

DEPARTAMENTO DE COMPUTAÇÃO
CURSO DE CIÊNCIA DA COMPUTAÇÃO

Rodrigo Maus

**ALGORITMO DE OTIMIZAÇÃO POR COLÔNIA DE ABELHAS
NA CLASSIFICAÇÃO DE IMAGENS**

Santa Cruz do Sul
2017

**ALGORITMO DE OTIMIZAÇÃO POR COLÔNIA DE ABELHAS
NA CLASSIFICAÇÃO DE IMAGENS**

Trabalho de Conclusão apresentado ao Curso de
Ciência da Computação da Universidade de Santa
Cruz do Sul, para obtenção parcial do título de
Bacharel em Ciência da Computação.

Orientadora: Prof.^a Dra. Rejane Frozza.

Santa Cruz do Sul
2017

RESUMO

Um dos grandes desafios da computação moderna é saber trabalhar com a grande quantidade de dados a serem analisados. Neste cenário, está inserida a descoberta de conhecimento que a cada dia vem ganhando mais importância nas mais diversas áreas onde a computação está inserida. O conhecimento é um diferencial para os processos de tomada de decisão em qualquer área de negócios e também para o desenvolvimento científico, tecnológico e humano. Desenvolver mecanismos, técnicas, algoritmos que objetivem otimizar e facilitar este processo de descoberta sobre dados traz contribuições para a Computação. Neste trabalho, o objetivo é desenvolver um algoritmo baseado na técnica de Otimização por Colônia de Abelhas para classificar imagens. A metodologia abordou levantamento bibliográfico sobre os assuntos envolvidos na pesquisa, busca por trabalhos relacionados para compreensão das técnicas de enxame estudadas (Otimização por Enxame de Partículas, Otimização por Colônia de Formigas e Otimização Colônia de Abelhas), decisão pela técnica desenvolvida, modelagem e desenvolvimento da técnica para classificação de imagens. Para a validação foram utilizadas três bases de dados contendo faces de pessoas, frutas e folhas de tabaco curadas. Para os três casos de bases diferentes foram atingidos resultados satisfatórios com alguns ajustes nas configurações do algoritmo da técnica implementada.

Palavras-chave: Descoberta de Conhecimento, Inteligência de Enxames, Tomada de Decisão, Algoritmo de Otimização Colônia de Abelhas, Classificação de Imagens.

ABSTRACT

One of the great challenges of modern computing is knowing how to work with the large amount of data to be analyzed. In this scenario, is inserted the discovery of knowledge that every day is gaining more importance in the most diverse areas where the computer is inserted. Knowledge is a differential for decision-making processes in any area of business and also for scientific, technological and human development. Developing mechanisms, techniques, algorithms that aim to optimize and facilitate this process of discovery on data brings contributions to Computing. In this theme, the objective is to develop an algorithm based on the technique of Optimization by Bee Colony to classify images. The methodology involved a bibliographic survey about the subjects involved in the research, search for related works to understand the swarm techniques studied (Optimization by Particle Swarm, Optimization by Colony of Ants and Optimization of Colony of Bees), decision by the technique developed, modeling and development Of the technique for classifying images. For the validation, three databases were used containing people's faces, fruits and cured tobacco leaves. For the three cases of different bases satisfactory results were obtained with some adjustments in the algorithm configurations of the implemented technique.

Keywords: Knowledge Discovery, Swarm Intelligence, Decision Making, Bee Colony Optimization Algorithm, Image Classification.

LISTA DE FIGURAS

FIGURA 1 – Algoritmo Colônia de Abelhas Artificial	18
FIGURA 2 – Estrutura Geral do Sistema Proposto	23
FIGURA 3 – Bibliometria Realizada na Base Web of Science	32
FIGURA 4 – Bibliometria Realizada na Base Scopus	33
FIGURA 5 – Procedimentos Metodológicos	34
FIGURA 6 – Fluxo do sistema desenvolvido.....	36
FIGURA 7 – Fluxo do algoritmo desenvolvido	37
FIGURA 8 – Fluxo da Dança das Abelhas.....	37
FIGURA 9 – Tela de Configuração do Sistema.....	39
FIGURA 10 – Entrada das Imagens a Serem Classificadas	40
FIGURA 11 – Tela de Conversão para Preto e Branco.....	41
FIGURA 12 – Tela Geração de Histograma	42
FIGURA 13 – Tela de Resultados do Sistema	43
FIGURA 14 – Logs do Sistema.....	43
FIGURA 15 – Tela de Configuração.....	45
FIGURA 16 – Tela da Entrada de Dados das Frutas.....	46
FIGURA 17 – Tela do Resultado da Classificação sem Aplicação de Filtros	47
FIGURA 18 – Tela da Aplicação do Filtro Preto e Branco	48
FIGURA 19 – Classificação após a Aplicação do Filtro Preto e Branco	49
FIGURA 20 – Resultado da Classificação após o aumento do número de indivíduos e ciclos	50
FIGURA 21 – Gráfico Representando os Ajustes das Configurações do Algoritmo Realizadas entre o Primeiro e o Segundo Ensaio	51
FIGURA 22 – Gráfico Representando o Resultado Obtido no Primeiro e Segundo Ensaio	51
FIGURA 23 – Entrada de Imagens Folhas de Tabaco Claras e Escuras.....	52
FIGURA 24 – Classificação das Imagens de folhas de tabaco	53
FIGURA 25 – Imagem das Folhas de Tabaco em Preto e Branco	54
FIGURA 26 – Resultado da Classificação das Folhas de Tabaco em Preto e Branco .	55
FIGURA 27 – Alteração das Configurações do Algoritmo	56

FIGURA 28 – Resultado após a Alteração das Configurações	57
FIGURA 29 – Gráfico Demonstrando a Diferença das Configurações entre o primeiro e o Segundo Ensaio	58
FIGURA 30 – Gráfico Comparativo do Primeiro e Segundo Ensaio.....	58
FIGURA 31 – Faces Humanas Utilizadas na Classificação.....	59
FIGURA 32 – Conversão das Imagens para Preto e Branco.....	60
FIGURA 33 – Histograma das Imagens em Preto e Branco	61
FIGURA 34 – Resultado da Classificação	62
FIGURA 35 – Alteração dos Parâmetros de Configuração.....	63
FIGURA 36 – Resultado da Classificação com os novos Parâmetros de Configuração.....	64
FIGURA 37 – Gráfico Comparativo das Configurações Utilizadas no Primeiro e Segundo Ensaio	65
FIGURA 38 – Gráfico Comparativo das Configurações Utilizadas no Primeiro e Segundo Ensaio	65

LISTA DE TABELAS

Tabela 1 – Quadro Comparativo dos Trabalhos Relacionados Estudados.....	30
Tabela 2 – Quadro Comparativo dos Algoritmos de Agrupamento Estudados	35
Tabela 3 – Quadro comparativo da classificação das bases	66

SUMÁRIO

RESUMO.....	3
LISTA DE FIGURAS.....	5
LISTA DE TABELAS.....	7
1. INTRODUÇÃO.....	10
2. ALGORITMOS DE OTIMIZAÇÃO UTILIZANDO INTELIGÊNCIA DE ENXAMES.....	14
2.1. TÉCNICA DE OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS (PSO).....	14
2.2. ALGORITMO DE OTIMIZAÇÃO COLÔNIA DE FORMIGAS (ACO).....	15
2.2.1 A COLÔNIA DE FORMIGAS.....	15
2.2.2 O ALGORITMO DE OTIMIZAÇÃO COLÔNIA DE FORMIGAS (ACO).....	15
2.3. TÉCNICA DE OTIMIZAÇÃO POR COLÔNIA DE ABELHAS (ABC).....	16
2.3.1. A COLÔNIA DE ABELHAS.....	17
2.3.2. O ALGORITMO DE OTIMIZAÇÃO COLÔNIA DE ABELHAS.....	18
2.4. AGRUPAMENTO/ CLASSIFICAÇÃO DE DADOS.....	20
3. TRABALHOS RELACIONADOS.....	22
3.1. UMA ABORDAGEM HÍBRIDA DE EVOLUÇÃO DIFERENCIAL E COLÔNIA ARTIFICIAL DE ABELHAS PARA SELEÇÃO DE CARACTERÍSTICAS (ZORARPACI; ÖZEL, 2016).....	22
3.2. CLASSIFICAÇÃO ATRAVÉS DE ENXAME DE PARTÍCULAS E ÁRVORE DE DECISÃO PARA CONJUNTO DE DADOS SOBRE DENGUE (RENUCA; RAO; SETTY, 2016).....	26
3.3. ALGORITMO DE OTIMIZAÇÃO COLÔNIA DE FORMIGAS EM MINERAÇÃO DE DADOS EM SISTEMA DE PRONTUÁRIO MÉDICO (BURSA; LHOTSKA,2016).....	27
3.4. CONSIDERAÇÕES.....	30
4. METODOLOGIA.....	32
5. SISTEMA DE OTIMIZAÇÃO POR COLÔNIA DE ABELHAS NA CLASSIFICAÇÃO DE IMAGENS.....	35
5.1. O SISTEMA DE CLASSIFICAÇÃO.....	38
5.2. RESULTADOS DA CLASSIFICAÇÃO.....	44
5.2.1. RESULTADOS DA CLASSIFICAÇÃO UTILIZANDO FRUTAS.....	44

5.2.2. RESULTADOS DA CLASSIFICAÇÃO UTILIZANDO FOLHAS DE TABACO	51
5.2.3. RESULTADOS DA CLASSIFICAÇÃO UTILIZANDO FACES DE PESSOAS NOS MAIS VARIADOS AMBIENTES E ILUMINAÇÃO	59
5.2.4. CONSIDERAÇÕES SOBRE A CLASSIFICAÇÃO DE IMAGENS	66
6. CONCLUSÃO	67

1. INTRODUÇÃO

O ser humano não está preparado para receber e interpretar uma grande quantidade de informações, tornando-se assim indispensável o uso de ferramentas e técnicas de descoberta de conhecimento, onde uma das etapas é a mineração de dados. Como informação e conhecimento são essenciais em qualquer organização, a mineração de dados possibilita descobrir novos e úteis conhecimentos para o processo de tomada de decisão (FAYYAD; PIATETSKY-SHAPIRO; SMYTH, 1996).

Os resultados obtidos com a utilização da descoberta de conhecimento podem ser utilizados no gerenciamento de informações, processamento de pedidos de informação, tomada de decisão, controles de processos, identificação de perfis, entre outras aplicações (DIAS, 2002).

Neste contexto de descoberta de conhecimento, a partir de padrões e tendências, e estudos da etologia (animais e insetos), é possível observar que os insetos sociais, já explorados pela Computação, propõem soluções para alguns problemas complexos, que visam encontrar uma solução ótima utilizando apenas informações locais e imprecisas (MALLON; PRATT; FRANKS, 2001). Entre estes problemas, cita-se descoberta de perfil de usuário, alocação de recursos e otimização de atividades.

Esta área de pesquisa denomina-se inteligência de enxames, sendo as técnicas mais conhecidas as de colônia de formigas, enxame de partículas e colônia de abelhas.

As principais propriedades de um algoritmo de inteligência de exames são (MILLONAS, 1994):

- Proximidade: Os agentes devem ser capazes de interagir.
- Qualidade: Os agentes devem ser capazes de avaliar seus comportamentos.
- Diversidade: Permite ao sistema reagir a situações inesperadas.
- Estabilidade: Nem todas as variações ambientais devem afetar o comportamento de um agente.
- Adaptabilidade: Capacidade de adequação a variações ambientais.

O algoritmo de otimização colônia de formigas (ACO – *Ant Colony Optimization Algorithm*) é um algoritmo que se baseia na forma como as formigas são capazes de encontrar

um caminho entre a colônia e a fonte de alimento. Para isso, a formiga desenvolve um caminho baseado na experiência e conhecimento de outras formigas que já o percorreram. A técnica é baseada em um método adaptativo, natural, paralelo e cooperativo, pois cada agente se comunica indiretamente com os demais através de rastros deixados no ambiente (GAMBARDELLA; DORIGO, 2000).

Também foram desenvolvidos algoritmos baseados em comportamento de colmeia de abelhas (*Artificial Bee Colony*), onde os autores realizaram testes em instâncias de problemas de agrupamento de massas e dados e obtiveram resultados melhores em relação a outros autores que utilizaram algoritmo genético, busca tabu e *simulated annealing* (ZHANG; OUYANG, 2010).

O algoritmo de otimização por colônia de abelhas simula a atividade de forrageamento (busca e exploração de recursos alimentares) de uma colônia de abelhas. Para tanto, de forma artificial estão presentes as fontes de alimento e os três tipos de abelhas envolvidas (abelhas observadoras, campeiras e exploradoras). As soluções candidatas representam as posições das fontes de alimento. As abelhas observadoras escolhem as soluções conhecidas pelas abelhas campeiras de acordo com a sua qualidade de resolver o problema. As abelhas campeiras e observadoras realizam ainda uma busca local em torno da fonte conhecida e sendo encontrada uma solução melhor, a fonte memorizada será substituída. As fontes conhecidas por abelhas campeiras que não melhoram durante o processo de busca são substituídas por outras geradas aleatoriamente, simulando, assim, a atividade de abelhas exploratórias (DUARTE, 2015).

Já a otimização por enxame de partículas (*Particle Swarm Optimisation* - PSO) é um algoritmo baseado no comportamento de grupos, por exemplo, uma revoada de pássaros ou um cardume de peixes. São consideradas as soluções individuais de cada membro de uma população, armazenando sempre a sua melhor posição visitada e a melhor posição visitada por sua vizinhança, logo combinando métodos de busca local e global (EBERHART; SHI; KENNEDY, 2001).

Em relação à classificação de dados, esta é uma atividade preditiva que consiste na análise de dados em busca da definição de padrões que descrevem tendências futuras para esses dados (PELEGRIN *et al.* 2005).

Em uma abordagem geral, consiste em fornecer dados de treinamento, cujas classes são conhecidas. Os dados de treinamento são então usados para gerar o modelo de classificação, que é posteriormente aplicado aos dados de teste. O objetivo é criar um modelo capaz de categorizar corretamente tanto os dados utilizados em seu treinamento, como dados nunca vistos antes, ou seja, um modelo com boa capacidade de generalização (PANG-NING, 2006).

Para possibilitar o processo de classificação de dados, a *clusterização* ou agrupamento visa classificar a informação em *clusters* ou classes. Cada um desses *clusters* é formado por elementos que possuem características similares em seus atributos. Essa classificação é feita de modo a maximizar as diferenças encontradas entre as classes e minimizar as diferenças entre exemplos pertencentes à mesma classe (FREITAS; CARVALHO, 2001).

Por realizar-se a classificação baseado nos valores dos atributos dos próprios exemplos, ou seja, “descobrir” classes para os exemplos e agrupar sem que seja informada referência externa, a *clusterização* é considerada uma forma de aprendizado não supervisionado (FREITAS; CARVALHO, 2001).

A *clusterização* prepara os dados para a aplicação de um algoritmo que realize a classificação, uma vez que divide estes dados em classes para uma análise posterior que pode ser feito por um outro algoritmo ou por uma pessoa na figura do usuário (CARVALHO, 2005).

Como justificativa científica para o desenvolvimento deste tema a classificação de dados envolvendo imagens possui diversos desafios a serem explorados e otimizados. Logo, este trabalho poderá trazer contribuições para a área já que será pesquisada e desenvolvida uma técnica de agrupamento e classificação de dados, utilizando o algoritmo de otimização colônia de abelhas.

Como justificativa empresarial para o desenvolvimento deste tema, a área de agrupamento e classificação de imagens, pode auxiliar nas rotinas diárias de uma empresa auxiliando nas mais diversas áreas, por exemplo no setor de tabaco onde deve-se fazer uma classificação das folhas de acordo com a sua coloração.

Pode-se assim, definir o problema de pesquisa: Como avaliar o comportamento da técnica de otimização por Colônia de Abelhas na classificação de imagens?

O principal objetivo é desenvolver um algoritmo baseado na técnica de Otimização por Colônia de Abelhas para classificar imagens.

Sendo assim, pretende-se atingir os seguintes objetivos específicos:

- Estudar como os enxames se comportam na natureza e como isto pode ser aproveitado para a computação.
- Pesquisar técnicas e modelos de algoritmo para a implementação da solução baseada em enxames.
- Analisar quais das técnicas e modelos de algoritmos de enxame podem ser utilizados na classificação de dados.
- Desenvolver e validar o algoritmo de enxame escolhido em um estudo de caso (aplicação).

O texto está organizado nos seguintes capítulos: O capítulo 2 apresenta a fundamentação teórica dos temas relacionados a este trabalho; o capítulo 3 apresenta trabalhos já desenvolvidos na área; o capítulo 4 apresenta a metodologia utilizada para a construção deste trabalho; o capítulo 5 apresenta o sistema desenvolvido e o capítulo 6 a conclusão deste trabalho.

2. ALGORITMOS DE OTIMIZAÇÃO UTILIZANDO INTELIGÊNCIA DE ENXAMES

Este capítulo aborda o tema referente aos algoritmos de otimização baseados em inteligência de enxames. Entre os diversos algoritmos de inteligências de enxames pode-se destacar o Algoritmo de Otimização por Enxame de Partículas (*Particle Swarm Optimization* - PSO), Algoritmo de Otimização por Colônia de Formigas (*Ant Colony Optimization* - ACO) e Algoritmo de Otimização Colônia de Abelhas (*Artificial Bee Colony* - ABC).

2.1. TÉCNICA DE OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS (PSO)

É baseado no comportamento de grupos, por exemplo, uma revoada de pássaros ou um cardume de peixes. São consideradas as soluções individuais de cada membro de uma população, armazenando sempre a sua melhor posição visitada e a melhor posição visitada na sua vizinhança, logo combinando métodos de busca local e global (faz a comparação da qualidade da partícula levando em conta todas as partículas do problema não somente com partículas da sua vizinhança como na busca local) (EBERHART; SHI, 2001).

