

# Segmentação Automática de Doenças em Imagens de Plantas através de Algoritmos Evolucionários

Luciano D. S. Pacifico<sup>1</sup>

<sup>1</sup>Departamento de Computação (DC) – Universidade Federal Rural de Pernambuco (UFRPE) – Recife – PE – Brazil

luciano.pacifico@ufrpe.br

**Abstract.** *In this work, image segmentation approaches to deal with leaf disease detection problem are presented, as part of an automatic plant disease classification system. Evolutionary Algorithms (EAs), which are global search meta-heuristics, are adapted as unsupervised data clustering methods, to tackle the image segmentation problem. Four evolutionary algorithms are selected and tested through twelve images, which present variant degrees of disease, as a manner to access how robust the selected models are while handling the problem. Experimental analysis showed that EAs are able to solve the image segmentation problem properly for the evaluated scenario.*

**Resumo.** *Neste trabalho, abordagens para a segmentação de doenças em imagens de folhas são apresentadas, como parte de um sistema automático de classificação de doenças em plantas. Para isso, Algoritmos Evolucionários (EAs), que são meta-heurísticas de busca global, são adaptados como técnicas não supervisionadas de agrupamento de dados, no intuito de lidar com o problema. Quatro algoritmos foram selecionados e testados através do uso de doze imagens, que apresentam diferentes graus de doença, de modo a avaliar o quão robusto são tais modelos na solução do problema. A análise experimental revelou que as abordagens utilizadas são capazes de realizar de forma satisfatória a tarefa de segmentação das doenças nas imagens avaliadas.*

## 1. Introdução

O rápido desenvolvimento das Tecnologias de Informação e Comunicação (TICs) nas últimas décadas tem trazido benefícios para diversas áreas, como medicina, engenharias, indústria, dentre outras, e muitas atividades que antes eram realizadas exclusivamente por seres humanos têm sido automatizadas, visando um aumento na produtividade dos serviços oferecidos. Uma área estratégica para países como o Brasil que tem sido bastante beneficiada por essa automação é o setor do agronegócio.

Um dos principais problemas que ocorrem em lavouras é o surgimento de doenças e pragas, sendo o rápido diagnóstico desses problemas de alto interesse econômico para os produtores [Barbedo et al. 2018]. Doenças em plantas geralmente manifestam seus primeiros sinais observáveis através das folhas, e muitos estudos focam na análise das folhas para a identificação dessas patologias [Barbedo et al. 2018, Sawarkar and Kawathekar 2018]. Pelo uso de técnicas avançadas de Aprendizagem de Máquina e Visão Computacional é possível não só a identificação dessas doenças, mas também a análise do grau do dano causado pelas mesmas [Tanmayee 2017,

Solanke et al. 2018]. Uma das etapas fundamentais para a identificação e análise do dano causado por patologias em plantas é a segmentação das imagens das folhas, porém, muitas das abordagens existentes realizam essa tarefa manualmente [Lee et al. 2015, Barbedo et al. 2018, Pacifico et al. 2019], o que requer um alto grau de esforço humano.

Neste trabalho, métodos automáticos de segmentação de imagens das plantas são apresentados, baseados em abordagens de aprendizagem não supervisionadas e de Algoritmos Evolucionários (EAs). Os EAs são meta-heurísticas inspiradas na seleção natural das espécies, que executam buscas globais no espaço do problema tratado, através de mecanismos que simulam processos biológicos, como mutação, recombinação e seleção [Eiben and Smith 2010]. Os EAs mantêm um conjunto (*população*) de soluções candidatas (*indivíduos*) do problema a cada iteração (*geração*) de suas buscas, sendo a busca realizada por cada indivíduo da população de um EA guiada com o objetivo de otimizar uma função critério (função de *fitness*). Entre os EAs mais populares estão o Algoritmo Genético (GA) [Holland 1992], a Evolução Diferencial (DE) [Storn and Price 1995], a Otimização por Enxame de Partículas (PSO) [Kennedy and Eberhart 1995], e a Otimização por Busca em Grupo (GSO) [He et al. 2009]. Tais algoritmos variam principalmente em relação à forma como seus operadores evolucionários conduzirão a população no espaço de busca do problema.

