

## Comparison of Extreme Learning Machine (ELM) and Multi-Support Vector Machine (Multi-SVM) Methods in Herbal Plants Identification

### Komparasi Metode *Extreme Learning Machine* (ELM) dan *Multi-Support Vector Machine* (Multi-SVM) pada Identifikasi Tanaman Herbal.

Luluk Sarifah<sup>\*1</sup>, Lailiyatus Sa'adah<sup>2</sup>, Iis Setiana<sup>3</sup>

<sup>13</sup> Program Studi Matematika, Fakultas Mipa, Universitas Annuqayah

<sup>2</sup> Program Studi Teknologi Informasi, Fakultas Teknik, Universitas Annuqayah

\*Corresponding Author

Email: <sup>1</sup>lu2ksarifah@istannuqayah.ac.id, <sup>2</sup>nailiaeljafar@gmail.com, <sup>3</sup>iissetianajay@gmail.com

Received: 8 September 2024, revised: 14 November 2024, accepted: 28 November 2024

#### Abstract

In Indonesia, there are more than 2.039 species of herbal medicinal plants, which sometimes have similarities and make it difficult to identify the type of herbal plant. The purpose of this study is to facilitate the identification of herbal plant species by comparing the performance of the Extreme Learning Machine (ELM) and Multi-Support Vector Machine (Multi-SVM) methods. The ELM method was created to overcome the weaknesses of feedforward artificial neural networks, especially in terms of learning speed, while the Multi-SVM method is an advanced development of the SVM method. The stages of this research begin with image input which is through previous data acquisition, data preprocessing, and then the identification with ELM and Multi-SVM methods. Based on the simulations that have been carried out, the average accuracy on training data for the ELM method is 93%, while the Multi-SVM method is 44%. Also, the average accuracy on testing data for the ELM method is 85%, while the Multi-SVM method is 40%.

**Keywords:** Identification, Comparison, Herbal Plants, ELM, Multi-SVM.

#### Abstrak

Di Indonesia, terdapat lebih dari 2.039 spesies tumbuhan obat herbal yang terkadang memiliki kemiripan dan menyulitkan dalam mengidentifikasi jenis tanaman herbal. Tujuan dari penelitian ini untuk memudahkan dalam mengidentifikasi jenis tanaman herbal dengan membandingkan kinerja metode *Extreme Learning Machine* (ELM) dan *Multi-Support Vector Machine* (Multi-SVM). Metode ELM dibuat untuk mengatasi kelemahan-kelemahan dari jaringan syaraf tiruan *feedforward* terutama dalam hal *learning speed*, sedangkan metode Multi-SVM merupakan



pengembangan lanjutan dari metode SVM. Tahapan penelitian ini diawali dengan *input* citra yang mana melalui akuisisi data sebelumnya, *preprocessing* data, kemudian identifikasi dengan metode ELM dan Multi-SVM. Berdasarkan simulasi yang telah dilakukan, rata-rata akurasi pada data *training* untuk metode ELM adalah 93%, sedangkan metode Multi-SVM adalah 44%. Adapun rata-rata akurasi pada data testing untuk metode ELM adalah 85%, sedangkan metode Multi-SVM adalah 40%.

**Kata Kunci:** Identifikasi, Komparasi, Tanaman Herbal, ELM, Multi-SVM

## 1. PENDAHULUAN

Tanaman herbal merupakan jenis tumbuhan yang dipercaya memiliki kandungan senyawa tertentu untuk mengatasi berbagai macam keluhan kesehatan. Salah satu bagian tanaman yang bermanfaat untuk kesehatan adalah daun, yang mana daun juga lebih mudah didapatkan dibandingkan bagian tanaman lainnya. Secara turun-temurun, masyarakat Indonesia memanfaatkan tanaman herbal untuk dijadikan pembuatan obat tradisional, bahkan dengan kemajuan teknologi, juga sudah dimanfaatkan pada bidang industri farmasi yang berkhasiat bagi kesehatan. Di Indonesia ada sekitar 38.000 spesies tanaman dengan lebih dari 2.039 spesies merupakan jenis dari tumbuhan obat herbal [9]. Meskipun terdapat beragam jenis tanaman herbal, masyarakat masih minim pengetahuan mengenai jenis dan tumbuhan tanaman herbal, dikarenakan banyaknya jenis tanaman herbal dengan tingkat kemiripan yang tinggi.

