marey et al. (2020) examinaram a capacidade de uma rede neural artificial (RNA) em estimar o desempenho dos parâmetros para um arado em três campos com diferentes solos. Com os valores das variáveis: força de tração, profundidades de aração, conteúdo de umidade do solo, volume de solo densidades, índices de textura do solo e potência do trator; a RNA realizou previsão de desempenho para os seguintes itens: velocidade de arado, capacidade de campo efetiva (EFC), taxa de consumo de combustível (FC), eficiência energética geral (OEE) e a taxa de volume do solo arado (SVR).

2.2 Produção brasileira de carne

O Brasil é uma potência agrícola e boa parte de sua produção, seja da agricultura ou da pecuária ajuda a saciar a fome de populações ao redor do mundo. O Balanço das exportações, importações e saldo da balança comercial do agronegócio brasileiro tem auxiliado nosso país a fechar a conta positivamente.

Segundo dados disponibilizados pelo Ministério da Agricultura Pecuária e Abastecimento e, exibidos no gráfico da Figura 01, pode-se notar a diferença entre as exportações e importações do agronegócio brasileiro apresentando, desde 1997, um saldo positivo na balança comercial.

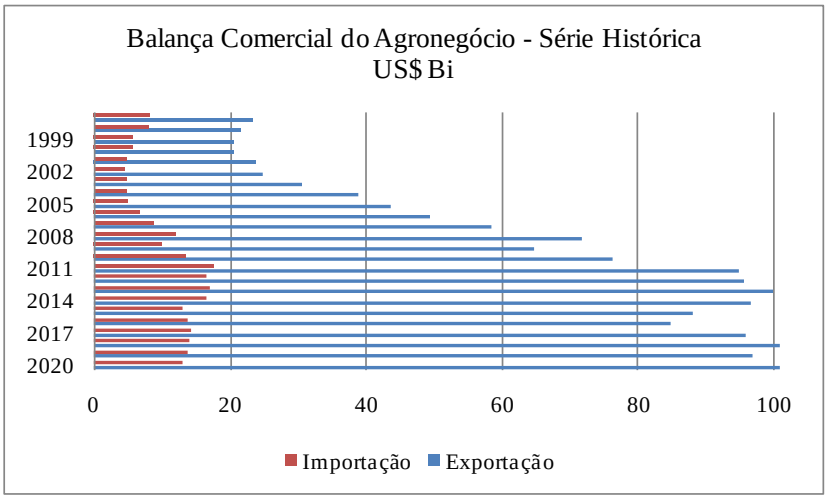

Figura 3 - Balança Comercial do Agronegócio – Série Histórica

Fonte: MAPA (2021)

Na Figura 02, pode-se observar os percentuais de participação dos principais mercados consumidores dos produtos do agronegócio brasileiro. Nota-se que a China se destaca como principal comprador de nossos produtos, com uma participação de 33,73% do total exportado, seguida da União Europeia com 16,17% e Estados Unidos com 6,91%.

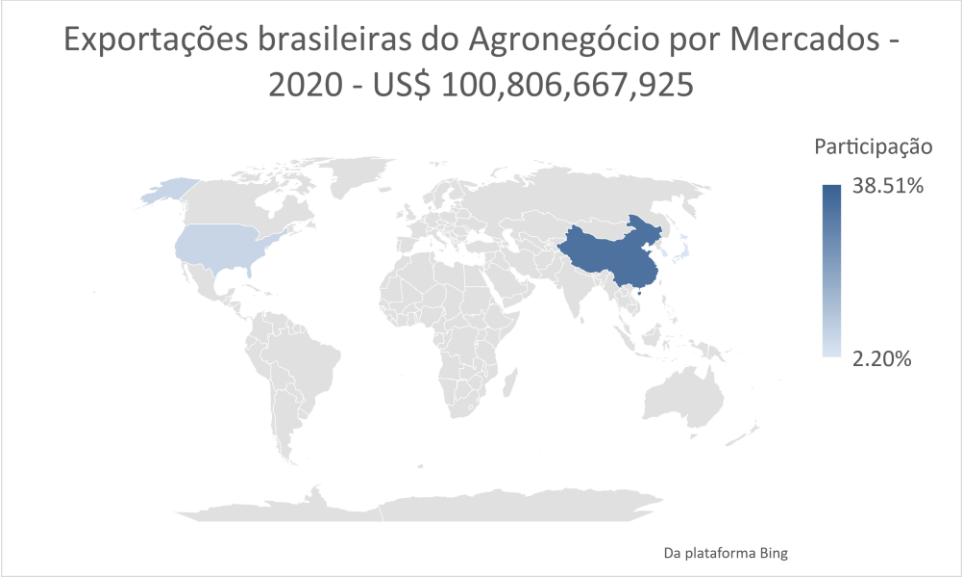

Figura 4 - Exportações Brasileiras do Agronegócio por Mercados

Fonte: MAPA (2021)

Analisando o gráfico da Figura 03, que apresenta os percentuais de participação dos estados no montante total das exportações do agronegócio, pode-se verificar que a

maioria das exportações (66,60%) está concentrada em cinco estados, relacionados em uma ordem decrescente de percentual, respectivamente: Mato Grosso (17,73%), São Paulo (17,09%), Paraná (13,18%), Rio Grande do Sul (9,96%) e Minas Gerais (8,64%).

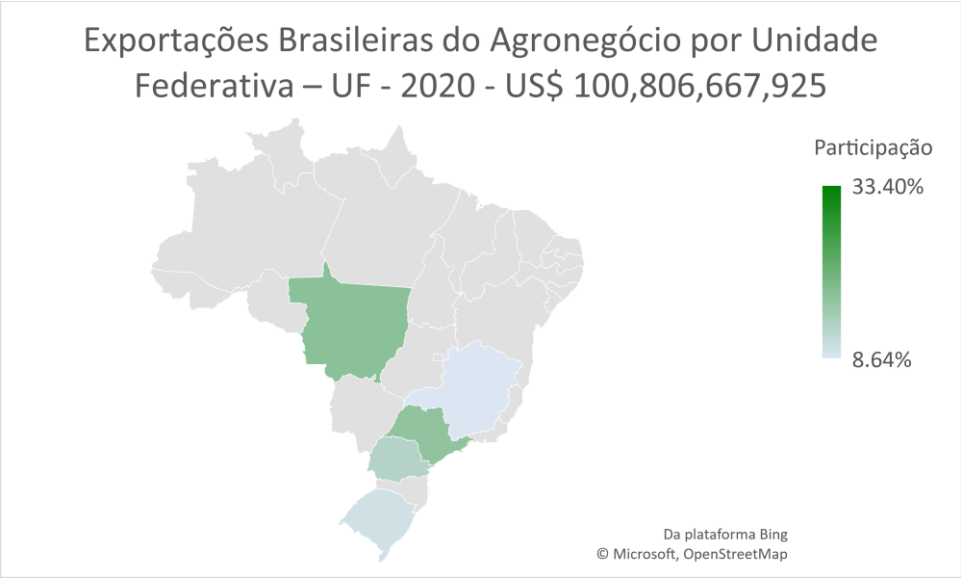

Figura 5 - Exportações Brasileiras do Agronegócio por Unidade Federativa – UF

Fonte: MAPA (2021)

Por fim, pode-se ver na Figura 04, a participação dos principais setores produtivos nas exportações do agronegócio brasileiro. Logo após o complexo soja, que lidera com 34,96% das exportações, vem em seguida a participação da exportação de carnes com 17,02% com um valor total exportado de US$17,16bi.

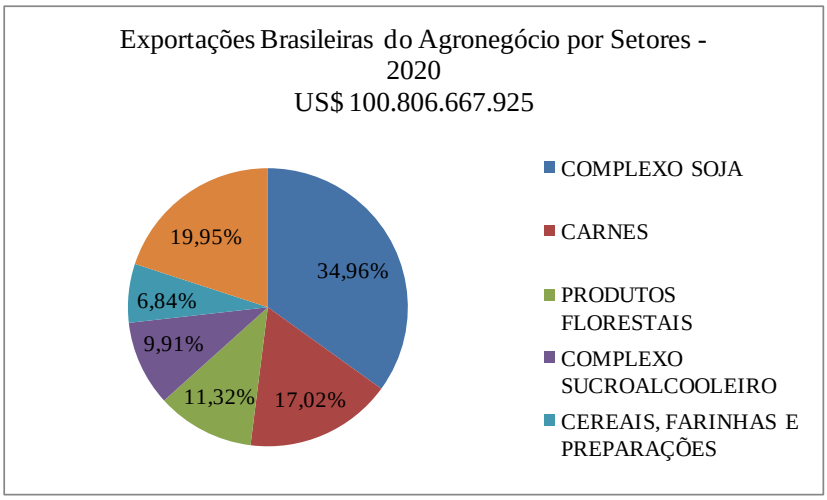

Figura 6 - Exportações Brasileiras do Agronegócio por Setores

Fonte: MAPA (2021)

É neste setor de produção de carne, mais especificamente de aves e suínos que se concentra esta pesquisado total de US$17,16 bilhões de carne exportada que, corresponde a 7,42 mil toneladas, pode-se identificar, na Figura 05, os percentuais de participação das carnes de frango, suínos e outros tipos e carne.

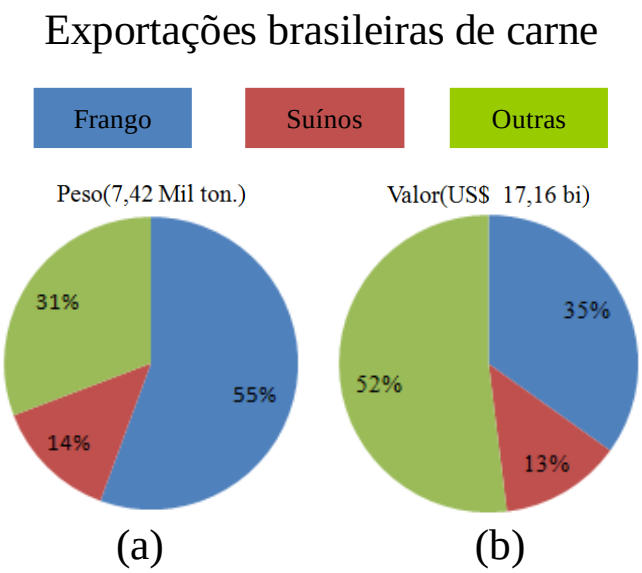

Figura 7 - Participação das exportações de frango, suínos e outras no total de carnes exportadas em 2020

Fonte: MAPA (2021)

Os dados apresentados pelos gráficos (a) e (b) da Figura 05 informam a proporcionalidade das exportações de frango, suínos e outras carnes dentro do total de carnes exportadas pelo Brasil em 2020. Observando-se os dados percentuais de frango, pode-se notar que, embora a quantidade exportada seja a maior (55%), o valor faturado (35%) não é proporcional à esta quantidade. Por outro lado, quando se observa os mesmos dados referentes à suínos, identifica-se uma proporcionalidade dos percentuais entre o peso e o valor faturado.

O Brasil é o maior exportador mundial de carne de corte. Controle de saúde, conhecimento e tecnologia bem como os aspectos naturais do país são apontados como as chaves para o sucesso desse produto no mercado (NÄÄS et al., 2015). Podemos constatar essa importância por meio dos estudos científicos realizados.

2.3 Produção animal de Precisão

A Produção Animal de Precisão é a modalidade que tem como objetivo maximizar vários aspectos da produção como: segurança, padronização, redução de custos, produtos ambientalmente corretos e processos que consideram e buscam o bem-estar dos animais (BANHAZI et al., 2012).

As indústrias pecuárias estão cada vez mais adotando ferramentas de agricultura de precisão e apoio à decisão. Como resultado, sensores, estações meteorológicas, rastreamento individual de animais, monitoramento de ração e outras fontes criam grandes volumes de dados, muitos dos quais são usados apenas para um único propósito. Existem benefícios potenciais inimagináveis de tornar os dados agrícolas interoperáveis e acessíveis e relacionando-os com fontes públicas de dados (BAHLOAC et al., 2019).

A agricultura terá que aumentar sua produção para atender à demanda, abrindo as portas para o aumento da automação e da inovação tecnológica; intensificando a agricultura sustentável; e aplicações de pecuária de precisão (PLF). Os primeiros indicadores de problemas médicos, que usam sensores para alertar os pecuaristas precocemente sobre animais que precisam de cuidados especiais, estão se proliferando (HALACHMI et al., 2019).

Nos domínios da agricultura e da pecuária, o processo de Big Data pode processar dados de diversas fontes heterogêneas, incluindo dados estruturados, por exemplo, dados de sensores, dados do tempo/climáticos e dados não estruturados como por exemplo, imagens e mapas de drone/satélite. Grandes quantidades de dados agrícolas podem ser usados para fornecer insights preditivos nas operações agrícolas, impulsionam decisões operacionais em tempo real e redesenham processos de negócios (ZEGINIS et al., 2019).

A Produção Animal de Precisão é definida como: "a aplicação de princípios e técnicas de engenharia de processos à pecuária para monitorar, modelar e gerenciar automaticamente a produção animal. O objetivo primário da Produção Animal de Precisão é para tornar a pecuária mais sustentável economicamente, social e ambientalmente e isso pode ser obtida por meio da observação, interpretação dos comportamentos e, se possível, controle individual dos animais (TULLO et al., 2019).

2.4 Aplicação da Otimização de Processos na Agricultura e Pecuária

Sherwin et al. (2019) usaram as técnicas GA e RSM na Otimização dos parâmetros da rede neural, ou seja, determinar dois parâmetros, incluindo o número de neurônios na camada oculta e o parâmetro de propagação da rede neural da RBF, com o objetivo de para modelar e predizer as energias de saída das granjas de frangos de corte. Os resultados obtidos, com uma correlação mínima é 0,57, indicaram que o sistema de produção avícola está diretamente relacionado ao consumo de insumos como: alimentos, eletricidade, óleo diesel, mão-de-obra humana, etc.

Wijayaningrum et al. (2017) implementaram um algoritmo metaheurístico híbrido composto pelo Algoritmo Genético e *Simulated Annealing* para maximizar a composição de ingredientes para ração de aves domésticas de corte. Os experimentos mostraram que o algoritmo híbrido tem tempo de processamento maior, porém, consegue obter melhores resultados. Em outra pesquisa, Wang et al. (2010) usaram Algoritmo Genético para analisar o fluxo de energia de um sistema CCHP (*combined cooling, heatind and power*) e identificar o consumo de energia primária após a demanda térmica de uma edificação. Três critérios: 1. economia de energia primária (PES), 2. economia total anual de custos (ATCS) e 3. redução de emissão de dióxido de carbono (CDER), foram selecionadas para avaliar o desempenho do sistema CCHP. Baseado no fluxo de energia do sistema CCHP, a capacidade e operação do sistema foi otimizada pelo algoritmo genético (GA). Os valores referentes as capacidades do sistema foram determinadas pelo GA considerando a estratégia operacional. Por meio de um exemplo numérico do sistema CCHP para um hotel em Pequim, a eficácia do método proposto foi demonstrada.

Kristensen e Cornou (2011) realizaram o monitoramento automático dos níveis de atividade dos rebanhos de frangos de corte para detecção de padrões irregulares de atividade, indicando potenciais problemas no bem-estar dos animais. A técnica aplicada utiliza o registro das atividades dos animais por meio de câmeras de vídeos posicionadas acima do criadouro. O nível de atividade dos animais é detectado com o número de mudanças no bloco de pixels entre imagens consecutivas registradas a cada minuto. Os resultados obtidos indicam o potencial para a detecção automática dos desvios dos níveis de atividade nos rebanhos de frangos de corte. Em virtude disto, uma aplicação foi desenvolvida utilizando os métodos e modelagens apresentadas por esta pesquisa, com a função de avisar, em tempo real, o produtor de algum desvio anormal da atividade do rebanho de frango de corte.

Aydin et al. (2014) propuseram um método de medição automática da quantidade de alimento ingerido por frangos de corte por meio de tecnologia de sons. Foi desenvolvimento de um algoritmo para detectar os sons das bicadas das aves e fazer uma relação com a quantidade de alimento ingerido. Os valores das quantidades de alimento ingerido foram obtidos por meio da medição da escala de peso e observações de vídeo. O som das bicadas de 12 frangos com idade de 28 dias da raça Ross-308, foram registrados durante 15 minutos por três dias consecutivos por um microfone instalado na área de alimentação. Três ensaios experimentais foram conduzidos com cada frango. Cada frango foi privado de alimento por quatro horas antes de cada experimento. Durante os experimentos, a quantidade de alimento disponibilizado foi automaticamente registrada usando um sistema de pesagem. O alimento desperdiçado,

em cada experimento, foi manualmente coletado e pesado. Baseado nos valores obtidos das medições do alimento disponibilizado e do alimento desperdiçado pelas aves, a quantidade de alimento ingerido foi calculada e usada para validação do algoritmo proposto. Os resultados mostraram que 93% dos sons das bicadas foram corretamente identificados pelo algoritmo. Além do mais, pela identificação do som das bicadas, uma relação entre o alimento fornecido, o alimento ingerido e o número de bicadas foi calculada e, uma relação linear entre estas três variáveis foi encontrada. Um teste de regressão linear foi realizado para definir o coeficiente de determinação entre o número de bicadas e o número de alimento fornecido as aves, cujo resultado foi de R^2=0,995. Além disso, a relação entre a quantidade de alimento ingerido e a quantidade de bicadas foi investigado e o coeficiente de determinação obtido foi de R2=0,985.

Aydin et al. (2015) propuseram um sistema de monitoramento avançado para medida precisa do nível de ingestão de alimentos de frangos de corte em grupo por meio de uma tecnologia de processamento de som em tempo real. Os sons de 10 frangos de corte com 39 dias de vida, foram registrados por um microfone instalado na área de alimentação. Ao mesmo tempo, uma câmera foi instalada na parte superior da mesma área de alimentação. Simultaneamente, um sistema de pesagem foi usado para registrar automaticamente o fornecimento de alimento aos animais. Um algoritmo foi desenvolvido para detectar os sons de 10 frangos enquanto eles estavam comendo juntos. A quantidade de alimento ingerido pelos animais foi obtida pela análise realizada pelo algoritmo, dos sons das bicadas enquanto as aves comiam. Os resultados obtidos do algoritmo foram comparados à referência dos valores obtidos do sistema de pesagem sobre a quantidade de alimento fornecido.

A relação entre a quantidade de alimento ingerido, apresentado pelo algoritmo e a quantidade de alimento ingerido registrado pela escala de peso foi investigado e uma forte relação foi encontrada entre estas duas variáveis. O coeficiente de correlação de Pearson foi calculado para estas duas variáveis e o índice obtido foi de R^2=0,994. Além disto, o sistema de análise por sons identificou corretamente a quantidade de alimento ingerido a uma taxa de 0,86.

Aydin (2017) apresentou uma nova técnica de detecção recente de defeitos em frangos de corte. Um grupo de frangos com cinco níveis predefinidos de marcha foram continuamente monitorados por câmeras digitais, como eles caminhavam através de um corredor de teste. Um algoritmo de análise de imagem foi utilizado para detectar algumas variáveis deste processo como: velocidade, frequência do passo, comprimento do passo e a oscilação lateral do corpo. Posteriormente, um teste de correlação foi aplicado para definir o coeficiente de correlação entre cada uma destas variáveis e o nível de marcha. Além disso, calculou-se a diferença estatística entre cada uma destas

variáveis investigada e o nível de marcha dos frangos com o objetivo de identificar o efeito do nível de marcha com cada uma destas variáveis. Os resultados mostraram que todas as variáveis foram eficazes na detecção de defeitos frangos jovens. Os resultados recomendam que um sistema de detecção totalmente automatizado tem potencial para ser usado como uma ferramenta de monitoramento em tempo real para detecção cedo de defeitos em frangos de corte.

Ahrendt et al. (2011) devido a mudanças na regulação para criação de gado para o processo de criação de porcos, e que acarreta em um aumento da carga de trabalho para os fazendeiros nos processos de localização e identificação de animais, um sistema de visão computacional em tempo real para rastreamento de porcos em estábulos, é apresentado. O algoritmo de rastreamento opera em duas etapas. A primeira etapa cria mapas de suporte, apontando para segmentos preliminares de porcos em cada quadro de vídeo. Na segunda etapa, os segmentos do mapa de suporte são usados para construir um modelo 5D-Gaussiano dos suínos individuais.

Experimentos em laboratório e em estábulos demonstram robustez do sistema. O sistema pode rastrear pelo menos três suínos ao longo de um intervalo de tempo mais longo (mais de 8 min.), sem perder a trilha e a identidade dos porcos individualmente.

Sales et al. (2015) implementaram e testaram um sistema de Radiofrequência para identificação de galinhas transitando em recintos de quatro compartimentos e duas camadas. Oito antenas RFID estavam localizadas perto das passagens entre os compartimentos e cada galinha usava uma etiqueta RFID em uma de suas pernas. O desempenho do sistema RFID foi avaliado determinando os intervalos de detecção em um teste controlado e comparando o número de entradas e duração em cada compartimento, conforme detectado pelo sistema RFID, para avaliação manual do vídeo gravado. O alcanRce de detecção do sistema RFID foi revelado para cobrir um raio de aproximadamente 29 cm da antena, excluindo uma parte do compartimento mais distante da antena. Os resultados implicam que o sistema RFID foi adequado para determinar o tempo total gasto em cada compartimento EPC, mas não é adequado para determinar o número de visitas.

Buijs et al. (2010) estudou a distribuição espacial de aves alojadas em vários agrupamentos para investigar as razões subjacentes ao padrão de distribuição espacial. Três possíveis razões foram consideradas: buscando cobertura de predadores no centro do rebanho, buscando cobertura de predadores próximos as paredes e evitar perturbações por parte de indivíduos específicos. A distribuição espacial foi analisada por comparação do número de aves em quatro partes separadas da área de confinamento. As áreas foram filmadas um dia por semana usando um sistema de gravação digital e uma câmera que poderia ser movida remotamente. As gravações

foram feitas no centro de cada área, em um ângulo de 90◦ em relação ao chão. Cada área foi gravada por 5 min. por vez, seis vezes por dia (duas vezes pela manhã, tarde e noite), todos os três períodos sob a luz. A distribuição espacial foi determinada nas semanas 4-6, por contagem do número de animais em quatro áreas da área de criação (interno, meio interno, meio externo, externo).Os resultados mostram que, na 4ª e 5ª semanas, mais animais estavam presentes no centro da área de criação do que nas outras áreas, em algumas densidades de tratamento. A distribuição espacial pode ser mais bem descrita como uma tentativa pelos pássaros para alcançar uma posição central em baixas densidades e para minimizar distúrbios por espécies específicas.

2.4.1 Avicultura

Uma das aviculturas mais desenvolvidas e competitivas do mundo está aqui, no Brasil, com a qual foram atingidos patamares de excelência que podem servir como referência para outros países. Uma série de fatores contribuíram para o alcance deste desse status. São eles: o clima, a água, a disponibilidade de terras agricultáveis para o plantio de grãos, a existência de institutos e grupos de pesquisa que desenvolveram tecnologia para a produção de aves de corte em condições de clima tropical e subtropical e, por fim, um mercado consumidor grande, com expansão contínua (MENDES, 2014).

Com predominância de localização nas regiões sul e sudeste, está havendo o desenvolvimento de novos polos de produção nas regiões centro-oeste e nordeste. A Figura 06 apresenta o Efetivo de aves no Brasil em 2019 distribuído por estado (IBGE, 2021).

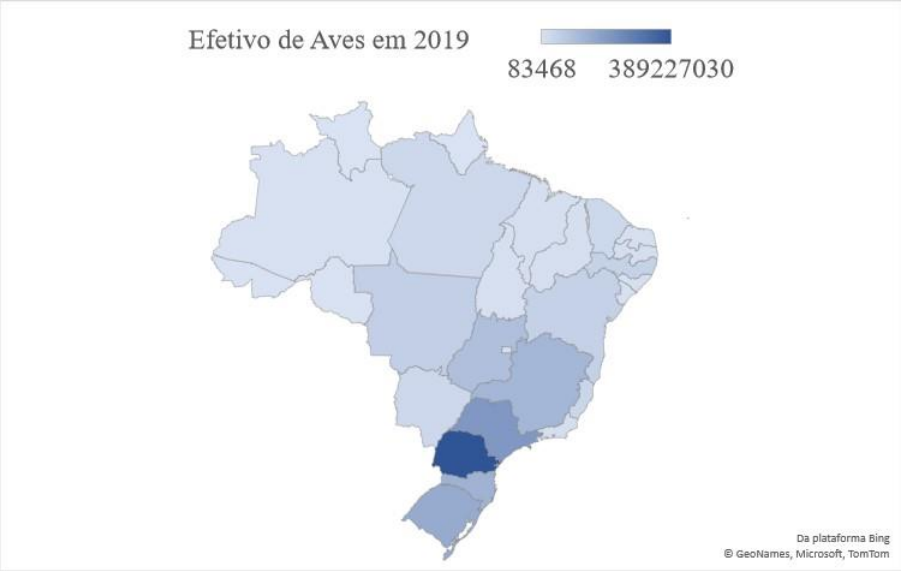

Figura 8 - Efetivo de aves no Brasil em 2019

Fonte: IBGE (2021)

O Brasil tem um grau de competitividade alto no cenário internacional em termos de produção de frango, porém a manutenção desta competitividade dependerá de sua capacidade de melhorar a infraestrutura e a logística e implementar sistemas tecnológicos que aumentem esta produtividade (FILHO e TALAMINI, 2014).

Observado o gráfico da Figura 07 pode-se notar primeiramente a proporção dos custos com alimentação dentro do processo e, que o custo deste fator é menor na Ucrânia. Desta forma pode-se inferir que, a variação do preço da alimentação tem um impacto significativo na determinação do preço final do frango. Considerando o custo total, também pode-se notar que o Brasil tem o menor custo total de produção.