O trabalho está organizado como segue. Na próxima seção (Seção 2), o processo de adaptação dos algoritmos evolucionários para o contexto de algoritmos de agrupamento é apresentado. Em seguida (Seção 3), a análise experimental e discussão dos resultados é feita, e, por fim, são apresentadas as conclusões e linhas para trabalhos futuros (Seção 4).

## 2. Metodologia

Nesta seção, o modelo genérico de adaptação de algoritmos evolucionários para o uso na tarefa de segmentação de imagens é apresentado. Uma abordagem de aprendizagem de máquina não supervisionada é usada, através da adaptação dos algoritmos evolucionários ao domínio das técnicas de *agrupamento particionais* [Chen and Ye 2004, Hruschka et al. 2009, Pacifico and Ludermir 2014].

Formalmente, considere uma partição  $P_C$  de uma base de dados com  $N$  padrões (cada padrão representado por um vetor  $\mathbf{x}_j \in \mathcal{R}^m$ , onde  $j = 1, 2, \dots, N$ ) em  $C$  agrupamentos. Cada agrupamento será representado por seu vetor centroide  $\mathbf{g}_c \in \mathcal{R}^m$  (onde  $c = 1, 2, \dots, C$ ).

Cada indivíduo da população  $S$  do EA será representado por um vetor  $\mathbf{X}_i \in \mathcal{R}^n$ , onde  $n = m \times C$ , correspondendo a  $C$  centroides, um para cada agrupamento da partição. Desta forma, cada indivíduo codificará uma partição da base de dados, que representa a solução final oferecida pelo mesmo. Na partição  $\mathbf{X}_i.P_C$ , determinada pelo indivíduo  $\mathbf{X}_i$ , os padrões da base de dados estarão associados ao grupo  $\mathbf{X}_i.\mathbf{g}_c$ , ( $c = 1, \dots, C$ ) ao qual sua distância seja mínima.

Embora a população de algoritmos evolucionários seja geralmente inicializada através de um processo completamente aleatório, no contexto de agrupamento de dados, uma abordagem que tem levado a melhores resultados é a inicialização de cada indivíduo  $\mathbf{X}_i$  pela escolha aleatória de  $C$  padrões da base de dados em análise para compor seus vetores centroides iniciais.

**Tabela 1. Parâmetros fixos para cada algoritmo.**

Algoritmo	Parâmetro	Valor
Todos os EAs	$S$ e $t_{max}$ $C$	20 e 100 5
GA	Taxa de elitismo Taxa de <i>crossover</i> e Taxa de mutação	20% 0.9 e 0.01
DE	Taxa de <i>crossover</i> e $F$	0.9 e 0.8
PSO	$w$ $c_1$ e $c_2$	0.9 a 0.4 2.0
GSO	$\theta_{max}$ e $\alpha_0$ Percentual de <i>scroungers</i> e $\beta_{max}$	$\pi/a^2$ e $\pi/4$ 80% e $\theta_{max}/2$

Uma função comumente adotada como critério de *fitness* para os EAs quando usados para agrupamento de dados é a Soma dos Erros Quadráticos dos Agrupamentos (eq. (1), vide Seção 3), assim como variações dessa função. Outras funções de *fitness* podem ser encontradas em trabalhos como [Hruschka et al. 2009, Wong et al. 2011].

Após a inicialização e o cálculo do valor do *fitness* da população inicial  $S^{(0)}$ , os *operadores evolucionários* do EA selecionado são aplicados à população durante um processo iterativo, evoluindo, desta forma, os vetores centroides representados pelos mesmos a cada etapa, até que um critério de parada seja atingido. A melhor solução global encontrada pela população é então retornada como solução final do algoritmo. Um algoritmo evolucionário particional genérico é apresentado no Algoritmo 1.