Beberapa cabang ilmu biologi seperti *cell biology*, *molecular biology*, *phytochemistry*, atau *morphologic anatomy* memungkinkan seseorang membedakan jenis tanaman tanpa kendala waktu. Namun, tidak semua masyarakat memiliki pengetahuan serta keahlian dalam bidang ilmu tersebut [4], [10]. Proses identifikasi secara manual membutuhkan waktu yang lama, tergolong mahal, membutuhkan bantuan para ahli dan pengetahuan sebelumnya [11], [14], [17]. Kesalahan identifikasi tanaman herbal bisa berakibat fatal bagi yang mengkonsumsi, bahkan dapat mengakibatkan kematian [19]. Untuk menghindari kesalahan dalam identifikasi tanaman herbal, masyarakat memilih menggunakan obat-obat kimia yang lebih mudah dan praktis, sehingga ribuan tanaman herbal berpotensi terbuang karena dianggap sebagai tanaman liar [22]. Oleh karena itu diperlukan sebuah sistem pengenalan tanaman herbal yang dapat menambah pengetahuan dengan memberikan kemudahan dalam mengenali dan menemukan jenis tanaman herbal.

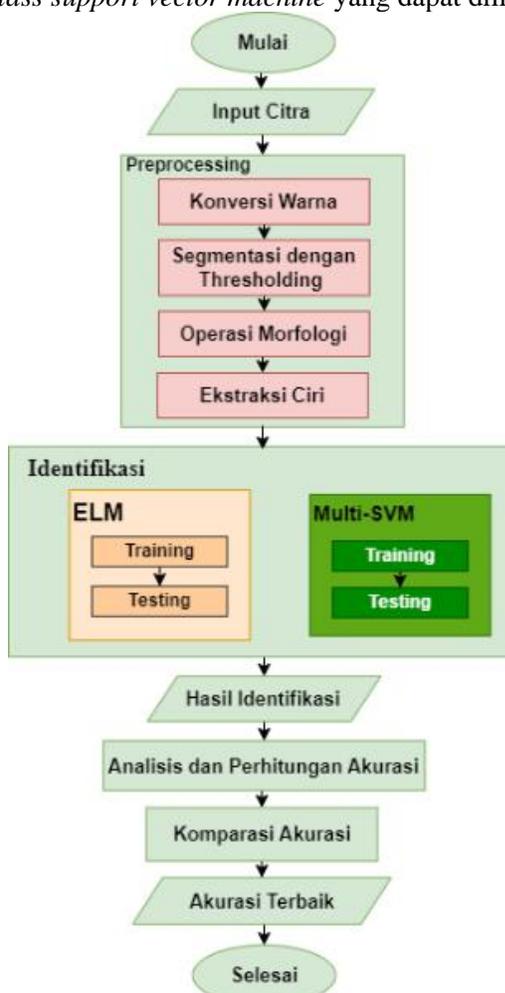
Penelitian ini menyajikan hasil implementasi dan analisis kinerja dari metode *Extream Learning Machine* (ELM) dan Metode *Multiclass Support Vector Machine* (Multi-SVM) untuk mengidentifikasi tanaman herbal, terutama tanaman herbal yang ada di Indonesia. Tujuan dari penelitian ini untuk memudahkan dalam mengidentifikasi jenis tanaman herbal menggunakan *machine learning* dan citra digital dengan membandingkan kinerja metode *Extreme Learning Machine* (ELM) dan *Multi-Support Vector Machine* (Multi-SVM), sehingga dapat diperoleh metode yang paling efektif dan efisien untuk identifikasi tanaman herbal.