O Algoritmo de Otimização por Enxame de Partículas se baseia no comportamento dos grupos de animais para sua implementação é necessário determinar o valor otimizado da função heurística referência (ZUN; LAI; WUN, 2011) (DEMIDOVA, SOKOLOVA, 2015).

Há tempos a otimização por enxame de partículas atingiu uma maior atenção na resolução de problemas de seleção de recursos. Foi sugerido uma metodologia de seleção de filtro, dependendo de um conjunto de dados binários e a teoria dos conjuntos. O resultado mostra que otimização por enxame de partículas tem melhor resultado comparado a algoritmo genético em caso de desempenho quando se trata de classificação (HUANG; DUN, 2008).

O algoritmo de otimização enxame de partículas se mostra promissor devido a esta técnica (MOHEMMED; ZHANG; JOHNSTON, 2009):

- Ter memória para armazenar a melhor localização da partícula distinta e também do enxame completo. A população preliminar é preservada durante o processo então o algoritmo de otimização enxame de partículas tem grande capacidade de descoberta.
- Conter apenas um operador evolutivo simples o que torna o procedimento proficiente tanto na velocidade de estimação e restrição de memória. Faz também com que

sejam tomadas medidas numerosas, como uma função de *fitness* equilibrada e controle de escala auto adaptativa.

- Ter conceito simples, pode ser implementado em poucas linhas de código, tem memória de interações anteriores, por outro lado se uma partícula não é selecionada a informação que contida nela é perdida, portanto isto pode aumentar a capacidade de pesquisa para encontrar uma solução ótima.

2.2. ALGORITMO DE OTIMIZAÇÃO COLÔNIA DE FORMIGAS (ACO)

A fonte inspiradora do Algoritmo de Otimização por Colônia de Formigas é o real comportamento das formigas dentro da sua colônia. A ideia é usar várias formigas computacionais construtivas. Com base nos resultados de experiências anteriores de cada formiga e da colônia, as formigas são guiadas a construir uma solução para o problema.

Este algoritmo baseia-se na forma como as formigas são capazes de encontrar um caminho entre a colônia e a fonte de alimento. Para isso, a formiga desenvolve um caminho baseado na experiência e conhecimento de outras formigas que já o percorreram. A técnica é baseada em um método adaptativo, natural, paralelo e cooperativo, pois cada agente se comunica indiretamente com os demais através de rastros deixados no ambiente (GAMBARDELLA; DORIGO, 2000).

2.2.1 A COLÔNIA DE FORMIGAS

Ao observar uma colônia de formigas pode-se perceber que as formigas se comunicam de forma indireta através do ambiente por rastros químicos chamados feromônios. Os caminhos com maior nível de feromônio são os caminhos percorridos por um número maior de formigas, enquanto os caminhos com menor nível de feromônio são escolhidos por um número menor de formigas. Este nível de feromônio é diminuído por evaporação. Esta forma de comunicação é conhecida por estigmergia, e fornece a colônia de formigas o caminho mais curto para a fonte de alimento.

2.2.2 O ALGORITMO DE OTIMIZAÇÃO COLÔNIA DE FORMIGAS (ACO)

O Algoritmo de Otimização Colônia de Formigas emprega formigas artificiais para encontrar boas soluções para os problemas de otimização. Estes algoritmos implementam agentes que imitam o comportamento das formigas biológicas em busca da fonte de alimento.

A seleção do caminho é um procedimento no qual são considerados como base dois parâmetros: O feromônio e os valores heurísticos. O valor do feromônio informa uma indicação do número de formigas que escolheram a trilha recentemente, pois o feromônio sofre evaporação, enquanto o valor da função heurística é um problema dependente da medida de qualidade. Quando uma formiga chega a um ponto de decisão, ela tende a escolher a trilha com maior feromônio e maior valor heurístico. Chegando ao seu destino, a solução correspondente ao caminho seguido da formiga é avaliado e o valor do feromônio do caminho é aumentado em conformidade com o resultado. Além disso, a evaporação faz com que o nível de feromônio de todas as trilhas passe a diminuir gradualmente. Assim, as trilhas que não são reforçadas gradualmente perdem feromônio e tendem a sumir.

Os cinco principais passos do Algoritmo de Otimização por Colônia de Formigas são (DORIGO; MANIEZZO; COLORNI, 1991):

- Um ambiente que represente o domínio do problema de tal forma que se possa construir uma solução incremental para o problema.
- A função de avaliação heurística deve fornecer uma medida de qualidade para os diferentes componentes da solução.
- A regra de atualização do feromônio, que leva em conta a evaporação e o reforço das trilhas.
- Uma regra de transição probabilística com base no valor da função heurística e a trilha de feromônios deixada pelas formigas.
- Uma especificação clara de quando o algoritmo converge para a solução.

2.3. TÉCNICA DE OTIMIZAÇÃO POR COLÔNIA DE ABELHAS (ABC)

O Algoritmo de Otimização Colônia de Abelhas (KARABOGA, 2005), é um algoritmo de otimização que imita o comportamento de busca por alimento inteligente de uma colônia de Abelhas. Este algoritmo tem forte robustez e alta flexibilidade (BOLAJI et al, 2013).

2.3.1. A COLÔNIA DE ABELHAS

Uma colônia de abelhas procura alimento por vários quilômetros de distância do seu ninho. A estratégia de busca de alimento visa visitar uma grande área em torno de seu ninho verificando a existência de alimentos e sua quantidade.

Foi desenvolvido então, um modelo de comportamento pela busca de alimento realizado pela colônia de abelhas baseado em equações de reação de difusão. Este método, propõe a aplicação de inteligência coletiva de enxame de abelhas e consiste em três componentes essenciais: Fontes de alimentos, abelhas empregadas e abelhas desempregadas. Define também dois modos principais de comportamento da colônia de abelhas: recrutamento a uma fonte de alimento e abandono de uma fonte de alimento (TERESHKO, 2000) (TERESHKO; LEE, 2002) (TERESHKO; LOENGAROV, 2005).

A seguir são representados os principais componentes do seu modelo (TERESHKO, 2000) (TERESHKO; LEE, 2002) (TERESHKO; LOENGAROV, 2005):

- Abelhas empregadas: Uma abelha empregada é uma abelha que está explorando uma fonte específica de alimento. Ela carrega informações sobre esta fonte e compartilha com outras abelhas. As informações compartilhadas incluem distância, direção e rentabilidade da fonte de alimento.
- Abelhas desempregadas: Uma abelha que está à procura por uma fonte de alimento para explorar é chamada de abelha desempregada. Ela pode ser um olheiro que procura no meio de forma aleatória ou um expectador que tenta encontrar uma fonte de alimento com base nas informações fornecidas pelas abelhas empregadas.

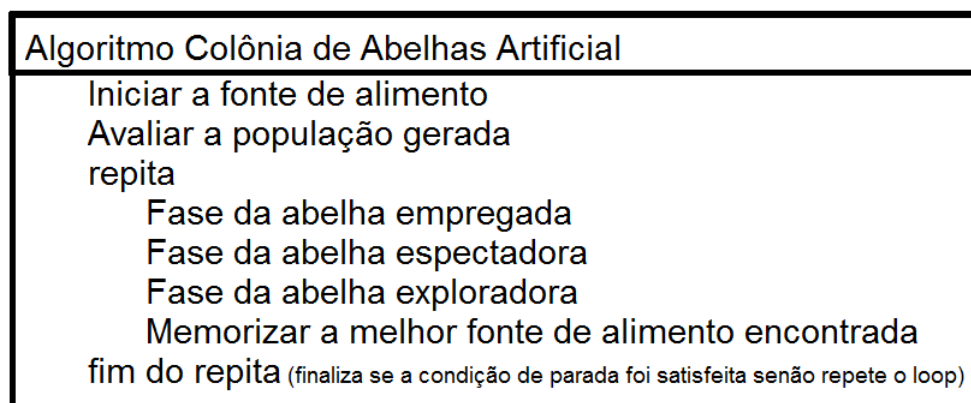
A troca de informações entre as abelhas é a ocorrência mais importante na formação do conhecimento. A parte mais importante da colmeia na troca de informações é a área da dança (área que fica geralmente na entrada da colmeia destinada às abelhas que estão chegando ou saindo da colmeia). Nesta área as abelhas empregadas informam as abelhas desempregadas sobre a qualidade da fonte de alimento, as abelhas desempregadas podem participar de várias danças e escolher empregar-se na fonte mais rentável.

2.3.2. O ALGORITMO DE OTIMIZAÇÃO COLÔNIA DE ABELHAS

No algoritmo de colônia de abelhas artificial a posição de uma fonte de alimento representa uma possível solução para o problema a ser otimizado e a quantidade de néctar de uma fonte de alimento é a qualidade da solução representada por esta fonte de alimento. Metade das abelhas de uma colônia de abelhas artificial é de abelhas empregadas e a outra metade é de abelhas espectadoras, apenas uma abelha empregada é ocupada por fonte de alimento. Quando uma fonte de alimento é esgotada a abelhas que estava trabalhando nesta fonte é alocada para uma nova fonte de alimento gerada pelo algoritmo (KARABOGA, 2005) (KARABOGA; BASTURK, 2007).

O algoritmo ABC é um algoritmo iterativo e começa através da geração de soluções iniciais (fontes de alimentos) distribuídas aleatoriamente, avaliando as condições de cada fonte de alimento as abelhas empregadas são designadas para as fontes de alimentos. Após a inicialização, o algoritmo tenta melhorar as soluções através de repetidas iterações (loops). Uma representação simples do algoritmo é mostrada na figura 1.

Figura 1. Algoritmo Colônia de Abelhas



Fonte: (ALSHAMIRI; SINGH; SURAMPUDI, 2017) traduzido pelo autor

A fase da abelha empregada visita a fonte de alimento determinada e avalia a quantidade de néctar (qualidade) encontrada em cada fonte é avaliada. Se a qualidade da nova fonte é melhor do que anterior a abelha empregada substitui a fonte de alimento antiga pela nova. O método de determinar uma nova fonte de alimento varia para cada problema analisado.

Na fase de abelha espectadora as abelhas empregadas procuram uma nova fonte de alimento recém-determinada ou não, elas compartilham as informações de suas fontes de

alimento com as abelhas expectadoras. A abelha expectadora avalia a aptidão de todas as novas fontes de alimento e escolhe uma fonte de alimento a ser explorada de acordo com a sua qualidade. Selecionando uma fonte de alimento a abelhas expectadora vai explorar esta fonte. No caso da abelha empregada se a nova fonte for melhor do que a antiga ela vai substituir a antiga pela nova.

A terceira e última fase do algoritmo se trata da fase da abelha exploradora, se a qualidade da fonte de alimento não pode ainda ser melhorada ao longo das inúmeras tentativas então a abelha que está nesta fonte de alimento se transforma em abelha observadora. Para esta nova abelha é gerada uma nova fonte de alimento, esta fonte de alimento pode ser gerada de forma aleatória ou com bases nos resultados que a colmeia coletou nos ciclos do algoritmo.

Estas três fases são repetidas até ser atingida a condição de término do algoritmo. Os principais passos do algoritmo são:

1. Gerar aleatoriamente as fontes de alimento iniciais.
2. Avaliar a população (fonte de alimento).
3. Produzir novas fontes de alimento e avaliar sua qualidade.
4. Executar uma comparação entre as novas e velhas fontes de alimento e selecionar as melhores.
5. Calcular as probabilidades das fontes de alimento e atribuir abelhas expectadoras a elas.
6. Produzir novas fontes de alimento para as abelhas expectadoras e avaliar a sua qualidade.
7. Comparar as novas e as velhas fontes de alimento e selecionar as melhores.
8. Substitua a fonte de alimento abandonada com o novo descoberto por abelhas exploradoras.
9. Memorize a melhor fonte de alimento alcançada até agora.
10. Se a condição de encerramento não for atingida, vá para a etapa 3, senão encerra a execução.

Esta técnica é utilizada para resolver problemas complexos como o popular caixeiro viajante e utilizado para realizar a classificação de dados, que será tratada no próximo tópico.

2.4. AGRUPAMENTO/ CLASSIFICAÇÃO DE DADOS

O processo de agrupamento busca detectar a existência de diferentes grupos dentro de um determinado conjunto de dados, baseando-se em medidas de similaridades e probabilísticas, determinando quais grupos, caso existam. Dados com atributos parecidos são agrupados no mesmo cluster, podendo ainda um dado estar classificado em mais de um cluster (SFERRA e CORREA, 2003) (REZENDE, 2003).

Uma técnica utilizada é a *k-means* que tem o objetivo de agrupar n elementos de uma base de dados em k agrupamentos, sendo que n corresponde ao número de itens a ser tomado como amostra e k representa o número de agrupamentos desejados, de forma que cada grupo conterà elementos com alguma proximidade (MACQUEEN, 1967).

O algoritmo *k-means* retira do banco de dados k casos para servir de semente para o processo. Esses casos podem ser retirados de forma aleatória ou por um padrão escolhido pelo usuário ou até mesmo os primeiros registros do banco de dados ou os últimos registros (CAZELLA et al., 2010).

Após, para cada registro do banco de dados, encontra-se a semente com características mais próximas para que este registro faça parte do grupo desta semente. Uma vez que todos os registros tenham sido associados a grupos determina-se novos centros sendo o ponto médio de todos os elementos que compõem cada cluster.

A vantagem desta técnica está na eficiência de tratar grandes conjuntos de dados, já a desvantagem vem da necessidade de informar o número k de agrupamentos no início do processamento, limitando assim a quantidade de grupos formados.

Outra técnica utilizada são as Rede Neurais Artificiais, utilizando o algoritmo de Kohonen, conhecido também como SOM (Self-Organizing Map). Para iniciar o processo de clusterização, inicializa-se aleatoriamente os pesos das sinapses (conexões) entre os neurônios com valores entre 0 e 1, define-se o número de iterações que acontecerão e define-se o raio de vizinhança de cada neurônio. Ao final deste processo, têm-se padrões organizados de forma que dados semelhantes estejam no mesmo cluster.

Além do K-means e da Rede Neural de Kohonen, há outras implementações de Redes Neurais que também podem ser aplicadas na tarefa de classificação de dados: Perceptron, Rede Hopfiels, Rede BAM, Redes ART, Rede IAC, Rede LVQ, Rede Couterpropagation, Rede RBF, Rede Pnn, Rede Time Delay, Neocognitron e Rede BSB (RABELO, 2007).

O algoritmo J48 é baseado nos métodos de construção de árvores de decisão. O algoritmo J48 constrói um modelo de árvore de decisão a partir de um conjunto de dados de treinamento. O modelo resultante é utilizado para classificar dados em outro conjunto (ALMEIDA, 2008).

A árvore gerada inclui o conjunto de treinamento e é construída em largura. Para a construção desta árvore existem duas operações principais: avaliação dos pontos de separação de cada nó interno da árvore e a criação dos subgrupos a partir da identificação do melhor grupo de separação (GOLDSCHMIDT & PASSOS, 2005).

O grande desafio dos algoritmos de classificação é criar uma árvore para tomada de decisão satisfatória. Para isso, a disposição dos atributos na árvore é de fundamental importância. A ordem dos mesmos segue dos mais representativos para os menos representativos (SOUZA, 2007).

3. TRABALHOS RELACIONADOS

Neste capítulo são apresentados alguns trabalhos relacionados. O estudo destes trabalhos serviu de fonte de inspiração e contribuiu para a realização do presente trabalho. Ressaltando que os mesmos estão ilustrando como os algoritmos de inteligência de enxames podem ser utilizados.

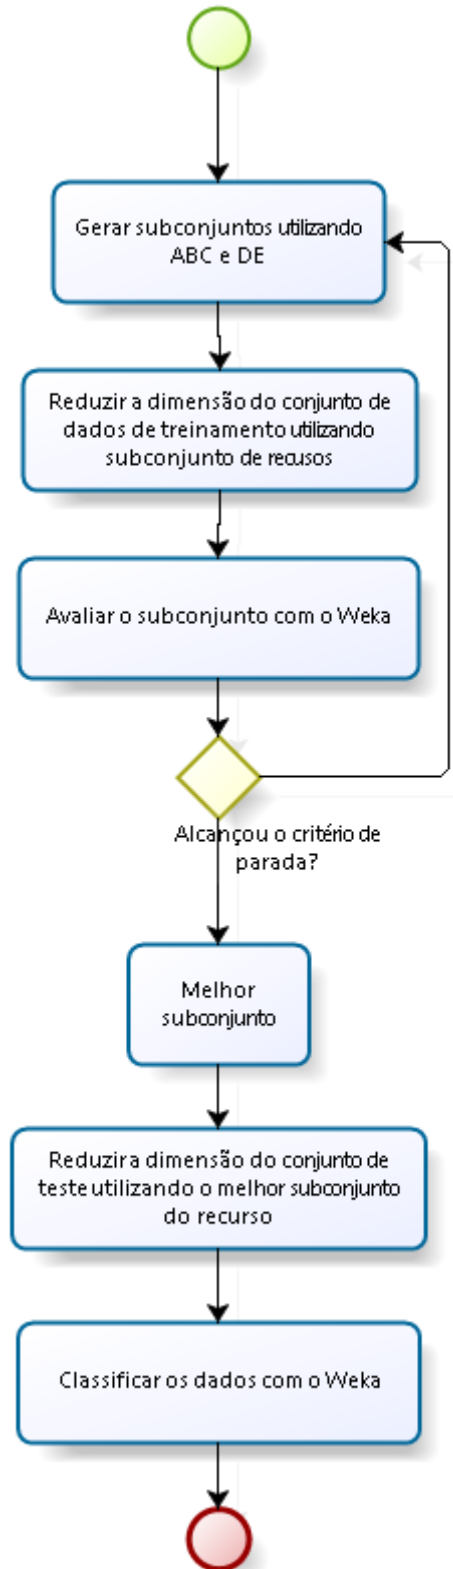
3.1. UMA ABORDAGEM HÍBRIDA DE EVOLUÇÃO DIFERENCIAL E COLÔNIA ARTIFICIAL DE ABELHAS PARA SELEÇÃO DE CARACTERÍSTICAS (ZORARPACI; ÖZEL, 2016)

Este trabalho combina os métodos de evolução diferencial e colônia de abelhas para seleção de características de tarefas de classificação.