---

**Algorithm 1** Algoritmo Evolucionário Particional Genérico

---

$t \leftarrow 0$ .

**Inicialize** cada indivíduo  $\mathbf{X}_i^{(0)} \in S^{(0)}$  pela escolha aleatória de  $C$  padrões da base de dados como seus centroides iniciais.

**Gere** a partição inicial  $\mathbf{X}_i^{(0)}.P_C^{(0)}$ , atribuindo cada padrão  $\mathbf{x}_j$  ao agrupamento mais próximo, para cada indivíduo  $\mathbf{X}_i^{(0)}$ .

**Calcule** o valor do *fitness* para cada  $\mathbf{X}_i^{(0)}$ .

**enquanto** (critérios de término não forem alcançados) **faça**

**Execute** cada operador evolucionário, de acordo com o algoritmo evolucionário selecionado, na população atual  $S^t$ .

**Atribua** cada padrão  $\mathbf{x}_j$  ao agrupamento mais próximo em  $\mathbf{X}_i^t.P_C^t$ , para cada  $\mathbf{X}_i^t$ .

**Calcule** o novo valor do *fitness* para cada  $\mathbf{X}_i^t \in S^t$ .

$t \leftarrow t + 1$ .

**fim\_enquanto**


**Retorne**  $\mathbf{X}_{melhor}^{t_{max}}$ .

---

No contexto de segmentação de imagens, cada pixel (em RGB) será considerado um **padrão**, de modo que  $m = 3$ , e cada imagem será considerada uma **base de dados**.

### 3. Avaliação Experimental

Nesta seção, os resultados experimentais são apresentados. Quatro algoritmos evolucionários foram adaptados para a tarefa de segmentação de imagens (vide Seção 2): GA, DE, PSO e GSO. Os hiperparâmetros para cada um dos EAs são apresentados na Tabela 1 [He et al. 2009, Abdel-Kader 2010, Pacifico and Ludermir 2018, Pacifico and Ludermir 2019].



**Figura 1.** Imagens selecionadas [Asuncion and Newman 2007, Prajapati et al. 2017]: (a) DSC\_0370 (Blight1), (b) DSC\_0372 (Blight2), (c) DSC\_0400 (Blight3), (d) DSC\_0702 (Blight4), (e) DSC\_0108 (BSpot1), (f) DSC\_0121 (BSpot2), (g) DSC\_0391 (BSpot3), (h) DSC\_0113 (BSpot4), (i) DSC\_0508 (LSmut1), (j) DSC\_0505 (LSmut2), (k) DSC\_0339 (LSmut3), (l) DSC\_0312 (LSmut4).

**Tabela 2. Dimensões das Imagens. Para cada classe de imagens, quatro amostras foram selecionadas.**

Classe: <i>Bacterial Leaf Blight</i>	Nome da Imagem	Blight1	Blight2	Blight3	Blight4
	Dimensões (em Pixels)	309x90	309x90	309x90	309x90
Classe: <i>Brown Spot</i>	Nome da Imagem	BSpot1	BSpot2	BSpot3	BSpot4
	Dimensões (em Pixels)	229x81	252x189	309x90	231x155
Classe: <i>Leaf Smut</i>	Nome da Imagem	LSmut1	LSmut2	LSmut3	LSmut4
	Dimensões (em Pixels)	312x176	332x90	309x90	309x90

Os experimentos foram conduzidos através da escolha de 12 imagens (Fig. 1) da base de dados *Rice Leaf Diseases* [Prajapati et al. 2017] do UCI Machine Learning Repository [Asuncion and Newman 2007]. As imagens selecionadas possuem diferentes níveis de lesões ocasionadas pelas doenças, o que acarreta variação no grau de dificuldade das mesmas. As imagens foram redimensionadas de acordo com a Tabela 2.