Beberapa peneliti telah menggunakan metode ELM dan Multi-SVM pada klasifikasi dan identifikasi tanaman herbal dengan hasil yang cukup bagus, namun hanya menggunakan 5 dan 6 jenis tanaman herbal [2], [18]. Peneliti lain menggunakan metode ELM dengan data citra digital dan diperoleh hasil yang cukup bagus [8], [13], [20]. Adapun penelitian lain terkait penerapan metode Multi-SVM yaitu, oleh Sari dan Sari [21], dimana dalam penelitian tersebut mengidentifikasi jenis bunga berbasis ekstraksi ciri orde satu dan didapatkan hasil akurasi sebesar 90.6667%. Putra dkk [16], penelitian tersebut menggunakan *Multiclass SVM* pada rekomendasi obat bebas dan obat bebas terbatas berdasarkan gejala penyakit dan diperoleh rata-rata akurasi 88,33%.

Proses identifikasi tanaman herbal diawali dengan pengambilan data daun dari tanaman herbal dan dikonversi dalam bentuk citra digital, kemudian di-*preprocessing* untuk memperbaiki kualitas citra, *preprocessing* dalam penelitian ini dimulai dengan melakukan segmentasi menggunakan metode *thresholding* untuk mempermudah pemisahan *background* dan *foreground*, operasi morfologi untuk memperbaiki bentuk citra, kemudian dilanjutkan dengan ekstraksi ciri. Setelah *preprocessing* dilakukan, dilanjutkan pada identifikasi dengan metode *Extreme learning machine* dan metode *Multiclass support vector machine*. Adapun setiap metode identifikasi baik ELM dan Multi-SVM, keduanya diproses melalui tahapan *training* dan *testing* untuk mendapatkan hasil akurasi.

## 2. METODOLOGI PENELITIAN

Berikut diagram alir dari identifikasi tanaman herbal dengan membandingkan metode *Extreme learning machine* dan *Multiclass support vector machine* yang dapat dilihat pada Gambar 2.1



**Gambar 2.1.** Diagram alir identifikasi tanaman herbal

Adapun tahapan dari Gambar 2.1 adalah sebagai berikut:

1. *Input* data citra daun tanaman herbal

Jenis tanaman herbal pada data citra daun yang digunakan berdasarkan buku “100 Top Tanaman Obat Indonesia [12] dan penelitian-penelitian sebelumnya, kemudian dipilih berdasarkan daun berkhasiat obat yang mudah ditemui. Simulasi pada program dilakukan pada gambar berekstensi *png*. Gambar yang digunakan telah tersimpan dalam penyimpanan komputer yang diperoleh melalui pengambilan citra secara mandiri menggunakan kamera dengan intensitas cahaya yang sama dan dari internet, dimana gambar-gambar tersebut dipotong (*crop*) menggunakan *PhotoScape* untuk menyamakan ukurannya menjadi ukuran piksel  $300 \times 300$ , kemudian data citra dibagi ke dalam dua kelompok yaitu data *training* dan data *testing*. Berikut beberapa tampilan dari data set gambar yang digunakan untuk simulasi yang dapat dilihat pada Gambar 2.2.



Gambar 2.2. Contoh data set

## 2. Preprocessing

Proses *pre-processing* citra yang bertujuan memperbaiki kualitas dan mempertajam fitur-fitur dari citra yang diinputkan. Teknik yang digunakan adalah mengkonversi ruang warna citra RGB menjadi HSV, mengekstrak komponen V (*value*) pada citra HSV, melakukan segmentasi citra menggunakan metode *thresholding* terhadap komponen *value* dan mengubahnya menjadi bentuk citra biner, melakukan *median filtering*, melakukan operasi morfologi dengan *filling holes* yang dilanjutkan dengan operasi morfologi area *opening* dan setelah itu operasi morfologi area *closing* untuk menyempurnakan hasil segmentasi, kemudian diekstraksi ciri morfologi berdasarkan nilai *area*, *perimeter*, *eccentricity*, *major axis length*, dan *minor axis length* [15].