Em um primeiro momento são gerados os subconjuntos de testes, após isto são gerados os subconjuntos de dados de treinamento, onde estes subconjuntos são avaliados pela ferramenta Weka, se alcançou o critério de parada é escolhido o melhor subconjunto senão retorna à fase de geração de subconjuntos.

Após alcançar o melhor subconjunto de treinamento os conjuntos de testes são reduzidos e após isto os dados classificados pela ferramenta Weka.

Figura 2. Estrutura Geral do Sistema Proposto



Fonte: (ZORARPACI; ÖZEL, 2017) traduzido pelo autor

A eficiência deste algoritmo está relacionada com o ajuste dos parâmetros de entrada (SÁ; ANDRADE; SOARES, 2008). A taxa de *crossover* é importante para equilibrar a busca. Um alto valor deste parâmetro define se a busca vai ser local ou global e diminuir o tempo de convergência para o melhor resultado. Outro parâmetro é o fator de escala de mutação que é um valor entre 0 e 2. Um baixo valor de mutação proporciona uma menor exploração e valores elevados proporciona uma maior exploração e reduz o risco de ficar preso em um local (MOHAMED, 2016).

É proposta uma nova forma de abordagem para a seleção de características, combinando a propriedade de exploração da evolução diferencial com o processo de abelha espectadora modificada da colônia artificial de abelhas. Os principais passos do método são descritos a seguir:

Passo 1: Determinar a população inicial de subconjuntos de soluções: nesta etapa, os conjuntos são apresentados em vetores binários.

Considerando a estrutura representada que tem 9 características os recursos selecionados são 1,4,5,6 e 7 isto significa que a tarefa de classificação será efetuada utilizando essas 5 características selecionadas.

Passo 2: Avaliação de aptidão: Nesta etapa se faz uma avaliação das soluções do subconjunto. Para o cálculo do fitness de uma solução os valores 0 do subconjunto são removidos.

Passo 3: Calcular valores de probabilidade de fitness: para cada subconjunto da solução na população.

Passo 4: Neste passo os dois casos a seguir são considerados para a escolha de subconjunto:

I. Se o valor de aptidão do indivíduo fonte é maior que um número aleatório produzido entre 0 e 1, o processo é realizado pela mutação evolução diferencial. Assim, três indivíduos aleatórios são escolhidos a partir da população para este indivíduo fonte. Depois de selecionar os indivíduos devem ser diferentes um do outro e o indivíduo fonte. Depois de selecionar os indivíduos deve-se encontrar entre os indivíduos, formando um novo vetor denominado vetor de diferença. Para construir o

vetor mutante ou operador de lógica binária é aplicado o operador lógico *ou* aos componentes do terceiro vetor escolhido aleatoriamente usando o vetor de diferença.

II. Caso contrário, para simular o processo de produção solução do algoritmo colônia de abelhas, para um indivíduo de origem, dois indivíduos aleatórios são escolhidos a partir da população. Em seguida um valor aleatório entre 0 e 1 são aplicados com o operador lógico “ou” para formar o terceiro vetor.

Passo 5: O valor de fitness do vetor de teste é calculado utilizando o Weka J48. Depois de calcular o valor de aptidão para o vetor que está sendo analisado, este valor é comparado com o valor de aptidão do vetor de origem. Se o vetor que está sendo analisado tem maior aptidão que o vetor origem o vetor comparado substitui o vetor origem para gerar a próxima geração, caso contrário o vetor origem permanece para gerar a próxima geração.

Passo 6: Calcular probabilidade do valor fitness: Após as etapas 4 e 5 serem aplicadas a todos os indivíduos da população, o valor de probabilidade de fitness é calculado usando a equação 2 para cada indivíduo, ou seja, para cada subconjunto.

Passo 7: Mutação do processo da abelha: Nesta etapa o valor da probabilidade fitness de um indivíduo é subtraído a partir de um, que é o valor máximo da probabilidade, e se este valor for maior do que um valor aleatório que é gerado ente 0 e 1, o operador lógico “NOT” é aplicado sobre o elemento.

O passo 7 é repetido n vezes, onde N é igual a metade do número total de indivíduos na população.

Os passos 3,4,5,6 e 7 são repetidos até que um critério de encerramento predeterminado é satisfeito. A melhor solução da população é a solução ideal.

A limitação do método híbrido proposto é a mesma comparada com métodos de heurísticas baseadas em colônia de formigas, colônia de abelhas e algoritmo genético, mas esta proposta tem um equilíbrio entre exploração e aproveitamento em termos de velocidade de convergência, uma vez que combina a forma lenta do algoritmo colônia de abelhas com a convergência rápida da evolução diferencial no processo de exploração. Uma desvantagem é que o algoritmo de evolução diferencial tem um maior tempo de execução que o algoritmo colônia de abelhas.

3.2. CLASSIFICAÇÃO ATRAVÉS DE ENXAME DE PARTÍCULAS E ÁRVORE DE DECISÃO PARA CONJUNTO DE DADOS SOBRE DENGUE (RENUCA; RAO; SETTY, 2016)

Na abordagem deste estudo de Algoritmo de Otimização por Enxame de Partículas é utilizado na seleção de forma aleatória para explorar uma forma eficiente um vasto espaço de busca, que é frequente necessário em caso de seleção de atributos e escolha de atributos para maximizar a probabilidade de classificação desejado.

A metodologia proposta é implementada em duas fases que são:

1ª Fase: Seleção de recursos usando Algoritmo de Otimização por Enxame de Partículas e Algoritmo de árvore de decisão;

2ª Fase: Classificação dos atributos selecionados através de Árvore de Decisão.

O método de seleção de recurso proposto neste estudo visa diminuir a dimensionalidade dos dados, escolhendo apenas as características que são essenciais para uma classificação precisa.

A otimização por enxame de partículas é mais objetiva e utilizada em várias situações tais como a otimização de função, o treinamento de rede neural, o controle de sistema *fuzzy* entre outros (KENNEDY; EBERHART, 1995).

Na metodologia proposta, o conjunto de dados de treinamento são a população inicial do algoritmo de otimização enxame de partículas. O critério de parada para o algoritmo se dá quando o algoritmo atingir o número máximo de gerações ou se não houver nenhuma alteração para melhor adequação da população transcorrido n gerações.

Para definir a função *fitness* e a taxa de erro foi utilizado o algoritmo de árvore de decisão tradicional.

A análise experimental para o estudo foi realizada com um total de 2.175 doentes cada um possuindo 17 atributos juntamente com a classe de destino. A qualidade deste método é superior quando comparado com o método tradicional e a taxa de erro é inferior à abordagem proposto em relação a abordagem tradicional.

Os resultados finais apresentam uma melhor precisão na classificação comparados às metodologias existentes e também mostrou uma diminuição considerável na taxa de erro no método proposto em comparação com o sistema de classificação existente.

Abaixo a descrição do algoritmo utilizado nesta proposta:

1. É considerado um conjunto de M dados com N atributos.
2. Estes atributos de cada amostra são divididos em conjuntos uniformemente distribuído.
3. Desta população inicial selecionamos o conjunto de dados inicial.
4. Definir o valor de aptidão.

5. Se a condição de término é atingida vai para a etapa 9 senão executa o passo 6.
6. Se a aptidão calculada da partícula é melhor do que a anterior, então temos que atualizar o valor da posição.
7. Determine a melhor partícula e o melhor atributo levando em consideração as melhores posições anteriores e atuais.
8. Atualizar o valor de aptidão da solução obtida.
9. Mover as partículas para as suas novas posições utilizando a função:
10. Posicionar os atributos mais aptos de cada amostra obtido através da função *fitness*.
11. Selecione um número de atributos otimizados para dar entrada ao algoritmo de classificação árvore de decisão.
12. Com base nos atributos o algoritmo de classificação árvore de decisão classifica as amostras em classes.

3.3. ALGORITMO DE OTIMIZAÇÃO COLÔNIA DE FORMIGAS EM MINERAÇÃO DE DADOS EM SISTEMA DE PRONTUÁRIO MÉDICO (BURSA; LHOTSKA,2016)

A asfixia durante o trabalho de parto pode resultar em graves complicações para o bebê. Se os médicos forem capazes de detectar precocemente sintomas da asfixia a cesariana pode ser indicada, a fim de acelerar todo o processo e reduzir o tempo que o recém-nascido fica sem oxigênio.

O processo normal de detecção é muito complicado e requer uma grande prática e é geralmente baseado no sinal de cardiografia (CTG) que está sendo monitorado durante o parto. Muitos estudos apontam que apenas o CTG não é suficiente para tomar a decisão correta, tendo que levar em considerações outras informações como o índice de Apgar, índices bioquímicos (valor de pH), histórico neonatal, fatores de riscos entre outros.

Em primeiro lugar os autores recuperaram os dados da base e os organizaram, o problema encontrado nesta fase foi o fato de os dados estarem armazenados em forma de texto livre sem estrutura. Após isto foi feita a correta classificação dos registros de pacientes e informações.

No método de otimização por colônia de formigas foi proposto que as árvores de decisão (solução) fossem induzidas a partir dos dados de entrada. A matriz serve como uma

memória do algoritmo (chamamos de matriz de feromônio) – de forma semelhante ao comportamento das formigas em seu ambiente.

Na fase inicial do algoritmo, a matriz é inicializada com valores aleatórios e a primeira população da árvore é induzida. Em seguida, na fase iterativa, a população é otimizada (valores de decisão em nós da árvore são otimizados, não a sua estrutura) e, em seguida, a contagem é aumentada e as piores soluções são removidas. De acordo com a relação de elite (um parâmetro do algoritmo), as melhores soluções voltam para a matriz de feromônio. A evaporação de feromônio ocorre por medida de adaptação para manter a população diversificada, fazendo assim com que a matriz de feromônio não fique saturada (convergência prematura).

Para implementar esta abordagem automatizada os autores precisaram adquirir conhecimento sobre o fato estudado, portanto fizeram consultas com especialistas para organizar a estrutura para projetar e desenvolver expressões.

Todo o conjunto de dados textuais a serem processados consistia em aproximadamente 50.000 a 120.000 registros com 20 atributos cada. Onde estes foram distribuídas em várias tabelas. O número de registros não é igual de uma paciente para outro e depende de diversos parâmetros e histórico de gravidez. Cada item do atributo continha cerca de 800 a 1500 caracteres de texto (diagnósticos, anamnese, medicamentos, notas entre outros).

Quando os autores avaliaram o comportamento humano dois principais padrões de comportamento foram descobertos: palavras semelhantes são agrupadas juntas e a estrutura espacial seguindo o fluxo natural de uma frase. Com isso temos métodos introduzidos para posicionar os dados espacialmente em um plano.

Foi desenvolvido uma metodologia para a mineração de dados em grandes textos e uma ferramenta para a extração e visualização das partes mais importantes de atributos com grandes textos que não possuem nenhuma estrutura.

O uso de modelos de probabilidade induzidos nos métodos aumenta a velocidade de analisar textos com atributos pouco estruturado ou sem nenhuma estrutura, a consulta a especialistas humanos permitiu desenvolver uma gramática léxica de forma mais eficiente em

comparação com métodos clássicos (o aumento de velocidade cerca de 5-10 minutos para aproximadamente 20-30 segundos para cada atributo).

Na fase experimental de classificação foram avaliados os resultados por 10 vezes. Além disso, para cada experiência cerca de 20 medidas quantitativas. Os valores médios e os melhores foram avaliados estatisticamente pelo teste de Friedman com procedimentos post-hoc Holm e Hochberg($\alpha=0,05$).

Também foi realizado o teste estatístico de Nemenyi. Baseado na avaliação estatística utilizando a metodologia acima mencionada, os autores concluíram que os métodos ACO DTree realiza melhora de nível cerca de 0,05 quando comparado com 41 casos distintos de classificadores.

O quadro experimental foi implementado com o objetivo de reprodutibilidade, robustez e solidez estatística dos resultados. A vantagem do método de colônia de formigas está na robustez conseguindo replicar a auto-organização e o comportamento das formigas que foi incorporado em um algoritmo para a indução de árvores de decisão.

O algoritmo utiliza a randomização da árvore de eixo paralelo para melhorar a solução final. Também foi melhorada a solução utilizando o algoritmo ACO DTree adicionando várias otimizações e paralelismos, com mais de 12 mil experimentos executados na fase final de avaliação.

O trabalho utilizou dados CTG e dados textuais a partir do hospital Czech, por consequência todo o trabalho de extração foi realizado em língua tcheca. Esta língua tem regras não tão rigorosas para posicionamento de palavras quando comparado, por exemplo, ao português e ao inglês. Portanto os registros contêm ambiguidades, por exemplo, sem sempre é claro para que palavra a negação (a palavra “não”) está se referindo, uma vez que pode ser posicionada antes ou depois ao termo relacionado. Além disso os médicos utilizam várias abreviaturas que não são padrões.

Deve-se reforçar que a ajuda de especialistas e uma pequena correção ainda é inevitável. Os resultados dos trabalhos são adotados para a regra de descoberta e são projetados para ser usado no auxílio de especialistas.

3.4. CONSIDERAÇÕES

A seguir é apresentado o Quadro 1 para uma melhor representação dos trabalhos relacionados.

Quadro 1. Quadro comparativo dos trabalhos relacionados estudados.

Autores	Objetivo	Técnica Utilizada	Resultados
Zorarpaco, Özel (2016)	Propor uma nova forma de abordagem para a seleção de características, combinando a propriedade de exploração da evolução diferencial com o processo da abelha expectadora da colônia artificial de abelha.	ABC (Otimização Colônia de Abelhas)	Demonstrou equilíbrio entre exploração e aproveitamento em termos de velocidade de convergência. Uma certa desvantagem, pois o algoritmo de evolução diferencial tem um maior tempo de execução que o algoritmo colônia de abelhas.
Renuca, Setty(2016)	Classificar características comuns entre pacientes que contraíram o vírus da dengue.	PSO (Otimização Enxame de Partículas)	Apresentou melhor precisão na classificação comparado a metodologias existentes e uma diminuição considerável na taxa de erro.
Bursa, Lhotska (2016)	Auxiliar na decisão do médico em descobrir quando há necessidade de se fazer cesariana em caso de asfixia durante o parto normal.	ACO (Otimização Colônia de Formigas)	Demonstrou resultados satisfatórios apesar de ter que contar com pequenas correções e opinião de um especialista.
Maus, Frozza (2017)	Classificar imagens conforme características comuns.	ABC (Otimização Colônia de Abelhas)	Eficiente nos casos estudados, porém dependente das configurações do algoritmo realizadas pelo usuário.

No quadro 1, pode-se observar que é possível aplicar algoritmo de inteligência de enxames nos mais variados problemas lineares, onde é muito difícil ou não é possível se encontrar uma solução ótima. Na maioria dos casos, estes algoritmos são combinados com outras técnicas de busca a fim de melhorar o tempo de busca ou melhorar o seu resultado final. Pode-se destacar o modelo implementado por Zorarpaco e Özel (2016) que utilizou um modelo híbrido envolvendo algoritmo de otimização por colmeia de abelhas e evolução diferencial, onde as técnicas escolhidas se complementaram para encontrar uma melhor solução em menos tempo.

Pode-se destacar no trabalho de Renuca e Setty (2016) utilizando algoritmo de otimização por enxame de partículas que obteve uma considerável diminuição na taxa de erro

dos resultados finais. O trabalho de Bursa e Lhotska (2016) demonstrou resultados satisfatórios, porém pela complexidade do problema a ser resolvido não é descartada a opinião de especialistas e pequenas correções nos resultados. Por último, este trabalho desenvolvido, demonstra resultados satisfatórios, porém é dependente das configurações do algoritmo realizadas pelo usuário.

4. METODOLOGIA

A pesquisa se caracteriza como exploratória, explicativa, estudo de caso e qualitativa, já que analisa os trabalhos de autores sobre o tema, descreve os algoritmos de otimização por enxame de abelhas, enxame de formigas e enxame de partículas, propõe realizar validação em uma aplicação estudo de caso com a descrição dos resultados obtidos.

Para aprofundar a busca de conhecimento sobre a inteligência de enxames fez-se o desenvolvimento de uma bibliometria realizada em agosto de 2016 no portal de periódicos da CAPES nas bases SCOPUS e *Web of Science*. Este estudo indicou que existe um grande número de publicações que relacionam os termos. Para a pesquisa utilizou-se os termos na língua inglesa.

A análise bibliométrica considerou apenas publicações recentes, ou seja, artigos publicados a partir de agosto de 2012 até agosto de 2016. Foram escolhidos termos específicos para cada área de conhecimento, como é mostrado nas figuras 3 e 4.