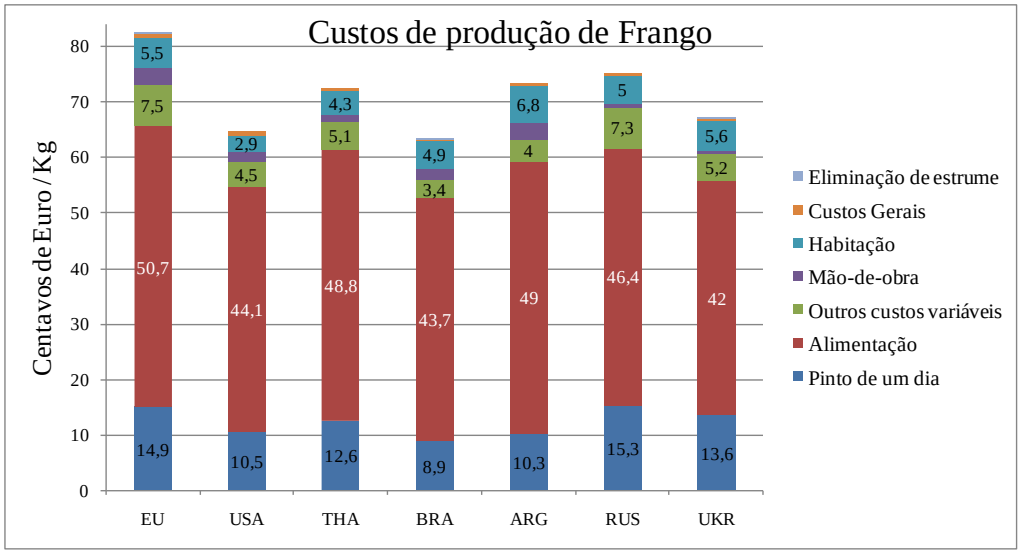

Figura 9 - Custos de produção de frango na União Europeia e seis países terceiros em 2017

Fonte: Wageningen University & Research (2018)

A Tabela 02 apresenta os percentuais de participação dos fatores que compõem os custos de produção de frango (EMBRAPA, 2021)

Tabela 2 - Composição dos custos de produção de frango

Composição do custo Frango	
73,76%	Alimentação
13,37%	Pinto de um dia
3,78%	Mão de obra
2,97%	Transporte
2,01%	Depreciação
1,64%	Custo de capital

1,46%	Energia elétrica | Cama | Calefação
0,65%	Manutenção | Financeiro | Funrural
0,18%	Diversos | Outros
0,18%	Sanidade

Fonte.: (EMBRAPA, 2021)

Da mesma forma como foi apresentado na Figura 07, a alimentação representa a maior parte dos custos de produção. No caso do Brasil este percentual é de 73,76%. Um outro custo que tem uma representatividade importante no total é o preço o Pinto de um dia com 13,37% de participação.

Após estes dados de exportação e de custos de produção, uma pergunta poderia surgir. O que deve definir o bom desempenho das exportações de frango do Brasil? Normalmente, o que define a competitividade de um determinado produto são dois fatores: 1º. Qualidade e 2º. Preço. Tendo em vista que a qualidade da carne das aves é definida basicamente pelo seu código genético, sem considerar a alimentação e que, este código genético é o mesmo em qualquer frango ao redor do mundo. Então resta a suspeita que o preço deve determinar este grau de competitividade onde, o menor preço define a maior quantidade de frango exportado. Então, desta forma, o que define o preço de um produto é basicamente o custo de produção deste produto. Com base neste raciocínio, efetuou-se um levantamento dos dados de preço e custos de produção de frango e calculou-se o grau de correlação entre estes dados. O resultado é apresentado na Tabela 03.

Tabela 3 - Preços e custos de produção de frangos

Fonte	**CEPEA/ESALQ (R$/kg) - FRANGO RESFRIADO**	**Embrapa**
Mês	**Atacado, média (R$/kg) das regiões: Grande São Paulo, São José do Rio Preto e Descalvado**	**Custo / tonelada**
01/2020	5,03	233,05
02/2020	4,81	237,30
03/2020	4,77	247,20
04/2020	4,11	263,02
05/2020	3,96	263,77
06/2020	4,50	262,06
07/2020	4,88	265,91

08/2020	5,00	282,48
09/2020	5,68	301,91
10/2020	6,07	328,76
11/2020	6,35	345,57
12/2020	6,03	336,88
Correlação Preço Médio x Custo	**0,82**	

Fonte.: (CEPEA/ESALQ, 2021; EMBRAPA(f), 2021)

Por fim, a Tabela 05 apresenta, os dados e o resultado do cálculo de correlação entre os preços médios de suíno vivo pagos nos estados de São Paulo, Santa Catarina, Rio Grande do Sul, Paraná e Minas Gerais (CEPEA/ESALQ, 2021) e os custos de produção (EMBRAPA(f), 2021). O valor resultante deste cálculo foi de 0,85 numa escala de 0 à 1. Ou seja, da mesma forma como no frango, obteve-se um grau de correlação que demonstra a importância da influência do custo de produção no preço final.

2.5 Uso de ferramentas computacionais na produção animal

Como apresentado na Tabela 03, a correlação entre os preços médios de frango pagos pelo frango resfriado nas regiões de Grande São Paulo, São José do Rio Preto e Descalvado (CEPEA/ESALQ, 2021) e os custos de produção (EMBRAPA(f), 2021) é de 0,82 numa escala de 0 à 1. Ou seja, um grau de correlação que demonstra a importância da influência do custo de produção no preço final.

2.5.1 Suinocultura

Para Santana et al. (2008) a produção de suínos no Brasil é composta por várias atividades como: a criação dos suínos (granjas), a transferência, as atividades de corte, de armazenamento e transporte e, finalmente, de consumo e as atividades de venda de carne in natura e de embutidos. Por outro lado, segundo Mota (2013) a cadeia produtiva de suínos envolve outras atividades como: a indústria de ração; a produção de milho e de soja; a indústria de saúde animal; os agentes encarregados do material genético.

Em seguida, é apresentado na Figura 08 um mapa com a representação da distribuição dos efetivos de suínos no território brasileiro.

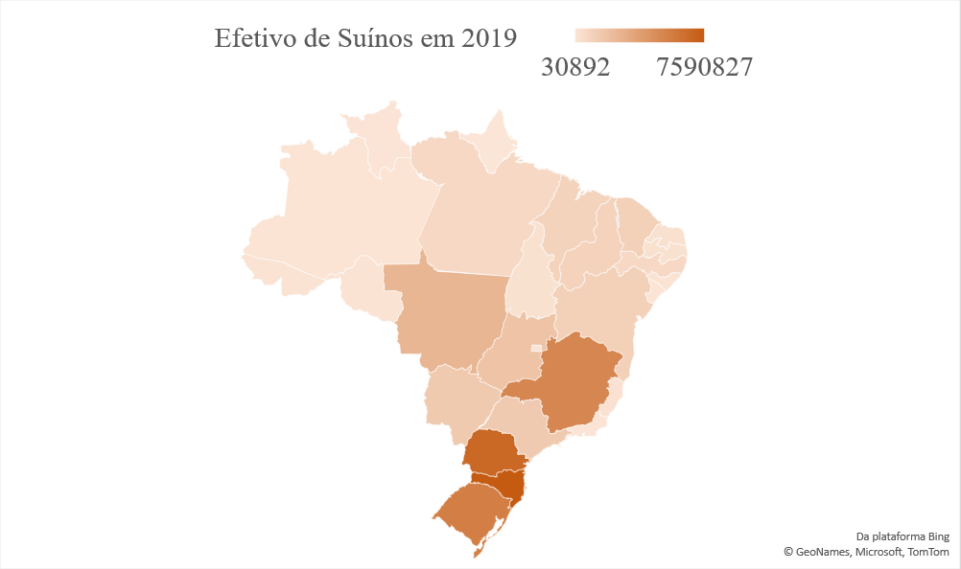

Figura 10 - Efetivo de suínos no Brasil em 2019

Fonte: IBGE (2021)

O mapa apresentado na Figura 08 ilustra a distribuição dos efetivos de suínos no Brasil no ano de 2019. De uma forma parecida como ocorre na distribuição dos efetivos de aves apresentado na Figura 06 a predominância dos planteis ocorre nas regiões sul e sudeste, desta vez, com uma forte presença também, no estado de Minas Gerais.

Outro fator importante da produção de suínos a ser analisado é o custo. Os custos de produção têm impacto determinante na competitividade. A competitividade brasileira ainda tem por base, além do preço dos grãos no Centro-Oeste, a sua eficiência zootécnica e, sobretudo, os custos da mão de obra e de instalações e equipamentos. Em 2018, o câmbio teve impacto determinante na competitividade dos países, com a desvalorização do Real de 19% ampliando a vantagem em custos no Brasil (MIELE, 2019).

O gráfico da Figura 09 apresenta os custos de produção de suínos em Euros por quilo, em vários países e, no Brasil também. Pode-se notar, pelos dados exibidos, que o Brasil e os Estados Unidos são os países com custos de produção mais baixos e por consequência, são os países com maior competitividade neste mercado.

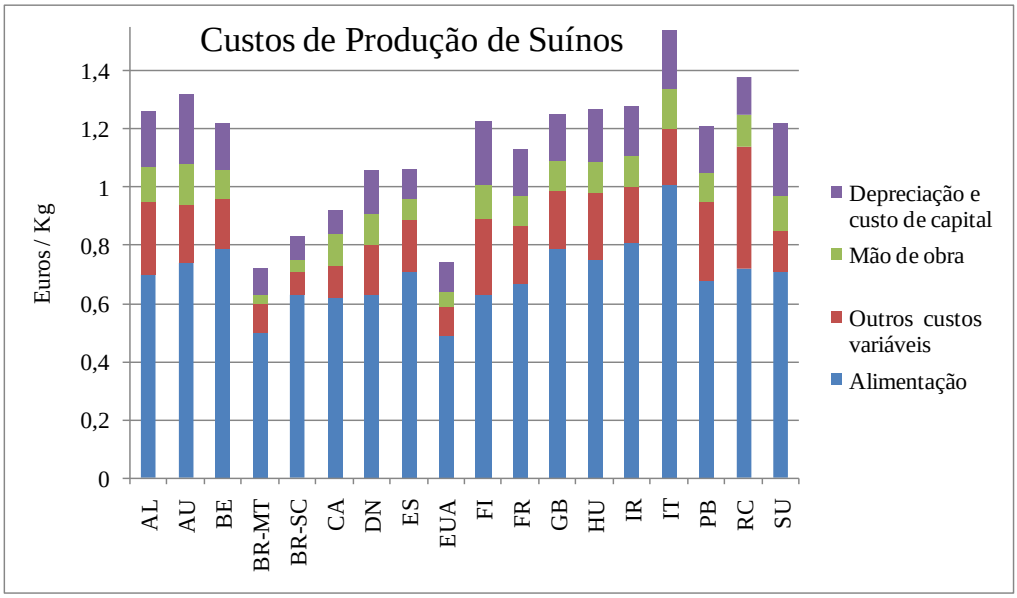

Figura 11 - Custos de produção de suínos na rede IntergPIG

Fonte: Miele (2019)

Um detalhe importante a ser ressaltado é que, embora os Estados Unidos tenham um custo de mão de obra maior que o Brasil também, têm um custo de alimentação menor. E como os custos com alimentação tem a maior participação no custo total de produção, torna os custos totais de produção americano competitivos com os custos brasileiros, mesmo com a cotação da moeda Real em baixa que, por sua vez, fazem os preços do produto brasileiro mais baixo no mercado global.

A Tabela 04 apresenta os percentuais de participação dos fatores que compõem os custos de produção de suínos (EMBRAPA_S, 2021)

Tabela 4 - Composição dos custos de produção de suínos

Composição do custo Suínos	
81,61%	Alimentação
2,90%	Mão de obra
2,90%	Transporte
2,12%	Depreciação
2,90%	Custo de capital
0,44%	Energia elétrica | Cama | Calefação
3,55%	Manutenção | Financeiro | Funrural
2,27%	Diversos | Outros
1,31%	Sanidade

Fonte.:(EMBRAPA(s), 2021)

Da mesma forma como foi apresentado na Figura 04, a alimentação representa a maior parte dos custos de produção. No caso do Brasil este percentual é de 81,61%. Como foi feito com os dados de produção e exportação de frangos no item 1.1.3.. Realizou-se o levantamento dos dados de preço pago ao produtor de suínos para, junto com os dados de custos de produção realizar o cálculo de correlação. Os dados e o resultado do cálculo de correlação são apresentados pela Tabela 05.

Tabela 5 - Preços e custos de produção de suínos

Fonte	**CEPEA/ESALQ (R$/kg) - SUÍNOS Preço recebido pelo produtor R$/Kg sem ICMS**						**Embrapa Custo / tonelada**
Mês	**SP**	**SC**	**RS**	**PR**	**MG**	**Média**	
01/2020	5,99	5,36	5,24	5,63	6,15	5,67	244,53
02/2020	5,37	4,92	4,86	5,10	5,57	5,16	246,88
03/2020	5,75	5,30	5,16	5,41	5,69	5,46	254,18
04/2020	4,31	3,79	3,96	3,97	4,14	4,03	263,09
05/2020	4,47	3,88	3,78	3,94	4,84	4,18	265,73
06/2020	4,72	4,11	4,13	4,17	5,23	4,47	264,50
07/2020	5,80	5,23	4,99	5,29	6,25	5,51	270,54
08/2020	7,23	6,68	6,28	6,80	7,50	6,90	288,40
09/2020	7,95	7,54	6,99	7,55	8,12	7,63	306,95
10/2020	8,77	8,27	7,73	8,29	8,76	8,36	352,95
11/2020	9,49	8,84	8,56	8,89	9,20	9,00	387,07
12/2020	7,46	7,27	7,49	6,92	7,31	7,29	375,17
Correlação Preço Médio x Custo						**0,85**	

Fonte.: (CEPEA/ESALQ, 2021; EMBRAPA(s), 2021)

Por fim, a Tabela 05 apresenta, os dados e o resultado do cálculo de correlação entre os preços médios de suíno vivo pagos nos estados de São Paulo, Santa Catarina, Rio Grande do Sul, Paraná e Minas Gerais (CEPEA/ESALQ, 2021) e os custos de produção (EMBRAPA(s), 2021). O valor resultante deste cálculo foi de 0,85 numa escala de 0 à 1. Ou seja, da mesma forma como no frango, obteve-se um grau de correlação que demonstra a importância da influência do custo de produção no preço final.

2.6 Uso de ferramentas computacionais na produção animal

O fato de ser um grande produtor e exportador de carne de corte não ocorre em vão. A produção cientifica, e o desenvolvimento de estudos, com o objetivo de melhorar a qualidade da carne e maximizar a produção, têm gerado conhecimento tecnológico que auxilia o agronegócio brasileiro a atingir esses objetivos.

Souza et al. (2020) realizaram um estudo que avaliou a suscetibilidade ß-lactam e a relação genotípica de Salmonella Heidelberg na cadeia produtiva avícola brasileira. Foram utilizadas 62 cepas de S. Heidelberg da cadeia produtiva de aves (aves, carne de aves e aves). Todas as cepas foram avaliadas para suscetibilidade antimicrobiana por teste de disco de difusão, bem como genes de resistência ß-lactam. A relação genotípica foi avaliada pela Eletroforese de Gel de Campo Pulsado, utilizando enzima de restrição Xba1. Quarenta e uma cepas foram caracterizadas como multidroga-resistentes de acordo com a caracterização do fenótipo. A disseminação da resistência pela ampC continua a aumentar, transformando assim a preocupação com a saúde pública, uma vez que os antimicrobianos β-lactam são usados como um tratamento terapêutico em humanos.

Anderson (2007) utilizou uma técnica denominada de “Esgrima virtual” que é um método de controle de animais. O controle ocorre alterando o comportamento de um animal através de uma ou mais pistas sensoriais administradas ao animal depois que ele tentou penetrar um limite gerado eletronicamente. Este limite pode ser de qualquer forma geométrica, e embora invisível pelo olho, é detectado por um dispositivo eletrônico usado pelo animal.

White et al. (2018) descreveram o processo de uso de big data e a estrutura analítica preditiva para criar ferramentas para impulsionar decisões na produção de frango, considerando a saúde e o bem-estar das aves. Os resultados experimentais mostraram que aplicações de análises preditivas, usando dados coletados ou que possam ser coletadas em operações pecuárias facilitarão o manejo de precisão de animais.

Halachmi e Guarino (2016) aplicaram conceitos de pecuária de precisão com o uso de dados, extraídos em tempo real, de parâmetros do leite, e do comportamento das vacas, por meio da ruminação, para detectar doenças pós-parto. Pereira et al. (2013) usaram técnicas combinadas de processamento de imagem e visão computacional para fornecer uma metodologia para identificar o comportamento do criador de frangos brancos. Os experimentos realizados apresentaram resultados que confirmaram a aplicabilidade da metodologia desenvolvida para o grupo de estudo em particular.

Terrasson et al. (2017) utilizaram soluções baseadas na agregação de tecnologias, como objetos onipresentes interconectados, para oferecer novas ferramentas para melhorar a produtividade da pecuária e a qualidade de seus respectivos produtos, simplificando, ao mesmo tempo, os processos. Já Ramirez et al. (2018) desenvolveram uma técnica para avaliar o ambiente térmico (TE – termal environment) de criadouros de porcos, em uma função da diferença da temperatura média confortável do corpo (ΔTb) usando massa corporal, temperatura da lâmpada seca (Tdb), umidade relativa (UR) e entradas de velocidade de ar.

Tullo et al. (2019) realizaram uma revisão do impacto ambiental das práticas atuais da pecuária e discutiram as vantagens oferecidas pela Pecuária de Precisão (PLF), como estratégia potencial para mitigar riscos ambientais. A literatura analisada mostrou que a aplicação da PLF em fazendas pode levar a uma redução de gases de efeito estufa (GEE) e emissão de amônia (NH_3) no ar, nitratos e poluição de antibióticos nos corpos d'água, fósforo, antibióticos e metais pesados no solo.

Banhazi e Black (2009) devido à exigência do sofisticado mercado global para produtos de pecuária, por segurança, padronização, barateamento, sustentabilidade e produtos favoráveis ao bem-estar; descreveram o papel potencial da Pecuária de Precisão (PLF) que, pode garantir que os conhecimentos existentes e novos sejam implementados efetivamente nas fazendas para melhorar o retorno do investimento dos produtores.

Vranken e Berckmans (2017) demonstraram que as ferramentas de criação de gado de precisão (PLF) desenvolvidas em laboratório podem ser totalmente operacionais nas fazendas e podem trazer valor aos agricultores e outros parceiros nas cadeias produtivas. No conceito de Pecuária de Precisão (PLF), o animal é usado como um sensor, e algoritmos traduzem as respostas animais medidas em indicadores-chave. Os autores alertaram para o fato de que se deve prestar atenção à formação adequada dos agricultores e à maior integração do sistema (PLF) nos sistemas de gestão operacional.

Amraei et al. (2018) realizaram o processamento de imagens digitais para investigar a possibilidade de estimativa do peso corporal de frangos de corte com base em um modelo dinâmico. Um total de 2440 imagens foram registradas de cima de uma área delimitada com 30 frangos. O algoritmo de ajuste elipse foi implementado para localizar os frangos dentro da área usando o método de Hough transformada. A cabeça e a cauda dos frangos foram desconsideradas usando o método Chan-Vese e, então, usando o processamento de imagem, seis medidas dos corpos foram calculadas. Um modelo dinâmico de segunda ordem foi utilizado para predizer o peso dos frangos. Os

resultados apresentaram a acurácia da predição do modelo usado na predição do peso dos animais atingiu um valor de 98%.

Waker e Nääs (2018) investigaram quais são os principais atores da cadeia de suprimentos do frango de corte e qual é a dinâmica desta cadeia. O estudo baseou-se nos principais atores da cadeia doméstica de produção de frango, no período de 2000 a 2015. Um indicador central foi estabelecido por meio de uma abordagem de análise das redes sociais para determinar suas posições na cadeia como um todo. Os resultados obtidos apresentaram a competitividade da cadeia da produção de aves domésticas demonstrada pelo ganho de produtividade dos recentes anos que, resultaram num progressivo decremento dos custos de produção e, consequentemente no preço, comparado com outras carnes.

Nääs et al. (2015) realizaram uma avaliação da cadeia de suprimento de carne de frango de 2000 a 2010, por meio de análise de dados disponibilizados pelas redes sociais (FAO, IBGE, MAPA, MDIC, USDA, CONAB, UBABEF), cujas fontes são, os governos e instituições privadas. O software UCINET6 for Windows, foi utilizado para calcular os atributos estruturais e os indicadores da rede. Os valores que explicam as interações da rede foram obtidos por meios dos seguintes cálculos: coeficiente de clusterização, distância média entre os atores, agrupamento e medida de centralidade e distância geodésica baseado em visão da rede como um conjunto de nós conectados por ligações usando teoria de grafos. Os resultados mostraram que a produção de carne de frango evoluiu positivamente nos últimos dez anos e, esta evolução foi influenciada levemente pelos desafios internacionais.

Os dados apresentados sobre a competitividade da pecuária de corte brasileira, especificamente aves e suínos, mostra primeiramente, que o Brasil tem um desempenho importante no comércio mundial, sendo um dos líderes na exportação desses produtos. Outro aspecto apresentado, refere-se aos custos de produção que, segundo os dados, o Brasil tem um dos menores dentre os líderes em produção e exportação de aves e suínos no mundo. Cálculos foram feitos para identificar o grau de correlação entre os custos de produção e o preço médio de frangos e suínos e, os resultados mostraram respectivamente graus de 0,82 para o frango e 0,85 para os suínos, numa escala de 0 à 1.

Por inferência, pode-se concluir que os custos de produção são um importante fator de determinação dos preços e, consequentemente da competitividade desses produtos no mercado mundial, uma vez que a qualidade, que seria o outro fator determinante da competitividade é relativamente a mesma em qualquer um dos países líderes em exportação no mercado mundial.

É então, neste momento que surge a importância de se manter os custos de produção em níveis baixos e isto torna-se possível por meio de métodos de otimização de processos e, um dentre eles é o algoritmo metaheurístico híbrido com mecanismo de aceleração de convergência (SAGAC), proposto por esta pesquisa.

2.7 Algoritmos de Otimização

Dentre as várias técnicas tradicionais de otimização, podemos citar: programação Linear, Programação Dinâmica e Programação Não-Linear (DING et al., 2006). Mas estas técnicas têm como principal característica, a verificação de todas as soluções existentes no conjunto de soluções, tornando assim, o processo de otimização lento, ou inviável quando conjunto de soluções é do tipo NP-Completo.

As técnicas metaheurísticas são ferramentas poderosas para resolução de problemas de otimização complexos cujos espaços de busca das soluções ótimas sejam muito grandes para que se possa determiná-las com precisão através de um método determinístico com tempo de processamento aceitável (PASZKOWICZ, 2009).

Dentre as várias técnicas metaheurísicas utilizadas atualmente destacam-se: os Algoritmos Genéticos (GA) (HOLLAND, 1975), *Simulated Annealing* (SA) (KIRKPATRICK, GELATTI e VECCHI, 1983), a Busca Tabu (BT) (GLOVER & LAGUNA, 1997), Sistema Colônia de Formigas (AntColony System – ACS) (DORIGO, MANIEZZO e COLORNI, 1996), o algoritmo híbrido GASA(*Genetic Algorithms and Simulated Annealing*) (ZHANG et al., 2009) entre outros. Para Oysu e Bingul (2009) dentre as técnicas supracitadas, o GA e o SA têm sido amplamente empregadas na resolução de problemas de otimização.

O GASA é uma técnica de otimização que aplica a computação evolucionária do GA e, em seguida, a abordagem estocástica do SA (ZHANG et al., 2009). O algoritmo SAGAC, similar ao GASA, também combina a aplicação das técnicas do GA e do SA mas, no sentido inverso. Este algoritmo metaheurístico híbrido, utiliza o *Simulated Annealing* (SA) para gerar uma população de soluções iniciais com um alto grau de qualidade. A partir daí, aplica o método evolucionário do Algoritmo Genético (GA) nesta população inicial com a inclusão de um mecanismo(função) que promove uma aceleração na convergência(AGAC) dos resultados obtidos.

2.7.1 *Simulated Annealing* (SA)

Segundo (KIRKPATRICK, GELATTI e VECCHI, 1983), *Simulated Annealing* (SA) ou têmpera simulada, é uma técnica de busca local que simula o processo de recozimento de metais, no qual o metal é aquecido a altas temperaturas e, em seguida, é feito um resfriamento sistemático do mesmo visando atingir um ponto de equilíbrio

caracterizado por uma microestrutura ordenada e estável. Antes de se processar o SA, é necessário definir o cronograma de resfriamento que, é determinado pelo Esquema de Decaimento da Temperatura.

O Esquema de Decaimento da Temperatura (EDT), define como a temperatura é decrescida e o número de iterações realizadas em cada temperatura. A convergência do SA, assim como o tempo de processamento e a probabilidade de aceitação estão diretamente ligados ao EDT adotado. Segundo Oysu e Bingul (2009) uma das dificuldades para se determinar o EDT, é que cada problema requer um tipo.

A Tabela 06 apresenta os parâmetros utilizados para se definir o EDT e o valor adotado para cada uma delas neste trabalho.

Tabela 6 - Parâmetros utilizados para definir o EDT

Parâmetro	Valor
Temperatura inicial (*Temp0*)	1.000.000
Função de decaimento da Temperatura (*Temp*)	*Temp(i+1)* = *Temp(i)*-1
Número de iterações em cada Temperatura	1
Critério de Parada do algoritmo	*Temp* = 0

A função de decaimento da temperatura, apresentada na Tabela 06, determina um esquema de decaimento Linear.A Figura 10 (VASAN e RAJU, 2009) ilustra os passos principais da técnica de otimização de processos por meio do *Simulated Annealing*.

No fluxograma da Figura 12, a variável NI refere-se ao número de iterações ou ciclos que o algoritmo irá repetir. O “critério Metropolis”, segundo Vasan e Raju (2009) é a probabilidade do ponto seguinte estar em $\mathrm{x(t' + 1)}$. Depende da diferença nos valores em função desses dois pontos ou $\mathrm{E = E(t' + 1) - E(t')\Delta}$. O valor de probabilidade $\mathrm{P(E\,(t' + 1))}$ é calculada usando a distribuição de probabilidade de Boltzmann, como mostra a Equação 1.

$$\mathrm{P(E(t' + 1)) = min(1, e(-\Delta E/kbT))} \quad (1)$$

onde, e $\mathrm{(-\Delta E/kbT)}$ determina a rapidez com decresce a temperatura.