## 3. Identifikasi

Proses identifikasi menggunakan metode *Extreme learning machine* (ELM) dan metode *Multiclass support vector machine* (Multi-SVM), dimana masing-masing metode memiliki dua tahapan proses yaitu *training* (pelatihan) dan *testing* (pengujian).

### a. Extreme Learning Machine

Metode ELM memiliki model matematis yang berbeda dari jaringan syaraf tiruan *feedforward*, dimana model matematis dari ELM lebih sederhana dan efektif [3]. Untuk  $N$  pasangan *input* dan *target output* yang berbeda  $(x_i, t_i)$ , dengan  $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$  dan  $t_i = [t_{i1}, t_{i2}, \dots, t_{in}]^T \in R^m$ , standar SLFNs dengan jumlah *hidden nodes* sebanyak  $\tilde{N}$  dan fungsi aktivasi  $g(x)$  dapat dimodelkan secara matematis sebagai berikut [6].

$$\sum_{i=1}^{\tilde{N}} \beta_i g(w_i \cdot x_j + b_i) = o_j, \quad j = 1, 2, \dots, N \quad (2.1)$$

dimana:

$w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$  merupakan vektor bobot yang menghubungkan *hidden node* ke- $i$  dan *input nodes*.

$\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$  merupakan vektor bobot yang menghubungkan *hidden node* ke- $i$  dan *output nodes*.

$b_i$  merupakan *bias* dari *hidden node* ke- $i$

$w_i \cdot x_j$  merupakan *inner product* dari  $w_i$  dan  $x_j$

SLFNs standar dengan  $\tilde{N}$  *hidden nodes* dan fungsi aktivasi  $g(x)$  diasumsikan dapat memperkirakan  $N$  sampel dengan tingkat *error* 0 yang artinya  $\sum_{j=1}^N \|o_j - t_j\| = 0$ , sehingga terdapat  $\beta_i, w_i$ , dan  $b_i$  sedemikian hingga [7]

$$\sum_{i=1}^{\tilde{N}} \beta_i g(w_i \cdot x_j + b_i) = t_j, \quad j = 1, 2, \dots, N \quad (2.2)$$

Persamaan (2.2) dapat dituliskan secara sederhana sebagai [7]:

$$H\beta = T \quad (2.3)$$

dimana:

$$H = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \cdots & g(w_{\tilde{N}} \cdot x_1 + b_{\tilde{N}}) \\ \vdots & \ddots & \vdots \\ g(w_1 \cdot x_N + b_1) & \cdots & g(w_{\tilde{N}} \cdot x_N + b_{\tilde{N}}) \end{bmatrix}$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_{\tilde{N}}^T \end{bmatrix} \text{ dan } T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}$$

dengan:

$H$  : Matriks *output* pada *hidden layer*

$w$  : Vektor bobot yang menghubungkan *hidden node* dan *input node*

$x$  : Vektor *input*

$b$  : Bias yang terhubung dengan *hidden node*

$\beta$  : Vektor bobot yang menghubungkan *hidden node* dan *output node* atau disebut sebagai matriks dari bobot *output*

$T$  : matriks target

$g(w_i \cdot x_j + b_i)$  : *output* dari *hidden neuron* yang berhubungan dengan *input*  $x_j$

Pada metode ELM, *input weight* dan *hidden bias* ditentukan secara *random*, sehingga bobot *output* yang berhubungan dengan *hidden layer* dapat diperoleh dari Persamaan (2.4) [7]:

$$\beta = H^\dagger T \quad (2.4)$$

dengan  $H^\dagger$  adalah *pseudoinvers* dari matriks.