Os algoritmos selecionados são avaliados através do uso de quatro métricas bem estabelecidas da área de análise de agrupamentos: a Soma dos Erros Quadráticos dos Agrupamentos (eq. (1)), o Erro de Quantização Ponderado (eq. (2)), a Distância Intra-Cluster (eq. (3)) e a Separação Inter-Cluster (eq. (4)).

$$J(P_C) = \sum_{c=1}^C \sum_{\mathbf{x}_j \in c} d(\mathbf{x}_j, \mathbf{g}_c) \quad (1)$$


$$J_{e_2}(P_C) = \sum_{c=1}^C [(\sum_{\mathbf{x}_j \in c} d(\mathbf{x}_j, \mathbf{g}_{ic}) / |N_{ic}|) \times (|N_{ic}| / N)] \quad (2)$$

$$D_{max}(P_C) = \max_{c=1, \dots, C} \{ \sum_{\mathbf{x}_j \in c} d(\mathbf{x}_j, \mathbf{g}_{ic}) / |N_{ic}| \} \quad (3)$$

$$D_{min}(P_C) = \min_{\forall c_1, c_2, c_1 \neq c_2} \{ d(\mathbf{g}_{ic_1}, \mathbf{g}_{ic_2}) \} \quad (4)$$

onde  $|N_{ic}|$  é o número de padrões associados ao agrupamento  $c$ , e

$$d(\mathbf{x}_j, \mathbf{g}_{ic}) = \sqrt{\sum_{k=1}^m (x_{jk} - g_{ick})^2} \quad (5)$$



**Figura 2. Exemplos de Sementação: (a) Blight3, (b) BSpot2, (c) LSmut3.**

é a distância euclidiana. Neste trabalho, todos os EAs fizeram uso da Soma dos Erros Quadráticos dos Agrupamentos como **função de fitness**.

A análise experimental inclui uma avaliação baseada no valor médio obtido para cada uma das métricas adotadas em relação a dez execuções independentes dos experimentos para cada imagem, assim como um sistema de *ranks* elaborado através da aplicação de testes de hipóteses do tipo *teste de Friedman/Nemenyi* [Friedman 1937, Nemenyi 1962, Demšar 2006] aos resultados. Os resultados experimentais são apresentados na Tabela 3.

Os resultados experimentais mostram que os algoritmos PSO e GSO foram os responsáveis pelos melhores valores para as métricas de avaliação adotadas. Os testes de Friedman/Nemenyi (Tabela 4) revelam que embora o GSO tenha obtido *ranks* levemente melhores que o PSO em relação aos índices  $J$  e  $J_{e_2}$ , enquanto o PSO obteve *ranks* sutilmente melhores para o  $D_{max}$  e o  $D_{min}$ , não há diferença estatística significativa entre essas duas técnicas. Porém, tanto o PSO quanto o GSO foram considerados melhores (com significância estatística) que o GA e o DE em relação às quatro métricas de avaliação.

A Figura 2 apresenta alguns exemplos dos resultados da segmentação realizada por cada algoritmo. Os resultados mostram que os melhores algoritmos (como o PSO e o GSO) foram capazes de identificar automaticamente as principais lesões nas imagens das plantas, mesmo no caso de lesões relativamente pequenas em relação às dimensões das imagens. Porém, em alguns casos (como os resultados obtidos para o DE na imagem LSmut3), há pouco contraste entre os agrupamentos finais gerados, o que pode tornar a identificação das lesões mais difícil.

#### 4. Conclusões

Neste trabalho, quatro algoritmos evolucionários foram empregados na tarefa de sementação automática de doenças em imagens de plantas: Algoritmos Genéticos, Evolução Diferencial, Otimização por Enxame de Partículas e Otimização por Busca em Grupo. Os EAs foram adaptados ao contexto de algoritmos de agrupamento particionais, de modo a realizarem a tarefa de sementação sem a necessidade do fornecimento de qualquer tipo de conhecimento prévio sobre o problema.