Figura 31 – Bibliometria realizada na base Web of Science

<u>BASE WEB OF SCIENCE</u> Quantidade de artigos publicados entre agosto de 2012 e agosto de 2016, de acordo com os assuntos relacionados ("Linha" AND "Coluna")	Enxame de Partículas	Colônia de Formigas	Colônia de Abelhas	Agrupamento de Dados
Enxame de Partículas	4671			
Colônia de Formigas		3392		
Colônia de Abelhas			586	
Agrupamento de Dados	212	82	29	4069

Fonte: (AUTORES, 2016)

Figura 4 - Bibliometria realizada na base Scopus

BASE SCOPUS Quantidade de artigos publicados entre agosto de 2012 e agosto de 2016, de acordo com os assuntos relacionados ("Linha" AND "Coluna")	Enxame de Partículas	Colônia de Formigas	Colônia de Abelhas	Agrupamento de Dados
Enxame de Partículas	6665			
Colônia de Formigas		2028		
Colônia de Abelhas			967	
Agrupamento de Dados	291	88	37	882

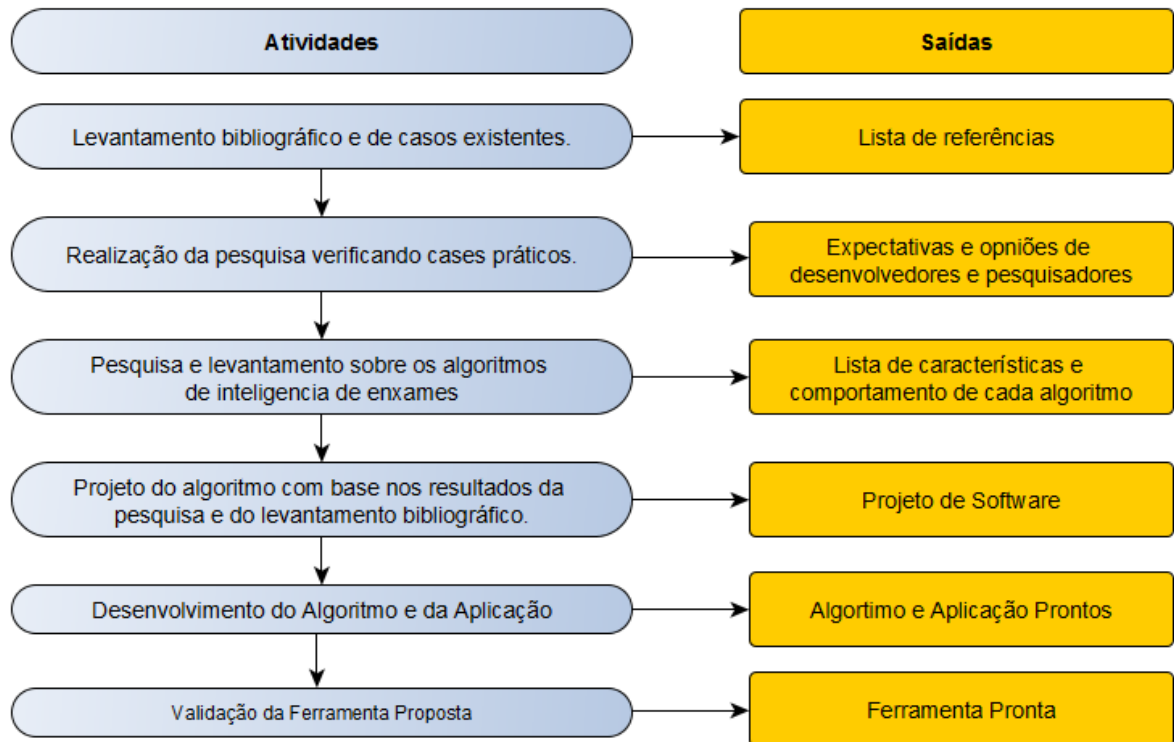
Fonte: (AUTORES, 2016)

A partir da bibliometria quantitativa, foram escolhidos três trabalhos relacionados, cada um com uma das técnicas citadas, a fim de realizar uma bibliometria qualitativa (capítulo 3) para entender o funcionamento de cada uma em um domínio específico.

A figura 5 apresenta as etapas necessárias durante a execução deste trabalho para sua conclusão.

Inicialmente, foi realizado um levantamento bibliográfico na busca por artigos na área de estudo e de trabalhos relacionados (casos práticos), a fim de encontrar opiniões e expectativas de desenvolvedores e pesquisadores. A partir destes dados, realizou-se uma pesquisa sobre técnicas de inteligência de enxames, escolha da técnica a ser desenvolvida, seguido do projeto de algoritmo da técnica, e finalizando com o desenvolvimento e a validação do algoritmo para classificação de imagens advindas de três bases (faces, frutas e folhas de tabaco). Para integrar estas etapas, foi desenvolvida uma ferramenta com uma interface para escolha de parâmetros.

Figura 5 – Procedimentos Metodológicos



Fonte: (AUTORES, 2017)

5. SISTEMA DE OTIMIZAÇÃO POR COLÔNIA DE ABELHAS NA CLASSIFICAÇÃO DE IMAGENS

Este capítulo apresenta as características do sistema desenvolvido.

Os algoritmos de otimização por inteligência de enxames apresentados possuem características próprias para buscar a melhor solução. O Quadro 2 demonstra algumas características destes algoritmos, que basearam-se nos autores dos trabalhos relacionados citados no capítulo 3.

Quadro 2. Quadro comparativo dos algoritmos de agrupamento apresentados.

Algoritmo de agrupamento	Modo de busca	Tempo de convergência	Complexidade de implementação
PSO (Otimização Enxame de Partículas)	O enxame de partículas faz busca cega em busca do melhor resultado. O critério de parada também pode ser definido por tempo de execução.	Maior tempo de convergência em relação com o ACO (Otimização Colônia de Formigas).	Complexidade Baixa
ACO (Otimização Colônia de Formigas)	Cada formiga inicia uma busca cega pelo resultado, onde cada formiga que retorna para a colônia deixa um rastro de feromônio, que é avaliado pelas outras formigas que retornam à colônia e os melhores caminhos (caminhos com maior índice de feromônio) são seguidos.	Menor tempo de convergência em comparação com o PSO (Otimização Enxame de Partículas)	Complexidade Mediana
ABC (Otimização Colônia de Abelhas)	Possui abelhas exploradoras e abelhas expectadoras, onde as abelhas exploradas saem em busca de fontes de alimentos e as abelhas expectadoras ficam na colmeia esperando o resultado das abelhas exploradas. Os	Tempo de convergência relativo ao número escolhido de abelhas expectadoras e exploradoras.	Complexidade Alta


	caminhos com melhor índice (este índice leva em conta a qualidade da fonte de alimento e o custo do caminho) são escolhidos pelas abelhas expectadoras para serem explorados.		
--	---	--	--

Fonte: (AUTORES, 2016)

Devido à grande dinamicidade do algoritmo ABC (Otimização por Colônia de Abelhas) em relação ao modo de busca e um tempo de convergência relativo à configuração escolhida para o algoritmo, este foi implementado para um sistema de classificação de imagens.

A figura 6 apresenta o fluxo de desenvolvimento do sistema. Inicialmente, dados são inseridos, é realizada a configuração das variáveis do algoritmo, realizada a *discretização* das imagens e, por último, são apresentados os resultados em tela.

Figura 6 – Fluxo do sistema desenvolvido



Fonte: (AUTORES, 2017)

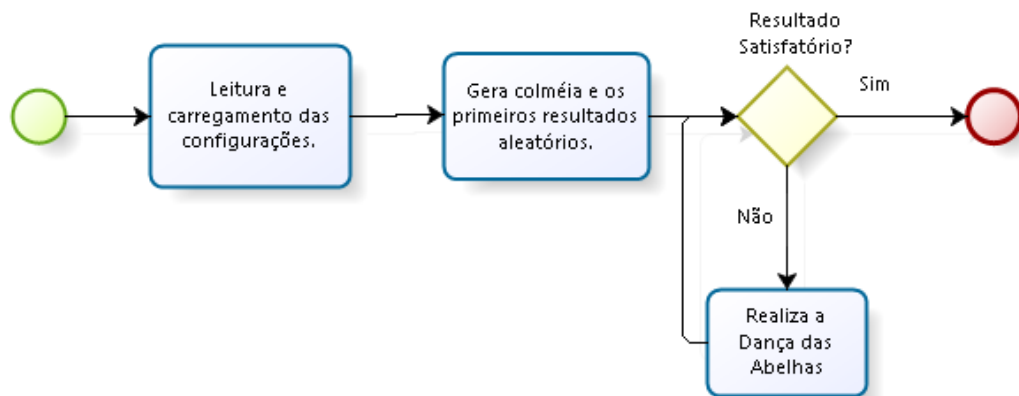
A base de dados contém três diferentes tipos de imagens, que são: Faces humanas, frutas e folhas de tabaco curadas.

Uma das bases de entrada utilizada é de faces humanas retiradas do site <http://www.vision.caltech.edu/html-files/archive.html>. Esta base de faces humanas contém quatrocentas e cinquenta imagens de rosto com dimensões de 896x592 *pixels*, formato Jpeg de 27 diferentes pessoas com diferentes iluminações, expressões e cenários de fundo. Também foram utilizadas imagens de frutas: banana, maçã, limão e laranja, que foram retiradas aleatoriamente da internet e de imagens de folhas de tabaco curado dos tipos L (folhas claras) e R (folhas escuras).

Na figura 7, é exemplificado o funcionamento do algoritmo Colônia de Abelhas desenvolvido. Inicialmente, é feita a leitura e o carregamento das informações, após é gerada

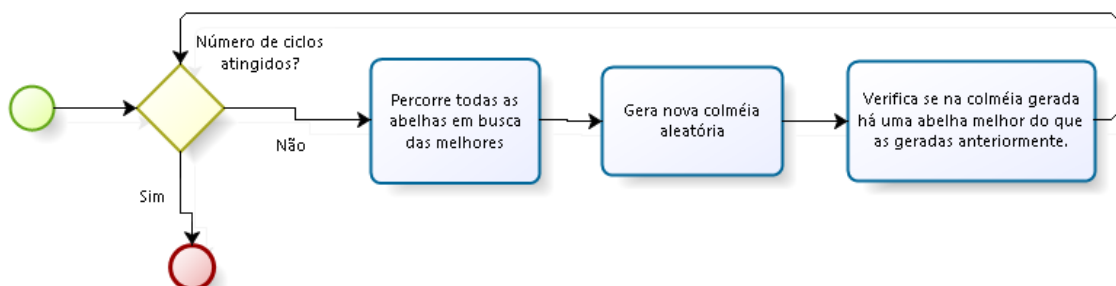
a primeira colônia aleatória, se esta colônia satisfaz os resultados esperados é encerrada a execução do algoritmo, porém, se o resultado não é satisfatório o mesmo realiza a dança das abelhas que é ilustrada na figura 8, que verifica se o número de ciclos foi atingido. Se sim, encerra o ciclo do algoritmo, se não percorre-se todas as abelhas em busca das melhores, gera-se uma nova colmeia aleatória, verifica se na nova colmeia gerada há abelhas com resultados melhores do que as separadas anteriormente e verifica-se novamente se o número de ciclos foi atingido.

Figura 7 – Fluxo do algoritmo desenvolvido



Fonte: (AUTORES, 2017)

Figura 8 – Fluxo da Dança das Abelhas



Fonte: (AUTORES, 2017)

5.1. O SISTEMA DE CLASSIFICAÇÃO

O sistema foi desenvolvido em linguagem C# utilizando o framework .NET 4. Foi utilizado um sistema de listas para guardar os resultados parciais de cada iteração da classificação. Uma lista representa as abelhas ativas, uma lista representa as abelhas inativas e outra lista representa as abelhas expectadoras. O número de elementos destas listas é informado na tela de configuração do algoritmo.

O usuário informa, na primeira aba da tela do sistema, as seguintes configurações, como é mostrado na figura 9:

- O algoritmo a ser utilizado para a classificação (Enxame de Partículas, Colônia de Formigas ou Enxame de Partículas, neste trabalho apenas o Colônia de Abelhas).
- Número total de indivíduos (abelhas).
- Número de visitas de cada indivíduo (visitas feitas às fontes de alimento – possível solução).
- Porcentagem de indivíduos ativos (abelhas que buscam novas soluções).
- Porcentagem de indivíduos inativos (abelhas que guardam as soluções geradas).
- Porcentagem de expectadores (abelhas que guardam as melhores soluções anteriores que não estão armazenadas nos indivíduos inativos).

Figura 9 – Tela de Configuração do Sistema

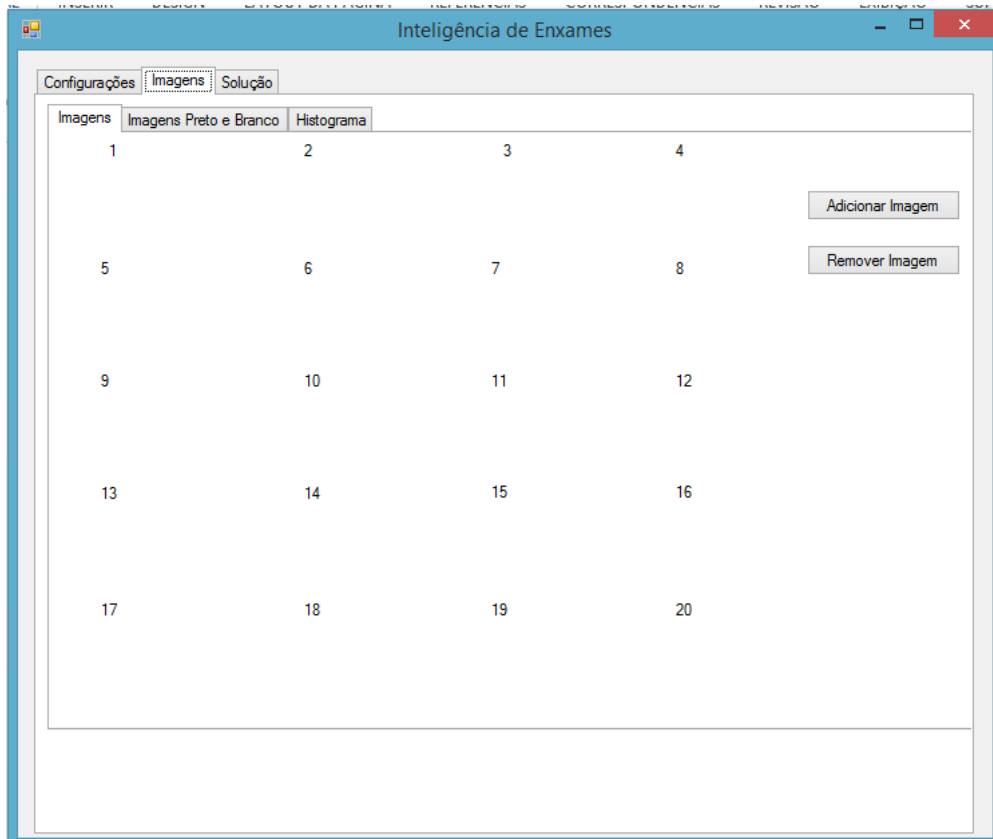
Parâmetro	Valor	Unidade
Algoritmo	Algoritmo Colônia de Abelhas (ABC)	
N° de individuos	500	
Ciclos	10570	
Visitas	95	
Ativas	75	%
Inativas	10	%
Expectadoras	15	%

Fonte: (AUTORES, 2017)

A segunda aba refere-se à entrada de imagens e é dividida em três abas: Na primeira o usuário faz a entrada normal de imagens (figura 10), na segunda transforma a imagem em preto e branco (figura 11) e na terceira gera o histograma da imagem (figura 12).

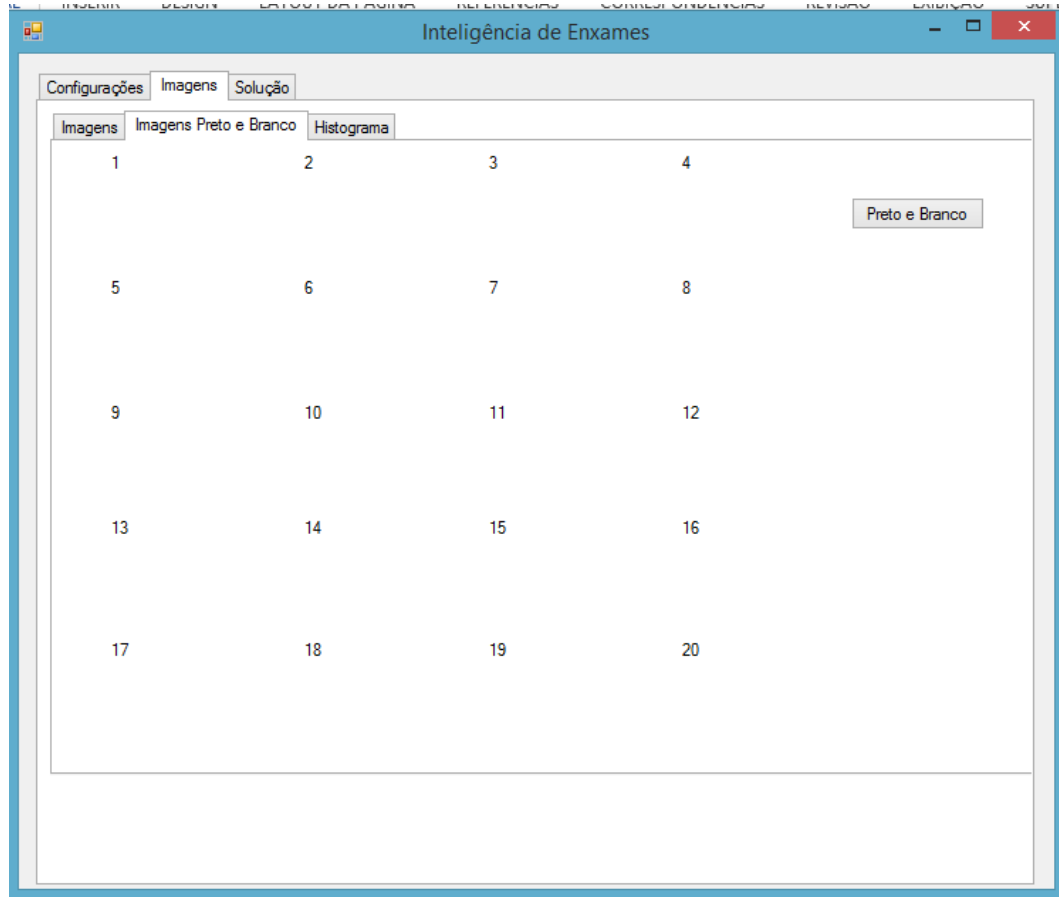
O histograma é uma das formas mais comuns de se representar a distribuição dos tons de cinza de uma imagem e, possivelmente, a mais útil em processamento digital de imagens. Fornece a informação sobre quantos pixels na imagem possuem cada valor do pixel que está sendo analisado.