#### b. Support Vector Machine

Metode SVM memiliki konsep mencari *hyperplane* terbaik yang berfungsi sebagai pemisah dua buah kelas pada *input space* [5]. Penjabaran secara singkat algoritma SVM adalah sebagai berikut:

- 1) *Input data*: diberikan dataset dengan label, data yang tersedia dinotasikan sebagai  $x_i$ , sedangkan label masing-masing dinotasikan dengan  $y_i$  untuk  $i = 1, 2, \dots, l$  yang mana  $l$  adalah banyaknya data.
- 2) Mencari *hyperplane*: algoritma akan mencari *hyperplane* (garis atau bidang pemisah) yang memisahkan kelas dengan *margin* maksimal. *Hyperplane* ini memenuhi persamaan berikut [1]:

$$w \cdot x + b = 0 \quad (2.5)$$

dengan:

$w$  = vektor bobot

$x$  = vektor fitur

$b =$  bias

- 3) Memaksimalkan *margin* yaitu jarak terdekat antara *hyperlane* dengan data. Data yang berada di tepi *margin* disebut *support vectors*.
- 4) Mencari solusi optimum, dengan meminimalkan fungsi objektif [1]

$$\min\left(\frac{1}{2} \|w\|^2\right) \quad (2.6)$$

dengan batasan bahwa setiap titik data memenuhi:

$$y_i(w \cdot x_i + b) \geq 1 \quad (2.7)$$

dimana  $y_i$  adalah label dari titik  $x_i$ .

- 5) *Kernel trick*: jika data tidak linier, SVM menggunakan *kernel trick* untuk memetakan data ke dimensi yang lebih tinggi sehingga data dapat dipisahkan dengan *hyperplane*. Dalam penelitian ini menggunakan kernel *Radial basis function*.

- 6) *Output*: Model SVM menghasilkan *hyperplane* optimal yang dapat digunakan untuk memprediksi label dari data baru dengan mengevaluasi posisi data terhadap *hyperplane*.

Menurut Hilmiyah [5], dalam *Multiclass Support Vector Machine* ada dua pilihan, yaitu dengan menggabungkan beberapa SVM biner atau menggabungkan semua data yang terdiri dari beberapa kelas ke dalam sebuah bentuk permasalahan optimal. Namun pada pendekatan yang kedua permasalahan optimasi yang harus diselesaikan jauh lebih rumit. Berikut ini adalah metode yang umum digunakan untuk mengimplementasikan multiclass SVM dengan pendekatan yang pertama:

- a) Metode *one-against-all* (satu lawan semua). Dengan menggunakan metode ini, dibangun  $k$  buah model SVM biner ( $k$  adalah jumlah kelas).
- b) Metode *one-against-one* (satu lawan satu). Dengan menggunakan metode ini, dibangun  $k(k - 1)/2$  buah model klasifikasi biner ( $k$  adalah jumlah kelas).

#### 4. Menganalisa dan mengevaluasi hasil

Hasil dari setiap metode dihitung nilai akurasi, akurasi yang diperoleh bisa dari proses *training* dan *testing* dari masing-masing metode. Berikut rumus yang digunakan untuk menghitung akurasi identifikasi [20]:

$$\text{akurasi} = \frac{\text{citra identifikasi benar}}{\text{banyaknya data citra}} \times 100\% \quad (2.8)$$

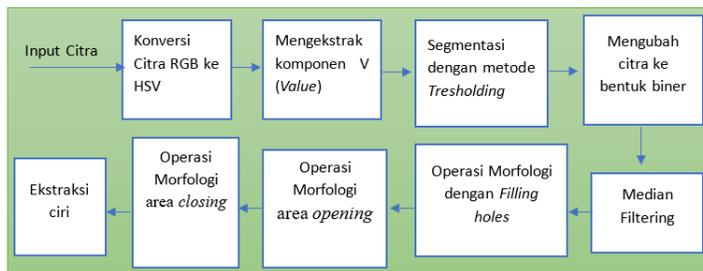
#### 5. Membandingkan hasil akurasi metode ELM dan Multi-SVM