Como forma de validação dos algoritmos selecionados, 12 imagens foram obtidas através da base de dados *Rice Leaf Diseases* do UCI Machine Learning Repository,

**Tabela 3. Resultados Experimentais. Para cada métrica é apresentado valor médio (*Média*) e o desvio padrão (*Std*) nas dez repetições do experimento.**

Imagem	Modelo	$J$		$J_{e2}$		$D_{max}$		$D_{min}$	
		Média	Std.	Média	Std.	Média	Std.	Média	Std.
Blight1	GA	1.04x10 <sup>7</sup>	1.63x10 <sup>6</sup>	373.7	58.53	1843.3	258.0	943.28	901.2
	DE	9.85x10 <sup>6</sup>	1.14x10 <sup>6</sup>	354.2	41.05	1946.9	291.2	1263.0	834.3
	PSO	9.95x10 <sup>6</sup>	2.42x10 <sup>6</sup>	357.9	87.0	1763.7	546.6	964.9	990.5
	GSO	<b>7.47x10<sup>6</sup></b>	<b>5.20x10<sup>6</sup></b>	<b>268.7</b>	<b>18.70</b>	<b>1357.4</b>	<b>110.5</b>	<b>1579.2</b>	<b>599.5</b>
Blight2	GA	1.98x10 <sup>7</sup>	2.54x10 <sup>6</sup>	713.1	91.46	2174.2	514.4	2878.4	2662.8
	DE	1.82x10 <sup>7</sup>	2.43x10 <sup>6</sup>	653.6	87.24	2228.5	481.9	<b>3874.0</b>	<b>2431.4</b>
	PSO	1.33x10 <sup>7</sup>	2.26x10 <sup>6</sup>	476.7	81.22	1353.5	205.8	3295.3	839.0
	GSO	<b>1.27x10<sup>7</sup></b>	<b>1.91x10<sup>6</sup></b>	<b>456.2</b>	<b>68.70</b>	<b>1222.2</b>	<b>100.8</b>	3438.0	534.4
Blight3	GA	5.74x10 <sup>6</sup>	6.16x10 <sup>5</sup>	206.5	22.16	1683.4	325.0	1065.6	714.5
	DE	5.92x10 <sup>6</sup>	5.43x10 <sup>5</sup>	212.9	19.51	1766.4	368.9	764.4	720.9
	PSO	4.83x10 <sup>6</sup>	8.42x10 <sup>5</sup>	173.8	30.29	1220.0	346.0	<b>1130.8</b>	<b>644.6</b>
	GSO	<b>4.20x10<sup>6</sup></b>	<b>3.24x10<sup>5</sup></b>	<b>151.1</b>	<b>11.64</b>	<b>1182.5</b>	<b>148.5</b>	904.2	239.7
Blight4	GA	1.35x10 <sup>7</sup>	1.75x10 <sup>6</sup>	484.9	62.9	1686.6	757.3	1424.6	825.7
	DE	1.39x10 <sup>7</sup>	2.10x10 <sup>6</sup>	501.5	75.66	2217.1	1515.8	2111.8	1819.5
	PSO	<b>1.02x10<sup>7</sup></b>	<b>1.45x10<sup>6</sup></b>	<b>366.1</b>	<b>51.97</b>	1240.7	104.6	<b>2561.0</b>	<b>1051.5</b>
	GSO	1.08x10 <sup>7</sup>	8.97x10 <sup>5</sup>	388.8	32.25	<b>1134.7</b>	<b>63.73</b>	2299.8	482.8
BSpot1	GA	1.23x10 <sup>7</sup>	6.94x10 <sup>5</sup>	665.8	37.42	3035.3	1372.5	1386.0	911.5
	DE	1.40x10 <sup>7</sup>	2.63x10 <sup>6</sup>	757.1	141.6	3376.5	1453.1	1383.7	729.4
	PSO	<b>9.08x10<sup>6</sup></b>	<b>1.53x10<sup>5</sup></b>	<b>489.3</b>	<b>8.23</b>	<b>1696.9</b>	<b>77.6</b>	<b>1667.6</b>	<b>53.3</b>
	GSO	9.76x10 <sup>6</sup>	8.23x10 <sup>5</sup>	526.2	44.37	2350.7	964.7	1408.2	234.7
BSpot2	GA	1.53x10 <sup>7</sup>	1.55x10 <sup>6</sup>	320.6	32.56	2380.4	666.9	<b>2083.4</b>	<b>1271.3</b>
	DE	1.45x10 <sup>7</sup>	1.53x10 <sup>6</sup>	305.3	32.16	1885.3	468.9	1537.4	889.1