Figura 10 – Entrada das Imagens a Serem Classificadas



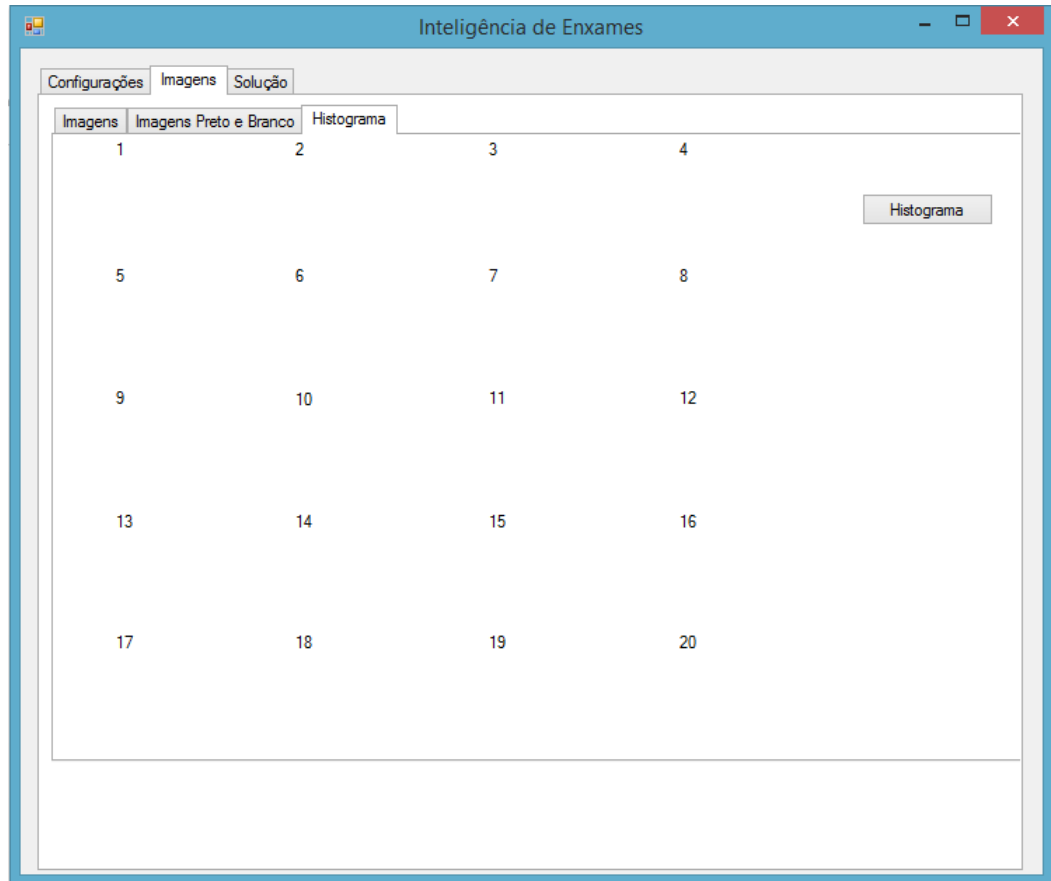
Fonte: (AUTORES, 2017)

Figura 11 – Tela de Conversão para Preto e Branco



Fonte: (AUTORES, 2017)

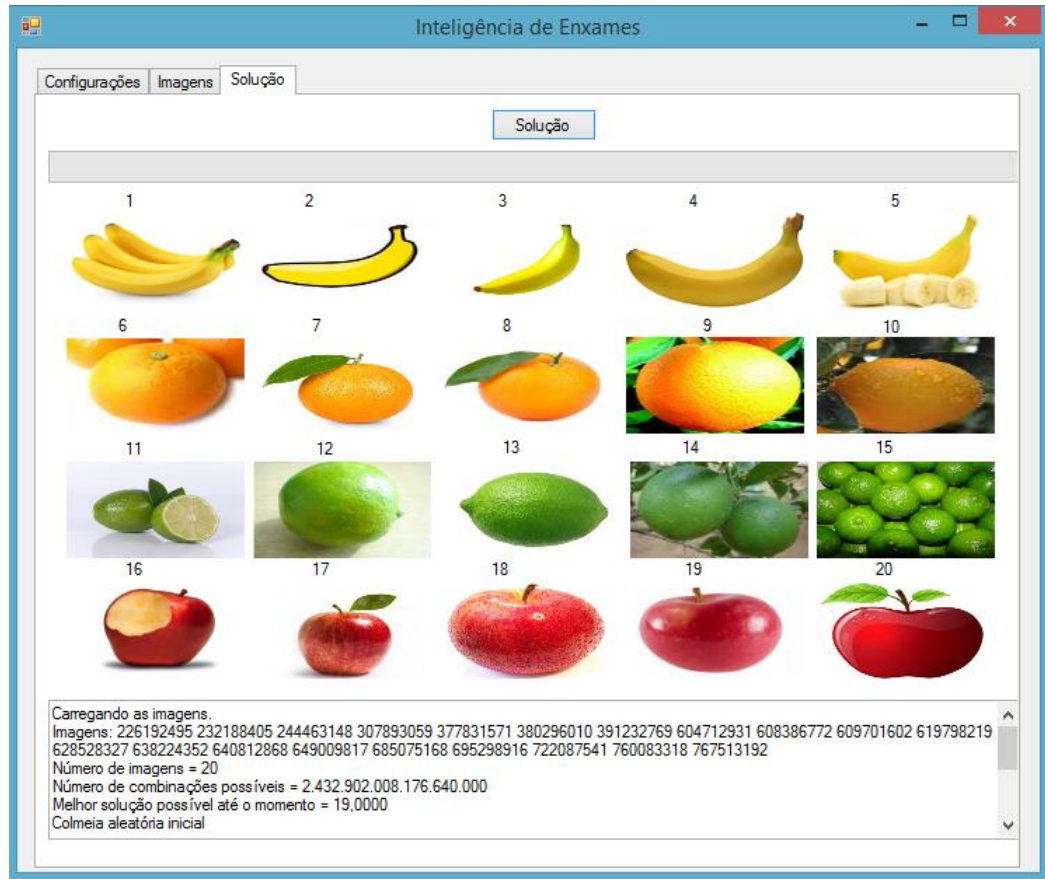
Figura 12 – Tela Geração de Histograma



Fonte: (AUTORES, 2017)

Na terceira aba é gerado o resultado. A tela mostra as imagens agrupadas, onde cada linha corresponde a um grupo; e há também uma área onde é feita a geração do log da aplicação, como mostrado na figura 13.

Figura 13 – Tela de Resultados do Sistema



Fonte: (AUTORES, 2017)

Na parte inferior da tela de resultados da classificação tem uma área onde são exibidos os logs do sistema, conforme é possível visualizar na figura 14.

Figura 14 – Logs do Sistema

```

Carregando as imagens.
Imagens: 1442304 3095040 4758720 6567424 8256256 9820416 11629312 13214976 14992832 16678592 17457088 18640832 19938304
21133248 22665984 24278528 25529216 26887104 28168768 29514816
Número de imagens = 20
Número de combinações possíveis = 2.432.902.008.176.640.000
Melhor solução possível até o momento = 19,0000
Colmeia aleatória inicial
17457088 21133248 25529216 26887104 14992832 13214976 29514816 18640832 19938304 9820416 1442304 6567424 4758720
3095040 11629312 8256256 16678592 22665984 24278528 28168768
Colmeia final
1442304 3095040 4758720 6567424 8256256 9820416 11629312 13214976 14992832 16678592 17457088 18640832 19938304 21133248
22665984 24278528 25529216 26887104 28168768 29514816
Melhor solução encontrada = 3,2569
Final do Bee Colony
  
```

Fonte: (AUTORES, 2017)

Na tela de logs é possível identificar o valor que cada imagem assume após passar pelo processo para deixá-la discreta, o número de imagens carregadas, o número de combinações possíveis, o número de testes a serem feitos, a colmeia inicial e final e a melhor solução encontrada. A melhor solução é o número de testes que são feitos para descobrir o grupo a que a imagem pertence.

5.2. RESULTADOS DA CLASSIFICAÇÃO

Nesta seção, são ilustrados os resultados com exemplos das diferentes classificações que foram feitas pelo sistema nas bases de dados mencionadas.

5.2.1. RESULTADOS DA CLASSIFICAÇÃO UTILIZANDO FRUTAS

Utilizando a base de dados de frutas aleatórias com a configuração de 500 abelhas, 10570 ciclos, 95 visitas sendo 75% das abelhas ativas, 10% inativas e 15% expectadoras, como ilustrado na figura 15.

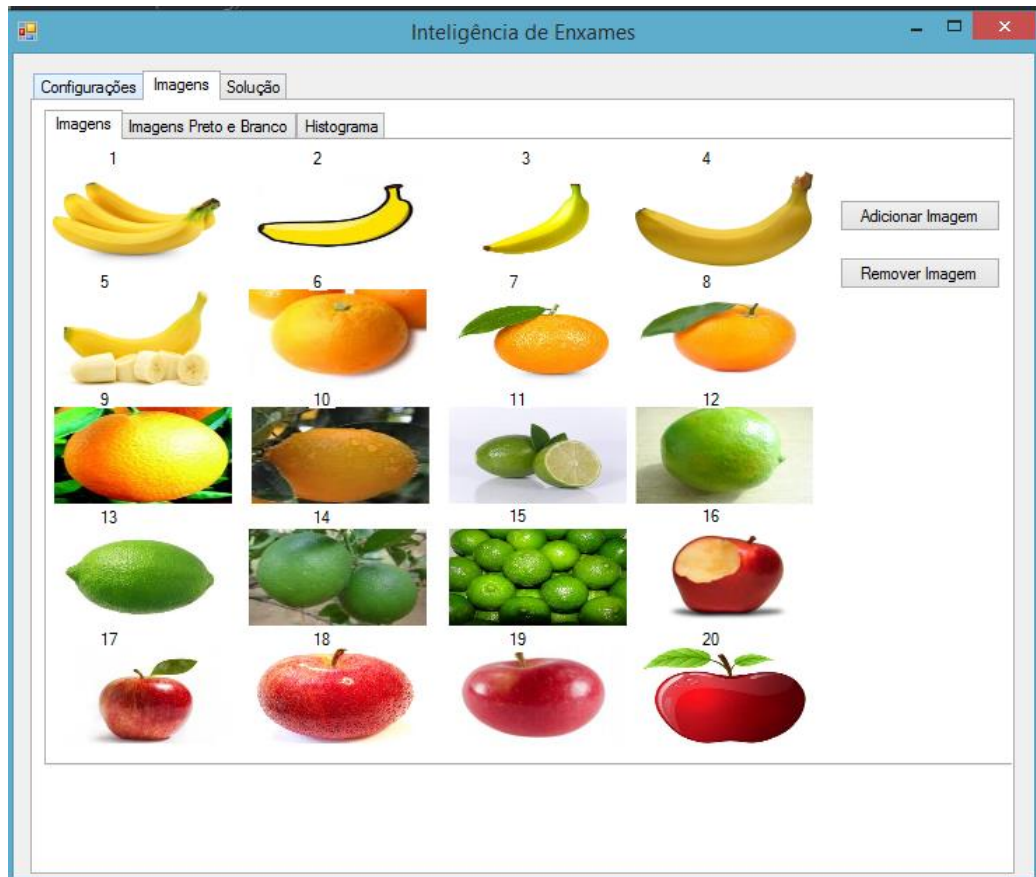
Figura 15 – Tela de Configuração

Parâmetro	Valor	Unidade
Algoritmo	Algoritmo Colônia de Abelhas (ABC)	
N° de indivíduos	500	
Ciclos	10570	
Visitas	95	
Ativas	75	%
Inativas	10	%
Expectadoras	15	%

Fonte: (AUTORES, 2017)

Utilizou-se imagens das seguintes, frutas banana, laranja, limão e maçã, conforme figura 16.

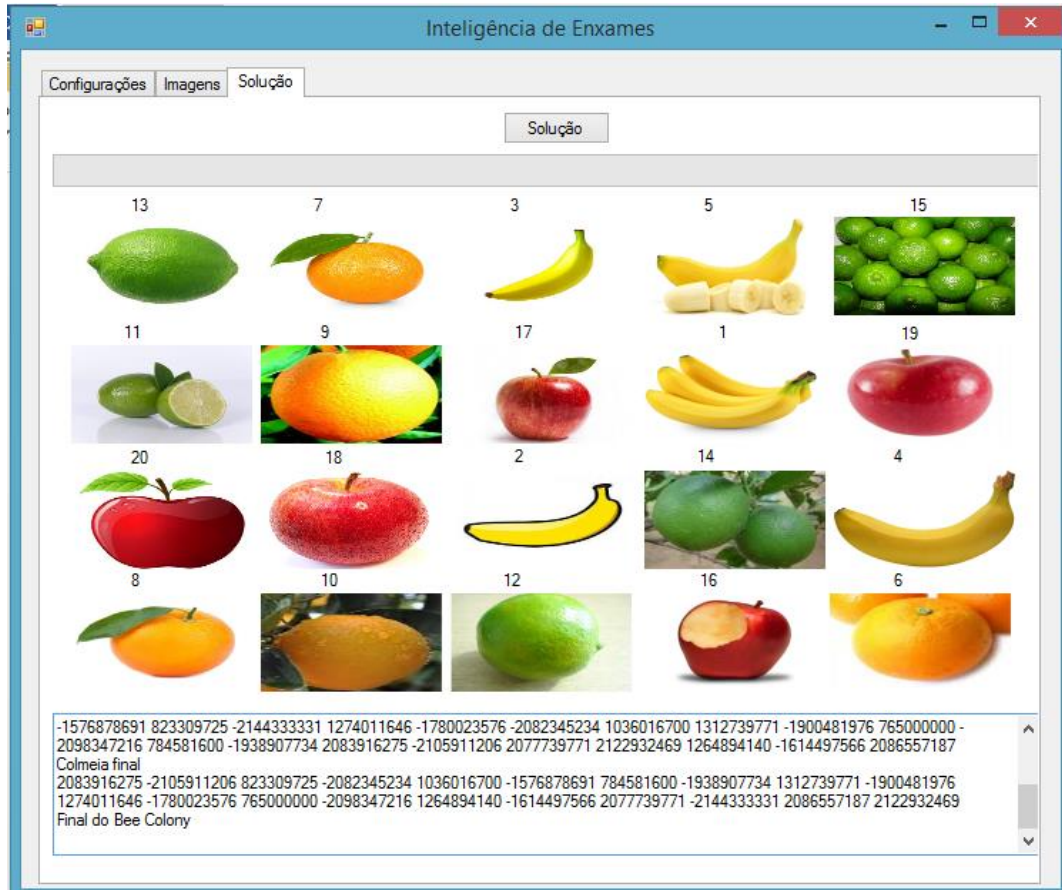
Figura 16 – Tela da Entrada de Dados das Frutas



Fonte: (AUTORES, 2017)

Foi realizada a classificação sem aplicar filtro à base de entrada, conforme figura 17.

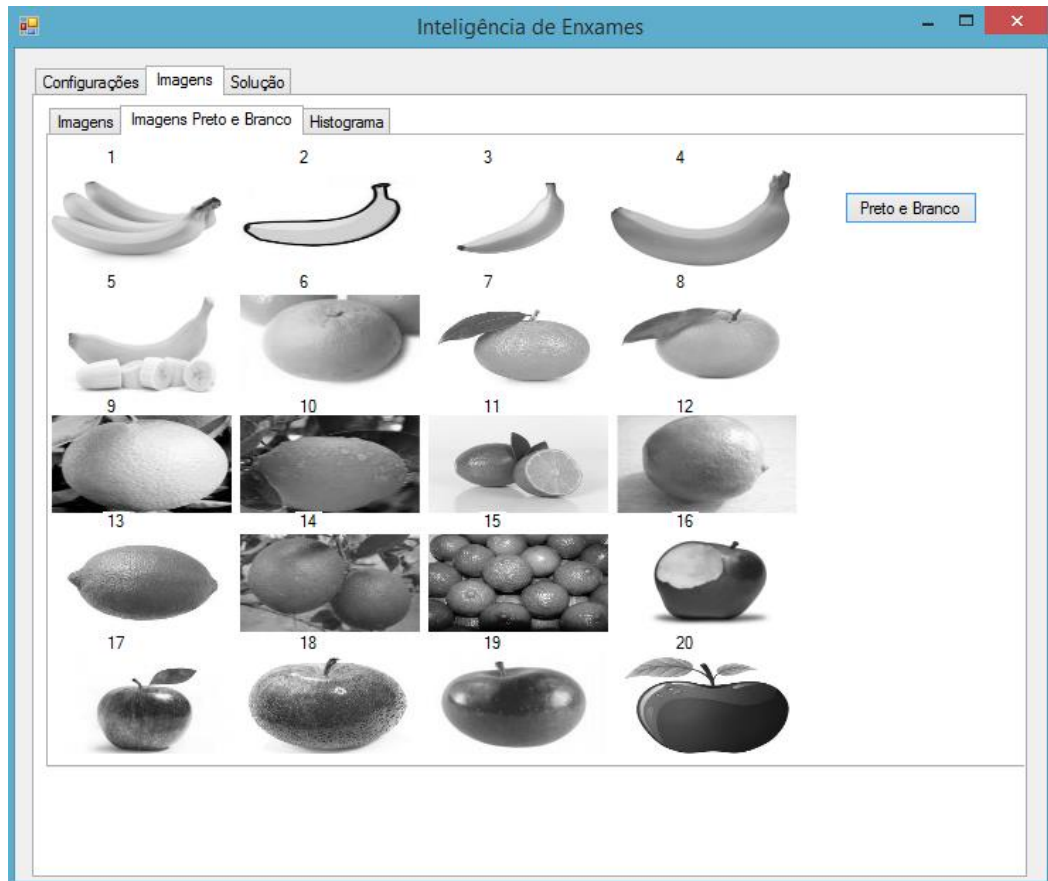
Figura 17 – Tela do Resultado da Classificação sem Aplicação de Filtros



Fonte: (AUTORES, 2017)

Aplicou-se o filtro para transformar a imagem em preto e branco, como ilustrado na figura 18.