#### 6. Memperoleh analisis dan metode terbaik dalam mengidentifikasi tanaman herbal

### 3. HASIL DAN PEMBAHASAN

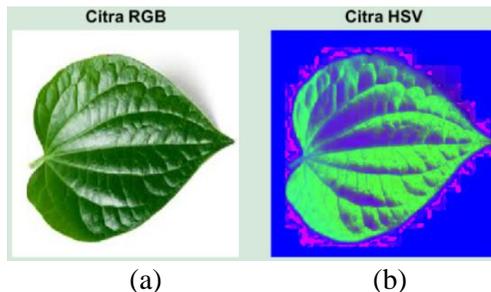
#### 3.1. *Preprocessing data*

Sebelum identifikasi tanaman herbal, citra yang sudah diinputkan harus melalui proses *preprocessing* terlebih dahulu. Berikut urutan proses *preprocessing* yang mana termasuk dalam proses pengenalan objek, dapat dilihat pada Gambar 3.1 [20].



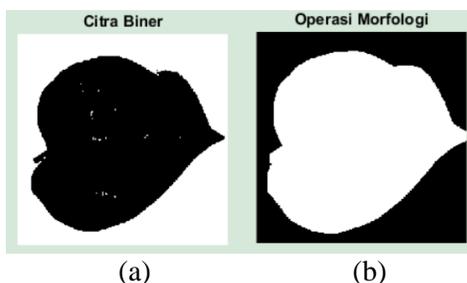
**Gambar 3.1.** Blok diagram proses pengenalan objek

Berdasarkan Gambar 3.1, berikut tahapan hasil dari *preprocessing* data yaitu: citra daun yang di-*inputkan* berupa citra RGB dengan ukuran piksel  $300 \times 300$  dikonversi ke citra HSV yang selanjutnya hanya menggunakan komponen V (*value*) untuk proses segmentasi. Hasil dari citra RGB yang dikonversi ke HSV dapat dilihat pada Gambar 3.2.



**Gambar 3.2.** (a). Citra *input* RGB, (b). Citra hasil konversi RGB ke HSV

Selanjutnya, setelah diperoleh citra HSV dan hanya komponen *value* yang digunakan untuk segmentasi menggunakan metode *Thresholding* yang hasilnya dapat dilihat pada gambar 3.3 (a) berupa citra biner, citra biner yang diperoleh di-*smoothing* dengan metode *median filtering* dan dilakukan operasi morfologi dengan *filling holes*, yang dilanjutkan dengan operasi morfologi *area opening* dan setelah itu operasi morfologi *area closing*. Hasil dari operasi morfologi dapat dilihat pada Gambar 3.3 (b).



**Gambar 3.3.** (a). Citra hasil segmentasi, (b). Citra hasil operasi morfologi

Untuk menyempurnakan hasil segmentasi dilakukan ekstraksi ciri morfologi berdasarkan nilai *area*, *perimeter*, *eccentricity*, *major axis length*, dan *minor axis length*, yang mana hasil ekstraksi ciri dapat dilihat pada Gambar 3.4.

Hasil Ekstraksi Ciri		
	Ciri	Nilai
1	Area	52012
2	Perimeter	865.3570
3	Eccentrici...	0.5221
4	Major Axi...	281.9728
5	Minor Axi...	240.4948