	PSO	<b>1.11x10<sup>7</sup></b>	<b>4.57x10<sup>5</sup></b>	<b>233.6</b>	<b>9.59</b>	<b>1558.0</b>	<b>237.6</b>	2027.1	563.8
	GSO	1.19x10 <sup>7</sup>	6.31x10 <sup>5</sup>	249.3	13.25	1722.8	167.6	1737.1	954.5
BSpot3	GA	6.92x10 <sup>6</sup>	6.23x10 <sup>5</sup>	248.7	22.42	1951.8	1030.8	750.52	627.6
	DE	7.52x10 <sup>6</sup>	1.19x10 <sup>6</sup>	270.4	42.63	1275.4	554.3	448.5	448.9
	PSO	6.29x10 <sup>6</sup>	1.01x10 <sup>6</sup>	226.2	36.26	<b>1131.3</b>	<b>315.2</b>	645.6	519.1
	GSO	<b>5.64x10<sup>6</sup></b>	<b>4.06x10<sup>5</sup></b>	<b>202.8</b>	<b>14.60</b>	1632.5	297.3	<b>1059.1</b>	<b>183.0</b>
BSpot4	GA	1.60x10 <sup>7</sup>	1.24x10 <sup>6</sup>	447.3	34.71	2135.4	315.6	1696.7	746.0
	DE	1.49x10 <sup>7</sup>	1.50x10 <sup>6</sup>	416.8	41.79	2092.5	304.7	1724.2	779.3
	PSO	<b>1.14x10<sup>7</sup></b>	<b>3.05x10<sup>5</sup></b>	<b>319.0</b>	<b>8.51</b>	<b>1614.2</b>	<b>33.22</b>	<b>2348.4</b>	<b>161.6</b>
	GSO	1.22x10 <sup>7</sup>	7.00x10 <sup>5</sup>	341.0	19.56	1745.6	149.4	1951.6	382.7
LSmut1	GA	1.74x10 <sup>7</sup>	1.45x10 <sup>6</sup>	316.3	26.45	1309.6	1089.3	258.5	189.5
	DE	1.86x10 <sup>7</sup>	1.03x10 <sup>6</sup>	338.9	18.83	<b>1018.1</b>	<b>304.4</b>	<b>641.6</b>	<b>486.3</b>
	PSO	<b>1.39x10<sup>7</sup></b>	<b>6.41x10<sup>5</sup></b>	<b>253.7</b>	<b>11.67</b>	1109.7	339.4	627.7	312.8
	GSO	1.43x10 <sup>7</sup>	1.04x10 <sup>6</sup>	259.8	18.99	1076.2	333.2	588.7	288.3
LSmut2	GA	2.03x10 <sup>7</sup>	1.90x10 <sup>6</sup>	680.4	63.71	2564.6	878.2	1871.7	1013.3
	DE	2.14x10 <sup>7</sup>	1.50x10 <sup>6</sup>	716.4	50.20	2850.8	1083.9	1583.4	821.6
	PSO	<b>1.54x10<sup>7</sup></b>	<b>1.63x10<sup>6</sup></b>	<b>517.0</b>	<b>54.64</b>	<b>1733.9</b>	<b>716.1</b>	<b>2473.7</b>	<b>268.0</b>
	GSO	1.64x10 <sup>7</sup>	1.35x10 <sup>6</sup>	549.1	45.02	1950.5	446.5	2061.6	519.4
LSmut3	GA	5.64x10 <sup>6</sup>	3.78x10 <sup>5</sup>	202.7	13.58	1829.3	614.4	714.83	606.1
	DE	6.19x10 <sup>6</sup>	5.04x10 <sup>5</sup>	222.7	18.11	1960.8	368.0	872.1	967.7
	PSO	4.54x10 <sup>6</sup>	7.71x10 <sup>5</sup>	163.2	27.71	1194.2	320.9	866.7	483.7
	GSO	<b>4.28x10<sup>6</sup></b>	<b>2.60x10<sup>5</sup></b>	<b>153.7</b>	<b>9.35</b>	<b>1125.8</b>	<b>166.7</b>	<b>1017.3</b>	<b>331.3</b>
LSmut4	GA	4.42x10 <sup>6</sup>	3.29x10 <sup>5</sup>	158.8	11.84	2083.3	889.0	608.04	427.0
	DE	4.53x10 <sup>6</sup>	5.85x10 <sup>5</sup>	162.8	21.02	1929.1	1451.9	524.4	339.7
	PSO	3.76x10 <sup>6</sup>	6.85x10 <sup>5</sup>	135.3	24.62	1257.3	417.5	487.5	240.9
	GSO	<b>3.38x10<sup>6</sup></b>	<b>1.35x10<sup>5</sup></b>	<b>121.5</b>	<b>4.86</b>	<b>1020.3</b>	<b>287.4</b>	<b>715.1</b>	<b>150.4</b>