Figura 18 – Tela da Aplicação do Filtro Preto e Branco



Fonte: (AUTORES, 2017)

Após a aplicação do filtro preto e branco, realizou-se a classificação novamente, conforme figura 19.

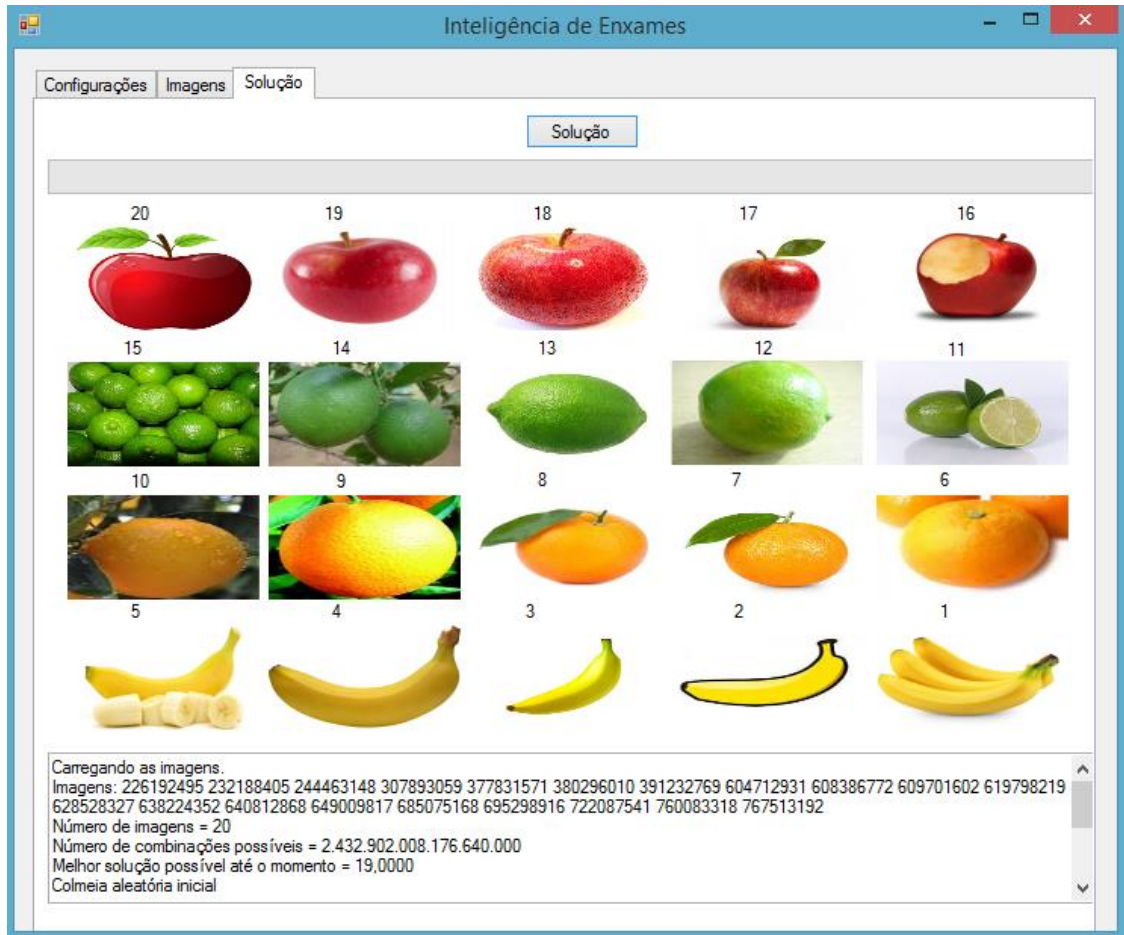
Figura 19 – Classificação após a Aplicação do Filtro Preto e Branco



Fonte: (AUTORES, 2017)

Aumentando o número de indivíduos de 500 para 900 e o número de ciclos de 10570 para 15000, a classificação foi refeita ao inverso, conforme figura 20.

Figura 20 – Resultado da Classificação após o aumento do número de indivíduos e ciclos.




Fonte: (AUTORES, 2017)

Para esta classificação não foi gerado o histograma das imagens.

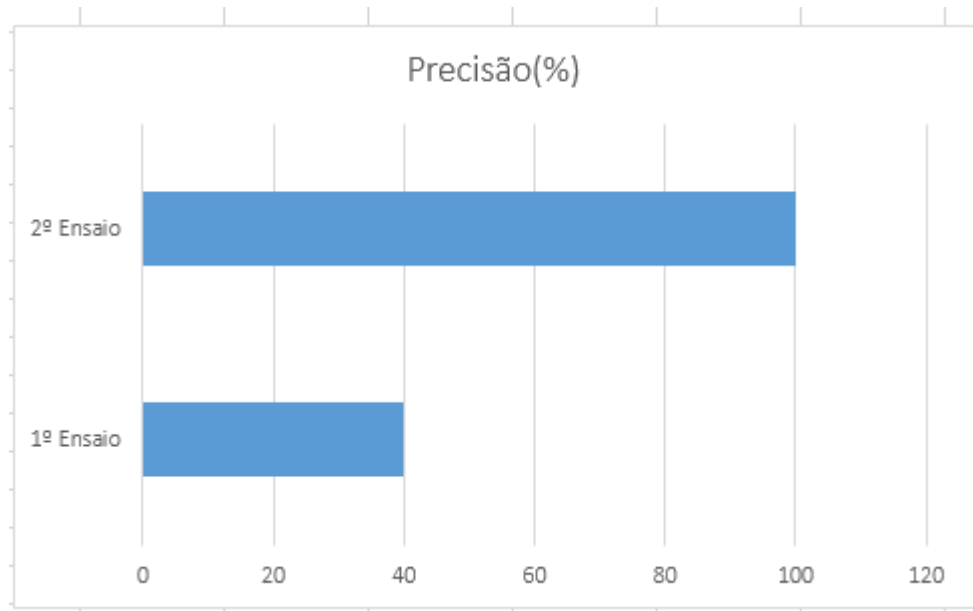
Na figura 21, é possível verificar através de gráficos a diferença nas configurações entre o primeiro e o segundo ensaio. Na figura 22 é representado o percentual de acerto no primeiro e segundo ensaio.

Figura 21 – Gráfico representado os ajustes das configurações do algoritmo realizados entre o primeiro e segundo ensaio.



Fonte: (AUTORES, 2017)

Figura 22 – Gráfico representado o resultado obtido no primeiro e segundo ensaio.



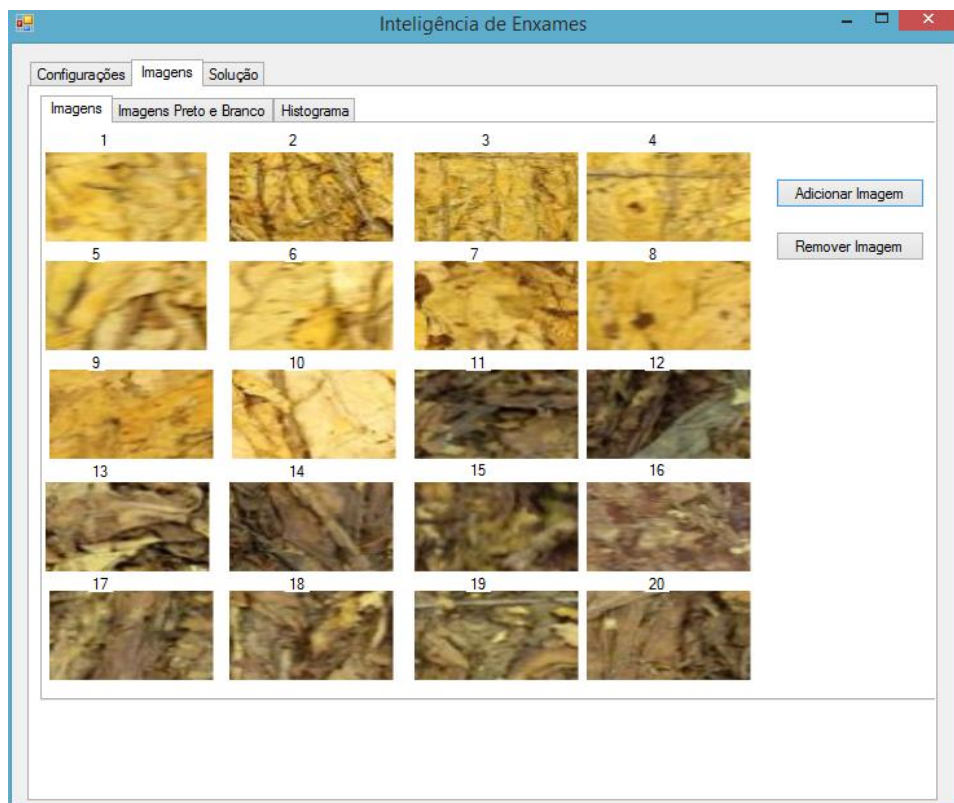
Fonte: (AUTORES, 2017)

5.2.2. RESULTADOS DA CLASSIFICAÇÃO UTILIZANDO FOLHAS DE TABACO

Na classificação das folhas de tabacos foram utilizadas as mesmas configurações da classificação anterior, conforme figura 15.

Utilizou-se amostra de 10 folhas de tabaco claras e 10 folhas de tabaco escuras, conforme figura 23.

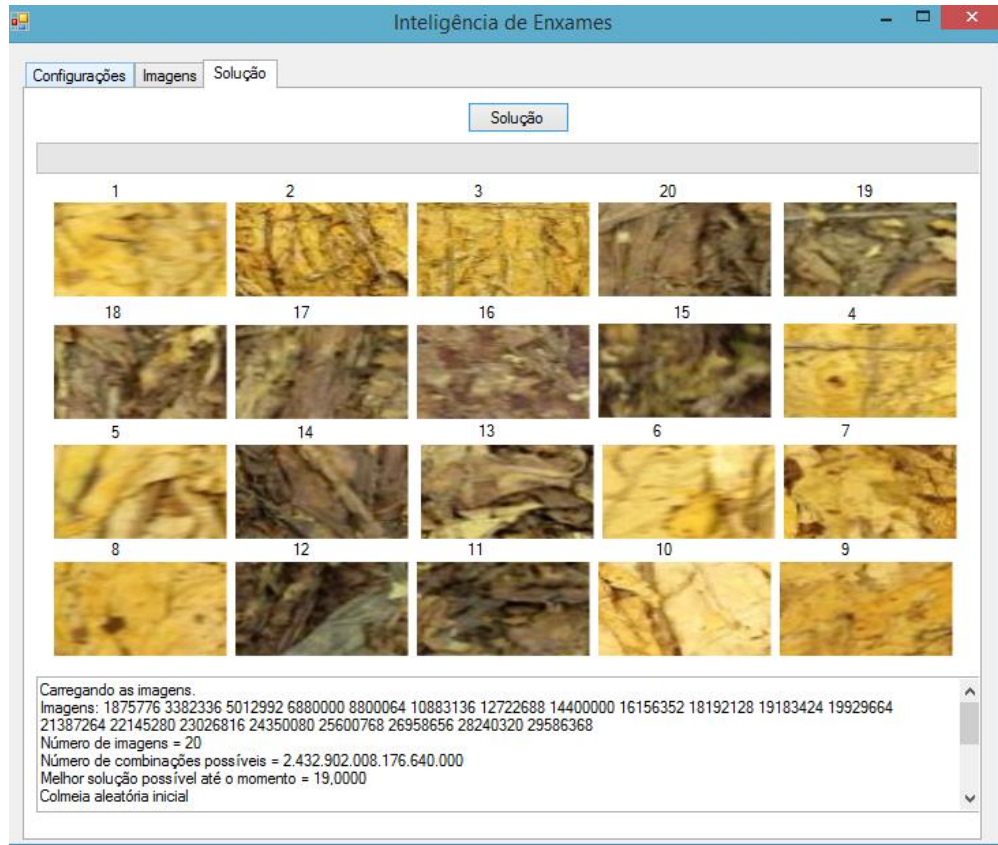
Figura 23 – Entrada de imagens folhas de tabaco claras e escuras.



Fonte: (AUTORES, 2017)

A classificação sem fazer a conversão para preto e branco também não foi satisfatória como no caso anterior, conforme figura 24.

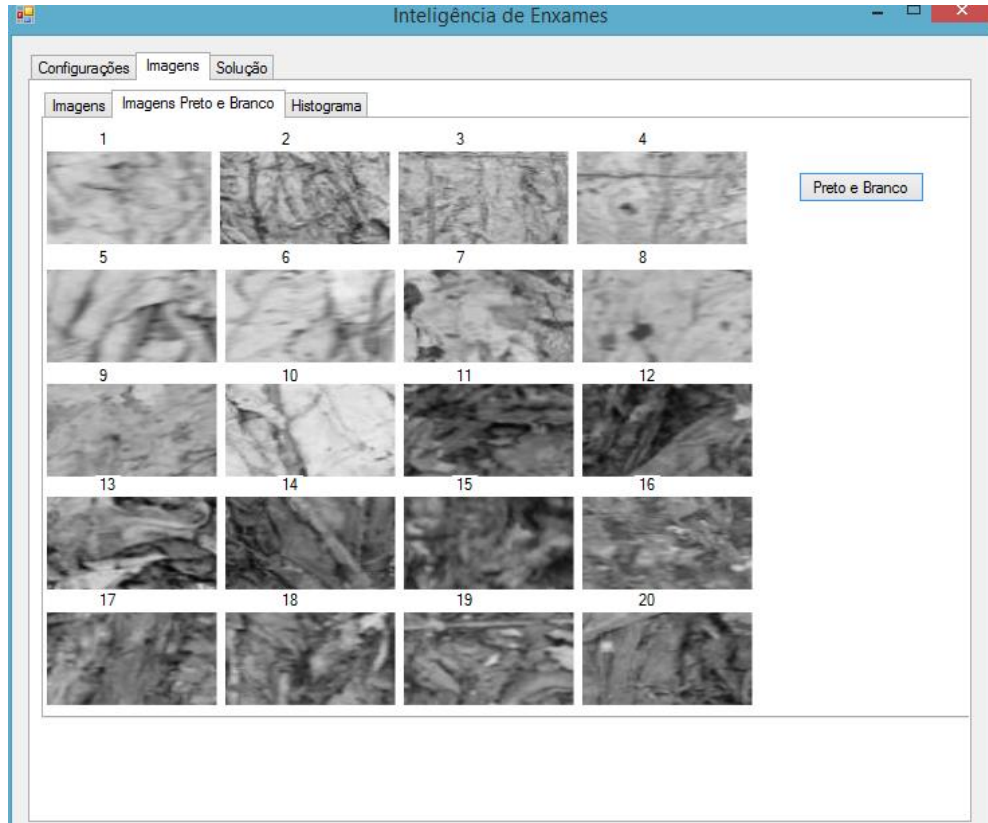
Figura 24 – Classificação das imagens de folhas de tabaco.



Fonte: (AUTORES, 2017)

Realizando a conversão das imagens para preto e branco, conforme figura 25, e realizando a classificação novamente o resultado ainda não foi satisfatório, conforme figura 26.

Figura 25 – Imagem das folhas de tabaco em preto e branco.



Fonte: (AUTORES, 2017)

Figura 26 – Resultado da Classificação das folhas de tabaco em preto e branco.



Fonte: (AUTORES, 2017)

Porém, alterando os parâmetros de configuração para 900 o número de abelhas e 15000 o número de ciclos, conforme figura 27, o algoritmo agrupou com maior coerência as imagens, conforme figura 28.

Figura 27 – Alteração das configurações do Algoritmo.