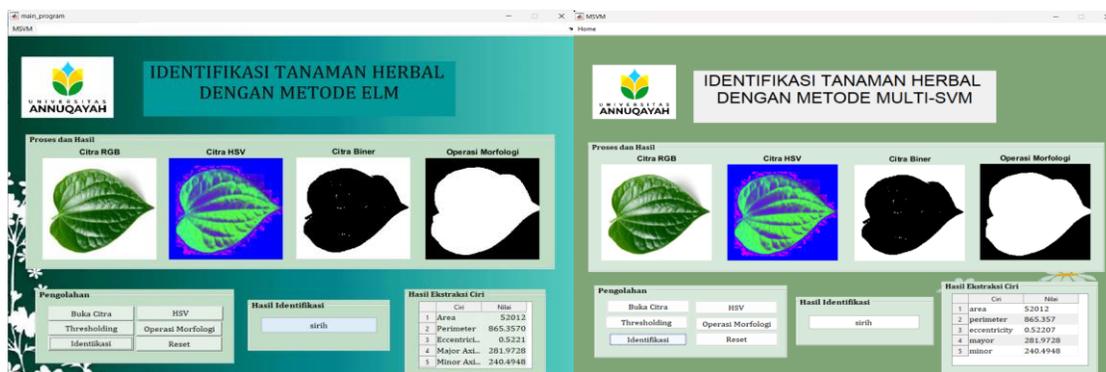
Gambar 3.4. Hasil ekstraksi ciri

Gambar 3.4 merupakan hasil dari ekstraksi ciri, yang mana keseluruhan dari *preprocessing* data merupakan tahapan dalam pengenalan pola, sehingga dapat membedakan bentuk objek satu dengan objek lainnya untuk dijadikan *input* pada proses identifikasi.

### 3.2. Identifikasi Tanaman Herbal

#### 3.2.1 Tampilan Simulasi Identifikasi Tanaman Herbal dengan metode ELM dan Multi-SVM

Simulasi identifikasi tanaman herbal menggunakan MATLAB R2021a dengan membuat *Graphical User Interface* (GUI). Pada Gambar 3.5 menampilkan simulasi identifikasi tanaman herbal dengan antarmuka sistem yang memiliki tampilan dengan nama *main\_program* dan *MSVM*, dan memiliki beberapa panel diantaranya panel proses dan hasil berisi tampilan dari input citra, hasil citra yang diubah dari RGB ke HSV, citra biner hasil segmentasi dengan *thresholding* dan citra hasil operasi morfologi. Panel pengolahan yang terdiri dari buka citra, HSV, *thresholding*, operasi morfologi, identifikasi dan *reset*, kemudian panel hasil identifikasi, serta panel hasil ekstraksi ciri.



Gambar 3.5. Tampilan simulasi identifikasi tanaman herbal

#### 3.2.2 Perhitungan Akurasi

Perhitungan akurasi pada identifikasi tanaman herbal dengan membandingkan metode ELM dan Multi-SVM adalah sebagai berikut:

##### 1. Identifikasi 5 Jenis Tanaman Herbal

Berikut hasil simulasi identifikasi tanaman herbal yang menggunakan 5 jenis data tanaman herbal [2], [18], [19] yang dapat dilihat pada Tabel 3.1, dimana masing-masing dari data *training* terdiri dari sepuluh data, sedangkan data *testing* masing-masing terdiri dari tiga data.

Tabel 3.1. Identifikasi tanaman herbal dengan 5 jenis data

No	Data	ELM		MSVM	
		Training	Testing	Training	Testing

		Benar	Salah	Benar	Salah	Benar	Salah	Benar	Salah
1	Mint (Mentha)	10	0	3	0	8	2	3	0
2	Murbei	10	0	3	0	6	4	2	1
3	Pegagan	10	0	3	0	7	3	1	2
4	Peterseli	10	0	3	0	5	5	1	2
5	Sirih	10	0	3	0	7	3	2	1
<b>Jumlah</b>		<b>50</b>	<b>0</b>	<b>15</b>	<b>0</b>	<b>33</b>	<b>17</b>	<b>9</b>	<b>6</b>
<b>Akurasi</b>		<b>100%</b>		<b>100%</b>		<b>66%</b>		<b>60%</b>	

Berdasarkan Tabel 3.1, untuk akurasi dari metode ELM baik data *training* maupun data *testing* diperoleh akurasi 100%, sehingga model dari ELM sangat bagus untuk mengenali lima jenis tanaman herbal. Adapun metode Multi-SVM, untuk data *training* diperoleh akurasi 66% dan *testing* 60%, sehingga model Multi-SVM kurang bagus untuk mengenali jenis tanaman herbal.