**Tabela 4. Avaliação Global: Rank médio do teste Friedman/Nemenyi por métrica, com uma Distância Crítica  $CD = 1.3540$ . Valores baixos de rank para  $J$ ,  $J_{e_2}$  e  $D_{max}$  indicam melhores soluções (métricas de *minimização*), enquanto valores altos de rank para o  $D_{min}$  indicam melhores soluções (métrica de *maximização*).**

Algoritmo	Rank <sub><math>J</math></sub>	Rank <sub><math>J_{e_2}</math></sub>	Rank <sub><math>D_{max}</math></sub>	Rank <sub><math>D_{min}</math></sub>
GA	28.5125	28.5125	26.9458	17.6542
DE	30.0583	30.0583	26.3083	18.3583
PSO	<b>11.9958</b>	<b>11.9958</b>	<b>14.0958</b>	<b>23.4042</b>
GSO	<b>11.4333</b>	<b>11.4333</b>	<b>14.6500</b>	<b>22.5833</b>

e quatro diferentes métricas de avaliação foram empregadas. Os resultados experimentais demonstram a capacidade dos EAs na realização da tarefa de sementação automática das lesões nas plantas, tendo os algoritmos PSO e GSO obtido os melhores valores nos experimentos para as métricas avaliadas.

Como trabalhos futuros, pretendemos ampliar a análise realizada com o estudo de novos algoritmos evolucionários e pelo aumento da quantidade de imagens testadas. O trabalho será também extendido pelo estudo de imagens de doenças em outras espécies de plantas. Por fim, pretendemos ainda desenvolver um sistema completo e automático de categorização das doenças em imagens de plantas.

## Referências

- Abdel-Kader, R. F. (2010). Genetically improved pso algorithm for efficient data clustering. In *Machine Learning and Computing (ICMLC), 2010 Second International Conference on*, pages 71–75. IEEE.
- Asuncion, A. and Newman, D. (2007). Uci machine learning repository.
- Barbedo, J. G. A., Koenigkan, L. V., Halfeld-Vieira, B. A., Costa, R. V., Nechet, K. L., Godoy, C. V., Junior, M. L., Patricio, F. R. A., Talamini, V., Chitarra, L. G., et al. (2018). Annotated plant pathology databases for image-based detection and recognition of diseases. *IEEE Latin America Transactions*, 16(6):1749–1757.
- Chen, C.-Y. and Ye, F. (2004). Particle swarm optimization algorithm and its application to clustering analysis. In *Networking, Sensing and Control, 2004 IEEE International Conference on*, volume 2, pages 789–794. IEEE.
- Demšar, J. (2006). Statistical comparisons of classifiers over multiple data sets. *The Journal of Machine Learning Research*, 7:1–30.
- Eiben, A. E. and Smith, J. E. (2010). *Introduction to evolutionary computing*, volume 2. Springer Berlin.
- Friedman, M. (1937). The use of ranks to avoid the assumption of normality implicit in the analysis of variance. *Journal of the american statistical association*, 32(200):675–701.
- He, S., Wu, Q. H., and Saunders, J. (2009). Group search optimizer: an optimization algorithm inspired by animal searching behavior. *IEEE Transactions on Evolutionary Computation*, 13(5):973–990.
- Holland, J. H. (1992). Genetic algorithms. *Scientific american*, 267(1):66–72.