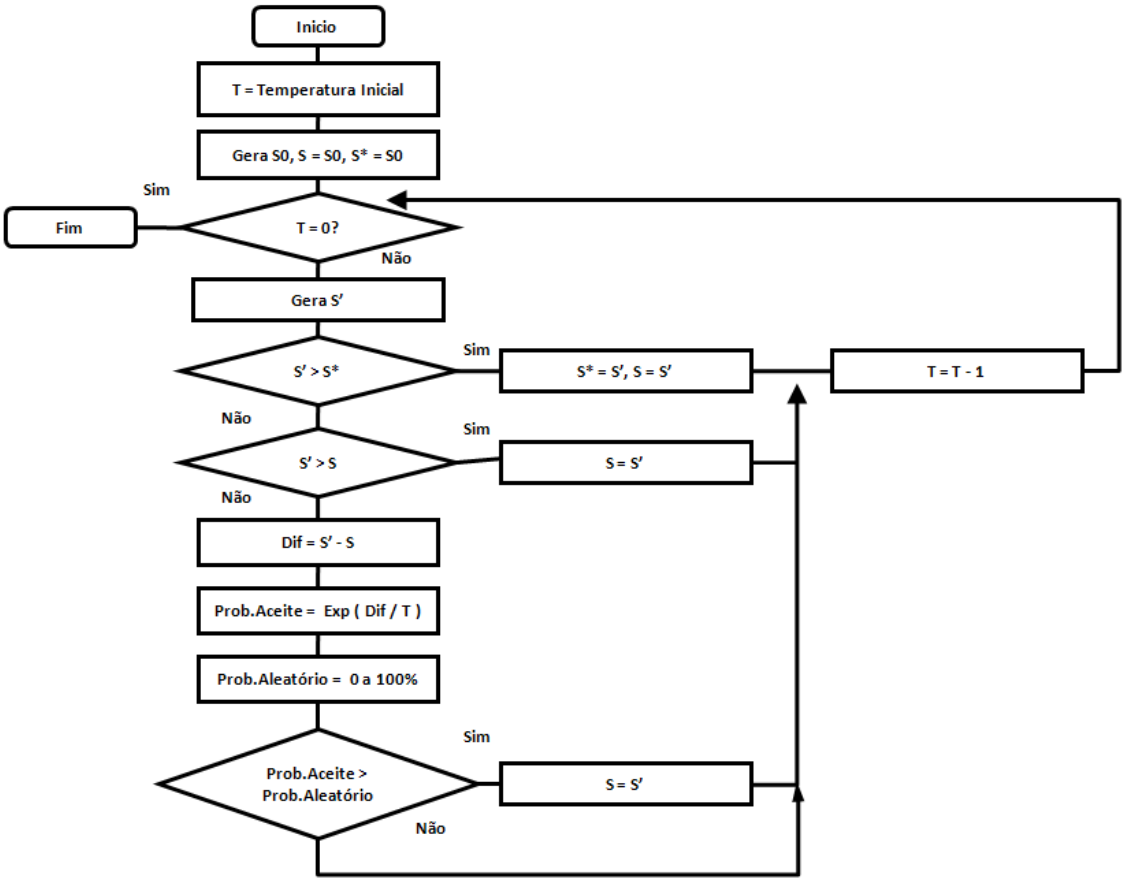

Figura 12 - Fluxograma do Simulated Annealing adaptada de (VASAN e RAJU, 2009)

Na Figura 12 é apresentado o fluxograma do algoritmo *Simulated Annealing* no qual algumas variáveis são utilizadas para o seu funcionamento. São elas:

. T = Temperatura inicial;

. S0 = Solução inicial;

. S = Solução anterior à Solução atual;

. S' = Solução atual;

. S* = Melhor solução

. Dif = Diferença entra a S' e S.

2.7.2 Algoritmos Genéticos (GA)

Segundo Holland et al. (1975) o algoritmo genético (GA) consiste em uma técnica metaheurística de otimização baseada no processo de seleção natural e tem sido usado para resolver problemas de otimização, em diversas áreas, nas últimas décadas.

Para Mitchell (1997) a pesquisa por uma hipótese apropriada começa com uma população, ou coleção, de hipóteses inicias. Membros da população atual dão origem à próxima população por meio de operações como, cruzamento e mutação aleatória, que são inspirados nos processos da evolução biológica. A cada passo, as hipóteses da

população atual são avaliadas em relação à uma dada medida de fitness, com as hipóteses mais adequadas selecionadas probabilisticamente como sementes para produzir a próxima geração.

A seguir, é apresentado, segundo Linden (2008) alguns termos utilizados quando é feita referência ao GA:

a. Cromossomos – é uma maneira e traduzir a informação do nosso problema de uma maneira viável de ser tratada pelo computador. Quanto mais ela for adequada ao problema, maior a qualidade dos resultados obtidos.

A Figura 13 apresenta o esquema da representação cromossômica como uma maneira de traduzir a informação de uma forma viável para que o computador possa tratar.

Valor Real=8				Valor Real=26					Valor Real=15			
Gen1				Gen2					Gen3			
1	**0**	**0**	**0**	**1**	**1**	**0**	**1**	**0**	**1**	**1**	**1**	**1**
Alelo 01	Alelo 02	Alelo 03	Alelo 04	Alelo 05	Alelo 06	Alelo 07	Alelo 08	Alelo 09	Alelo 10	Alelo 11	Alelo 12	Alelo 13

Figura 13 - Esquema cromossômico para três variáveis

No esquema cromossomial representado na Figura 13 pode-se verificar os elementos que compõem a informação dentro do cromossomo. O Alelo é a unidade binária de informação. Um conjunto de alelos compõem um Gene que, representa em código binário o valor Real de cada uma das variáveis do problema.

Portanto, um cromossomo é a concatenação das variáveis que fazem parte de um determinado problema.

b. População Inicial – é o conjunto de indivíduos (cromossomos) escolhidos aleatoriamente.

c. Função de Avaliação – é a maneira utilizada pelo GA para determinar a qualidade de um indivíduo como solução do problema em questão.

d. Seleção de pais – o método de seleção de pais deve simular o mecanismo de seleção natural que atua sobre as espécies biológicas, em que os pais mais capazes têm maiores chances de gera filhos, ao mesmo tempo em que os pais menos aptos também podem gerar descendentes. Deste modo, os indivíduos com melhor avaliação têm privilégios neste processo, sem desprezar completamente aqueles com pior avaliação.

e. Cruzamento – Após a seleção dos pais, um ou mais pontos de corte no cromossomo são selecionados separando-o em partes. O cruzamento de partes distintas dos cromossomos de cada par de pais formará um novo par de indivíduos, chamados Filhos. Estes filhos farão parte da nova população.

Não há um padrão nem uma regra fixa a ser obedecida no que tange à quantidade de pontos de corte dos cromossomos dos pais para realizar o cruzamento. Isto também vale para a(s) posição(ões) dos cromossomos onde haverá(ão) este(s) corte(s). O que determina isto é apenas a vontade do programador no momento da criação do Algoritmo Genético.

A Figura 14 ilustra um cruzamento de dois indivíduos pais formados por três genes simulando as três variáveis envolvidas em um processo (concentração, temperatura e tempo). Cada variável tinha um ponto de corte que, conforme foi estabelecido na calibração do GA tinha sua posição determinada aleatoriamente.

Conforme mostrado na Figura 14, os filhos A e B são gerados da seguinte forma: O filho A é formado pela junção da Parte 1 do cromossomo do pai A mais, a Parte 2 do cromossomo do pai B mais, a Parte 3 do cromossomo do pai A mais, a Parte 4 do cromossomo do pai B. Então, o filho B é formado pela junção da Parte 1 do cromossomo do pai B mais, a Parte 2 do cromossomo do pai A mais, a Parte 3 do cromossomo do pai B mais, a Parte 4 do cromossomo do pai A.

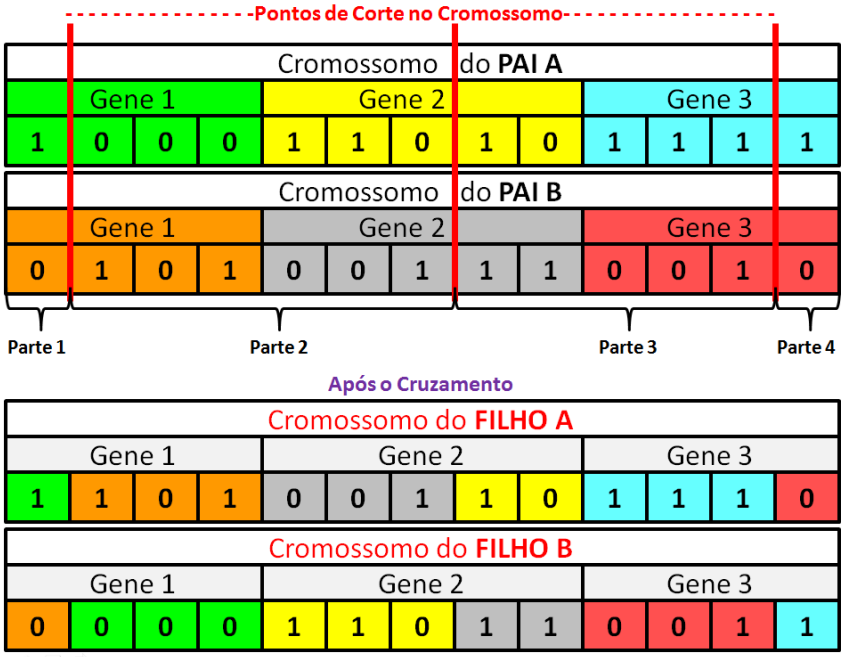

Figura 14 - Esquema de cruzamento do GA com três genes

f. Ponto de Corte – é uma posição entre dois alelos de um cromossomo. Cada indivíduo de n alelos contém $n - 1$ pontos de corte, e este ponto de corte é o ponto de separação entre cada um dos alelos que compõem o material genético e cada pai. O ponto de corte pode ser fixo ou determinado aleatoriamente. Também pode haver mais de um ponto de corte no cromossomo e, estes pontos de corte podem ser fixos ou, determinados aleatoriamente, dependendo do esquema de cruzamento escolhido.

g. Mutação – Depois de gerados os filhos, entra em ação o operador de mutação. Este opera da seguinte forma: ele tem associado, na maioria das vezes, uma probabilidade baixa e é sorteado um número entre 0 e 1. Se ele for menor que a probabilidade predeterminada então o operador atua sobre um alelo pré-determinado ou, escolhido aleatoriamente ou por meio de uma regra, alterando o seu valor binário, ou seja, para 0 ser for igual a 1 ou, para 1 se for igual a 0.

O valor da probabilidade que decide se o operador de mutação será ou não aplicado é um dos parâmetros do GA.

h. Elitismo – é uma pequena alteração na função de população que melhora o tempo de processamento, mas que garante que o desempenho do GA cresça com o decorrer das gerações. A idéia básica por trás do elitismo é a seguinte: os n melhores indivíduos de cada geração não devem “morrer” junto com a geração, mas sim passar para a próxima geração visando garantir que seus genomas sejam preservados.

i. Geração – é o conjunto de indivíduos (população) que é submetido aos operadores de avaliação, cruzamento e mutação em cada laço de repetição do processamento do GA. Ao determinar a quantidade de gerações que um GA terá em seu processamento, determinou-se o seu número de laços de repetição ou ciclos.

A Figura 15 ilustra passo a passo, para um melhor entendimento, a técnica de otimização de processos por meio de algoritmos genéticos.

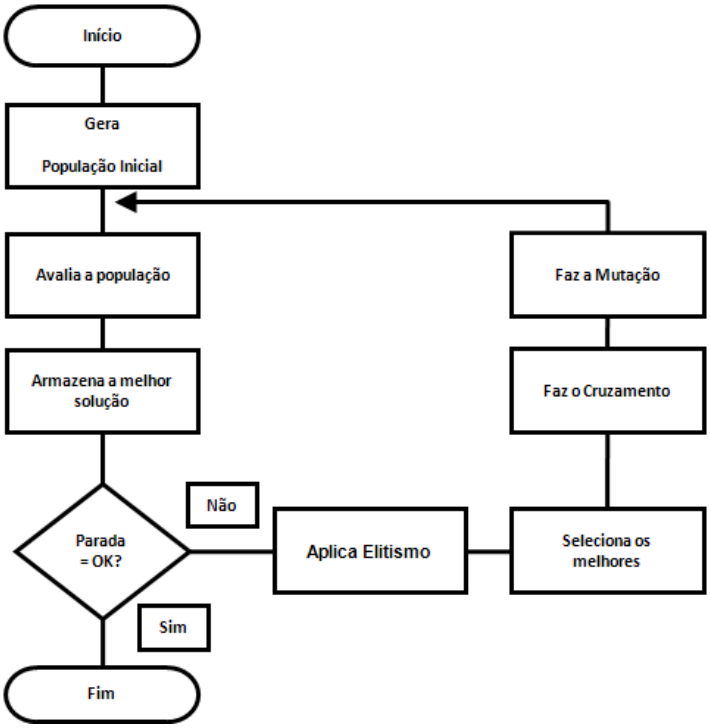

Figura 15 - Fluxograma do Algoritmo Genético.Adaptado de Linden (2008)

Como se pode observar, na Figura 15, a técnica considera todos os elementos responsáveis pelo processo de evolução das espécies desde os microscópicos como o Cromossomo até os Macroscópicos como Indivíduos, Gerações, etc.

Com cada gene é possível representar, para cada parâmetro, um valor de intervalo, o que atende as restrições impostas. O GA é configurado da seguinte maneira:

(a) Número de gerações;

(b) Tamanho da população;

(c) Taxa de mutação;

(d) Taxa de elitismo;

(e) Esquema de cruzamento.

Conforme Linden (2008) em cada geração a probabilidade de um ou vários indivíduos, tornar-se uma solução do problema é aumentada. Diferente de outras técnicas de busca, o GA

opera sobre a população paralelamente, rendendo várias soluções em um momento.

2.7.3 Mecanismo de Aceleração de Convergência

O Algoritmo Genético com Aceleração de Convergência é constituído pelas mesmas etapas que compõem o GA com a apresentação de uma modificação na etapa

de geração de novas gerações que é responsável pela convergência dos resultados de forma mais acelerada que o GA convencional.

Os pseudocódigos 01 e 02 apresentam os esquemas básicos do GA e do AGAC para fins de comparação e apresentam das alterações realizadas no GA que culminaram na geração do algoritmo AGAC.

2.7.4 Esquema básico GA

Início

a) Inicialize a população de cromossomos.

b) Avalie cada cromossomo na população.

c) Enquanto o critério de parada não for satisfeito.

c.a. Selecione os pais para gerar novos cromossomos.

c.b. Aplique os operadores de recombinação e mutação a estes pais de forma a gerar os cromossomos da nova geração

c.c. Avalie os novos cromossomos gerados.

d) Fim-Enquanto

e) Apresentar o melhor cromossomo gerado

Fim.

Pseudocódigo 01– Algoritmo básico do GA.

2.7.5 Esquema básico AGAC

Início

a) Inicialize a população de cromossomos.

b) Avalie cada cromossomo na população.

c) Enquanto o critério de parada não for satisfeito.

a. Selecione os pais para gerar novos cromossomos.

b. Valor dos Filhos pior em relação aos pais

c. Enquanto filhos pior que pais ou Qtde.Tentativas de melhora menor que Qtde.Max.Tentativas.

i. Aplique os operadores de recombinação e mutação a estes pais de forma a gerar os cromossomos da nova geração (Filhos)

ii. Avalie os cromossomos filhos gerados.

iii. Trocar o pior pai pelo melhor pai vizinho mais próximo, ou seja, outro membro do grupo elite que tenha o valor de fitness maior e mais próximo que o do pior pai.

d. Fim-Enquanto

d) Fim-Enquanto

e) Apresentar o melhor cromossomo gerado

Fim.

Pseudocódigo 02 – Algoritmo básico do AGAC.

Como apresentado no pseudocódigo 02, as mudanças ocorridas no GA que geraram o algoritmo AGAC foram implementadas entre os processos de geração de cromossomos filhos e a seleção dos cromossomos que serão os pais da geração como segue:

Passo 1. Cada par de cromossomos filhos gerados é avaliado em relação aos seus pais.

Passo 2. O(s) filho(s) que for de qualidade pior em relação ao pai de pior qualidade será(ão) descartado(s) juntamente com este pai.

Passo 3. Outro pai de melhor qualidade, e mais próximo dos pais originais, é selecionado e o processo de geração é repetido para substituição do(s) filho(s) descartados.

Passo 4. Os passos de 1 a 3 se repetem até que os filhos apresentem melhora ou que a quantidade de tentativas de melhoria seja atingida.

Passo 5. Caso a quantidade de tentativas de melhoria seja atingida sem a melhora dos filhos, estes serão incorporados a nova geração e passarão pelo próximo processo de seleção dos novos pais.

Mesmo que os filhos não sejam melhores que seus pais, eles podem ter uma qualidade que seja suficiente para fazer parte do grupo (elite) de novos pais para a nova geração.A Figura 16 apresenta o esquema de funcionamento do GA com a inclusão da heurística de aceleração de convergência.

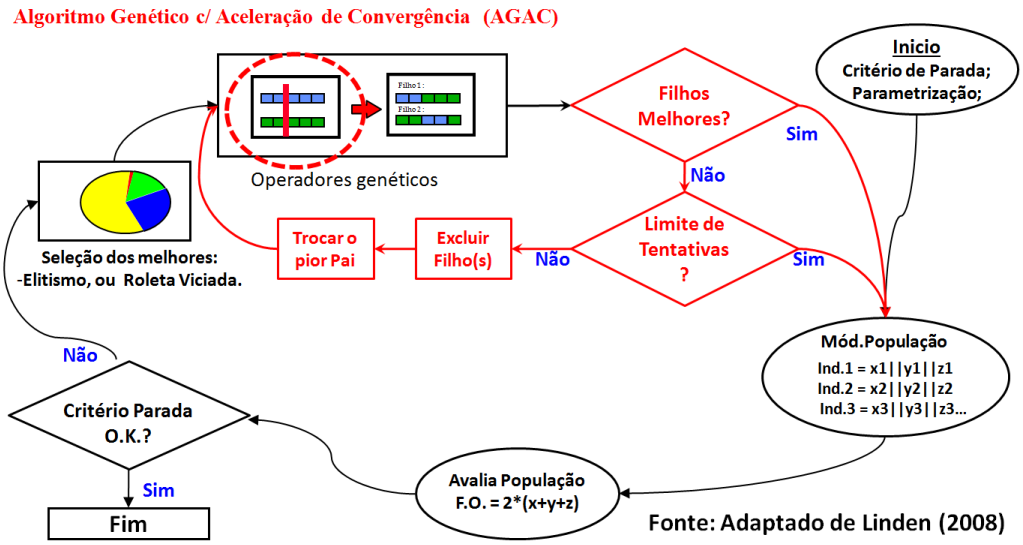

Figura 16 - Esquema do funcionamento de um AGAC

Na Figura 16 é apresentado o novo esquema proposto para o GA onde, ocorre uma avaliação imediata dos filhos após a sua geração por meio do método de *crossover*(cruzamento dos pais). Se um ou, os dois filhos têm uma avaliação pior que a avaliação do pior indivíduo que faz parte do grupo de elite então, verifica-se se o número de tentativas,de obtenção de filhos com melhores, pré-determinada tenha sido atingido. Caso não tenha sido atingido, um ou ambos os filhos serão descartados, o pior indivíduo dos pais também será descartados e um novo pai com avaliação melhor é selecionado para o cruzamento e geração dos novos filhos. Caso o número de tentativas tenha sido atingido, os filhos gerados serão incluídos na nova geração independentemente da sua avaliação.

2.7.6 Esquema básico SAGAC

O algoritmo SAGAC é composto por dois algoritmos: o *Simulated Annealing* (SA) e o Algoritmo Genético (GA) com a inclusão de um mecanismo (função) que promove uma Aceleração na Convergência (AC) dos resultados obtidos.

O algoritmo SA atua na geração de um conjunto resultados (população) que é transferido para GA compondo assim, a sua População Inicial de resultados. Com o uso do algoritmo SA é possível ter a composição de uma população inicial de boa qualidade, ou seja, indivíduos (resultados) pré-otimizados.

O comportamento rotineiro do algoritmo AGAC que promove a Aceleração da Convergência em que, após o cruzamento, há uma avaliação dos indivíduos (Filhos) gerados e uma verificação da melhoria da qualidade em relação aos indivíduos do grupo de elite da população. Se tal desenvolvimento não ocorrer, o(s) indivíduo(s) do(s) indivíduo(s) filho(s) é(são) descartado(s), o indivíduo pai de pior qualidade é trocado por outro indivíduo do grupo de elite que seja mais próximo e melhor que o indivíduo pai que foi descartado.

Após a mudança do indivíduo pai, ocorre um novo cruzamento para a geração do(s) filho(s) indivíduo(s) filho(s) excluído(s).

Essa sequência de etapas será repetida até que ambos os filhos atendam aos critérios de melhora ou, até que o número de tentativas de melhoria estipulado destes filhos seja alcançado.

A Figura 17 mostra o fluxograma do algoritmo híbrido SAGAC.

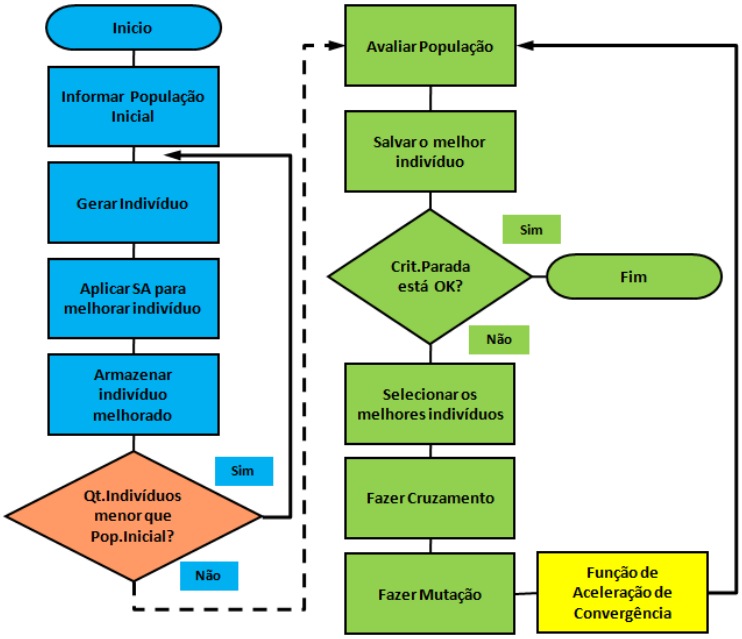

Figura 17 - Esquema do algoritmo híbrido SAGAC

A cada ciclo de processamento do algoritmo *Simulated Annealing* (SA), o melhor resultado (individual) obtido é armazenado para compor a população inicial utilizada pelo Algoritmo Genético modificado com mecanismo de aceleração de convergência (AGAC).

CAPÍTULO 3

3 Metodologia

A metodologia de pesquisa escolhida para realização deste trabalho foi a experimental. A pesquisa experimental determina um objeto de estudo, selecionam-se as variáveis que seriam capazes de influenciá-lo, definem-se as formas de controle e de observação dos efeitos que as variáveis produzem no objeto (GIL, 2002).

Iniciando o item de Materiais e Métodos, é apresentada a Figura 16, que mostra o algoritmo para implementação, teste e análise de desempenho do SAGAC na otimização dos processos.

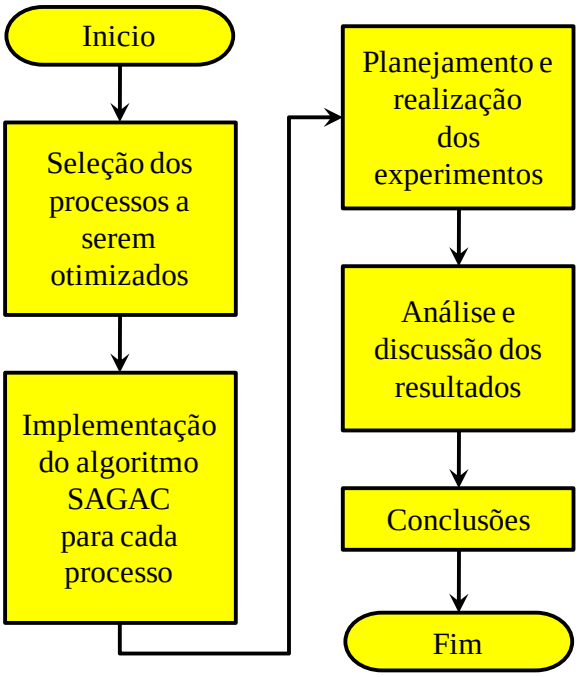

Figura 18 - Algoritmo para implementação, teste e análise de desempenho do SAGAC

A seguir apresenta-se um detalhamento das etapas do trabalho contidas na Figura 18:

a. Seleção dos processos a serem otimizados

Foram selecionados os modelos de três processos de criação de animais para a abate: 1.Aves e 2. Suínos.

b. Implementação do SAGAC

A fase de implementação é a fase na qual foram desenvolvidos os programas que aplicam o algoritmo do SAGAC para otimização dos modelos dos processos propostos.

c. Planejamento e realização dos experimentos

Na fase de planejamento de experimentos é definida uma tabela com os parâmetros do algoritmo SAGAC na qual, valores propositais são definidos para os

parâmetros de processamento do algoritmo, de modo que se possa realizar uma avaliação do seu desempenho.

A fase de realização dos experimentos ocorre de acordo com a tabela de planejamento de experimentos desenvolvida na etapa anterior. Cada experimento é realizado pelo algoritmo SAGAC seguindo os valores determinados para os parâmetros de processamento.

d. Análise dos resultados

Após a realização dos experimentos são coletados os resultados gerados pelo algoritmo SAGAC e feita uma análise estatística comparativa por meio de medidas de tendência como Média e Desvio Padrão.

e. Conclusões.

Por meio da análise comparativa dos resultados é possível chegar a alguma(s) conclusão(ões) na(s) qual(ais) identificamos o grau de desempenho do algoritmo SAGAC na otimização de cada processo.

3.1 Infraestrutura computacional

Os aplicativos foram desenvolvidos em linguagem Microsoft® VBA (Visual Basic for Applications) no Excel, linguagem de programação da Microsoft® que roda dentro dos aplicativos do Office®. O equipamento utilizado para o desenvolvimento e implementação do algoritmo é um Notebook com processador Intel® de quatro núcleos, modelo Intel(R)_Core(TM)_I3-2328M e memória RAM (Randomic Access Memory) tipo DDR2 com 4 gigabytes de espaço de armazenamento.