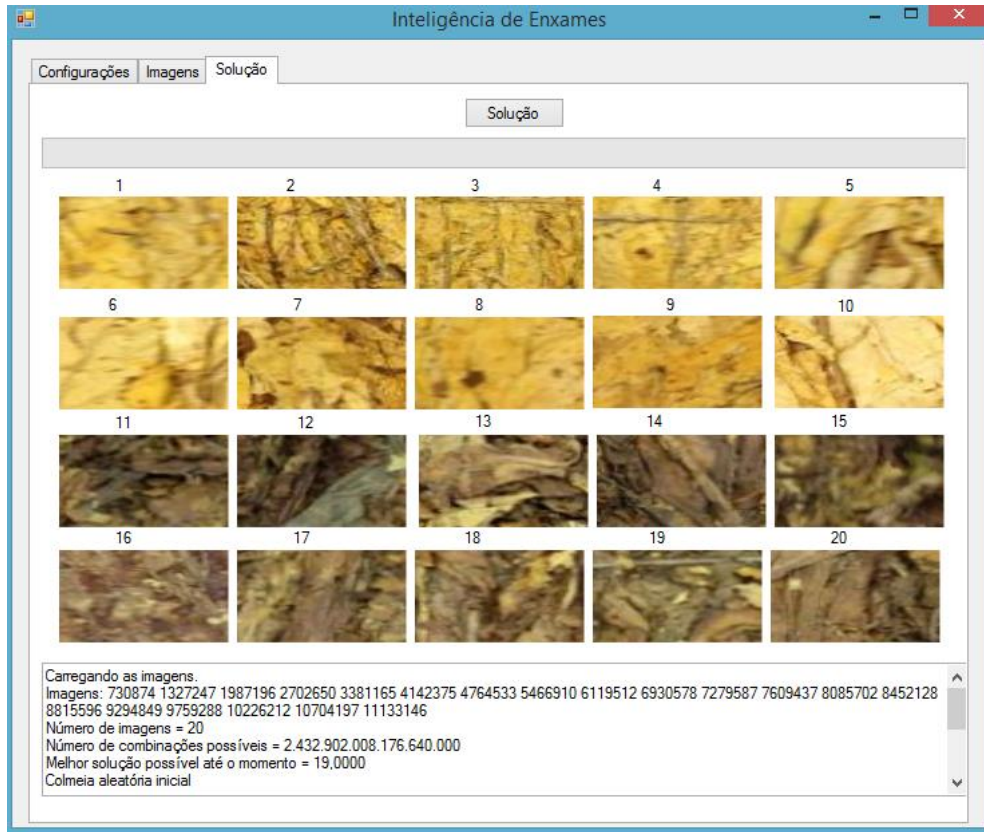
Configurações | Imagens | Solução

Algoritmo: Algoritmo Colônia de Abelhas (ABC)

N° de indivíduos	900	Ativas	75	%
Ciclos	15000	Inativas	10	%
Visitas	95	Expectadoras	15	%

Fonte: (AUTORES, 2017)

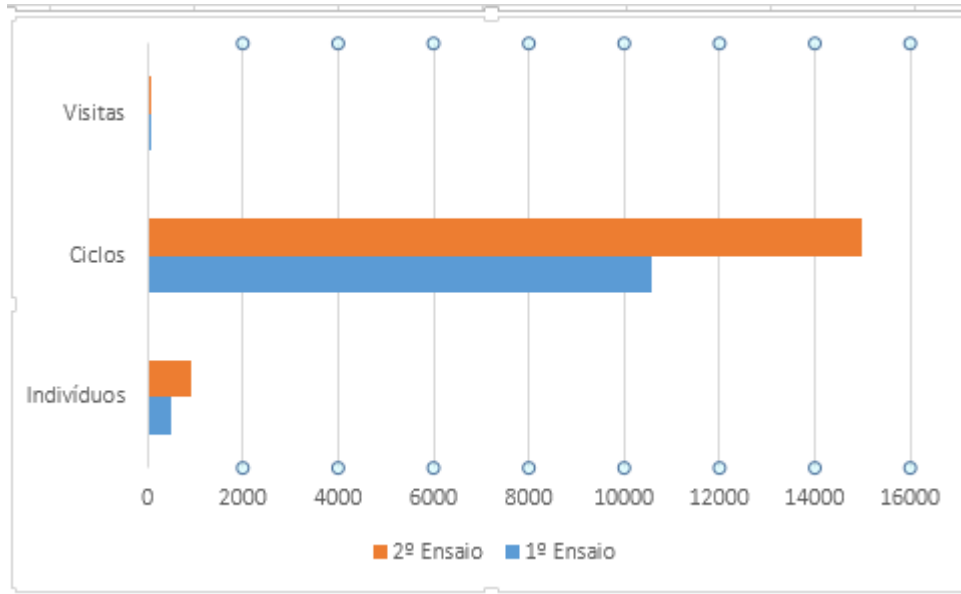
Figura 28 – Resultado após a alteração das Configurações.



Fonte: (AUTORES, 2017)

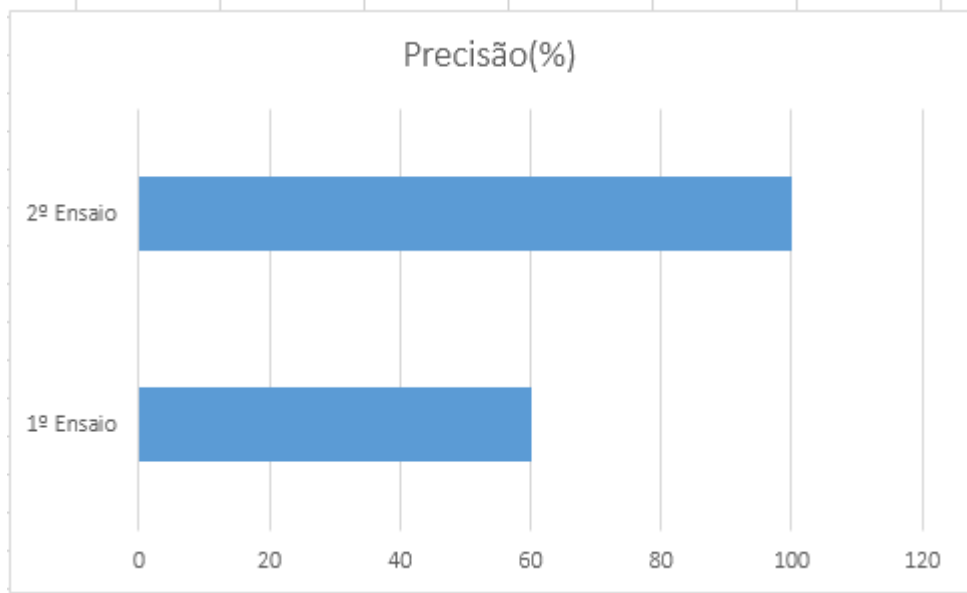
Na figura 29, é possível visualizar o gráfico da diferença dos ensaios e na figura 30 a comparação da precisão entre os resultados do primeiro e segundo ensaio.

Figura 29 – Gráfico demonstrando a diferença das configurações entre o primeiro e segundo ensaio.



Fonte: (AUTORES, 2017)

Figura 30 – Gráfico comparativo do primeiro e segundo ensaio.



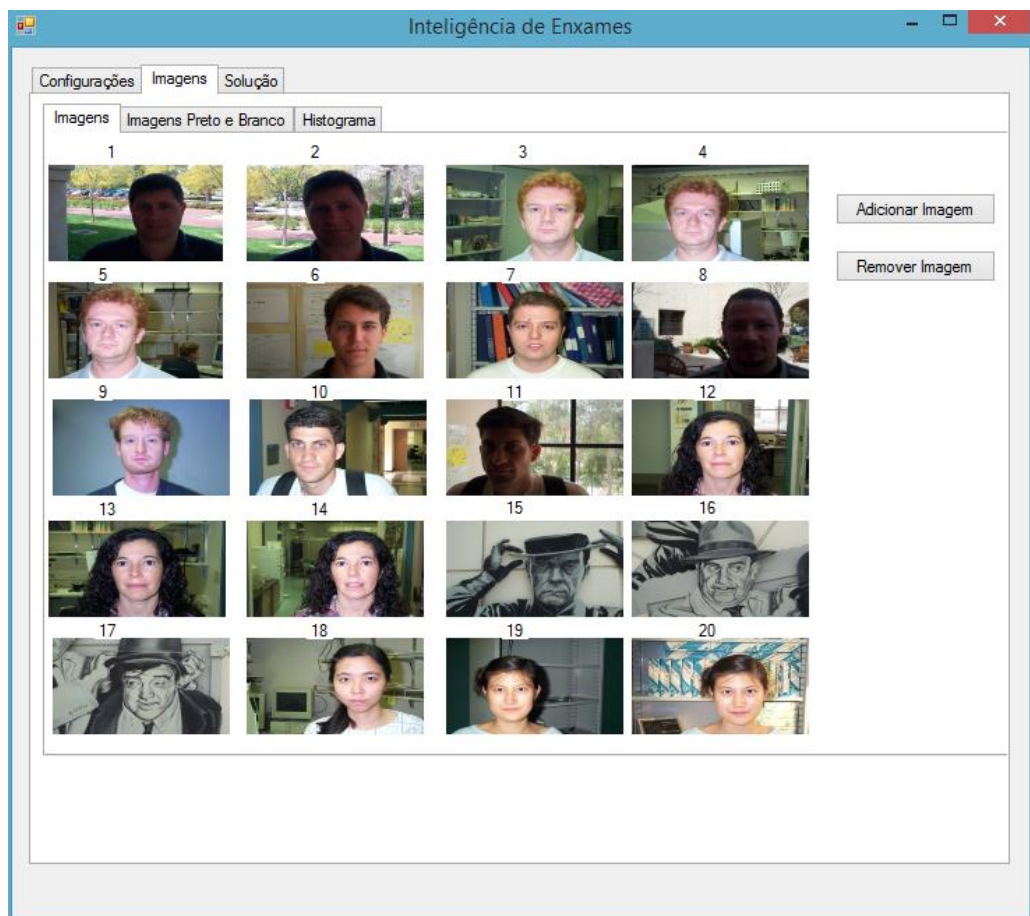
Fonte: (AUTORES, 2017)

5.2.3. RESULTADOS DA CLASSIFICAÇÃO UTILIZANDO FACES DE PESSOAS NOS MAIS VARIADOS AMBIENTES E ILUMINAÇÃO

Nesta classificação foram utilizados os mesmos parâmetros de configuração iniciais das classificações anteriores, conforme figura 15.

As imagens utilizadas na classificação podem ser observadas na figura 31.

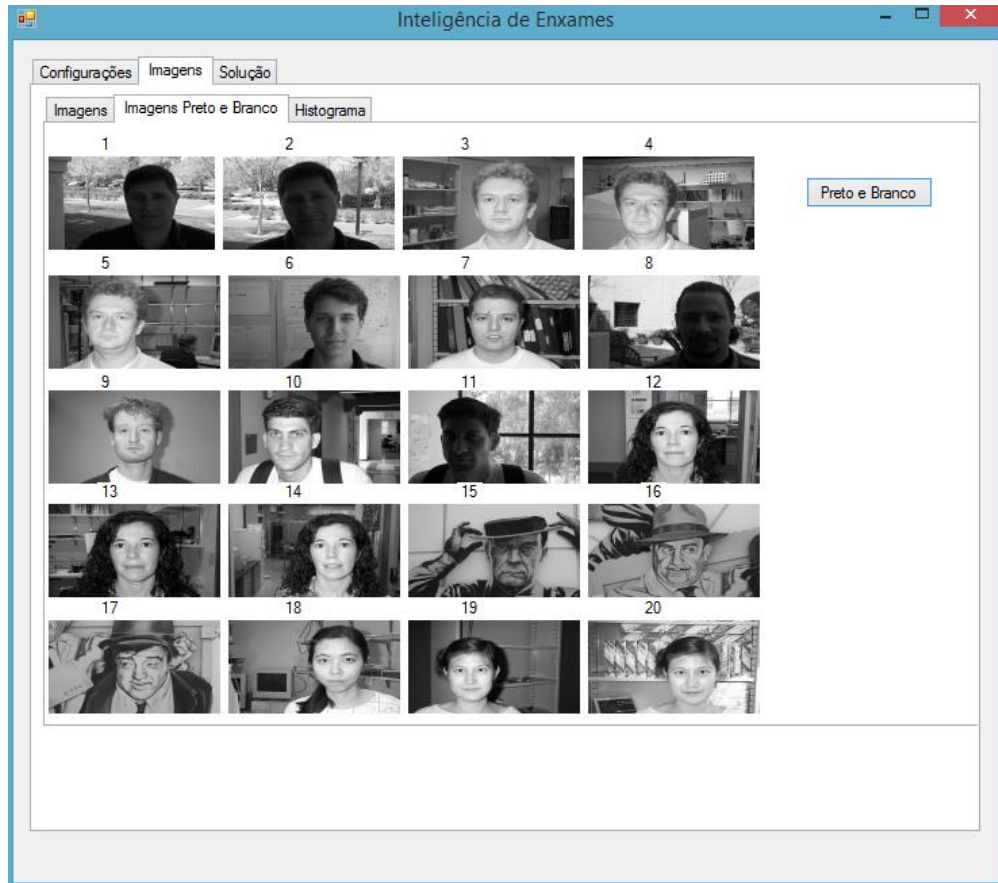
Figura 31 – Faces humanas utilizadas na classificação.



Fonte: (AUTORES, 2017)

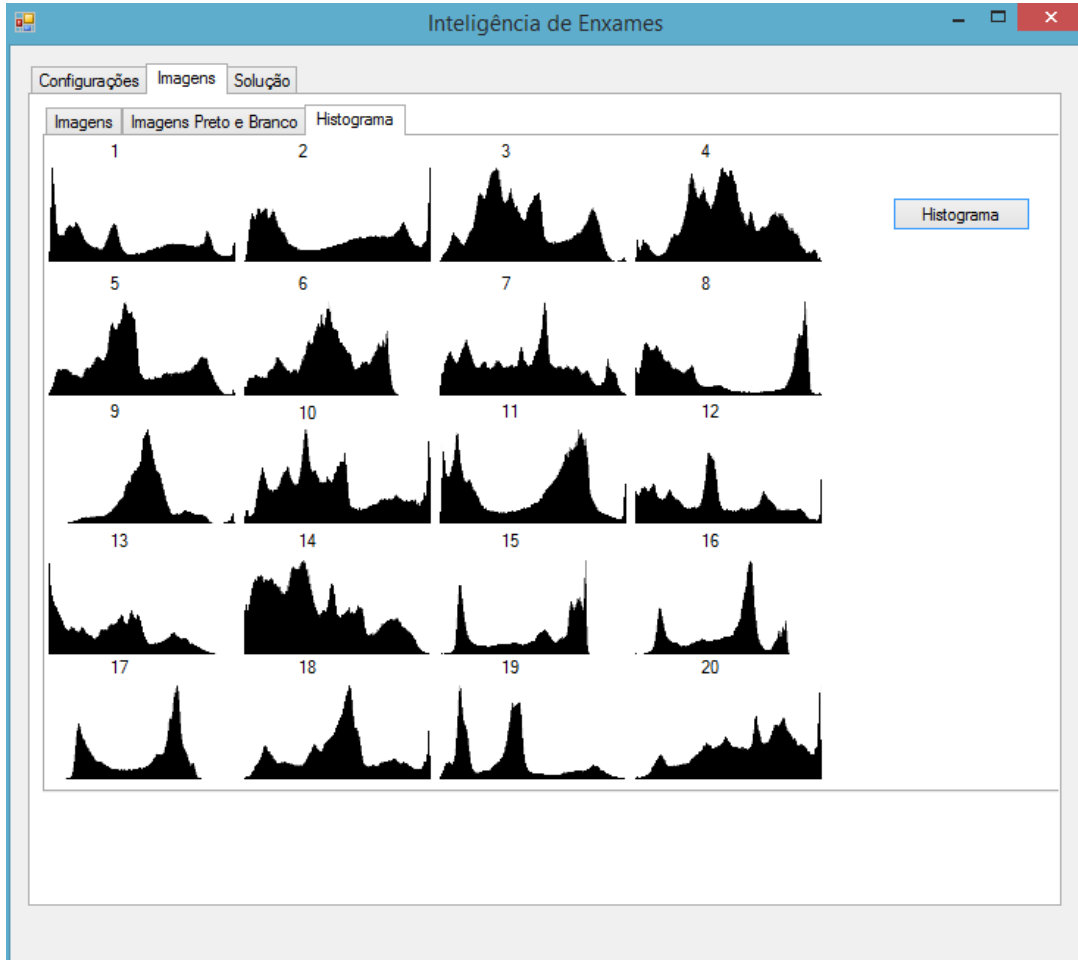
Foi realizada a conversão para preto e branco, conforme figura 32, e após isto foi feita a geração do histograma de cada imagem, conforme figura 33.

Figura 32 – Conversão das imagens para preto e branco.



Fonte: (AUTORES, 2017)

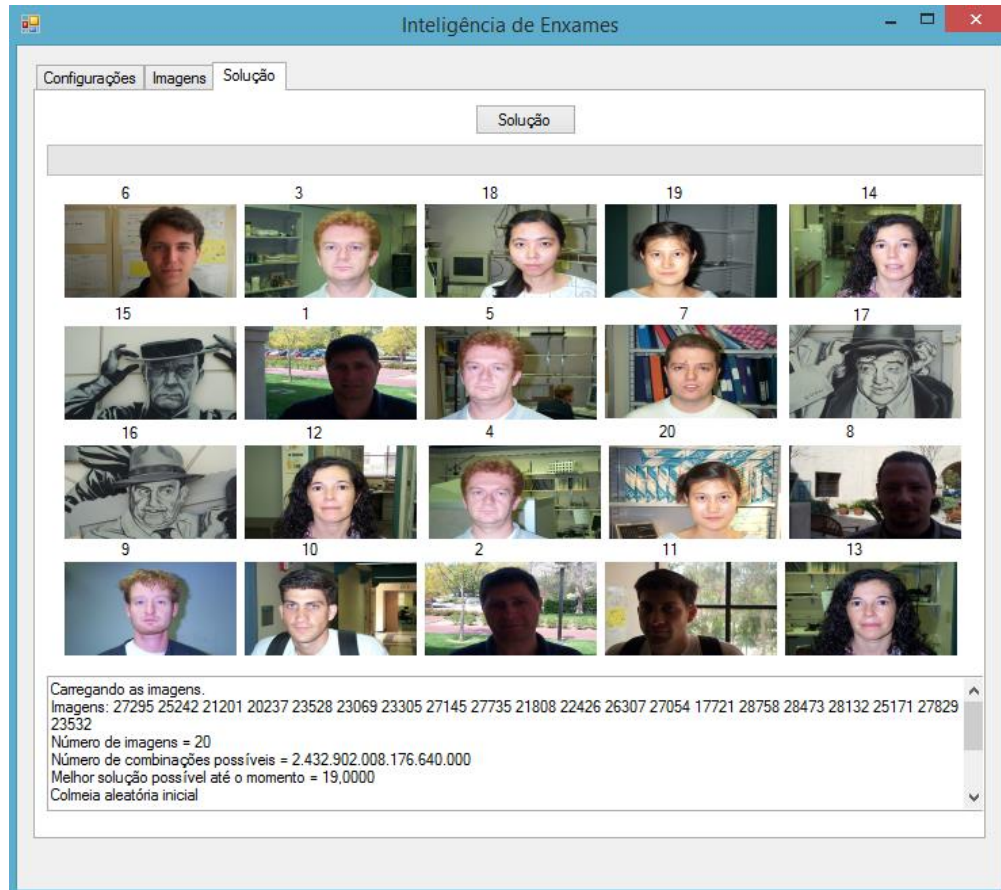
Figura 33 – Histograma das imagens em preto e branco.