- Hruschka, E. R., Campello, R. J., Freitas, A. A., et al. (2009). A survey of evolutionary algorithms for clustering. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 39(2):133–155.
- Kennedy, J. and Eberhart, R. (1995). Particle swarm optimization. In *Neural Networks, 1995. Proceedings., IEEE International Conference on*, volume 4, pages 1942–1948. IEEE.
- Lee, S. H., Chan, C. S., Wilkin, P., and Remagnino, P. (2015). Deep-plant: Plant identification with convolutional neural networks. In *2015 IEEE international conference on image processing (ICIP)*, pages 452–456. IEEE.
- Nemenyi, P. (1962). Distribution-free multiple comparisons. In *Biometrics*, volume 18, page 263. International Biometric Soc 1441 I ST, NW, Suite 700, Washington, DC 20005-2210.
- Pacifico, L. D. S., Britto, L. F. S., Oliveira, E. G., and Ludermir, T. B. (2019). Automatic classification of medicinal plant species based on color and texture features. In *2019 8th Brazilian Conference on Intelligent Systems (BRACIS)*, pages 741–746. IEEE.
- Pacifico, L. D. S. and Ludermir, T. B. (2014). A group search optimization method for data clustering. In *Intelligent Systems (BRACIS), 2014 Brazilian Conference on*, pages 342–347. IEEE.
- Pacifico, L. D. S. and Ludermir, T. B. (2018). Hybrid k-means and improved group search optimization methods for data clustering. In *2018 International Joint Conference on Neural Networks (IJCNN)*, pages 1–8. IEEE.
- Pacifico, L. D. S. and Ludermir, T. B. (2019). Hybrid k-means and improved self-adaptive particle swarm optimization for data clustering. In *2019 International Joint Conference on Neural Networks (IJCNN)*, pages 1–7. IEEE.
- Prajapati, H. B., Shah, J. P., and Dabhi, V. K. (2017). Detection and classification of rice plant diseases. *Intelligent Decision Technologies*, 11(3):357–373.
- Sawarkar, V. and Kawathekar, S. (2018). A review: Rose plant disease detection using image processing. *IOSR Journal of Computer Engineering (IOSR-JCE) e-ISSN*, pages 2278–0661.
- Solanke, S., Mehare, P., Shinde, S., Ingle, V., and Zope, S. (2018). Iot based crop disease detection and pesting for greenhouse-a review. In *2018 3rd International Conference for Convergence in Technology (I2CT)*, pages 1–4. IEEE.
- Storn, R. and Price, K. (1995). Differential evolution—a simple and efficient adaptive scheme for global optimization over continuous spaces. international computer science institute, berkeley. Technical report, CA, 1995, Tech. Rep. TR-95–012.
- Tanmayee, P. (2017). Rice crop monitoring system—a lot based machine vision approach. In *2017 International Conference on Nextgen Electronic Technologies: Silicon to Software (ICNETS2)*, pages 26–29. IEEE.
- Wong, M. T., He, X., and Yeh, W.-C. (2011). Image clustering using particle swarm optimization. In *Evolutionary Computation (CEC), 2011 IEEE Congress on*, pages 262–268. IEEE.