3.2 Os passos da pesquisa

Como esta pesquisa busca essencialmente avaliar o desempenho do algoritmo SAGAC em um caso empírico de otimização já realizado por uma ou mais outras técnicas, os passos da pesquisa são reduzidos a:

1. Realização dos experimentos de otimização;
2. Análise dos resultados obtidos pelo SAGAC na otimização dos processos.
3. Discussão sobre os resultados
4. Conclusões

3.3 Realização dos experimentos

Para realizar uma avaliação do SAGAC serão processados ensaios experimentais. Para isto implementa-se uma aplicação que represente o algoritmo

SAGAC em linguagem VBA/Excel. Foi escolhida esta ferramenta pois há uma facilidade na geração e tabulação dos dados em tabelas e a atualização de gráficos.

3.4 Pseudo-código

Os algoritmos heurísticos e metaheurísticos de otimização devem ser implementados (códigos-fonte desenvolvidos em linguagem de programação) para cada problema (processo) nos quais serão aplicados. Isto, porque, para cada problema (processo) tem-se um modelo (função objetivo) que descreve o processo em questão e, o modelo do processo faz parte do código-fonte gerado pelo algoritmo. Portanto, a forma genérica de um algoritmo que pode ser utilizada para o desenvolvimento do código-fonte em linguagem de programação que será aplicada em qualquer tipo de problema é o pseudo-código. A seguir são apresentados os três pseudo códigos dos algoritmos que compõem o algoritmo metheurístico híbrido SAGAC (*Simulated Annealing*, Algoritmo Genético e a Função de Aceleração de Convergência).

3.4.1 Pseudo-código do *Simulated Annealing*

```
Algorithm Simulated Annealing (SA) - Beginning
for index = 1 to popsize times
    t ← temperature, initially a high number
    prod ← probability to accept new random solution
    S ← random initial solution
    AssessFitness(S)
    Best_SA ← S
    repeat
        R ← random soultion
        AssessFitness(R)
        Δ = Fitness(R) - Fitness(S)
        if Δ > 0 then
            S ← R
        else
            if e^(Δ/t) ≤ prob then
                S ← R
            end-if
        end-if
```

```
        if Fitness(R) better than Fitness(S) then
        S ← R
        Decrease t
        if Fitness(S) better than Fitness(Best_SA) then
            Best_SA ← S
    until t < 0
    P ∪ Best_SA
    if Fitness(Best_SA) better than Fitness(Best_GA) then
        Best_GA ← Best_SA
next index
Algorithm Simulated Annealing (SA) - End
```

3.4.2 Pseudo-código do Algoritmo Genético

```
Algorithm Genetic Algorithm (GA) - Beginning
repeat
    sort P in descending order of Fitness value
    exclude (P – elite_group_size)
    for i = 1 to elite_group_size step 2
        repeat
            Parent Pi ← SelectWithReplacement(P)
            Parent Pi+1 ← SelectWithReplacement(P)
            Children Ci, Ci+1 ← Crossover(Copy(Pi), Copy(Pi+1))
            generate random value between 0 and 1
            if random value ≤ prob_mutation then
                Mutate(Ci), Mutate(Ci+1)
            end-if
    next índex
    generate (P – elite_group_size) randomly
    AssessFitness for each Pi
until have run out of time
return Best_GA
```

Algorithm Genetic Algorithm (GA) – End

3.4.3 Pseudo-código da Função de Aceleração de Convergência

Function Aceleration Convergence (AC) - Beginning

```
total_attempts ← 0
if total_attempts < qt_atempt then
    if Children Ci or Children Ci+1 worse than elite Parent Pelite_group_size then
        exclude Children that is worse than elite Parent Pelite_group_size
        replace worse Parent P between Parent Pi and Parent Pi+1 by another
        Paren P
    end-if
    total_attempts = total_attempts + 1
end-if
until (Children Ci or Children Ci+1 better than ore qual to elite Parent
Pelite_group_size)  or (total_attempts = qt_atempt)
```

Function Aceleration Convergence (AC) – End

No Anexo 1 está disponibilizado o pseudo-código do algoritmo SAGAC que, é a união dos três pseudo-códigos anteriores.

CAPÍTULO 4

4 Resultados e Discussão

Nesta seção são apresentados os resultados parciais obtidos com a pesquisa até o presente momento. A Tabela 07 apresenta a relação dos resultados obtidos.

Tabela 7 - Resultados parciais da pesquisa publicados em congressos e/ou revistas científicas

Relação de resultados parciais obtidos com a pesquisa		
Seq.	Título	Publicação
01	Optimization Algorithm Applied to Environmental Control in Broiler Houses	Brazilian Journal of Poultry Science
02	Application of Hybrid Metaheuristic Optimization Algorithm (SAGAC) in Beef Cattle Logistics	APMS 2021
03	Hybrid metaheuristic algorithm for optimizing monogastric growth curve (pigs and broilers)	Agri Engineering

Na Tabela 07 são apresentados os resultados parciais obtidos com a pesquisa e, publicados em congressos e em revista científica.

Nos subtópicos Resultado 1 a 3, são apresentados em detalhes os dados de cada um destes resultados. Os artigos científicos gerados a partir desses resultados estão disponíveis nos anexos deste relatório.

4.1 Artigo 1

O artigo 1 intitulado Optimization Algorithm Applied to Environmental Control in Broiler Houses, está em fonte aberta encontra-se no link:

https://www.scielo.br/j/rbca/a/6ySZL9zwBhn3dTxb8wNr5Jn/abstract/?lang=en

Referente à Figura 2, os gráficos (“a”, “b”, “c”, “d”, “e”) apresentam as distribuições de frequencia dos resultados obtidos das otimizações para os quatro tipos de aviários blue-house (A), dark-house(B), mansory walls(C) and wide broiler house(D).

Os pesos W_1 a W_5 utilizados na equação 2, foram extraídos de Martinez et al. (2021).

Brazilian Journal of Poultry Science
Revista Brasileira de Ciência Avícola

ISSN 1516-635X 2020 / v.22 / n.3 / 001-006

http://dx.doi.org/10.1590/1806-9061-2020-1372

Original Article

Optimization Algorithm Applied to Environmental Control in Broiler Houses

■Author(s)

Bamanga MAO https://orcid.org/0000-0001-6441-1456
Nilsa IAV https://orcid.org/0000-0003-0663-0377
Lima NDS https://orcid.org/0000-0002-1284-7810
Carvalho-Cut TMRF https://orcid.org/0000-0002-2996-4466
Reis JGM https://orcid.org/0000-0001-6409-2299

I Graduate Program in Production Engineering, Universidade Paulista, São Paulo, Brazil.
II Faculdade Anhanguera, Campinas, SP, Brasil.

■Mail Address

Corresponding author e-mail address
Nilsa DS Lima
Universidade Paulista. Rua Dr. Bacelar 1212, São Paulo, SP, Brazil.
Phone: +55 11 5586-4145
Email: nilsa.lima@stricto.unip.br

■Keywords

Broiler rearing, broiler production, heat stress mitigation, Simulated Annealing.

CC BY

Submitted: 01/August/2020
Approved: 22/September/2020

ABSTRACT

The present study aimed to apply the Simulated Annealing (SA) optimization algorithm to find the ideal control of broiler housing rearing environment at 21, 28, 35, and 42 days of growth. Data from four types of houses using environmental control and similar flock density were recorded weekly in the morning and afternoon, during two seasons (summer and winter). The variables related to environmental and air quality data (temperature, relative humidity, air velocity, ammonia, and carbon dioxide concentrations) were registered and organized into the database to provide a descriptive analysis. The ideal rearing conditions were established as a goal, and we used the Simulated Annealing optimization algorithm to process the data. Such an approach may be applied in the cases that the ideal condition of optimization has multiple objectives, and when each variable is the result of a process. The model was implemented considering the optimal controlled environmental condition that depends on the age of broilers. Results indicated that there was a large dispersion of the data collected from the environmental variables. The process suggested that the optimized functions lead to absolute values obtained by the algorithm for each of the environmental factors of the controlled environmental system, representing the optimal condition of the environment found for each broiler age, considering the interactions of the variables. The maximum optimization was prominent to 21 and 35-d old birds, representing 40-48% of the improvement of the process. 28 and 42-d old birds might benefit from the controlled environmental optimization process by up to 30%.

INTRODUCTION

The ideal conditions of air temperature and relative humidity for broiler chickens rearing throughout the growth allows the best performance. In current literature (Yahav, 2000; Quinteiro-Filho *et al.*, 2012; Olfati *et al.*, 2018; Yousaf *et al.*, 2019), authors state the importance of maintaining the proper thermoneutral zone for allowing the birds to avoid heat or cold stress according to the stage of growth. Such conditions demand the use of controlled environmental systems tuned to the age of the broilers.

According to Meluzzi & Sirri (2008), when the outside temperature is above 30 °C, the temperature inside the house must not exceed 3°C concerning the outside temperature, whereas if the outside temperature is below 10 °C, the humidity must not exceed 70%. When the relative humidity is below 50%, there is an increase in dust and microorganism dispersion in the air, leading to respiratory diseases (Yahav, 2000). Relative humidity above 80% hinders the latent heat loss of the birds, generated by an environment with a high flock density in a cooler period. Therefore, controlling the relative humidity using adequate

airflow is essential to achieve thermal comfort inside broiler housing.

Ventilation rate and distribution is a critical aspect in controlled environmental systems in broiler houses. Inadequate ventilation might lead to high concentrations of noxious gases, impairing the birds' breathing and damaging the eyes with serious welfare consequences (Oyetunde *et al.*, 1978; Nääs *et al.*, 2007; Nassem & King, 2018). The association with proper ventilation to remove gases and dust and evaporative cooling to reduce the air temperature is the best solution. However, for each week of growth, the needs of broilers change, making the design of an adequate environmental system a big challenge.

According to Kirkpatrick *et al.* (1983), Simulated Annealing (SA) or simulated tempering, is a technique that simulates the process of annealing metals, in which the metal is heated to high temperatures and a systematic cooling of it is carried out in order to reach an equilibrium point characterized by an orderly and stable microstructure. Before processing the SA, it is necessary to define the cooling chrono-gram determined by the Temperature Decline Scheme (TDS). The TDS defines how the temperature is decreased and the number of iterations performed at each temperature. The convergence of the SA, the processing time, and the probability of acceptance are directly linked to the adopted TDS. Oysu & Bingul (2009) point out that one of the difficulties in determining TDS is that each problem requires a type of temperature variation, similarly to the broiler rearing conditions.

Since the variation of broiler housing cooling depends on the birds' age and a proper balance of environmental and air quality variables, we aimed to apply the Simulated Annealing (SA) optimization algorithm to find the ideal control of broiler housing rearing environment.

MATERIAL AND METHODS

The study was based on four types of houses (blue-house, dark-house, masonry walls, and wide). The blue-house (A) had eight exhaust fans in the air outlet, open-sided walls closed with two layers of blue polypropylene curtains, a mean flow of 22000 m³ h⁻¹, and the evaporative cooling pads were located at the front of the house. The dark-house (B) had had ten exhaust fans, open-sided walls closed with two layers of black polypropylene curtains, and a mean flow of 34000 m³ h⁻¹. The mansory walls (C) house had 16 exhaust fans and a mean flow of 41100 m³ h⁻¹. The wide broiler house (D) had 15 exhaust fans and flow of 50460 m³ h⁻¹. All houses had similar flock density. Houses B, C, and D had lateral evaporative cooling pads in the air inlet.

Environmental and air quality data (temperature, Tbs; relative humidity, RH; air velocity, Var; ammonia, NH_3; and carbon dioxide, CO_2) were collected weekly, twice a day (morning and afternoon) and in two seasons (winter and summer) during the medium to the last stage of growth (21-d to 42-d old broilers).

The Simulated Annealing (SA) algorithm

Table 1 shows the parameters used to define the TDS and the value adopted for each of them in this study.

Table 1 – Parameters used to define the Temperature Decline Scheme (TDS).

Parameter	Value
Initial temperature (Temp0)	1.000.000
The function of temperature decrease (Temp)	Temp (i+1) = Temp (i)-1
Number of iterations in each temperature	1
The criterion to stop the algorithm process	Temp = 0

The function of the decrease in temperature (Table 1) determines a linear decrease. Figure 1 (Vasan & Raju, 2009) illustrates the main steps of the process optimization technique through Simulated Annealing.

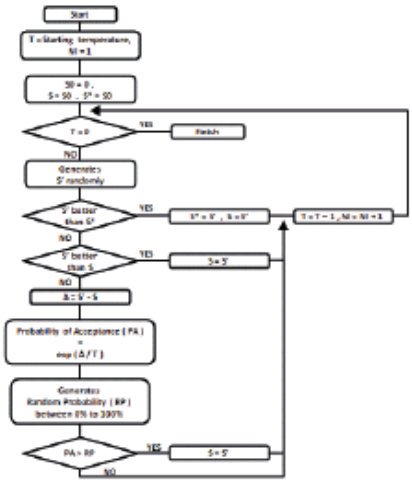

Figure 1 - Flowchart of the optimization strategy using the Simulated Annealing. Adapted from Vasan & Raju (2009).

In the flowchart of Figure 1, the variable number of iterations (NI) refers to the number of iterations or cycles that the algorithm will repeat. The "Metropolis criterion," according to Vasan & Raju (2009), is the probability that the next point will be at x (t' + 1). It

varies on the difference in values depending on these two points or $\Delta E = E(t' + 1) - E(t')$. The probability of $P(E(t' + 1))$ is calculated using Boltzmann probability distribution (Eq. 1).

$$P(E(t'+1)) = \min(1, e(-\Delta E/kbT)) \quad (1)$$

where $e(-\Delta E/kbT)$ indicates the speed of the temperature decrease.

The basic scheme of the experiment can be described as follows: f(x) is the studied phenomenon that is the maximization of the environmental variables of broiler housing (variables x1, x2, x3, x4, x5).

The environmental and air quality variables (temperature, Tbs; relative humidity, RH; air velocity, Var; ammonia, NH_3; and carbon dioxide, CO_2) were considered dependent variables, and the response variable was estimated as the performance of the broilers in each breeding period (21, 28, 35 and 42 days of growth). The ideal rearing conditions were considered, according to the current literature (Yahav, 2000, Yahav *et al.*, 2001; Nääs *et al.*, 2010; Quinteiro-Filho *et al.*, 2012; Yousaf *et al.*, 2019).

The optimization of the model was performed using the metaheuristic algorithm Simulated Annealing (SA) (Eq. 2). The model was implemented in cases of optimization with multiple objectives when each variable is the result of a process (Kikpatrick *et al.*, 1983). Seven design variables were considered in the time of data collection (x_1), Tbs (x_2), UR (x_3), Var (x_4), NH_3 (x_5), CO_2 (x_6).

$$f(x) = \sum_{i=1}^{n} W_i E_i x_i \quad (2)$$

where xi= variables, and Wi=weight of each variables. Wi is the weight adopted for each xi, as W1 = 3, W2 = 1, W3 = 2, W4 = 4, and W5 = 1.

The interval of x_i variation and the domain range of the environmental variables involved in the optimization model is shown in Table 2. These data are considered by the optimization algorithm, which must not exceed the limits of this established domain when assigning values for each of the variables.

Simulated Annealing is a technique that simulates the forging of metals, followed by a systematic change of temperature in order to reach an equilibrium point characterized by a stable microstructure (Kirkpatrick *et al.*, 1983). Before processing the SA, the cooling schedule determined by the Temperature Decline Scheme (TDS) is defined. The TDS refers to the temperature decrease and the number of iterations performed at each temperature. The convergence of the SA, the processing time, and the probability of acceptance are directly linked to the adopted TDS (Linden, 2008). In the present study, the variable Ei is the scaling weight for each variable x_i (Eq. 2) changed by the age of the bird (21, 28, 35, and 42 days) (Table 3).

The scaling weights (Table 3) balances equivalent possible differences in scales between the variables that make up the multiobjective function. If any variable is on a scale different from the others, any increase or decrease in the value of these, even if relatively insignificant, can dominate any other variable disproportionately (Linden, 2008; Gandomi *et al.*, 2013).

Table 2 – Interval domain of the variable x_i by the age of broilers.

Variables domain							
Day of growth	Limit	Time	Tbs (°C)	UR (%)	Var (m/s)	NH_3 (ppm)	CO_2 (ppm)
21	Min.	1	24	50	0.50	1	1500
	Max.	2	26	60	0.80	10	2500
28	Min.	1	20	50	1.50	1	1500
	Max.	2	24	65	2.50	10	2500
35	Min.	1	20	50	1.75	1	1500
	Max.	2	24	70	2.50	10	2500
42	Min.	1	18	50	1.75	1	1500
	Max.	2	24	70	2.50	10	2500

Table 3 – Scaling weight of each variable x_i

Weight (age of broiler, day)	Tbs (°C)	UR (%)	Var (m/s)	NH_3 (ppm)	CO_2 (ppm)
E1(21)	$3.1\ 10^{-2}$	$1.3\ 10^{-2}$	1.0	0.08	$3.2\ 10^{-4}$
E2(28)	$8.3\ 10^{-2}$	$3.1\ 10^{-2}$	0.8	0.20	$8.0\ 10^{-4}$
E3(35)	$8.3 10^{-2}$	$2.8\ 10^{-2}$	0.8	0.20	$8.0\ 10^{-4}$
E4(42)	$8.3\ 10^{-2}$	$2.9\ 10^{-2}$	0.8	0.20	$8.0\ 10^{-4}$

Experimental procedure

Experimental tests were treated separately for the domain values of the process variables obtained from the databases by the age of the birds. For this, an application was developed that represented the SA algorithm in VBA/Excel language. This application was selected due to the simplicity in generating

and tabulating data in tables and updating graphs. The optimization of the model was done using the metaheuristic algorithm Simulated Annealing (SA) (Akay & Karaboga, 2012).

The parameterization of SA requires the selection of the variables that influence the behavior of the algorithm, which are its processing parameters (Kirkpatrick *et al.*, 1983; Mezura-Montes & Colle, 2005). Those were considered the SA parameters, as follows:

1) Initial Temperature = 100; the number of cycles that will be processed in a loop of repetition of the algorithm;
2) TDS = 1; the Temperature Decline Scheme and defines how the temperature is decreased, and the number of iterations performed for each temperature.

The temperature decrease function is represented in Eq. 3, using the number of iterations in each temperature = 1.

$$Temp_{i+1} = Temp_i - 1 \text{ (Linear decline)} \quad (3)$$

RESULTS AND DISCUSSION

The environmental data of the studied houses were tabulated and organized, and the descriptive analysis is presented in Figure 2.

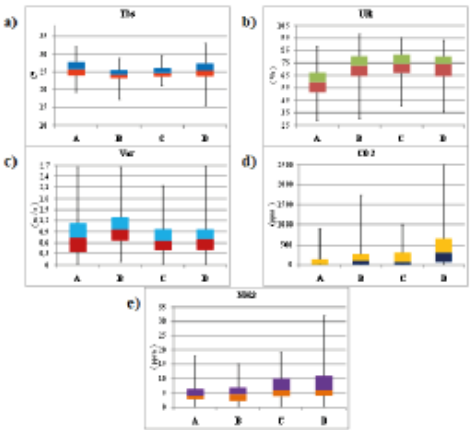

Figure 2 – Boxplot of the environmental variables recorded in the studied broiler houses. Tbs (a), UR (b), Var (c), CO_2 (d), and NH_3 (e).

Figure 5 shows the dispersion of the data collected from the environmental variables by each studied broiler house with the information of the median and quartiles. The first quartiles represent the bases of the rectangles. Below, these points are located 25% of the observations in the ordered series. The rectangles (or boxes) are divided by a line segment, representing the median (as 50% of the observations are below and 50% above). The top of the rectangles corresponds to the third quartile. Below this point is 75% of the observations and above 25%. The ends of the line segments above and below represent the maximum and minimum points of the ordered series. Table 4 shows the comparison of the data using measures of the central position.

Table 4 – Measurement of the environmental variables inside the blue-house, dark-house, giant, and masonry walls house.

Measurement	Blue-house	Dark-house	Masonry walls	Giant
Tbs (°C)				
Mean	25.69	24.20	24.81	25.38
Median	24.55	24.08	25.00	29.55
SD	2.73	1.91	1.76	3.28
Mini	19.23	17.36	21.14	15.52
Max	31.96	28.71	29.56	32.94
UR (%)				
Mean	59.53	72.37	73.97	71.65
Median	59.70	54.40	66.10	73.60
SD	11.94	10.99	10.73	11.76
Mini	28.60	30.10	40.40	35.40
Max	88.20	98.30	95.00	93.20
Var (m s^{-1})				
Mean	0.79	0.97	0.71	0.74
Median	0.15	1.35	0.25	0.70
SD	0.51	0.45	0.39	0.45
Mini	0.04	0.10	0.00	0.01
Max	2.65	2.65	2.14	2.66
CO_2 (ppm)				
Mean	99.71	192.59	158.71	433.97
Median	0.00	0.00	0.00	0.00
SD	180.53	296.91	202.29	481.84
Mini	0.00	0.00	0.00	0.00
Max	900.00	1750.00	1000.00	2500.00
NH_3 (ppm)				
Mean	4.89	4.67	7.19	8.24
Median	4.00	2.00	3.00	4.00
SD	3.24	3.04	4.32	6.13
Mini	0.00	0.00	0.00	0.00
Max	18.00	15.00	19.00	32.00

After processing the experimental tests performed separately according to the age of the birds (21, 28, 35, and 42 days), the results were collected, and it was possible to identify the improvement rates of the combined environmental conditions obtained in the optimization process. Figure 3 shows the behavior of the curves resulting from the improvement index data between the first obtained results at each age of the birds (21-d to 42-d). The data refer to results obtained

by the optimization algorithm to estimate the optimal variables of the controlled environment factors and the borderline values of these values for the domain range.

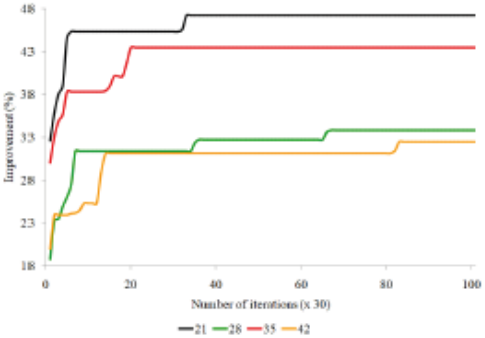

Figure 3 – Results of the application of the SA algorithm for describing the improvement (%) of the combined environmental variables vs. the number of interactions.

Each experimental trial, performed by the Simulated Annealing algorithm, occurred in a total of 3,000 iterations. Finally, the most valuable data are the absolute values obtained by the algorithm for each of the environmental factors of the controlled environmental system, which, combined with the objective function used in this research, represent the optimal condition of the environment found for each broiler age (Table 5). The maximum optimization was noticeable to 21 and 35-d old birds, representing 30-48% of the increase in the efficiency of the process. 28 and 42-d old birds might profit from the controlled environmental optimization process by up to 30%.

The data from the optimization results presented in Table 5 provide the farmer with optimum environmental values of the variables that might minimize cost and maximize production (Vasan & Raju, 2009).

Heat stress is a challenge in tropical countries such as Brazil. Broilers exposed to heat stress impact performance (Zhou &Yamamoto, 1997; Quinteiro-Filho *et al.*, 2012; Baracho *et al.*, 2019) and decrease the relative weight of the lymphoid organs (Niu *et al.*, 2009; Quinteiro-Filho *et al.*, 2012). Usually, a controlled environment system is used by farmers to mitigate heat stress (Zhao *et al.*, 2013). However, when not properly designed, the system might use energy but does not remove the excess of heat inside the housing. On the other hand, excess ventilation might increase the dust distribution, reducing air quality (Banhazi *et al.*, 2008).

Table 5 – Results of the optimization of the broiler housing environmental conditions.

Age (day)	Time	Tbs_Int	UR_Int	Var_Int	NH_3_Int	CO_2_Int
21	2	25.85	59.35	0.77	9.99	1945.02
28	2	23.60	63.64	2.38	9.76	2185.31
35	2	23.51	67.76	2.39	9.57	2163.63
42	2	23.52	68.60	2.42	9.95	1940.18

Tbs_Int=optimized value of Tbs; UR_Int= optimized value of UR; Var_Int= optimized value of Var; NH3_Int= optimized value of NH_3; CO_2_Int= optimized value of CO_2.

Another critical issue inside broiler housing is the noxious gases from the built-up litter and the broilers respiration. Both ammonia and carbon dioxide need to be removed by the ventilation to reduce the risk of respiratory diseases and improve air quality (Yahav *et al.*, 2001; Nääs *et al.*, 2007). The harmful effects of ammonia on broiler chicken performance have been previously studied (Naseem & King, 2018).

Chronic e xposure to NH_3 may provoke a compensatory response to the pollutant and lessen its harmful effect (Yahav, 2004). Exposure to ammonia leads to changes in the pulmonary function that supports the broiler respiratory system, which plays a significant part in controlling body temperature (by panting) at high environmental temperatures. The effect of ammonia on the ability of broiler chickens to thermoregulate was studied by Yahav (2004). The author concluded that different ammonia concentrations significantly reduce broiler performance. Therefore, proper ventilation of the poultry house is essential to maintain air quality.

The search for more efficient solutions in broiler production requires optimizing a set of processes, which depend mainly on monitoring by sensors and equipment. In practice, it improves the use of tools by increasing precision, reducing errors, and supporting decision making (Sinduja *et al.*, 2016; Amir *et al.*, 2016; Yasmeen *et al.*, 2019). The results of the present study suggest that this approach has the potential to improve strategies for controlling environmental conditions on farms during the production process, supporting automatic control.

CONCLUSION

A metaheuristic optimization algorithm Simulated Annealing (SA) was proposed to improve the multivariable issue of developing an environmental control system for poultry houses. The results found suggest that it is possible to reach up to 48% improvement in the system.

ACKNOWLEDGMENT

We thank CAPES for the doctoral scholarship of the first author. The authors acknowledge FACTA for the Lamas Award 2020 - 'Honorable Mention' received on the preliminary results of this study.

REFERENCES

Akay B, Karaboga D. Artificial bee colony algorithm for large-scale problems and engineering design optimization. Journal Intelligent Manufacturing 2012;21(4):1001–1014.

Amir NS, Abas AMFM, Azmi NA, Abidin ZZ, Shafie AA. Chicken farm monitoring system. Proceeding of the 2016 International Conference on Computer and Communication Engineering; 2016 Jul 26-27; Kuala Lumpur. Malaysia: IEEE, 2016. p.132-137.

Banhazi TM, Seedorf J, Laffrique M, Rutleya DL. Identification of the risk factors for high airborne particle concentrations in broiler buildings using statistical modeling. Biosystems Engineering 2008;101:100-110.