Fonte: (AUTORES, 2017)

O resultado da classificação pode ser visto na figura 34.

Figura 34 – Resultado da Classificação.



Fonte: (AUTORES, 2017)

Alterando os parâmetros de configuração do algoritmo, para 800 indivíduos e 15000 ciclos, conforme figura 35, obteve-se o resultado da figura 32.

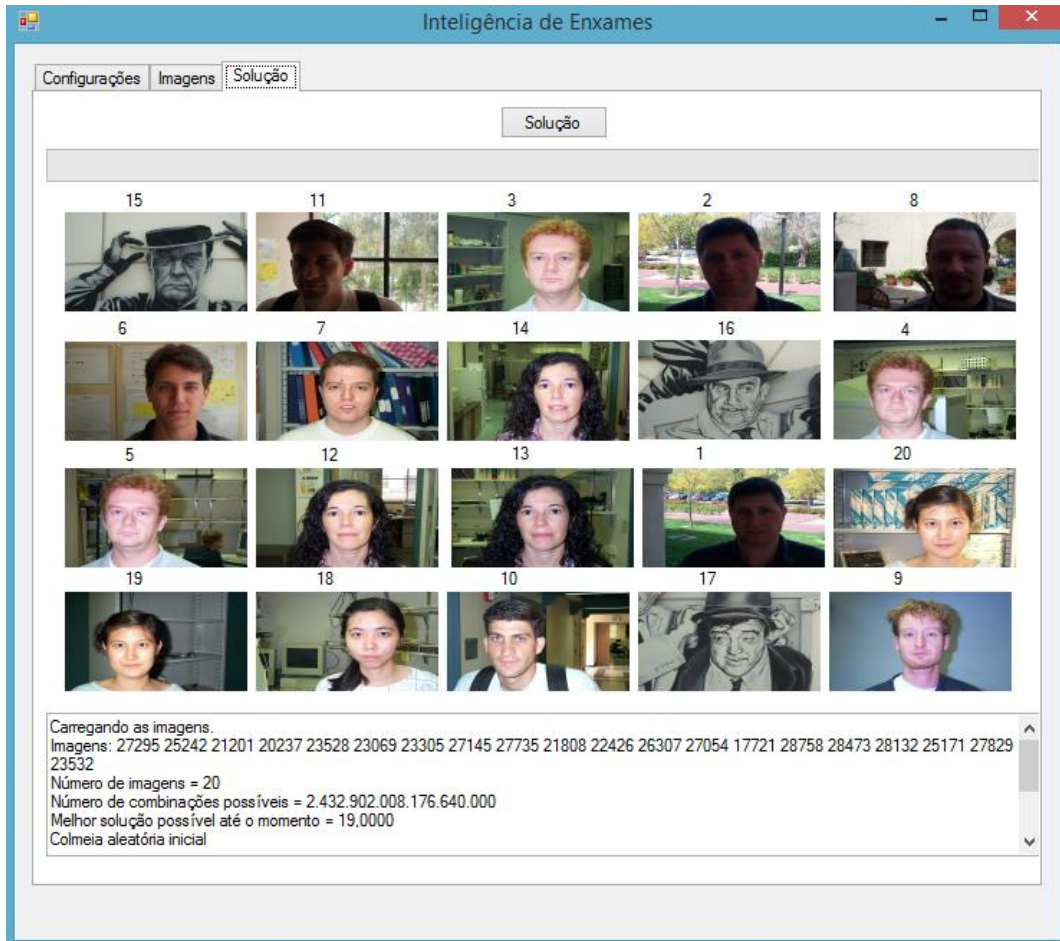
Figura 35 – Alteração dos parâmetros de Configuração.

The screenshot shows a software window titled "Inteligência de Enxames" with a "Configurações" tab selected. The configuration is for the "Algoritmo Colônia de Abelhas (ABC)". The parameters are as follows:

Parameter	Value	Unit
N° de indivíduos	800	
Ciclos	15000	
Vistas	95	
Ativas	75	%
Inativas	10	%
Expectadoras	15	%

Fonte: (AUTORES, 2017)

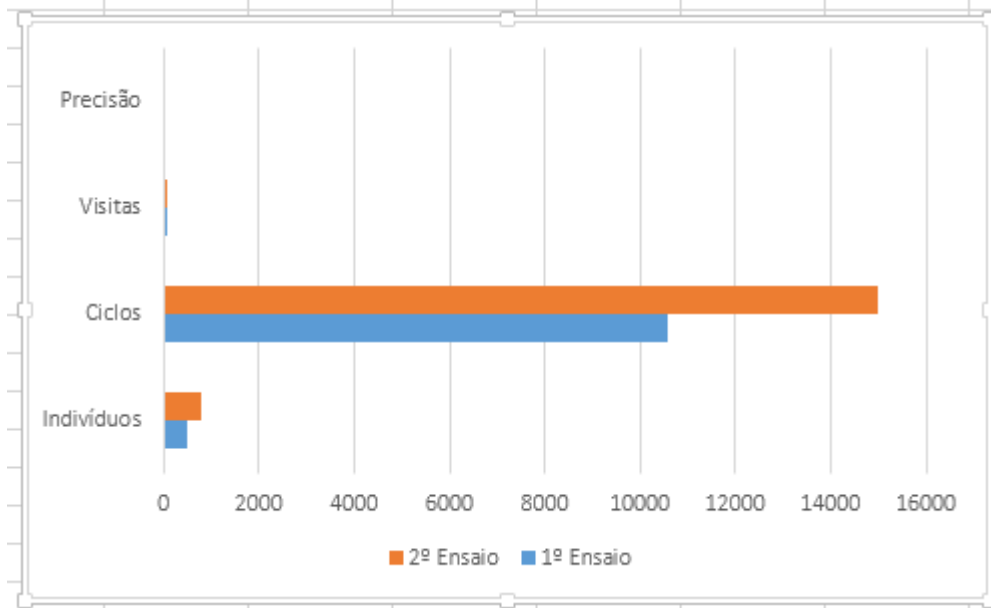
Figura 36 – Resultado da Classificação com os novos parâmetros de configuração.



Fonte: (AUTORES, 2017)

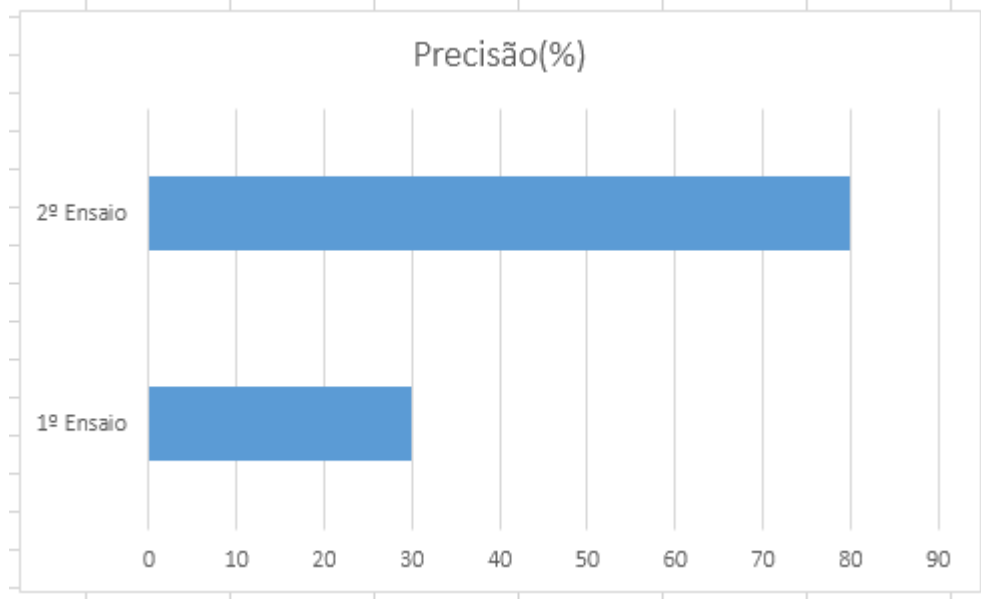
A figura 37 mostra o gráfico da diferença de configuração entre o primeiro e o segundo ensaio. Na figura 38 é feito o comparativo entre os resultados obtidos no primeiro e segundo ensaio.

Figura 37 – Gráfico comparativo das configurações utilizadas no primeiro e segundo ensaio.



Fonte: (AUTORES, 2017)

Figura 38 – Gráfico comparativo das configurações utilizadas no primeiro e segundo ensaio.



Fonte: (AUTORES, 2017)

5.2.4. CONSIDERAÇÕES SOBRE A CLASSIFICAÇÃO DE IMAGENS

A classificação de imagens se mostrou eficiente em todos os casos, devendo o usuário fazer ajustes nos parâmetros de configurações, conforme as imagens a serem classificadas.

O quadro 3 apresenta um comparativo dos resultados das classificações com as três bases de dados utilizadas.

Quadro 3. Quadro comparativo da classificação das bases.

Base de Dados	Configurações do Algoritmo
Base de dados com folhas de tabaco curadas	Poucos ajustes de configuração. A partir dos parâmetros iniciais, pode-se observar grupos com alguma coerência.
Base de dados contendo frutas	Necessidade de mais ajustes a partir dos parâmetros iniciais, e não se chega a uma lógica na formação dos grupos.
Base de dados com faces humanas	As imagens ficam embaralhadas a partir dos parâmetros iniciais, mas com ajustes nos parâmetros de configuração do algoritmo é possível chegar a uma coerência na classificação.

Fonte: (AUTORES, 2017)

Destaca-se que, a partir da validação realizada neste trabalho, não há um conjunto padrão de parâmetros que possa ser definido para classificação de qualquer conjunto de imagens. A indicação é avaliar o resultado da classificação com os ajustes dos parâmetros.

6. CONCLUSÃO

Este trabalho de conclusão abordou o tema inteligência de enxames, apresentando conceitos, etapas, tipos de abordagem e suas utilidades. Neste trabalho, foi abordada a classificação de dados, mais especificamente de imagens, utilizando o algoritmo de otimização colônia de Abelhas.

Também foram apresentadas ao longo deste trabalho, pesquisas relacionadas que fazem o uso das outras inteligências de enxames como: Algoritmo de Otimização Colônia de Formigas e Algoritmo de Otimização Enxame de Partículas e exemplificado suas diversas aplicações em tomadas de decisão do tipo: Auxiliar na decisão do médico em descobrir quando há necessidade de se fazer cesariana em caso de asfixia durante o parto normal, classificar características comuns entre pacientes que contraíram o vírus da dengue e seleção de características dos diversos casos de evolução diferencial estatística.

Como solução foi desenvolvido um sistema de classificação de imagens abordado no capítulo 5. Tal sistema utiliza técnicas de discretização de imagem como: Transformar a imagem para preto e branco e gerar seu histograma. Após, o sistema classifica as imagens conforme as características extraídas, visando auxiliar na tomada de decisão.

Através dos testes efetuados, foi possível concluir que é possível classificar os mais diferentes tipos de imagens como os utilizados neste trabalho - faces humanas, frutas e folhas de tabaco curadas. Porém, fica explícito que a ferramenta é dependente das configurações informadas pelo usuário, pois as mesmas variam de acordo com o tipo de imagem a ser classificada.

Para trabalhos futuros, sugere-se incrementar este sistema de classificação implementando, além do Algoritmo de Otimização Colônia de Abelhas, também os Algoritmos de Otimização Colônia de Formigas e Enxame de Partículas. Também pode ser implementada uma função para verificar a qualidade da classificação, pois isto hoje é feito a partir da análise do usuário.

Outra possibilidade de incremento é utilizar o Algoritmo de Otimização Colônia de Abelhas implementado neste trabalho para classificar outros tipos de bases de dados além de imagens, como bases de dados contendo informações de pacientes que chegam à emergência de um hospital, ou o perfil de universitários de cada curso de uma universidade.

REFERÊNCIAS

AGHDAM, M. H.; KABIRI, P. Feature Selection for Intrusion Detection System Using Ant Colony Optimization. *International Journal of Network Security*. Vol. 18, No.3, pag. 420-432. 2016.

ALSHAMIRI, A. K.; SINGH, A.; SURAMPUDI, B. R. Artificial bee colony algorithm for clustering : an extreme learning approach. *Soft Comput*. 2016.

BALASUBRAMANI, K. A Comprehensive review of Artificial Bee Colony Algorithm. *International Journal of Computers e Technology*. Vol. 5, No. 1. 2013.

BOLAJI, A. L. A.; KHADER, A. T.; AL-BETAR, M. A.; AWADALLAH, M. A. Artificial Bee Colony Algorithm, its variants and applications : a survey. *Journal of Theoretical and Applied Information Technology*. Vol. 47, No.2, pag. 434-459. 2013.

BURSA, M; LHOTSKA, L. Ant-inspired Algorithms in Health Information System Data Mining, Classification and Visualization. *IFMBE Proceedings*. Vol. 57, pag 868-873.2016.

DEMINOVA, L.; NIKULCHEV, E.; SOKOLOVA, Y. The SVM Classifier Based on the Modified Particle Swarm Optimization. *Internaltional Journal of Advanced Computer Science and Applications*. Vol. 7, No. 2, 2016.

DEMIDOVA L.; SOKOLOVA, YU. Modification of Particle Swarm Algorithm For The Problem Of The SVM Classifier Development. *International Conference ‘Stability and Control Processes’*. Pag. 623-627. 2015.

DEVI, B. R.; RAO, K. N.; SETTY, S. P. Towards Better Classification Using Improved Particle Swarm Optimization Algorithm and Decicion Tree for Dengue Datasets. *International Journal of Soft Computing*. Pag. 18-25.

DORIGO, M.; MANIEZZO, V. COLORNI, A. Positive feedback as a search strategy *Dipartimento di Elettronica e Informatica*. 1991.

GABARDELLA, L. M.; DORIGO, M. Solving symmetric and asymmetric TSPs by ant colonies. In: EVOLUTIONARY COMPUTATION, 1996.

GAMBARDELLA, L. M.; DORIGO, M. An ant colony system with a new local search for the sequential ordering problem. *INFORMS Journal on Computing*. Vol. 12, No. 2, pag. 237-255. 2000.

HUANG, C. L.; DUN, J. F. A distributed PSO-SVM hybrid system with feature selection and parameter optimization. *Applied Soft Comput.* Vol.8, pag. 1381-1391. 2008.

KARABOGA, D. An idea based on honey bee swarm for numerical optimization. Erciyes University, Engineering Faculty, Computer Engineering Department. 2005.

KARABOGA, D.; BASTURK B. A powerful and efficient algorithm for numerical function optimization : artificial bee colony(abc) algorithm. *J Glob Optim.* Vol. 39, No. 3, pag. 459-471. 2007.

KENNEDY, J.; EBERHART, R. Particle swarm optimization. *Proceedings of the IEEE International Conference on Neural Networks*. Vol. 4, pag. 1942-1948. 1995.

KOURAV, D.; KHILRANI, A.; NIGAM, R. Class Clustering with Ant Colony Rank Optimization (CCACRO) for Data Categorization. *International Conference on Applied and Theoretical Computing and Communication Technology*. Pag. 201-206. 2016.

MATERNIS, D.; BACKER, M.; HAESSEN, R.; VANTHIENE, J.; SNOECK, M.; BAESSENS, D. Classification With Ant Colony Optimization. *IEEE Transactions on Evolutionary Computation*. Vol. 11, No. 5. 2007.

MOHEMMED, A.W.; ZHANG, M.; JOHNSTON, M. Particle swarm optimization based adaboost for face detection. *Proceedings of the IEEE Congress on Evolutionary Computation*. Pag. 2494-2501. 2009.

MOHAMED, A. W.; SABRY H. Z.; KHORSHID, M. An alternative differential evolution algorithm for global optimization. *Journal of Advanced Research*. Vol 3, No. 2, pag 149-165. 2012.

SÁ, A. A.; ANDRADE, A. O.; SOARES A. B. Exploration vs. Exploitation in differential evolution. In AISB Convention Communication. Interaction and Social Intelligence. Vol. 1, pag 57-63. 2008.

SHI, Y.; EBERHART, R. A modified particle swarm optimizer. Proceedings of the World Congress on Computational Intelligence and IEEE International Conference on Evolutionary. Pag. 69-73. 1998.

SUN, J.; LAI, C.-H.; WU, -J. Particle Swarm Optimisation : Classical and Quantum Perspectives. 2011.

TERESHKO, V. Reaction-diffusion model of a honeybee colony's foraging behavior. Parallel Problem Solving from Nature VI, Lecture Notes in Computer Science. Vol. 1917. 2000.

TERESHKO, V.; LEE T. How information mapping patterns determine foraging behavior of a honeybee colony. Open Systems and Information Dynamics. Vol.9, pag. 181-193. 2002.

TERESHKO, V.; LOENGAROV, A. Collective Decision-Making in Honey Bee Foraging Dynamics. Computing and Information Systems Journal. Vol. 9, No.3. 2005.