Baracho MS, Nääs IA, Lima NDS, Cordeiro AFS, Moura DJ. Factors affecting broiler production: A meta-analysis. Brazilian Journal of Poultry Science 2019;21(3):1052.

Gandomi AH, Yang XS, Alavi AH. Cuckoo search algorithm: a metaheuristic approach to solve structural optimization problems. Engineering with Computers 2013;29(1):17–35.

Kirkpatrick S, Gelatti CD, Vecchi MP. Optimization by simulated annealing. Science1983;220(4598):671-680.

Linden R. Algoritmos genéticos – uma importante ferramenta de inteligência computacional. 2nd ed. Rio de Janeiro: Brasport; 2008.

Mezura-Montes E, Coello CAC. Useful infeasible solutions in engineering optimization with evolutionary algorithms. Proceedings of the 4th Mexican International Conference on Advances in Artificial Intelligence; 2005; Berlin, Heidelberg: Spring-Verlag; 2005. p.652–662.

Nääs IA, Romanini CEB, Neves DP, Nascimento GR, Vercellino RA. Broiler surface temperature distribution of 42-day old chickens. Scientia Agricola 2010;67(5):497-502.

Nääs IA, Miwa YM, Baracho MS, Moura DJ. Ambiência aérea em alojamento de frangos de corte: poeira e gases. Engenharia Agrícola 2007;27(2):326-335.

Naseem S, King AJ. Ammonia production in poultry houses can affect health of humans, birds, and the environment—Techniques for its reduction during poultry production. Environmental Science and Pollution Research 2018;25:15269–15293.

Niu ZY, Liu FZ, Yan QL, Li WC. Effects of different levels of vitamin E on growth performance and immune responses of broilers under heat stress. Poultry Science 2009;88:2101-2107.

Olfati A, Mojtahedin A, Sadeghi T, Akbari M, Martinez-Pastor F. Comparison of growth performance and immune responses of broiler chicks reared under heat stress, cold stress and thermoneutral conditions. Spanish Journal of Agricultural Research 2018;16(2):1-7.

Oyetunde OOF, Thomson RG, Carlson HC. Aerosol exposure of ammonia, dust and *Escherichia coli* in broiler chickens. Canadian Veterinary Journal 1978;19:187–193.

Oysu C, Bingul Z. Application of heuristic and hybrid-GASA algorithms to tool-path optimization problem for minimizing airtime during machining. Engineering Applications of Artificial Intelligence 2009;22(3):389-396.

Quinteiro-Filho WM, Gomes AV, Pinheiro ML, Ribeiro A, Ferraz de Paula V, Astolfi Ferreira CS, *et al.* Heat stress impairs performance and induces intestinal inflammation in broiler chickens infected with Salmonella enteritidis. Avian Pathology 2012;41:421-427.

Sinduja K, Jenifer SS, Abishek MS, Sivasankari B. Automated control system for poultry farm based on embedded system. International Research Journal of Engineering and Technology 2016;3(3):620-624.

Vasan A, Raju KS. Comparative analysis of Simulated Annealing, Simulated Quenching and Genetic Algorithms for optimal reservoir operation. Applied Soft Computing 2009;9(1):274-281.

Yahav S. Relative humidity at moderate ambient temperatures: its effect on male broiler chickens and turkeys. British Poultry Science 2000;41:94–100.

Yahav S, Straschnow A, Vax E, Razpakovski V, Shinder D. Air velocity alters broiler performance under harsh environmental conditions. Poultry Science 2001;80(6):724-726.

Yahav S. Ammonia affects performance and thermoregulation of male broiler chickens. Animal Research 2004;53:289–293.

Yasmeen R, Ali Z, Tyrrel S, Nasir ZA. Estimation of particulate matter and gaseous concentrations using low-cost sensors from broiler houses. Environmental Monitoring and Assessment 2019;191:470.

Yousaf A, Jabbar A, Rajput N, Azizullah M, Shahnawaz R, Mukhtar N, *et al.* Effect of environmental heat stress on performance and carcass yield of broiler chicks. World's Veterinary Journal 2019;9(1):26-30.

Zhao Y, Xin H, Shepherd TA, Hayes MD, Stinn J, Li H. Thermal environment, ammonia concentrations, and ammonia emissions of aviary houses with white laying hens. Transaction of the ASABE 2013;56:1145–1156.

Zhou WT, Yamamoto S. Effects of environmental temperature and heat production due to food intake on abdominal temperature, shank skin temperature and respiration rate of broilers. British Poultry Science 1997;38:107-114.

4.2 Artigo 2

O artigo 2 intitulado Application of Hybrid Metaheuristic Optimization Algorithm (SAGAC) in Beef Cattle Logistics, está em fonte aberta encontra-se no link:

https://www.researchgate.net/profile/Marco-Benvenga/publication/354273919_Application_of_Hybrid_Metaheuristic_Optimization_Algorithm_SAGAC_in_Beef_Cattle_Logistics/links/613228550360302a007a5736/Application-of-Hybrid-Metaheuristic-Optimization-Algorithm-SAGAC-in-Beef-Cattle-Logistics.pdf

ResearchGate

See discussions, stats, and author profiles for this publication at: https://www.researchgate.net/publication/354272819

Application of Hybrid Metaheuristic Optimization Algorithm (SAGAC) in Beef Cattle Logistics

Chapter · August 2021

DOI: 10.1007/978-3-030-89802-2_82

CITATIONS
2

READS
21

2 authors:

Marco Antonio Campos Benvenga
Universidade Paulista
8 PUBLICATIONS 43 CITATIONS

SEE PROFILE

Irenilza A. Nääs
Universidade Paulista
520 PUBLICATIONS 3,788 CITATIONS

SEE PROFILE

Some of the authors of this publication are also working on these related projects:

ANALYSIS OF HYBRID METAHEURISTIC ALGORITHM WITH INCLUSION OF MECHANISM FOR ACCELERATION OF CONVERGENCE IN THE OPTIMIZATION OF PROCESSES OF BREEDING ANIMALS FOR SLAUGHTER View project

Comparison of the use of traceability for swine in group or individually View project

All content following this page was uploaded by Marco Antonio Campos Benvenga on 03 September 2021.

The user has requested enhancement of the downloaded file.

Application of hybrid metaheuristic optimization algorithm (SAGAC) in beef cattle logistics

Marco Antonio Campos Benvenga[1[0000-0001-6441-1456]], Irenilza de Alencar Nääs[1[0000-0003-0663-9377]]

[1]Paulista University, São Paulo, Brazil
marcocampos453@yahoo.com, irenilza@gmail.com

Abstract. The study objective was to evaluate the performance of SAGAC in optimizing a linear mathematical model in whole variables to determine the most cost-effective solution in transporting cattle for slaughter. The model determines the choice of refrigerator truck, road (route), and an open-truck in a scripting process. The tests performed with the SAGAC algorithm for optimizing the proposed model were compared with the results obtained, under similar conditions, by the branch-and-bound method for solving entire problems and solving a problem optimally. After the first twenty-two experimental trials, for comparison between the two methods, nine more experimental trials were carried out, with an increase in the degree of complexity, only with the SAGAC algorithm. The results obtained in the first twenty-two experimental trials demonstrate an equivalent performance between the two methods, showing that the SAGAC algorithm, even though it is not a technique that guarantees optimal results, in this case, was also able to find them. The nine final experiments performed only by SAGAC showed satisfactory results, with an evolutionary curve of exponential behavior.

Keywords: Meat production, Optimization, Algorithm, Logistics, Transportation

1 Introduction

Brazil has a substantial production capacity in agricultural activity sectors due to the available agricultural area. A large part of Brazilian agribusiness production represents an important share in the country's GDP and the balance of our exports, where agriculture has fundamental importance.

Brazil is the world's largest exporter of beef. Health control, knowledge and technology, and the country's natural aspects are pointed out as the keys to this product's success in the market [9]. The development of the food sector and market causes numerous organizational changes and structural in the chain, acting on the agents of production, transformation, trade, and distribution.

As a significant exporter of agribusiness products, Brazil's position has ensured the intense professionalization of the main objective of meeting markets' requirements with high safety standards, such as Europe and the United States. About 150 countries import Brazilian products of animal origin. Of a total of around US$16 10^9 of Brazili-

an exports in 2018, nearly 45% is beef, 42% chicken meat, 10% pork, and 3% other types of meat such as turkey, goose, sheep, and duck [8]. Brazilian meat production from 1994 to 2016 presents an increase in cattle, pork, and chicken production of 85% (nearly 3% per year), 162% (4% per year), and 285% (6% per year), respectively [1].

A factor considered in beef cattle transportation is minimizing the animals' stress during the movement between the farm and the slaughterhouse. Transport might cause a decrease in the meat's quality due to possible injuries caused by the vehicles' displacement and the stress of travel time [12].

Up to 3% of the live animal's weight loss occurs in the loading and unloading procedure, one of the main losses in the first hours and kilometers traveled in the transport [2]. The size of the animals, the type of truck used for transportation, the distances between the points of origin and destination (routes), the state of conservation of the road pavement, and the use of trucks with greater load capacity are the main determining factors of hematoma causes [6]. Other factors causing damage to animals' carcasses during transport for slaughter, such as transport cost, carrier density, loading, and accidents with vehicles, have also been studied [7].

The objective of this study is to compare the performance of the SAGAC hybrid metaheuristic algorithm with that of the Branch-and-bound [10] algorithm in a logistical process of routing cattle load from farms to slaughterhouses using trucks, determining the best possible combination of slaughterhouse factors, route, and truck that promotes the best value paid to producers.

2 Methods

2.1 Process model

The model presented in the sequence was proposed by Ribeiro et al. (2018). The data to detail the mathematical model and develop the computational tool capable of assisting the rural producer in the decision-making process are as follow:

N = Total number of cattle to be transported for slaughter; G = estimated weight of cattle (in arrobas); F = Number of slaughterhouses available for slaughter; R = number of routes that can be used for the transport of livestock; C = number of trucks available for the transportation of cattle; T = Number of trucks to be effectively used in cattle transport; CFi = Slaughter capacity of the slaughterhouse i (cattle heads); Ai = Price paid by the slaughterhouse i for each amount of cattle (Reals); Dj = Distance between the farm and the refrigerator by route j (km); REj = estimation of weight reducers (per km) for route j (%); CCk = capacity of truck k (cattle heads); RCk = estimation of weight reducers (per km) for truck k (%); Hk = Freight price of truck k (Reals).

The estimated price (Reals) is calculated (Eq. 1) for the payment of the cattle transported from the farm to the processing plant i using route j on the truck k:

$$P_{ijk}=GA_i - GA_i D_j (RE_j + RC_k) = GA_i (1 - D_j (RE_j + RC_k)) \quad (1)$$

Be y_{ijk} the binary decision variable defined by:

y_{ijk}={1 if the cattle are transported to the refrigerator *i* by route *j* using truck *k* and, 0 otherwise}.

The entire decision variable for the problem is given by x_{ijk}=number of cattle heads sent to the processing plant *i* by route *j* employing truck *k*. The mathematical model of whole linear programming for the problem is described in Eq. 2 through 9, namely:

$$\text{Maximize: } f = \Sigma(Pijkxijk) - \Sigma(Hkyijk) \quad (2)$$

Subject to:

$$\Sigma xijk = N \quad (3)$$

$$\Sigma xijk \leq CFi \ (i=1..) \quad (4)$$

$$xijk \leq CCkyijk \ (i=1..,j=1..R,k=1..C) \quad (5)$$

$$\Sigma yijk \leq 1 \ (k=1..) \quad (6)$$

$$\Sigma yijk = T \quad (7)$$

$$xijk \geq 0 \text{ and } integer \quad (8)$$

$$y_{ijk} = 0/1 \quad (9)$$

2.2 The hybrid metaheuristic algorithm (SAGAC)

The model is formed using two algorithms, the Simulated Annealing (SA) and the Genetic Algorithm (AG), with the inclusion of a mechanism (function) that promotes acceleration in the convergence (AGAC) of the obtained results. The SA algorithm acts on the generation of individuals who make up the modified genetic algorithm's initial population (AGAC). With the use of the SA algorithm, it is possible to have a good quality initial population composition, that is, pre-optimized individuals.

The routine behavior of the AGAC algorithm promotes Convergence Acceleration in which, after crossing, there is an assessment of the individuals (Sons) generated and a check for quality improvement concerning the individuals of the elite group of the population. If such development does not occur, the individual (s) of the offspring (ren) is (are) discarded, the individual (parent) of the worst quality is exchanged for another individual in the elite group who is closest and is better than the individual (Father) who was changed. After the individual's change (Father), a new crossing occurs for the missing child's generation (s). This sequence of steps will be repeated until both offsprings meet the criteria for improvement or the stipulated number of attempts is reached. Fig. 1 shows the flowchart of the SAGAC hybrid algorithm.

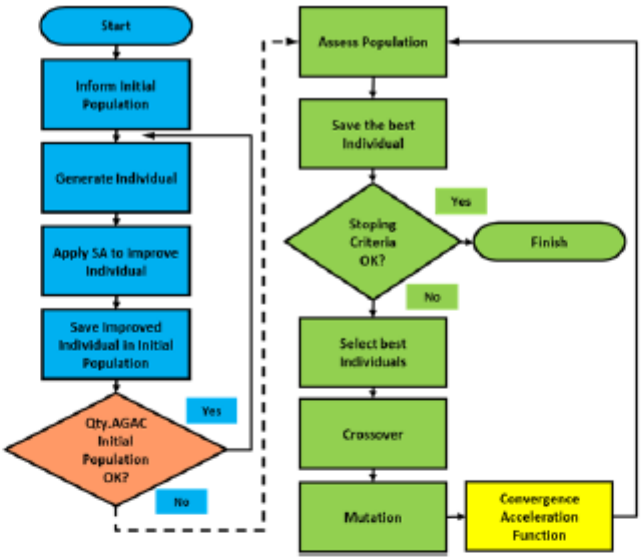

Fig. 1. Flowchart of the hybrid SAGAC algorithm

With each cycle of processing of the Simulated Annealing (SA) algorithm, the best result (individual) is stored to compose the initial population used by the modified Genetic Algorithm with convergence acceleration mechanism (AGAC).

2.3 Setup Parameters of SAGAC

In the case of SAGAC, the variables that influence the algorithm's behavior are its processing parameters [11, 8, 3].

Parameters of SA

1°. Initial Temperature = 100; it is the number of cycles that will be processed in an algorithm repetition loop;

2°. TDS = 1; it is related to the Temperature Decay Scheme - defines how the temperature is decreased and the number of iterations performed for each temperature.

- the Temperature Decay Function is represented in Eq. 10.

$$〖Temp〗_(i+1)= 〖Temp〗_i-1 \tag{10}$$

- Number of Iterations at each Temperature = 1.

Parametersof AGAC

1st. Population size = 100; 2nd. Generations Qty. = 1000; 3rd. Elitism = 10%; 4th. Mutation = 7%; and, for the case of the Convergence Acceleration Genetic Algorithm (AGAC); 5th. Qty of attempts to generate children in the elite = 1.

The optimization experiments (maximization of the cattle transport payment) were carried out based on the results developed by [10]. Was performed computational tests with the mathematical model proposed for 22 problems of shipping cattle from slaughterhouses. In all tests, the number of refrigerators, the number of routes (or roads), and the number of trucks available were respectively 3, 4, and 5. The other

data used related to the sign's price, the routes, the trucks, price reducers, and freight charges are shown in Table 1, in [10], 22 computational experiments.

Table 1. Data used in [10], 22 experiments.

Data					
N	60				
G	15				
F	3				
R	4				
C	5				
T	3				
Cfi	Cf1 = 40	Cf2 = 40	Cf3 = 40		
Ai	A1 = 120.00	A2 = 110.00	A3 = 130.00		
Rej	Re1 = 0.1	Re2 = 0.2	Re3 = 0.1	Re4 = 0.1	
CCk	CC1 = 12	CC2 = 12	CC3 = 12	CC4 = 24	CC5 = 28
RCk	RC1 = 0.03	RC2 = 0.03	RC3 = 0.03	RC4 = 0.02	RC5 = 0.01
Hk	H1 = 500.00	H2 = 500.00	H3 = 500.00	H4 = 500.00	H5 = 500.00

3 Results and Discussion

Analysis and comparison of the results obtained by SAGAC and those of other techniques used the optimize the same process.

Fig.4 shows the average convergence of the results obtained by SAGAC in the experimental trials. It represents the percentage of the evolution of the values obtained by the SAGAC method from the first Generation of the Genetic Algorithm to the last generation processed.

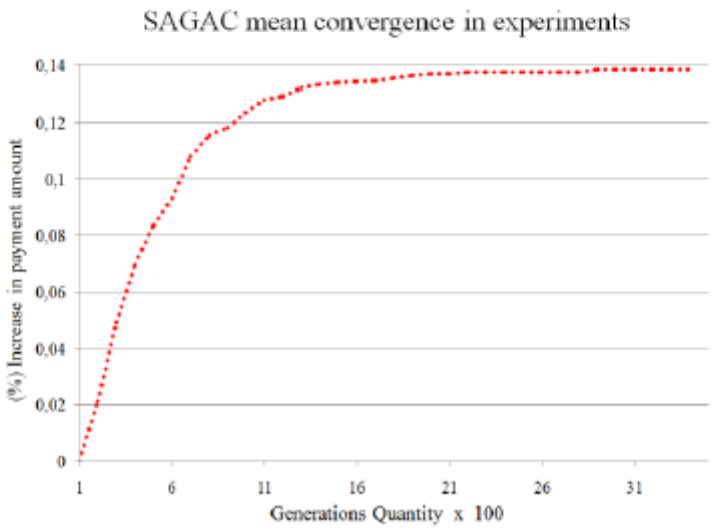

Fig. 2. Average convergence of the results obtained by the SAGAC method

Table 2 presents the results obtained by the two methods: branch-and-bound [10] and the SAGAC method. The first twenty-two results are sequenced descending because they are more easily located in their source [10]. The average of the results

obtained between comparative tests (1 and 22) shows that the SAGAC algorithm presented a better performance (81.117,75) than that found by [10] (81.078,49). From experimental assay 23, the results data were obtained only by the SAGAC method.

Table 2. Comparative of the results obtained (Payment, $)

Assay	N	T	[10]	SAGAC	Comparison
22	12	1	18724.00	18724.00	0
21	19	1	29938.00	29938.00	0
20	20	1	31540.00	31540.00	0
19	26	1	41152.00	41152.00	0
18	33	2	51776.00	51686.00	-90
17	35	2	54944.00	54818.00	-126
16	38	2	56969.00	59516.00	2547
15	40	2	62864.00	62648.00	-216
14	47	2	72014.00	72522.00	508
13	52	2	79604.00	79932.00	328
12	54	3	82896.00	82896.00	0
11	58	3	88824.00	88824.00	0
10	60	3	91812.00	91812.00	0
9	65	4	99097.00	98839.00	-258
8	67	4	102139.00	101725.00	-414
7	70	4	106054.00	106054.00	0
6	72	4	108940.00	108940.00	0
5	75	4	113269.00	113269.00	0
4	78	5	117590.00	116954.30	-635.7
3	80	5	120476.00	119696.60	-779.4
2	84	5	125181.20	125181.20	0
1	86	5	127923.50	127923.50	0
23	90	6		135345.10	
24	100	6		149333.00	
25	110	6		162557.40	
26	120	6		174860.20	
27	130	7		188159.20	
28	140	7		199558.60	
29	152	8		213975.20	
30	176	9		241093.20	
31	204	10		273953.20	
Average between 1 and 22 tests			81.078.49	81.117.75	

Fig. 3 5 shows the behavior of the results obtained by the SAGAC method in the thirty-one tests performed. The behavior of the SAGAC algorithm results indicates a correlation between the number of animals transported and the amount paid to producers according to the routes indicated by the SAGAC algorithm. Results obtained between experimental tests 1 and 22 by the SAGAC algorithm, which were compared with the results obtained by [10], have a degree of correlation of 99.97%. This correlation can be explained because the results presented by tests 1 to 22 were the optimum results or very close to the optimum. It can be inferred that the results obtained

by the SAGAC algorithm between tests 23 and 31, which presented a degree of correlation of 99.94%, must be excellent or are very close to the optimum, thus confirming the excellent performance of the SAGAC algorithm.

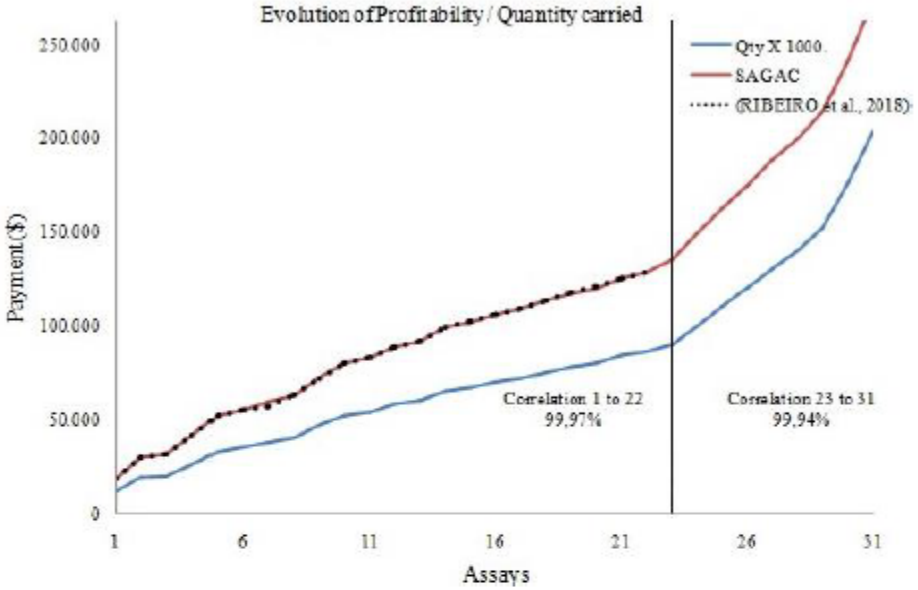

Fig. 3. The behavior of the data obtained by SAGAC in the 31 experimental trials.

4 Final remarks

A hybrid metaheuristic optimization algorithm (SAGAC) was presented in this work as an alternative to solve logistics problems, more specifically, the selection of the set of factors: refrigerator, route, truck, and quantity of cattle transported, in order to maximize the value of the payment to the producer. This algorithm can optimize combinatorial analysis problems in which the factual solution spaces are too large (NP-Hard), making the application of deterministic algorithms that, in turn, ensure an unfeasible optimal solution.

From the results performed by the SAGAC algorithm, in the twenty-two comparative trials with the branch-and-bound deterministic algorithm, SAGAC obtained a higher mean difference of 0.14%. Nine experimental trials (from 23 to 31) with a higher degree of complexity were conducted. The resultant data showed exponential progression with an $R^2 = 0.927$, suggesting that profitability increases when the number of cattle transported increases.

Acknowledgment. The first author wishes to thank the Coordination of Superior Studies (Capes) for the scholarship.

References

1. Embrapa, Cias - Central de Inteligência de Aves e Suínos, https://www.embrapa.br/qualidade-da-carne/carne-em-numeros-2. Access 07/07/2020.
2. Barnes, K., Smith, S. e Lalman, D. Managing shrink and weighing conditions in beef cattle. 2007. Oklahoma CooperativeExtension Service, ANSI-3257, Oklahoma StateUniversity. Disponível em: http://pods.dasnr.okstate.edu/docushare/dsweb/Get/Rendition-7449/ANSI-3257web.pdf. Acesso em: 21/04/2017.
3. Kirkpatrick, S.; Gelatti, C. D.; Vecchi, M. P. Optimization by Simulted Annealing. Science, New Series, vol.220, n.4598, p.671-680, May.1983.
4. Linden, R, Algoritmos Genéticos – Uma importante ferramenta de inteligência computacional,2a.ed., Brasport, 2008.
5. MAPA, Ministério da Agricultura, Pecuária e Abastecimento, AGROSTAT - Estatisticas de Comércio Exterior do Agronegócio Brasileiro, Acesso em 07 de julho de 2020, Disponível em http://indicadores.agricultura.gov.br/agrostat/index.htm, 2020.
6. Mendonça, F. S., Vaz, R. Z., Cardoso, F. F., Restle, J., Vaz, F. N., Pascoal, L. L., Reimann, F. A. e Boligon, A. A. Pre-slaughtering factors related to bruises on cattle carcasses. Animal Production Science, v. 58, n. 2, p. 385-392, 2016.
7. Miranda-de la Lama, G. C., Villarroel, M. e María, G. A. Livestock transport from the perspective of the pre-slaughter logistic chain: a review. Meat Science, v. 98, n. 1, p. 9-20, 2014.
8. Mitchell, T. M. Machine Learning. McGraw-Hill Science, cap.9. 1997.
9. Nääs I. A. I., Mollo Neto M. I., Canuto S. A. I.,Waker R. I., Oliveira D. R. M. S. I. I., Vendrametto O. I. Brazilian Chicken MeatProduction Chain: a 10-year Overview, BrazilianJournalofPoultry Science (Revista Brasileira de Ciência Avícola), 2015.
10. Ribeiro J. F. F., Oliveira M. M. B., Filho M. A. C., Um modelo para a logística do abate do gado de corte, Pesquisa Operacional para o Desenvolvimento, ISSN 1984-3534, 2018
11. Santana, J. C., C.; Mesquita, R.,A.; Tamborgi, E., B.; Librantz, A., F., H.; Benvenga M., A., C. Obtenção da Condição Ótima do Processo de Hidrólise do Amido de Mandioca por Amilases de Aspergillusniger, XVIII SINAFERM – Simpósio Nacional de Bioprocessos, 2011.
12. Schwartzkopf-Genswein, K. S., Faucitano, L., Dadgar, S., Shand, P., González, L. A. e Crowe, T. G. Road transport of cattle, swine and poultry in North America and its impact on animal welfare, carcass and meat quality: a review. Meat Science, v. 92, n. 3, p. 227-243, 2012.
13. USDA - United States Department of Agriculture. Agricultural Projections to 2026, Report Interagency Agricultural Projections Committee USDA Long-term Projections, 100 p., 2017.

The appendix 1 shows results of simulations which indicate the combination of processing plant (i), route (j), employimg truck (k).

Appendix 1 – Results of simulations of SAGAC and Ribeiro et al. (2018)

Assay	Payment($)	Routes (Xijk)	
		SAGAC	Ribeiro et al., 2018
22	18,724.00	X115 = 12	x115 = 12
21	29,938.00	X115 = 19	x115 = 19
20	31,540.00	X115 = 20	x115 = 20
19	41,152.00	X115 = 26	x115 = 26
18	51,686.00	X115 = 28 / X113 = 5	x114 = 5, x115 = 28
17	54,818.00	X115 = 28 / X113 = 7	x114 = 7, x115 = 28
16	59,516.00	X115 = 28 / X113 = 10	x114 = 10, x115 = 28
15	62,648.00	X115 = 28 / X111 = 12	x114 = 12, x115 = 28
14	72,522.00	X115 = 28 / X112 = 12 / X344 = 7	x115 = 28, x344 = 19
13	79,932.00	X115 = 28 / X112 = 12 / X344 = 12	x114 = 24, x345 = 28
12	82,896.00	X115 = 28 / X113 = 12 / X344 = 14	x111 = 12, x115 = 28, x344 = 14
11	88,824.00	X113 = 12 / X115 = 28 / X344 = 18	x111 = 12, x115 = 28, x344 = 18
10	91,812.00	X114 = 24 / X111 = 12 / X345 = 24	x111 = 12, x114 = 24, x345 = 24
9	98,839.00	X114 = 24 / X111 = 12 / X345 = 28 / X342 = 1	x111 = 4, x112 = 12, x114 = 24, x345 = 25
8	101,725.00	X113 = 12 / X114 = 24 / X345 = 28 / X342 = 3	x111 = 4, x112 = 12, x114 = 24, x345 = 27
7	106,054.00	X114 = 24 / X111 = 12 / X345 = 28 / X342 = 6	x112 = 12, x114 = 24, x341 = 6, x345 = 28
6	108,940.00	X112 = 12 / X114 = 24 / X345 = 28 / X343 = 8	x112 = 12, x114 = 24, x343 = 8, x345 = 28
5	113,269.00	X112 = 12 / X114 = 24 / X345 = 28 / X341 = 11	x112 = 12, x114 = 24, x341 = 11, x345 = 28
4	116,954.30	X345 = 28 / X341 = 12 / X113 = 12 / X114 = 24 / X232 = 2	x111 = 12, x113 = 4, x114 = 24, x343 = 10, x345 = 28
3	119,696.60	X113 = 12 / X114 = 24 / X341 = 12 / X345 = 28 / X232 = 4	x111 = 12, x113 = 4, x114 = 24, x342 = 12, x345 = 28
2	125,181.20	X343 = 12 / X345 = 28 / X114 = 24 / X111 = 12 / X232 = 8	x112 = 12, x114 = 24, x233 = 8, x341 = 12, x345 = 28
1	127,923.50	X114 = 24 / X111 = 12 / X343 = 12 / X345 = 28 / X232 = 10	x111 = 12, x114 = 24, x233 = 10, x342 = 12, x345 = 28
23	134,978.00	X341 = 12 / X346 = 28 / X112 = 12 / X115 = 28 / X234 = 10	
24	148,904.00	X342 = 12 / X345 = 28 / X111 = 12 / X116 = 28 / X234 = 20	
25	162,201.30	X341 = 12 / X346 = 28 / X115 = 28 / X113 = 12 / X234 = 24 / X232 = 6	
26	174,752.20	X233 = 12 / X234 = 24 / X115 = 28 / X111 = 12 / X342 = 12 / X346 = 28 / X127 = 4	
27	186,812.20	X231 = 12 / X237 = 24 / X115 = 28 / X113 = 12 / X346 = 28 / X342 = 12 / X124 = 14	
28	198,872.20	X115 = 28 / X112 = 12 / X233 = 12 / X234 = 24 / X341 = 12 / X346 = 28 / X127 = 24	
29	213,704.00	X348 = 12 / X3410 = 28 / X236 = 28 / X231 = 12 / X115 = 28 / X113 = 12 / X124 = 24 / X459 = 8	
30	240,686.40	X124 = 24 / X3410 = 28 / X343 = 12 / X235 = 28 / X232 = 12 / X116 = 28 / X111 = 12 / X457 = 24 / X459 = 8	
31	273,953.20	X238 = 12 / X233 = 12 / X564 = 24 / X115 = 28 / X111 = 12 / X127 = 24 / X3410 = 28 / X459 = 24 / X452 = 12 / X116 = 28	

The Appendix 1 presents the results of comparison between SAGAC algorithm and Ribeiro et al. (2018). The results of comparison are in assays 1 to 22. The assays 23 to 31 belong to SAGAC only. The assays 23 to 31 show the results of a test performance of SAGAC algorithm which simulates transport of 90 units at 23 assay to 204 units to at 31 assay.

4.3 Artigo 3

O artigo 3 intitulado Hybrid metaheuristic algorithm for optimizing monogastric growth curve (pigs and broilers), está em fonte aberta encontra-se no link:

https://www.mdpi.com/2624-7402/4/4/73

AgriEngineering

MDPI

Article

Hybrid Metaheuristic Algorithm for Optimizing Monogastric Growth Curve (Pigs and Broilers)

Marco Antonio Campos Benvenga [1], Irenilza de Alencar Nääs [1,*], Nilsa Duarte da Silva Lima [2] and Danilo Florentino Pereira [3]

[1] Graduate Program in Production Engineering, Universidade Paulista, R. Dr. Bacelar 1212, São Paulo 04026-002, Brazil
[2] Department of Animal Science, Federal University of Roraima, BR 174, km 12, Monte Cristo, Boa Vista 69300-000, Brazil
[3] Department of Management, Development and Technology, School of Science and Engineering, São Paulo State University—UNESP, Av. Domingos da Costa Lopes 780, Tupã, São Paulo 17602-496, Brazil
* Correspondence: irenilza.naas@docente.unip.br

Abstract: Brazil is one of the world's biggest monogastric producers and exporters (of pig and broiler meat). Farmers need to improve their production planning through the reliability of animal growth forecasts. Predicting pig and broiler growth is optimizing production planning, minimizing the use of resources, and forecasting meat production. The present study aims to apply a hybrid metaheuristic algorithm (SAGAC) to find the best combination of values for the growth curve model parameters for monogastric farm animals (pigs and broilers). We propose a hybrid method to optimize the growth curve model parameters by combining two metaheuristic algorithms Simulated Annealing (SA) and Genetic Algorithm (GA), with the inclusion of a function to promote the acceleration of the convergence (GA + AC) of the results. The idea was to improve the coefficient of determination of these models to achieve better production planning and minimized costs. Two datasets with age (day) and average weight (kg) were obtained. We tested three growth curves: Gompertz, Logistic, and von Bertalanffy. After 300 performed assays, experimental data were tabulated and organized, and a descriptive analysis was completed. Results showed that the SAGAC algorithm provided better results than previous estimations, thus improving the predictive data on pig and broiler production consistency. Using SAGAC to optimize the growth parameter models for pigs and broilers led to optimizing the results with the nondeterministic polynomial time (NP-hardness) of the studied functions. All tuning of the growth curves using the proposed SAGAC method for broilers presented R^2 above 99%, and the SAGAC for pigs showed R^2 above 94% for the growth curve.

Keywords: computational intelligence; optimization; production forecast; SAGAC

check for updates

Citation: Benvenga, M.A.C.; Nääs, I.d.A.; Lima, N.D.d.S.; Pereira, D.F. Hybrid Metaheuristic Algorithm for Optimizing Monogastric Growth Curve (Pigs and Broilers). *AgriEngineering* **2022**, *4*, 1171–1183. https://doi.org/10.3390/agriengineering4040073

Academic Editors: Luca Di Nunzio and Muhammad Sultan

Received: 25 June 2022
Accepted: 15 November 2022
Published: 28 November 2022

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.

Copyright: © 2022 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (https://creativecommons.org/licenses/by/4.0/).

1. Introduction

By the mid-19th century, Gompertz [1] proposed a sigmoid function that describes growth as being the slowest at the start and end of a given period. Because a stable population would consequently have a saturation-level point and form a numerical upper bound on the growth size, Verhulst [2] proposed to limit this constraint and introduced the Logistic growth function. Afterward, Winsor [3] studied the parallelism between the Gompertz curve and the Logistic one. The Gompertz and the Logistic curves have similar properties, making them useful for the empirical representation of growth phenomena. Von Bertalanffy [4] postulated the General System Theory (GST), a logical concept applicable to all systems-related sciences, implying that specific principles have pertinence to systems. It explains the occurrence of isomorphous laws in various scientific fields. Such concepts were, after that, used to develop growth curves in living organisms and used as a basis for the genetic development of farm animals [5–7].

Growth is a continuous function during the animal's life, from embryonic stages to adult age. Growth models mathematically explain it with biological meaning parameters [6]. Most functions are resultant of empirical data from specific experiments. Associating parameters with animal productivity and reproductive traits is a valuable resource for selection programs [8]. Using the growth curve, it is possible to describe animal body changes, such as size, mass, volume, and other units of performance interest. Furthermore, relative growth rates are essential for evaluating growth performance and efficiency [9].

Pig and broiler growth depends on feed efficiency and varies with the animal's age or stage of production. The study of animal growth models facilitates monitoring their development, which can help establish the optimum slaughter time. Growth curves help explain body development patterns in birds and pigs [6]. The growth curve can be analyzed in three defined stages: (1) shortly after birth or hatching when there is a moderate growth rate; (2) after a certain age, the curve settles, and the growth rate is maximum; and (3) at the end of growth, the rate is slowed down and ends in an asymptote in the mature phase [10]. The use of non-linear models helps consolidate large volumes of information into a set of constraints that can be explained biologically [7,11,12].

The growth rate is the main focus of pig farming systems, including key performance indicators such as weight gain, feed intake, and feed conversion [7,13–15]. Current broilers are high-yielding and growing due to excellent feed conversion [16]. As development progresses, a more significant amount of energy is destined for the maintenance of the organism, thus reducing the mass gain and growth of the animals [17]. Growth curves are vital to support monogastric breeding programs. The three previously described functions (Gompertz, Logistic, and von Bertalanffy) generate satisfactory results; however, they differ slightly along the curve. Mathematic models such as growth curves that result from field trials cannot necessarily be applied to all datasets, because they are developed from specific experimental conditions. A way to search for the optimal growth curve is to use the hybrid metaheuristic algorithm strategy. By optimizing the growth curve model, we can define the increase in body weight as a function of age based on the weight vs. age indicators, which is critical for the production of monogastric animals.

Simulated Annealing (SA) is a metaheuristic algorithm that applies a metal cooling process simulation. This method reaches a better status than the current one. If some movement generates the worst status, it may be accepted according to probability [18]. The second algorithm is the Genetic Algorithm (GA). GA is also a metaheuristic algorithm that applies a search and optimization method based on Charles Darwin's theory of natural selection of species, according to which it is advocated that over the generations of a population of individuals of any species, only the best or most adapted to the environment in which they live will survive. GAs are search algorithms based on the principles of natural selection and genetics, inspired by the biological evolution of living beings; therefore, surviving individuals have a chance to pass on their genetic code to subsequent generations [19,20].

In the current literature, there is no consensus on the best model to describe the growth curve of monogastric animals. The differences between the models may be due to many reasons, including breed or population structure, sex, feeding management, environmental conditions, sampling, and statistical methods. Metaheuristics algorithms are usually used in problems with combinatorial analysis features with many possible solutions. In this case of growth curves, the average quantity of possible solutions is nearly 1.17×10^{12} (NP-hardness in the computational complexity theory). The present study proposes optimizing the parameters of monogastric growth curves by applying a hybrid metaheuristic algorithm (SAGAC) to field data to select the best available growth curve model functions of monogastric farm animals (pigs and broilers).

2. Materials and Methods

2.1. Database of Age and Live Weight

A sample of an actual dataset with age (day) and average weight (kg) was extracted from [21]. To assess the coefficient of determination for the growth curves in pigs, the sample data of age/average pig live weight are shown in Table 1. They were used to evaluate the coefficient level of the growth curves.

Table 1. Database sample of age and pig live weight.

Age (Day)		Average Weight (kg)	
21	105	5.95	61.77
28	112	8.05	68.62
35	119	10.62	75.56
42	126	13.68	82.52
49	133	17.25	89.46
56	140	21.34	96.33
63	147	25.93	103.08
70	154	30.99	109.68
77	161	36.48	116.09
84	168	42.37	122.28
91	175	48.58	128.25
98	182	55.07	133.97

One essential piece of information calculated using this data is the total average live weight ($\overline{y}$ = 2.66 kg), and it was used in Equation (4). This research used historical information on the growth of broilers in the period from 0 to 41 days. The variables used were retrieved from previous research [2,4,21] and are x (age, day), and y (weight, g), shown in Table 2.

Table 2. Database of broilers' historical growth, age, and weight.

Model	Parameter	Value Range			
		Pig		Broiler	
		Min	Max	Min	Max
Gompertz	y_1, kg	1.7421	1.7421	46.0000	46.0000
	L, g/g	0.0600	0.1200	0.0600	0.1200
	K, t^{-1}	0.0154	0.0186	0.0153	0.0186
Logistic for pig	A, kg	114.8539	194.1031	-	-
	K, t^{-1}	0.0130	0.0220	-	-
	M, kg/kg	4.9246	8.3226	-	-
Logistic for broiler	A, kg	-	-	2616.3727	3165.8110
	L, g/g	-	-	0.1182	0.1430
	K, t^{-1}	-	-	24.4545	29.5900
Von Bertalanffy	A, kg	253.1169	427.7676	5652.4909	6839.5140
	B, kg/kg	0.0000	0.9000	0.7909	0.9570
	K, t^{-1}	0.0070	0.0100	0.0273	0.0330

2.2. Growth Curve Models

The present study evaluated four growth curve models, two of which are generic (Equations (1) and (2)), described by [22], and two specific ones, Equation (3) for pigs [22] and Equation (4) for broilers [23].

$$Gompertz\ (\hat{y}) = y_1.e^{[(\frac{L}{K})(1-e^{Kt})]} \quad (1)$$

$$Von\ Bertalanffy\ (\hat{y}) = \frac{A}{[1-b(e^{Kt})]^3} \quad (2)$$

$$Logistic\ for\ pigs\ (\hat{y}) = \frac{A}{(1 - e^{Kt})^m} \quad (3)$$

$$Logistic\ for\ broilers\ (\hat{y}) = \frac{A}{(1 + e^{-L(t-K)})} \quad (4)$$

where y_1 = the first occurrence of independent variable y of the data sample; K = postnatal maturity rate, in which high values indicate early maturity and low values delayed maturity; L = the angle of the growth curve when t is 1, or the specific initial growth rate; A = the upper asymptotic weight when t; m = the constant that determines the behavior of the function, enabling a variable inflection point; and b = the constant of integration without biological interpretation.

Table 3 shows the specific range of values of the models' parameters. This range of values is used by the SAGAC algorithm to vary the values in the equations and to calculate the $\hat{y}$ estimated for each age (shown in Table 1).

Table 3. Range values of the function parameters for the studied models.

Model	Parameter	Value Range			
		Pig		Broiler	
		Min	Max	Min	Max
Gompertz	y_1, kg	1.7421	1.7421	46.0000	46.0000
	L, g/g	0.0600	0.1200	0.0600	0.1200
	K, t^{-1}	0.0154	0.0186	0.0153	0.0186
Logistic for pig	A, kg	114.8539	194.1031	-	-
	K, t^{-1}	0.0130	0.0220	-	-
	M, kg/kg	4.9246	8.3226	-	-
Logistic for broiler	A, kg	-	-	2616.3727	3165.8110
	L, g/g	-	-	0.1182	0.1430
	K, t^{-1}	-	-	24.4545	29.5900
Von Bertalanffy	A, kg	253.1169	427.7676	5652.4909	6839.5140
	B, kg/kg	0.0000	0.9000	0.7909	0.9570
	K, t^{-1}	0.0070	0.0100	0.0273	0.0330

The range values permitted for variation in the SAGAC algorithm are defined in Table 3. The precision levels of the parameters are different from each other, and the parameter y_1 has no level variation with a unique value (1.7421). After the SAGAC algorithm calculates estimated values ($\hat{y}$) for all ages (day) in the sample data, the coefficient of determination (R^2) may be calculated using Equation (5).

$$Maximize\ R^2 = \frac{\sum_{i=1}^{n}(\hat{y}_i - \overline{y})^2}{\sum_{i=1}^{n}(y_i - \overline{y})^2} \quad (5)$$

where y = the independent variable of the data, $\overline{y}$ = the mean of the independent variables, and $\hat{y}$ = the estimated value of y (sample data) according to the models.

2.3. *The Hybrid Metaheuristic Algorithm (SAGAC)*

The model is formed using two algorithms, Simulated Annealing (SA) and the Genetic Algorithm (GA), with the inclusion of a mechanism (function) that promotes acceleration of the convergence (GA + AC) of the obtained results. The SA algorithm acts on the generation of individuals who make up the modified Genetic Algorithm's initial population (GA + AC). Using the SA algorithm makes it possible to obtain a composition of a good-quality initial population, that is, pre-optimized individuals. In this topic, the SAGAC algorithm is presented in detail, including which parts compose it and how it works. First, it is critical to mention that SAGAC is a hybrid metaheuristic algorithm formed by two algorithms.

The main novelty presented by the SAGAC algorithm is the inclusion of a mechanism (function) in the Genetic Algorithm that can promote a convergence acceleration (AC) of the obtained results; that is, the improvement in the obtained results tends to occur in a smaller number of generations. This mechanism (function) acts within the Genetic Algorithm in the crossover functionality. The integration of the convergence acceleration (AC) mechanism (function) with the Genetic Algorithm (GA) is named (AGAC). The first stage of SAGAC's functionality is in charge of Simulated Annealing (SA). SA generates the individuals for the initial population or the first generation. The modified Genetic Algorithm (AGAC) uses this initial population or generation. With the use of the SA algorithm, it is possible to obtain a composition of an initial population of good-quality, pre-optimized individuals.

The behavior of the routine of the AGAC algorithm promotes convergence acceleration. After crossing, there is an evaluation of the generated individuals (children) and a verification of the quality improvement concerning the individuals of the elite population group. If this does not occur, the individual(s) child(ren) is(are) discarded, and the individual (Father) of worse quality is replaced by another individual from the elite group that is closer and better than the individual (Father) who was changed. After the exchange of the individual (Father), a new crossing occurs for the generation of the missing individual(s) child(ren). This sequence of steps is repeated until both children satisfy the improvement criterion or the stipulated limit of the number of attempts is reached. Figure 1 presents the flowchart of the SAGAC hybrid algorithm.

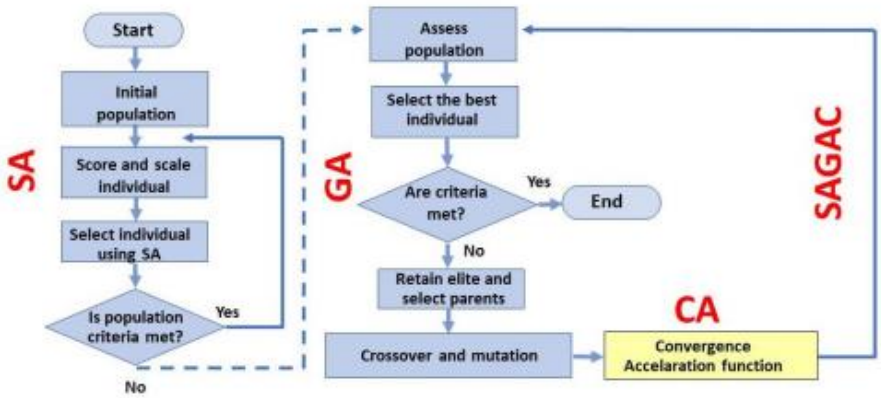

Figure 1. Flowchart of the hybrid SAGAC algorithm.

With each cycle of processing of the Simulated Annealing (SA) algorithm, the best result (individual) is stored to compose the initial population used by the modified Genetic Algorithm (GA) with the convergence acceleration mechanism (AGAC). Figure 2 shows the GA with the inclusion of the convergence acceleration mechanism CA [24], with a mechanism to increase the probability of an individual's continuous evolution over the generations.

The algorithm checks whether they have the minimum qualifications to be part of the elite in each generation of children. If this does not occur, these children are disposed of, and a generation of others is added after changing one of the parents with the worst evaluation [25]. In the case of SAGAC, the variables that influence the algorithm's behavior are its processing parameters [18,26,27]. The values for the SAGAC algorithm's parameter setup and their performance in the optimization process are shown in Table 4.

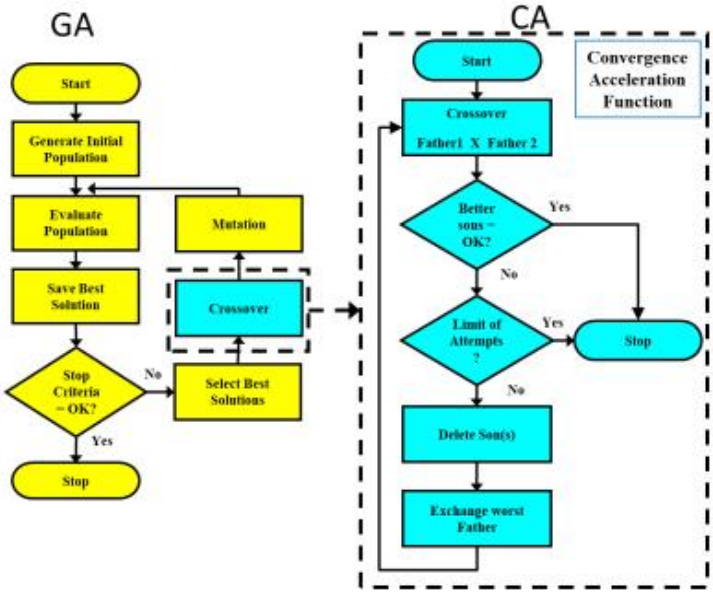

Figure 2. Flowchart of a Genetic Algorithm with the convergence acceleration mechanism.

Table 4. Setup parameters of SAGAC algorithm.

Setup Parameters of SAGAC	
SA Parameters	
Initial Temperature	100
TDS (Temperature Decay Scheme)	1
AGAC Parameters	
Population size	400
Generations (Quantity)	200
Elitism	0.1
Mutation	0.05
Quantity of attempts to generate children in the elite	1

2.4. Statistical Analysis

After optimizing the process and comparing the performance between both the RSM algorithms [28] and SAGAC, a sample of optimization assays was performed with the SAGAC algorithm. This test aimed to observe the stability of the results produced by it. A total of 300 assays were performed using 200 generations. We plotted the results convergence of one experiment. Because in 200 generations, there was no apparent stabilization of the curve convergence, we processed a demonstrative assay with 250 generations to determine the curve convergence after the 200 generations. After the 300 assays, the experimental data were tabulated and organized, and a descriptive analysis was presented. The descriptive statistical analysis was performed using the data from the results of the 300 assays. We used R^2 (the coefficient of determination) to determine the proportion of variance in the dependent variable that the independent variable can explain to compare the models. The coefficient of determination (R^2) is used to identify the strength of a model.

3. Results

3.1. The Analysis of the Algorithms SA and GA

The use of a new hybrid algorithm (SAGAC), as a union of two or more algorithms, such as SA and GA, is presented as an innovation to improve the performance of the optimization process. The comparison between this new hybrid algorithm, SAGAC, and its ancestor algorithms, SA and GA, is necessary to verify the effectiveness of the hybridization. Then, a set of 300 experiments on the growth curve optimization with the ancestor algorithms was conducted, and the results were compared with the SAGAC results. The experimental data of the SAGAC, SA, and GA algorithms were tabulated and organized, and the descriptive analysis is displayed in Figure 3. The boxplot graph describes the data dispersion from the performance of each algorithm.

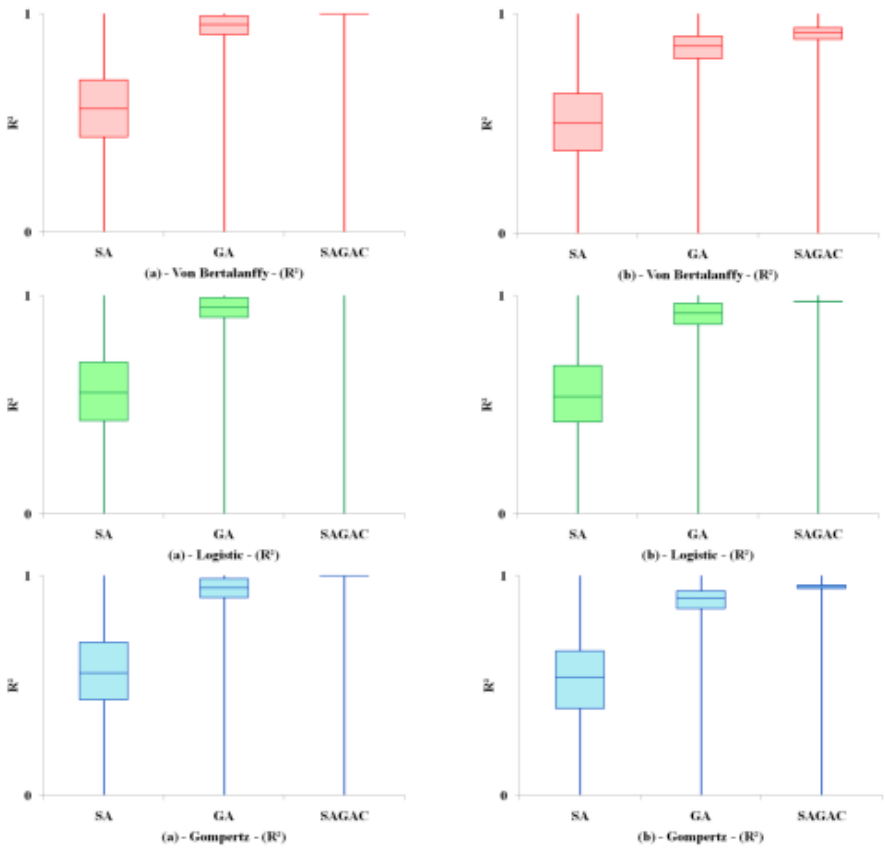

Figure 3. Descriptive analysis of experimental data of performance algorithms (SA, GA, and SAGAC) in growth curve optimization for broilers (**a**) and pigs (**b**).

An analysis of the results of the 300 experimental assays of each algorithm makes it possible to identify the specific performance of each algorithm in the optimization process. When comparing the updated results produced by the Simulated Annealing (SA) techniques and the Genetic Algorithm (GA), it is feasible to observe that the SA and GA algorithms present a lower performance than that of the SAGAC algorithm. Meanwhile, the union of the two algorithms (SA and GA) in a new hybrid algorithm (SAGAC) makes the performance more effective.

3.2. Optimization Experiments

After the implementation and setup of the parameters of the SAGAC algorithm, a series of experimental trials were performed. The results data were collected and tabulated. According to the data, it is possible to identify the performance of the SAGAC algorithm in process optimization. The convergence curve of the resulting data (Figure 4) was generated using the coefficient of determination of the growth curves obtained with value-parameter combination after 250 algorithm interactions (Generation) for broilers and pigs.

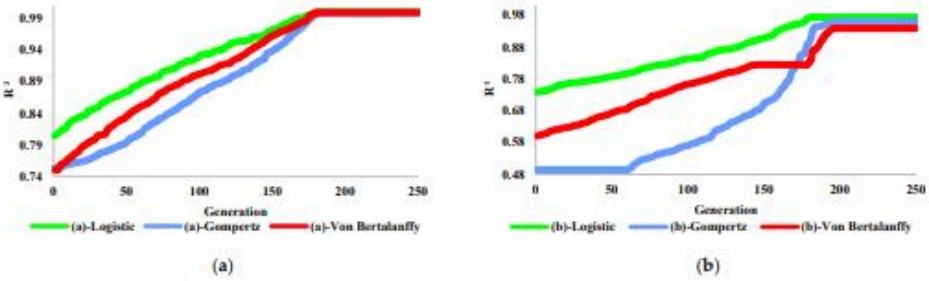

Figure 4. Example of the data convergence curves of determination coefficient models for optimization process (R^2) for broilers (**a**) and pigs (**b**).

Table 5 presents the results obtained by the standard growth curves (von Bertalanffy, Logistic, and Gompertz) [22] after applying the SAGAC algorithm. Comparing the data of the coefficient of determination is possible to check that the SAGAC algorithm finds values for the parameters that give the model the best R^2 value for all models. Comparing the R^2 values obtained using SAGAC between models, the Logistic model has the best coefficient of determination, suggesting that it can provide more reliable prevision values.

Table 5. Comparison of the obtained results for the three tested models for pigs.

	SAGAC					
Model	**Von Bertalanffy**		**Logistic**		**Gompertz**	
Parameter	A, kg	259.524	A, kg	140.4539	y_1, kg	1.7421
	b, kg/kg	0.8277	K, t^{-1}	0.0220	L, g/g	0.0784
	K, t^{-1}	0.0078	M, kg/kg	8.3226	K, t^{-1}	0.0175
R^2	0.9389		0.9738		0.9595	

Results from [7] indicate that the Logistic and von Bertalanffy curves did not accurately estimate both the initial and slaughter weights. On the other hand, the Gompertz equation [1] was the most adequate to describe the pigs' growth curve. The result in the present study is similar to [22]. However, when optimized using the hybrid metaheuristic algorithm (SAGAC), we found a rate of improvement (1%) compared to the Logistic and von Bertalanffy models. This might suggest that these models are more accurate and adjusted or that the other models have a superior flexibility in adjustment rates in the

growth curves. After carrying out the experimental tests, the data generated by the SAGAC algorithm using the Gompertz, Logistic, and von Bertalanffy models, which simulate the growth curve of broilers, are compared with each other and presented in Table 6.

Table 6. Comparison of the obtained results for the three tested models for the broilers.

	SAGAC					
Model	**Von Bertalanffy**		**Logistic**		**Gompertz**	
Parameter	A, kg	5800.4909	A, kg	2884.3727	y_1, kg	46.0000
	b, kg/kg	0.9570	L,(g D^{-1})	0.1430	L, g/g	0.0904
	K, t^{-1}	0.0330	K,(g D^{-1})	29.5900	K, t^{-1}	0.0165
R^2	0.999739		0.999955		0.999998	

Among the models studied, the Gompertz model has the highest coefficient of determination when analyzing the results presented for broilers, which explains the behavior of the curves, with the Logistic model having the second-best outcome. Considering the results' correlation, which measures the correspondence between the pairs of values presented between the sample data and the simulated data, the Gompertz model is more successful, followed by the von Bertalanffy model. Figure 5 illustrates the simulated curves of the models with the errors between the database curves for broilers and pigs. The shaded area is the distance between the actual value and the simulated one.

According to this numerical evidence, the Logistic model improves adherence to the data sample curve and promotes a more confident prevision of swine and broiler growth. The numerical evidence of this adherence is available in Table 3.

The boxplot graph (Figure 6) presents the data dispersion from the performance of the SAGAC algorithm on the standard growth curve models. Detailed data on this performance are shown in Table 3.

The data shown in Table 7 refer to the SAGAC algorithm's behavior in 300 optimization assays to determine the parameter values for the process. It is possible to note that the average relation between the standard deviations and means measures is equal to 0.83%, which means that the deviation of the results is small, which means a slight oscillation. Because the SAGAC results present a slight deviation fluctuation, it explains that the algorithm is stable.

Table 7. Performance of SAGAC in 300 trials for each model related to the dispersion obtained for each assay for all models.

Measure	Coefficient of Determination (R^2)					
	Broiler			Pig		
	Gompertz	Logistic	Von Bertalanffy	Gompertz	Logistic	Von Bertalanffy
Mean	0.998872	0.999957	0.999780	0.948674	0.974265	0.903218
Median	0.999279	0.999955	0.999739	0.950769	0.974241	0.914902
Standard Deviation	0.001177	0.000006	0.000076	0.008878	0.000440	0.041319
Minimum	0.993010	0.999955	0.999739	0.931708	0.973787	0.731966
Maximum	0.999998	0.999993	0.999992	0.959962	0.974999	0.949889

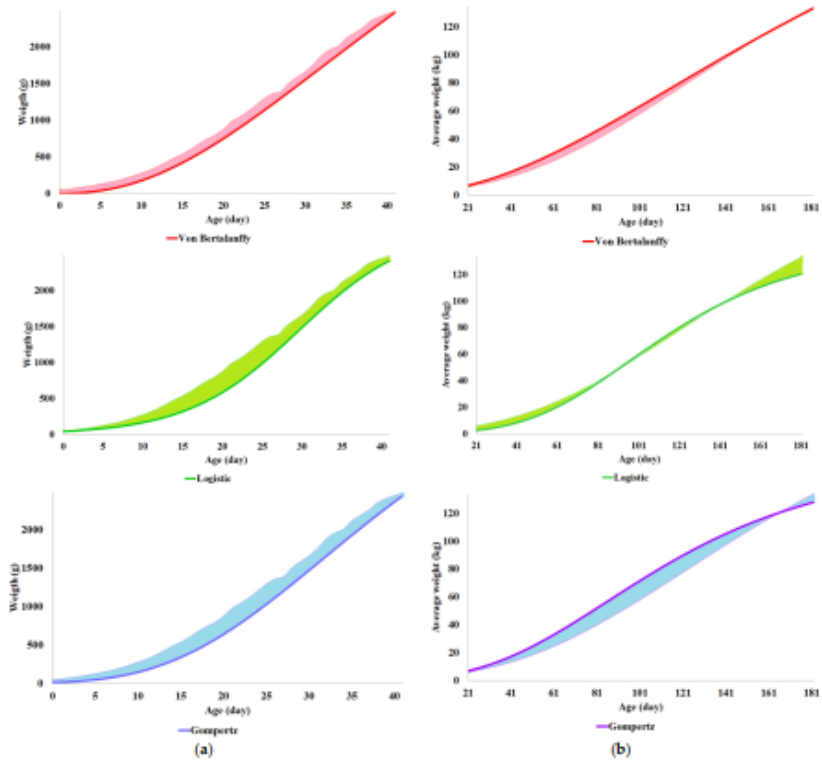

Figure 5. Simulated curves of the models with errors between the database curves for broilers (**a**) and pigs (**b**).

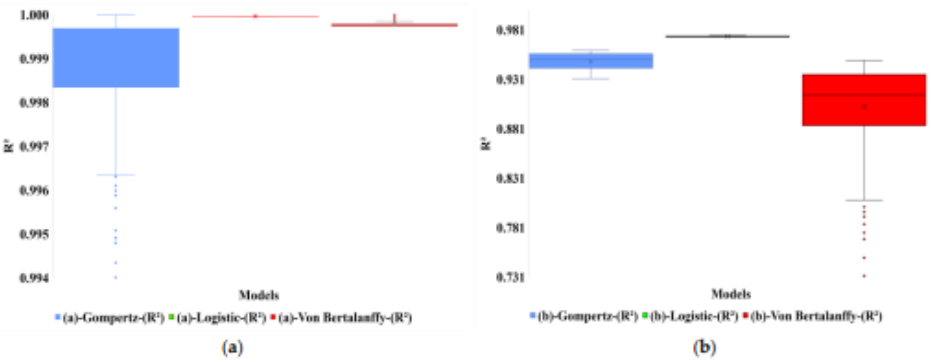

Figure 6. Descriptive analysis of experimental data from 300 assays of performance of SAGAC algorithm in process optimization for broilers (**a**) and pigs (**b**).

4. Discussion

We tested the metaheuristic hybrid algorithm SAGAC to find the best fit among the possible models available for pig and broiler growth. The growth curve parameters provide an opportunity to design selection strategies by modifying either feeding practices or the genetic makeup of the growth curve shape. The quality of fit of a model of an animal species, among other factors, is dependent on the number of weight-age parameters evaluated (sex, breed, management, age of the animal) [22]. The classical Logistic growth equation [2] has been used as a basis for several extended models. Each is helpful to accommodate physical growth without the constraint that the maximum growth rate should occur at half of the carrying capacity in the case of population dynamics or the maximum possible dimension for the physical growth of the system being tested [29]. Previous experimental research was carried out to directly assess the genetic variation inherent in the growth parameters of chickens using a cross-incorporating progeny of both sexes [30]. The authors' results indicate a moderate improvement using the genetic modifications, mainly due to biological limitations. Our results suggest enhancing the animals' weight prediction by optimizing the growth curve parameter values. This is reached by the adherence of the simulated growth curve to the empirical ones.

Vertical management of the poultry and swine industries facilitates product segmentation and a precision approach to optimization solutions for strategic and operational decisions, such as the 'best combination of parameter values of growth models' that would promote slaughter time planning [31]. A comprehensive computational study might solve the integrated planning problem when considering solutions for optimizing the production chain. Hatching eggs, allocating broiler flocks on farms, and collecting broilers for slaughter were applied to accurate data. They showed that value could be added to planning, improving solutions by 15 to 24% [32].

The metaheuristics algorithms use their strategies to search the result set for a better possible outcome in a short time of processing. The SAG successfully optimized cassava starch hydrolysis to produce biofuel [33]. The SAGAC was previously applied to optimize the pre-processing vacuum cooling of broccoli handling [34]. The refined combination of SA and GA (SAG) and adding the convergence acceleration function (AC) improved the performance of the hybrid algorithm (SAGAC) in the optimization process. One characteristic of SAGAC that could be considered a limitation is that the algorithm does not have the optimal result for each problem; however, it finds a satisfactory result due to the complexity of the problem. The computational cost (due to the NP-hardness of the functions) is often unfeasible if an exact algorithm is used for these problems. Our findings show that the Logistic model fits live weight data very well for studying the growth of pigs ($R^2 = 0.9738$). The best-fitted model for the broiler is the Gompertz model ($R^2 = 0.999998$). This result agrees with [6], who found that the Gompertz model was the best model for male and female broilers.

The biological interpretations rationalized for parameters from growth functions and their specific cases have been a primary reason for their popularity [35]. The von Bertalanffy equation was directly argued from metabolic laws [8]. Biological understandings have evolved after choosing a mathematical model on empirical grounds, so it is not unexpected that the functions do not always hold for all models and datasets [36–39]. Therefore, the curve growth functions vary depending on the species and environmental conditions of housing. In our study, there is a slight difference in the results; however, using the SAGAC algorithm decreases that disparity.

There is a constant search for tools and methods to improve production and meat quality [40]. The forecasting of pig growth to devise the market is optimizing production planning and management. In the present research, a hybrid metaheuristic algorithm (SAGAC) was tested to better estimate the model's parameters for predicting pig and broiler growth curves, thus promoting greater reliability in the predictive data of the meat supply chain.

5. Conclusions

The current models for predicting growth curves for monogastric farm animals are developed using experimental data (curve fitting), and these models cannot generalize these curves to other datasets. All tuning of the growth curves using the proposed SAGAC method for broilers presented an R^2 value above 99%, and the SAGAC for pigs presented an R^2 value above 94% for the growth curve. Our study showed that within the three tested models for each monogastric animal (pig and broiler), there is a prevalence of the Logistic model for pig production and the Gompertz model for broiler production.

This study proposes applying SAGAC to optimize the growth parameter models for pigs and broilers, effectively reducing the NP-hardness of the studied functions. Our results improve prediction reliability and enhance production planning quality, minimizing production costs.

Author Contributions: Conceptualization, I.d.A.N., N.D.d.S.L., M.A.C.B. and D.F.P.; methodology, M.A.C.B., I.d.A.N. and N.D.d.S.L.; software, M.A.C.B.; formal analysis, M.A.C.B., I.d.A.N., N.D.d.S.L. and D.F.P.; data curation, M.A.C.B.; writing—original draft preparation, M.A.C.B., I.d.A.N., N.D.d.S.L. and D.F.P.; writing—review and editing, M.A.C.B., I.d.A.N., N.D.d.S.L. and D.F.P.; supervision, I.d.A.N. All authors have read and agreed to the published version of the manuscript.

Funding: This research received no external funding.

Institutional Review Board Statement: Not applicable.

Informed Consent Statement: Not applicable.

Data Availability Statement: The data presented in this study are available upon request from the data curation.

Acknowledgments: We thank the Coordination of Superior Level Staff Improvement—CAPES and the National Council for Scientific and Technological Development for the scholarships.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Gompertz, B. On the nature of the function expressive of the law of human mortality, and on a new method of determining the value of life contingencies. *Phil. Trans. Roy. Soc.* **1825**, *115*, 513–585.
2. Verhulst, P.F. Notice sur la loi que la population suit dans son accroissement. *Corresp. Math. Phys.* **1838**, *10*, 113–126.
3. Winsor, C.P. The Gompertz curve as a growth curve. *Proc. Natl. Acad. Sci. USA* **1932**, *18*, 1–8. [CrossRef] [PubMed]
4. Von Bertalanffy, L. An outline of general system theory. *Br. J. Philos. Sci.* **1950**, *1*, 134–165. [CrossRef]
5. Thornley, J.H.M.; France, J. *Mathematical Models in Agriculture: Quantitative Methods for the Plant, Animal and Ecological Sciences*, 2nd ed.; CABI Publishing: Wallingford, UK, 2007; p. 887.
6. Selvaggi, M.; Laudadio, V.; Dario, C.; Tufarelli, V. Modelling growth curves in a nondescript Italian chicken breed: An opportunity to improve genetic and feeding strategies. *J. Poult. Sci.* **2015**, *52*, 0150048. [CrossRef]
7. Ceron, M.S.; Oliveira, V.D.; Pieve, N.A.N.N.; Silva, N.C.D.; Rossi, C.A.R.; Fraga, B.N.; Kessler, A.D.M. Non-linear equations to determine the growth curve of immunocastrated pigs. *Pesqui. Agropecu. Bras.* **2020**, *55*, e01184. [CrossRef]
8. Fitzhugh, H.A., Jr. Analysis of growth curves and strategies for altering their shape. *J. Anim. Sci.* **1976**, *42*, 1036–1051. [CrossRef]
9. Pommerening, A.; Grabarnik, P. Principles of Relative Growth Analysis. In *Individual-Based Methods in Forest Ecology and Management*; Springer: Cham, The Netherlands, 2019. [CrossRef]
10. Wilson, B.J. Growth curves: Their analysis and use. In *Production*; Boorman, K.N., Wilson, B.J., Eds.; British Poultry Science Ltd.: Edinburgh, UK, 1977; pp. 89–115.
11. Şengül, T.; Kiraz, S. Non-Linear models for growth curves in Large White turkeys. *Turkish J. Vet. Anim. Sci.* **2005**, *29*, 331–337. Available online: https://dergipark.org.tr/en/pub/tbtkveterinary/issue/12545/151373 (accessed on 18 July 2021).
12. Demmers, T.G.M.; Cao, Y.; Gauss, S.; Lowe, J.C.; Parsons, D.J.; Wathes, C.M. Neural predictive control of broiler chicken and pig growth. *Biosyst. Eng.* **2018**, *173*, 134–142. [CrossRef]
13. Luo, J.; Lei, H.; Shen, L.; Yang, R.; Pu, Q.; Zhu, K.; Zhu, L. Estimation of growth curves and suitable slaughter weight of the Liangshan pig. *Asian-Australas. J. Anim. Sci.* **2015**, *28*, 1252. [CrossRef]
14. Camp Montoro, J.; Manzanilla, E.G.; Solà-Oriol, D.; Muns, R.; Gasa, J.; Clear, O.; Calderón Díaz, J.A. Predicting productive performance in grow-finisher pigs using birth and weaning body weight. *Animals* **2020**, *10*, 1017. [CrossRef] [PubMed]
15. Remus, A.; Hauschild, L.; Methot, S.; Pomar, C. Precision livestock farming: Real-time estimation of daily protein deposition in growing–finishing pigs. *Animal* **2020**, *14* (Suppl. 2), s360–s370. [CrossRef] [PubMed]

16. Siegel, P.B. Evolution of the modern broiler and feed efficiency. *Annu. Rev. Anim. Biosci.* **2014**, *2*, 375–385. [CrossRef] [PubMed]
17. Carvalho, G.; Freitas, G.; Sousa, L.; Cassiano, R.; Garcia Neto, M.; Filardi, R. Programa prático de modelagem de curvas aplicado a Mazama gouazoubira. *Arch. Vet. Sci.* **2018**, *23*, 65–68. [CrossRef]
18. Kirkpatrick, S.; Gelatti, C.D.; Vecchi, M.P. Optimization by simulated annealing. *Science* **1983**, *220*, 671–680. [CrossRef]
19. Holland, H.J. *Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence*; MIT Press: Ann Arbor, MI, USA, 1975; p. 207.
20. Haldurai, L.; Madhubala, T.; Rajalakshmi, R.A. Study on genetic algorithm and its applications. *Int. J. Comput. Sci. Eng.* **2016**, *4*, 139–143. Available online: https://www.ijcseonline.org/pdf_paper_view.php?paper_id=1092&22-IJCSE-01860-4.pdf (accessed on 30 May 2022).
21. Rostagno, H.S.; Albino, L.F.T.; Donzele, J.L.; Gomes, P.C.; Oliveira, R.F.; Lopes, D.C.; Ferreira, A.S.; Barreto, S.L.T.; Euclides, R.F. *Tabelas Brasileiras Para aves e Suínos: Composição de Alimentos e Exigências Nutricionais*, 3rd ed.; UFV: Viçosa, Brasil, 2011; p. 252.
22. Freitas, A.R.D. Curvas de crescimento na produção animal. *Rev. Bras. Zootec.* **2005**, *34*, 786–795. [CrossRef]
23. Freitas, A.D.; Costa, C.D. Ajustamento de modelos não-lineares a dados de crescimento de suínos. *Pesq. Agropec. Bras.* **1983**, *18*, 1147–1154. Available online: https://www.alice.cnptia.embrapa.br/bitstream/doc/43218/1/15452682511SM.pdf (accessed on 15 May 2022).
24. Linden, R. *Algoritmos Genéticos— Uma Importante Ferramenta de Inteligência Computacional*, 2nd ed.; Brasport: São Paulo, Brazil, 2008; p. 488.
25. Goldberg, D.E. *Genetic Algorithms in Search, Optimization, and Machine Learning*; Addison-Wesley Pub. Inc.: Boston, MA, USA, 1989; p. 248.
26. Mitchell, T.M. *Machine Learning*; McGraw-Hill: New York, NY, USA, 1997; p. 421.
27. Benvenga, M.A.C.; de Alencar Nääs, I. Application of Hybrid Metaheuristic Optimization Algorithm (SAGAC) in Beef Cattle Logistics. In *Advances in Production Management Systems. Artificial Intelligence for Sustainable and Resilient Production Systems*; Dolgui, A., Bernard, A., Lemoine, D., von Cieminski, G., Romero, D., Eds.; In Proceedings of the APMS 2021 IFIP Advances in Information and Communication Technology, Nantes, France, 5–9 September 2021; Springer: Cham, The Netherlands, 2021; Volume 631. [CrossRef]
28. Maache-Rezzoug, Z.; Pierre, G.; Nouviaire, A.; Maugard, T.; Rezzoug, S.A. Optimizing thermomechanical pretreatment conditions to enhance enzymatic hydrolysis of wheat straw by response surface methodology. *Biomass Bioenerg.* **2011**, *35*, 3129–3138. [CrossRef]
29. Tsoularis, A.; Wallace, J. Analysis of logistic growth models. *Math. Biosci.* **2002**, *179*, 21–55. [CrossRef]
30. Barbato, E.G. Genetic architecture of growth curve parameters in chickens. *Theor. Appl. Genet.* **1991**, *83*, 24–32. [CrossRef] [PubMed]
31. Rizzi, C.; Contiero, B.; Cassandro, M. Growth patterns of Italian local chicken populations. *Poult. Sci.* **2013**, *92*, 2226–2235. [CrossRef] [PubMed]
32. Brevik, E.; Lauen, A.Ø.; Rolke, M.C.; Fagerholt, K.; Hansen, J.R. Optimisation of the broiler production supply chain. *Int. J. Prod. Res.*. **2020**, *58*, 5218–5237. [CrossRef]
33. Benvenga, M.A.C.; Nääs, I.A. Hybrid metaheuristic algorithm (SAGAC) used in optimization of vacuum cooling treatment of postharvest broccoli. *Revista FSA* **2021**, *18*, 160–172. [CrossRef]
34. Benvenga, M.A.C.; Nääs, I.A. Optimization of hydrolysis of cassava starch for biofuel production using a Hybrid Metaheuristic Algorithm. *Biomass Conv. Bioref.* **2022**, *12*, 1–13. [CrossRef]
35. Bean-Hodgins, L.; Mohammadigheisar, M.; Edwards, A.M.; Wang, C.; Barbut, S.; Kiarie, E.G. Comparative impact of conventional and alternative gut health management programs on growth performance and breast meat quality in broiler chickens raised in commercial and research settings. *J. Appl. Poult. Res.* **2022**, *31*, 100228. [CrossRef]
36. Robertson, T.B. On the normal rate of growth of an individual, and its biochemical significance. *Dev. Genes Evol.* **1908**, *25*, 581–614. [CrossRef]
37. Oviedo-Rondon, E.O. Model applications in poultry production and nutrition. In *Nutritional Modelling for Pigs and Poultry*; Sakomura, N.K., Gous, R.M., Kyriazakis, I., Hauschild, L., Eds.; CAB International: Wallingford, UK, 2015; pp. 125–140.
38. Coffey, D.; Dawson, K.; Ferket, P.; Connolly, A. Review of the feed industry from a historical perspective and implications for its future. *J. Appl. Anim. Nutr.* **2016**, *4*, E3. [CrossRef]
39. Lee, L.; Atkinson, D.; Hirst, A.G.; Cornell, S.J. A new framework for growth curve fitting based on the von Bertalanffy growth function. *Sci. Rep.* **2020**, *10*, 7953. [CrossRef]
40. Piran, F.S.; Lacerda, D.P.; Camanho, A.S.; Silva, M.C.A. Internal benchmarking to assess the cost efficiency of a broiler production system combining data envelopment analysis and throughput accounting. *Int. J. Prod. Econ.* **2021**, *238*, 108173. [CrossRef]

CAPÍTULO 5

5 Considerações Finais

5.1 Conclusões

Este projeto apresentou um algoritmo metaheurístico híbrido de otimização como uma ferramenta viável para os processos do agronegócio, melhorando a eficiência desses processos e também da qualidade de seus produtos. O objetivo era investigar o desempenho do algoritmo metaheurístico híbrido SAGAC na solução de alguns problemas de produção de proteína animal de precisão. Três artigos foram desenvolvidos e publicados durante este projeto e, uma síntese de cada um deles é apresentada a seguir.

Para o artigo 1, aplicou-se o algoritmo metaheurístico para pesquisar uma combinação dos parâmetros ambientais (Temperatura = Tbs (°C), Umidade Relativa do ar = UR (%), Velocidade do vento = Var (m/s), Concentração de Amônia = NH_3 (ppm) e Concentração de gás carbônico = CO_2 (ppm)). O processo de otimização considerou quatro faixas etárias das aves (21, 28, 35, 42 dias) e os resultados obtidos mostraram que houve aumento na taxa de melhoria da ambiência para as quatro faixas etárias, com a maior taxa de melhoria para as aves com 21 dias de idade.

Para o artigo 2, aplicou-se o SAGAC para otimizar os parâmetros logísticos (frigorífico, rota, caminhão) do processo de transporte de gado de corte entre o produtor e o frigorífico. Neste caso, haviam resultados obtidos por meio de um algoritmo determinístico (Branch-and-bound) os quais foram comparados com os resultados obtidos pelo SAGAC. Nas 22 duas simulações realizadas, o SAGAC obteve um desempenho médio 0,14% melhor que o algoritmo Branch-and-bound.

Para o artigo 3, utilizou-se o SAGAC para otimizar a combinação dos parâmetros de três modelos de curvas de crescimento (Gompertz, Logistic e Von Bertalanffy) de monogástricos (frangos e suínos) com o intuito de obter o maior coeficiente de derminação (R^2) que representa a probabilidade de acerto dos dados simulados em relação aos dados reais de crescimento dos animais, indicando, por consequencia, o grau de confiabilidade nos dados do planejamento do processo. Os resultados obtidos apresentaram percentuais de coeficiente de determinação acima de 99% para frangos, com destaque para o modelo Gompertzque apresentou a maior taxa (99,998%) e, acima de 93% para suínos, com destaque para o modelo Logistic que apresentou a maior taxa (97,380%).

No que tange ao objetivo deste trabalho que é investigar o desempenho do algoritmo metaheurístico híbrido SAGAC constatou-se, por meio dos três artigos apresentados que o objetivo foi alcançado e que o algoritmo SAGAC apresentou desempenho superior à outras técnicas nos casos abordados.

5.2 Recomendações de trabalhos futuros

Percebe-se após a conclusão deste trabalho que o algoritmo metaheurístico híbrido SAGAC e as técnicas heurísticas e metaheurísticas como um todo podem ser melhoradas e aplicadas em diversos problemas de otimização.

Implementar o SAGAC em outros problemas práticos cujos resultados obtidos por outros algoritmos não foram satisfatórios, seria um campo com potencial de sucesso a ser considerado.

Outra possibilidade seria a comparação do SAGAC com técnicas híbridas de otimização que, têm demonstrado obter melhores resultados em processos de otimização.

Agradecimentos

Agradeço à CAPES/PROSUP pela bolsa recebida.

Agradeço à UNIP pelo suporte.

REFERÊNCIAS

Abreu L. H. P., Junior T. Y., Bahuti M., Hernández-Julio Y. F., Ferraz P. F. P., Artificial neural networks for prediction of physiological and productive variables of broilers, Engenharia Agrícola, ISSN: 1809-4430, 2020

Ahrendt P., Gregersen T., Karstoft H., Development of a real-time computer vision system for tracking loose-housed pigs, Computers and Electronics in Agriculture, 2011

Almeida D. P., Ferreira M. C., Santos R. T. S., Griesang F., Santos E. S., Timossi P. C., Influence of glyphosate concentrations on spray solution physicochemical characteristics and drift potential, Engenharia Agrícola, Doi: http://dx.doi.org/10.1590/1809-4430-Eng.Agric.v40n1p69-77/2020, 2020

Amraei S., Mehdizadeh S. A., Nääs I. A., Development of a transfer function for weight prediction of live broiler chicken using machine vision, EngenhariaAgrícola, 2018

Anderson D.M., Virtual fencing – past, present and future, U.S. Department of Agriculture, Agriculture Research Service, Jornada Experimental Range, Box 30003, MSC 3JER, NMSU, Las Cruces, New Mexico 88003-8003, USA, 2007.

Arcoverde S. N. S., Souza C.M. A., Rafull L. Z. L., Cortez J. W., Orlando R. C., Soybean agronomic performance and soil physical attributes under tractor traffic intensities, Engenharia Agrícola, Doi: http://dx.doi.org/10.1590/1809-4430-Eng.Agric.v40n1p113-120/2020, 2020

Aydin A., Bahr C., Viazzi S., Exadaktylos V., Buyse J., Berckmans D., A novel method to automatically measure the feed intake of broiler chickens by sound technology, Computers and Electronics in Agriculture, 2014

Aydin A., Bahr c., Berckmans D., A real-time monitoring tool to automatically measure the feed intakes of multiple broiler chickens by sound analysis, Computers and Electronics in Agriculture, 2015

Aydin A., Development of an early detection system for lameness of broilers using computer vision, Computers and Electronics in Agriculture, 2017

Bahloac C., Dahlhausac P., Thompsonac H., Trotterbc M., The role of interoperable data standards in precision livestock farming in extensive livestock systems: A review, Computers and Electronics in Agriculture, Volume 156, January 2019, Pages 459-466, https://doi.org/10.1016/j.compag.2018.12.007, 2019

Baldacci R., Boschetti M. A., Ganovelli M., Maniezzo V., Algorithms for nesting with defects, Discrete Applied Mathematics, Doi: 10.1016/j.dam.2012.03.026, 2012

Banhazi T.M., Black J.L., Precision livestock farming: a suite of electronic systems to ensure the application of best practice management on livestock farms, australian journal of multi-disciplinary engineering, 7:1, 1-14, DOI:10.1080/14488388.2009.11464794, 2009

Banhazi T.M., Babinszky L., Halas V., Tscharke M., PRECISION LIVESTOCK FARMING: PRECISION FEEDING TECHNOLOGIES AND SUSTAINABLE ANIMAL PRODUCTION, INT. J. AGRIC. & BIOL. ENG., 2012

Barros Neto, B.; Scarminio, I. S.; Bruns, R. E.Como Fazer Experimentos: Pesquisa e Desenvolvimento na Ciência e na Indústria.vol. 1, 1ª edição, Coleção livros - textos, EDUNICAMP, Campinas – SP, 2001, 406p.

Benvenga, M. A. C., Alencar Nääs, I. D. (2021, September). Application of Hybrid Metaheuristic Optimization Algorithm (SAGAC) in Beef Cattle Logistics. In IFIP International Conference on Advances in Production Management Systems (pp. 585-593). Springer, Cham.

Bertrand, J. W. M.; Fransoo, J. C. Modelling and Simulation Operations Management research methodologies quantitative modeling.International Journal of Operations and Production Management, vol.22, n.2, p.241-261, 2002.

Buijs S., Keeling L. J., Vangestel C., Baert J., Vangeyte J., Tuyttens F. A. M., Resting or hiding? Why broiler chickens stay near walls and how density affects this, Applied Animal Behaviour Science, 2010

Centro de Estudos Avançados em Economia Aplicada – CEPEA. (2017). PIB do agronegócio brasileiro: PIB do Agronegócio - Dados de 1996 a 2017. Retrieved in 2018, February 12, from
https://www.cepea.esalq.usp.br/br/pib-do-agronegocio-brasileiro.aspx

CGEE - Centro de Gestão e Estudos Estratégicos, Bioetanol combustível: uma oportunidade para o Brasil, pag.22, 2009.

CEPEA/ESALQ, 2021, Índices Exportação do Agronegócio, CEPEA – Centro de Estudos Avançados em Economia Aplicada – ESALQ-USP, https://cepea.esalq.usp.br/upload/kceditor/files/Cepea_Export_1_quadri_2021.pdf.

Christ, G. D., Strauch, A. G. N., Santos, L. P. D., & Assis Shikida, P. F. (2021). A competitividade do agronegócio brasileiro no comércio internacional. Revista de Política Agrícola, 30(4), 122.

Curvelo-Santana, J. C., Araújo, S. A., Librantz, A. F. H., R. R., Tambourgi, E. B. Optimization of Corn Malt Drying by Use of a Genetic Algorithm, Drying Technology, 28: 11, 1236 a 1244,2010.

de Arruda Silva, V., Cordeiro, C. C. M., de Barros Baltar, M. L., Bender, J. É. C., & Bortolini, J. (2020). Forecasting storage capacity using exponential smoothing method. Revista Produção e Desenvolvimento, 6.

Dias C. A., Andrade E. T., Lemos I. A., Borém F. M., Barros E. A., Sorption isotherms and isosteric heat of pericarp and endosperm tissues of arabica coffee fruit, Doi: http://dx.doi.org/10.1590/1809-4430-Eng.Agric.v40n1p78-89/2020, 2020

Diel P. B., Casarin V. A., Stracke M. P., Silva D. J. C., Santos A. V., Przyczynski R., Economic management model of electricity generated from biomass in a pig farm, Doi: http://dx.doi.org/10.1590/1809-4430-Eng.Agric.v40n2p132-138/2020, 2020

Ding, H.; Benyoucef, L.; Xie, X.A simulation-based multi-objective genetic algorithm approach for networked enterprises optimization, Engineering Applications of Artificial Intelligence, vol.19, p.609-623, 2006.

Dorigo, M.; Maniezzo, V.; Colorni, A.The Ant System: optimization by a colony of cooperating agents. IEEE Transactions on Systems, Man, and Cybernetics.Part B: Cybernetics, vol.26, n.1, p.29-41, 1996.

Dos Santos, J. A., Moura-Leite, R., Pereira, M. W. G., & Pagán, M. (2020). Social and environmental disclosure of the largest companies in Brazil's agribusiness sector. Social Responsibility Journal. Embrapa, Cias - Central de Inteligência de Aves e Suínos, https://www.embrapa.br/qualidade-da-carne/carne-em-numeros-2, acessado em 07/07/2020, 2020

Embrapa(f), Central de inteligência de aves e suínos, https://www.embrapa.br/suinos-e-aves/cias/custos/icpfrango, consultado em 09/01/2021, 2021

Embrapa(s), Central de inteligência de aves e suínos, https://www.embrapa.br/suinos-e-aves/cias/custos/icpsuino, consultado em 09/01/2021, 2021

Filho J. I. S., Talamini D. J. D., Produção de Frangos de Corte, FACTA- Fundação Apinco de Ciência e Tecnologia Avícolas, 1a.Edição, Capítulo 23, Campinas, 2014

Glover, F.; Laguna, M. Tabu Search.Kluver Academic Publishers, 1997.

Gov.br, Governo do Brasil, DESEMPENHO AGROPECUÁRIO, Valor da produção agropecuária de 2020 é o maior dos últimos 32 anos, https://www.gov.br/pt-br/noticias/agricultura-e-pecuaria/2021/01/valor-da-producao-agropecuaria-de-2020-e-o-maior-dos-ultimos-32-anos, acessado em 15/02/2021, 2020

Hjersted, J.; Henson, M.A. Population modeling for ethanol productivity optimization in fed-batch yeast fermenters.American Control Conference, 2005.

Halachmi I., Guarino M., Editorial: Precision livestock farming: a 'per animal' approach using advanced monitoring technologies, The Animal Consortium, pp 1482–1483, doi:10.1017/S1751731116001142, 2016.

Halachmi I., Guarino M., Bewley J., Pastell M., Smart Animal Agriculture: Application of Real-Time Sensors to Improve Animal Well-Being and Production, Annual Review of Animal Biosciences, Vol. 7:403-425 (Volume publication date February 2019), https://doi.org/10.1146/annurev-animal-020518-114851, 2019

Holland, H. J. Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence. MIT Press, Ann Arbor, 1975.

IBGE, elaborado por SEPLAG, DEPLAN, disponibilizado por Secretaria de Planejamento, Orçamento e Gestão, Rio Grande do Sul, https://atlassocioeconomico.rs.gov.br/midia/imagem/map-2016-2018-aves-br , consultado em 09/01/2021, ,2020

Iliev , V. Stoycheva, J.; Angelov, M.; Kostov, G.; Koprinkova-Hristova, P.; Popova, S. Bio-ethanol production optimization using ACD with ESN critic. Innovations in Intelligent Systems and Applications (INISTA), International Symposium, 2011.

Jafarzadeh H., Moradinasabb N., Eskandaric Ebrahim Fayyazi, Barat Ghobadian*, Gholamhassan Najafi, and Bahram Hosseinzade H., Gholamid S., Genetic Algorithm for A Generic Model of Reverse Logistics Network, International Journal of Engineering Innovation & Research, 2017

Kirkpatrick, S.; Gelatti, C. D.; Vecchi, M. P. Optimization by SimultedAnnealing.Science, New Series, vol.220, n.4598, p.671-680, May.1983.

Konzen, P. H. A.; Furtado, J. C.; Carvalho, C. W.; Ferrão, M. F.; Molz, R. F.; Bassani, I. A.; Hüning, S. L. Otimização de métodos de controle de qualidade de fármacos usando algoritmo genético e busca tabu. Scielo, Pesqui. Oper. vol.23 n.1 Rio de Janeiro Jan./Apr. 2003.

Kristensen H. H., Cornou C., Automatic detection of deviations in activity levels in groups of broiler chickens e A pilot study, Biosystems Engeneering, 2011

Li, L.; Wang, L.; Liu, L.An effective hybrid PSOSA strategy for optimization
and its application to parameter estimation. Applied Mathematics and Computation 179, 135-146 , 2006.

Linden, R. AlgoritmosGenéticos. cap.4. 2008.

Martinez, Angel Antonio Gonzalez, Irenilza de Alencar Nääs, Thayla Morandi Ridolfi de Carvalho-Curi, Jair Minoro Abe, and Nilsa Duarte da Silva Lima. 2021. "A Heuristic and Data Mining Model for Predicting Broiler House Environment Suitability" Animals 11, no. 10: 2780. https://doi.org/10.3390/ani11102780

Mitchell, T. M. Machine Learning. McGraw-Hill Science, cap.9. 1997.

MAPA, Ministério da Agricultura, Pecuária e Abastecimento, AGROSTAT - Estatisticas de Comércio Exterior do Agronegócio Brasileiro, Acesso em 30 de janeiro de 2021, Disponível em http://indicadores.agricultura.gov.br/agrostat/index.htm, 2021.

Marey S., Aboukarima A., Almajhadi Y., Predicting the performance parameters of chisel plow using neural network model, Engenharia Agrícola, Doi: http://dx.doi.org/10.1590/1809-4430-Eng.Agric.v40n6p719-731/2020, 2020

Mendes A.A., Produção de Frango de Corte – A cadeia avícola brasileira, FACTA – Fundação de Amparo de Ciência e Tecnologia Avícolas, coeditora – FAPESP, Cap.1,2014

Miele M., Custos de produção de suínos em 2018 nos países da rede InterPIG, Comunicado técnico 565, Embrapa, Concórdia , SC, disponível na Central de Inteligência de Aves e Suínos (CIAS), https://ainfo.cnptia.embrapa.br/digital/bitstream/item/207049/1/final9279.pdf, 2019

Mota, E.V. O biodigestor no tratamento de dejetos suínos como mecanismo de controle ambiental. 2013. 35p. Trabalho de Conclusão de Curso II (Graduação em Ciências Contábeis) – Uni-RV - Universidade de Rio Verde, Rio Verde,2013.

Mukherjee, I., e Ray, P.K. A review of optimization techniques in metal cutting process. Computers & Industrial Engineering, 2006, 50 (1-2), 15-34.

Nääs I. A. I., Mollo Neto M. I., Canuto S. A. I.,Waker R. I., Oliveira D. R. M. S. I. I., Vendrametto O. I. Brazilian Chicken Meat Production Chain: a 10-year Overview, Brazilian Journal of Poultry Science (Revista Brasileira de CiênciaAvícola), 2015

Neto, B. B., Scarminio, I. S., Bruns, R. E., Planejamento e Otimização de Experimentos, UNICAMP, 2ª.ed, 1994;

Oliveira J. T., Roque C. G., Teodoro P., Montanari R., Spatial variability of irrigated common bean yield correlated with the fertility of a sandy soil, Engenharia Agrícola, Doi: http://dx.doi.org/10.1590/1809-4430-Eng.Agric.v40n5p645-656/2020, 2020

Oysu C., Bingul Z., Application of heuristic and hibrid-GASA algorithms to tool-path optimization problem for minimizing airtimeduringmachinning. Eng. Appl. Artif.Intell 22.(3): 389-396, 2009.

Paszkowicz, W. Genetic Algorithms, a Nature-Inspired Tool: Survey of Applications in Materials Science and Related Fields. Materials and Manufacturing Processes, 2009, 24 (2), 174-197.

Peipei, G.; Chunkeng, H.; Zhongfeng, G.; Danghui, S.; Gongxun, Y. Process optimization for very high concentration ethanol fermentation by self-flocculating yeast. Remote Sensing, Environment and Transportation Engineering (RSETE), International Conference, 2011.

Pereira D.F., Miyamoto B.C.B., Maia G.D.N., Sales G.T., Magalhães M.M., Gates R.S., Machine vision to identify broiler breeder behavior, Computers and Electronics in Agriculture, 194–199, 2013.

Petry M. T., Basso L. J., Carlesso R., Armoa M. S., Henkes J. R., Modeling yield, soil water balance, and economic return of soybean under different water deficit levels, Engenharia Agrícola, Doi: http://dx.doi.org/10.1590/1809-4430-Eng.Agric.v40n4p526-535/2020, 2020

Pessôa, A. S. M., & SIMÕES, D. D. C. (2020). Key success factors for the Brazilian grains and meat industry. China-Brazil partnership on agriculture and food security. Piracicaba: Esalq, 154-183.

Puchalsky, W., Ribeiro, G. T., da Veiga, C. P., Freire, R. Z., & dos Santos Coelho, L. (2018). Agribusiness time series forecasting using Wavelet neural networks and metaheuristic optimization: an analysis of the soybean sack price and perishable products demand. International Journal of Production Economics, 203, 174-189.

Qiu, H.; Zhou, W. ; Wang, H. A Genetic Algorithm-Based Approach to Flexible Job-Shop Scheduling Problem. Natural Computation, 2009. ICNC '09. FifthInternationalConference.

Ramirez B.C., Hoff S.J., Harmon J.D., Thermal environment sensor array: Part 2 applying
the data to assess grow-finish pig housing, Biosystems engineering, 341 – 351, 2018.

Sales G.T., Green A.R., Gates R.S., Brown-Brandl T.M., Eigenberg R.A., Quantifying detection performance of a passive low-frequency RFID system in an environmental preference chamber for laying hens, Computers and Electronics in Agriculture, 2015

Santana, A. et al. Suinocultura: carne in natura, embutidos e defumados. Estudos de mercado. SEBRAE, ESPM, 2008.

Santana, J. C., C.; Mesquita, R.,A.; Tambourgi, E., B.; Librantz, A., F., H.; Benvenga, M., A., C. Obtenção da Condição Ótima do Processo de Hidrólise do Amido de Mandioca por Amilases de Aspergillusniger, XVIII SINAFERM – Simpósio Nacional de Bioprocessos, 2011.

Schinckel A. P., Richert B. T., Sholly D. M., Radcliffe J. S., Sutton A. L., Einstein M. E., Impact of Weaning Weight and Early Postweaning Growth of Pigs to Late Finishing Growth When Fed Either Corn- and Soybean Meal-Based Diets or Low Nutrient Excretion Nutrient-Dense Diets, Department of Animal Sciences, Purdue University, West Lafayette, IN 47907-2054, DOI: 10.15232/S1080-7446(15)30703-8, 2009

Schweiger, C.; Sayyar-Rodsari, B.; Bartee, J.; Axelrud, C. Plant-wide optimization of an ethanol plant using parametric hybrid models. DecisionandControl (CDC), 49th IEEE Conference, 2010.

Sherwin A., Morteza T., Abbas R., Applied improved RBF neural network model for predicting 3 the broiler output energies, Applied Soft Computing Journal, 2019

Sreekara Reddy, M.B.S., Ratnam, C., Rajyalakshmi, G., Manupati, V.K,, An effective hybrid multi objective evolutionary algorithm for solving real time event in flexible job shop scheduling problem, Measurement: Journal of the International Measurement Confederation, Volume 114, January 2018, Pages 78-90, Elsevier, 2017

Sosa, N. G. M.; Galvão, R. D.; Gandelman, D. A. Algoritmo de Busca Dispersa aplicado ao problema clássico de roteamento de veículos. Scielo, Pesqui. Oper. vol.27 n.2 Rio de Janeiro Mai./Ago. 2007.

Sousa, V. N.; Moretti, A. C.; Podestá, V. A. Programação da grade de horário em escolas de ensino fundamental e médio. Scielo, Pesqui. Oper. vol.28 n.3 Rio de Janeiro Set./Dez. 2008.

Souza A.I.S., Saraiva M.M.S., Casas M.R.T., Oliveira G.M., Cardozo M.V., Benevides V.P., Barbosa F.O., Neto O.C.F., Almeida A.M., Berchieri A., High occurrenceof ß-lactamase-producing Salmonella Heidelberg frompoultryorigin, PloSone, Vol.15(3), 2020.

Strathe A. B., Danfer A., Sorensen H., Kebreab E., A multilevel nonlinear mixed-effects approach to model growth in pigs, American Society of Animal Science, doi:10.2527/jas.2009-1822, 2009

Tavanti R. F. R., Montanari R., Panosso A. R., Freddi O. S., Paz-González A., Pedotransfer function to estimate the soil structural “S” index and spatial variability in an oxisol within a livestock farming system, Engenharia Agrícola, Doi: http://dx.doi.org/10.1590/1809-4430-Eng.Agric.v40n1p34-44/2020, 2020

Terrasson G., Villeneuve E., Pilnière V., Llaria A., Precision Livestock Farming: A Multidisciplinary Paradigm, SMART 2017 : The Sixth International Conference on Smart Cities, Systems, Devices and Technologies, 2017.

Trienekens, J.; Zuurbier, P.; Quality and safety standards in the food industry, developments and challenges, International Journal of Production Economics, 2007.

Tullo E., Finzi A., Guarino M., Review: Environmental impact of livestock farming and Precision Livestock Farming as a mitigation strategy, Science of the Total Environment, 2751–2760, 2019.

Vasan, A. ; Raju, K. S. Comparative analysis of Simulated Annealing, Simulated Quenching and Genetic Algorithms for optimal reservoir operation. Applied Soft Computing, 2009.

Vranken E., Berckmans D., Precision livestock farming for pigs, Animal Frontiers, SoundTalks, Kapeldreef 60, 3001 Leuven, Belgium, doi:10.2527/af.2017.0106, 2017.

Wageningen University & Research, Competitiveness of the EU poultry meat sector, base year 2017: international comparison of production costs, acesso em: https://www.avec-poultry.eu/wp-content/uploads/2018/12/WUR-report-2018-116-Competitiveness-EU-poultry-meat-PvanHorne_def.pdf, 2018

Waker R. I., Nääs I. A. I., Structural Attributes Dynamics of the Brazilian Broiler Production Chain, Brazilian Journal of Poultry Science (Revista Brasileira de CiênciaAvícola), 2018

Wang J. J., Jing Y. Y., Zhang C. F., Optimization of capacity and operation for CCHP system by genetic algorithm, Applied Energy, 2010

White B.J., Amrine D.E., Larson R.L., BIG DATA ANALYTICS AND PRECISION ANIMAL AGRICULTURE, SYMPOSIUM: Data to decisions, Beef Cattle Institute, Kansas State University, Manhattan, KS, Oxford University Press on behalf of American Society of Animal Science, doi: 10.1093/jas/skx065, 2018.

Wijayaningrum V. N., Mahmudy W. F., Natsir M. H., Optimization of Poultry Feed Composition Using Hybrid Adaptive Genetic Algorithm and Simulated Annealing, Journal of Telecommunication, Electronic and Computer Engineering, 2017

Wulantuya, Wang H., Wang C., Qinglin, Theoretical analysis and experimental study on the process of conveying agricultural fiber materials by screw conveyors, Engenharia Agrícola, Doi: http://dx.doi.org/10.1590/1809-4430-Eng.Agric.v40n5p589-594/2020, 2020

Zahedi, G.; Elkamel, A.; Lohi, A. Genetic algorithm optimization of supercritical fluid extraction of nimbin from neem seeds. Journal of Food Engineering 97, p. 127-134 , 2010.

Zeginis D., Kalampokis E., Tarabanis K., Statistical Challenges Towards a Semantic Model for Precision Agriculture and Precision Livestock Farming, http://ceur-ws.org/Vol-2549/article-09.pdf, https://www.cybele-project.eu/, 2019

Zhang, D.; Xie, X.; Liu, S., Zhang, S.An intelligently optimized SEDC for multimodal SSR mitigation.Eletric Power System Research, vol.79, 2009.

ANEXOS

Anexo 1 – Pesudo-código do algoritmo SAGAC

```
Algorithm  Hybrid SAGAC - Beginning
popsize ← desired population size
P ← {} - “vector of GA population”
Best_GA ← *none
elite_group_size ← popsize * 0.1
qt_atempt ← 1
prob_mutation ← 0.04
Algorithm Simulated Annealing (SA) - Beginning
for index = 1 to popsize times
    t ← temperature, initially a high number
    prod ← probability to accept new random solution
    S ← random initial solution
    AssessFitness(S)
    Best_SA ← S
    repeat
        R ← random soultion
        AssessFitness(R)
        Δ = Fitness(R) - Fitness(S)
        if Δ > 0 then
            S ← R
        else
            if e^(Δ/t) ≤ prob then
                S ← R
            end-if
        end-if
        if Fitness(R) better than Fitness(S) then
        S ← R
        Decrease t
        if Fitness(S) better than Fitness(Best_SA) then
            Best_SA ← S
    until t < 0
    P ∪ Best_SA
    if Fitness(Best_SA) better than Fitness(Best_GA) then
        Best_GA ← Best_SA
next index
Algorithm Simulated Annealing (SA) - End
Algorithm Genetic Algorithm (GA) - Beginning
repeat
```

```
    sort P in descending order of Fitness value
    exclude (P – elite_group_size)
    for i = 1 to elite_group_size step 2
        repeat
            Parent Pi ← SelectWithReplacement(P)
            Parent Pi+1 ← SelectWithReplacement(P)
            Children Ci, Ci+1 ← Crossover(Copy(Pi), Copy(Pi+1))
            generate random value between 0 and 1
            if random value ≤ prob_mutation then
                Mutate(Ci), Mutate(Ci+1)
            end-if
Function Aceleration Convergence (AC) - Beginning
            total_attempts ← 0
            if total_attempts < qt_atempt then
                if Children Ci or Children Ci+1 worse than elite Parent Pelite_group_size then
                    exclude Children that is worse than elite Parent Pelite_group_size
                    replace worse Parent P between Parent Pi and Parent Pi+1 by another Paren P
                end-if
                total_attempts = total_attempts + 1
            end-if
        until (Children Ci or Children Ci+1 better than ore qual to elite Parent Pelite_group_size) or
(total_attempts = qt_atempt)
Function Aceleration Convergence (AC) - End
    next índex
    generate (P – elite_group_size) randomly
    AssessFitness for each Pi
until have run out of time
return Best_GA
Algorithm Genetic Algorithm (GA) - End
Algorithm  Hybrid SAGAC – End
```

Anexo 2 – Registro de software do aplicativo desenvolvido no Artigo 1

Como mais um produto desta tese obteve-se junto ao INPI o registro do software relacionado ao artigo 1.

REPÚBLICA FEDERATIVA DO BRASIL
MINISTÉRIO DA ECONOMIA
INSTITUTO NACIONAL DA PROPRIEDADE INDUSTRIAL
DIRETORIA DE PATENTES, PROGRAMAS DE COMPUTADOR E TOPOGRAFIAS DE CIRCUITOS INTEGRADOS

Certificado de Registro de Programa de Computador

Processo Nº: **BR512020002610-9**

O Instituto Nacional da Propriedade Industrial expede o presente certificado de registro de programa de computador, válido por 50 anos a partir de 1º de janeiro subsequente à data de 11/08/2020, em conformidade com o §2º, art. 2º da Lei 9.609, de 19 de Fevereiro de 1998.

Título: OTIMIZADOR MULTIOBJETIVO

Data de publicação: 11/08/2020

Data de criação: 11/08/2020

Titular(es): MARCO ANTONIO CAMPOS BENVENGA

Autor(es): IRENILZA DE ALENCAR NÄÄS; NILSA DUARTE DA SILVA LIMA; THAYLA MOURANDI RIDOLFI DE CARVALHO

Linguagem: VISUAL BASIC

Campo de aplicação: AG-10; IF-10

Tipo de programa: AP-01

Algoritmo hash: SHA-512

Resumo digital hash:
0B4D845431888B9300AFA094AD4E0A6AEB1D5ED1BFF668F9BF854B05675F5BFFE05AB05453DB41EEA0B01F131DA525E6A00E336B3012111398DE09CDB3015E4E

Expedido em: 24/11/2020

Aprovado por:
Helmar Alvares
Chefe da DIPTO - Portaria/INPI/DIRPA Nº 09, de 01 de julho de 2019