## 2. Identifikasi 10 Jenis Tanaman Herbal

Berikut hasil simulasi identifikasi tanaman herbal yang menggunakan 10 jenis data tanaman herbal yang dapat dilihat pada Tabel 3.2.

**Tabel 3.2.** Identifikasi tanaman herbal dengan 10 jenis data

No	Data	ELM				MSVM			
		Training		Testing		Training		Testing	
		Benar	Salah	Benar	Salah	Benar	Salah	Benar	Salah
1	Jelatang	9	1	3	0	9	1	3	0
2	Kelor	10	0	3	0	10	0	3	0
3	Kratom	10	0	3	0	8	2	3	0
4	Mint	10	0	3	0	5	5	1	2
5	Murbei	10	0	3	0	6	4	1	2
6	Pegagan	10	0	2	1	2	8	0	3
7	Peterseli	10	0	3	0	3	7	1	2
8	Salam	10	0	3	0	0	10	0	3
9	Sirih	10	0	3	0	2	8	0	3
10	Teh Hijau	10	0	3	0	2	8	0	3
<b>Jumlah</b>		<b>99</b>	<b>1</b>	<b>32</b>	<b>1</b>	<b>47</b>	<b>53</b>	<b>12</b>	<b>18</b>
<b>Akurasi</b>		<b>99%</b>		<b>96.667%</b>		<b>47%</b>		<b>40%</b>	

Berdasarkan Tabel 3.2, akurasi dari metode ELM pada data *training* diperoleh sebesar 99%, sedangkan data *testing* diperoleh akurasi 96.667%, sehingga model dari ELM sangat bagus untuk mengenali 10 jenis tanaman herbal. Adapun metode Multi-SVM, untuk data *training* diperoleh akurasi sebesar 47% dan *testing* 40%, sehingga model Multi-SVM kurang cocok untuk mengenali 10 jenis tanaman herbal.

## 3. Identifikasi 20 Jenis Tanaman Herbal

Berikut hasil simulasi identifikasi tanaman herbal yang menggunakan 20 jenis data tanaman herbal yang dapat dilihat pada Tabel 3.3.

**Tabel 3.3.** Identifikasi tanaman herbal dengan 20 jenis data

No	Data	ELM				MSVM			
		Training		Testing		Training		Testing	
		Benar	Salah	Benar	Salah	Benar	Salah	Benar	Salah
1	Bayam Merah	10	0	2	1	10	0	3	0
2	Beluntas	8	2	3	0	6	4	2	1

3	Binahong	9	1	2	1	8	2	3	0
4	Daun Jambu	9	1	2	1	6	4	1	2
5	Jelatang	9	1	1	2	7	3	2	1
6	Jeruk Nipis	9	1	2	1	7	3	3	0
7	Katuk	10	0	3	0	5	5	2	1
8	Kelor	9	1	2	1	5	5	1	2
9	Kratom	10	0	3	0	3	7	0	3
10	Mimba	10	0	3	0	4	6	2	1
11	Mint	9	1	1	2	3	7	1	2
12	Murbei	9	1	3	0	2	8	1	2
13	Pegagan	9	1	2	1	0	10	0	3
14	Peterseli	9	1	3	1	2	8	1	2
15	Sage	9	1	3	0	2	8	1	2
16	Salam	6	4	2	1	0	10	1	2
17	Sambiloto	9	1	2	1	0	10	0	3
18	Sembung	10	0	3	0	1	9	0	3
19	Sirih	9	1	2	1	1	9	0	3
20	Teh Hijau	10	0	1	2	0	10	0	3
<b>Jumlah</b>		<b>182</b>	<b>18</b>	<b>45</b>	<b>15</b>	<b>72</b>	<b>128</b>	<b>24</b>	<b>36</b>
<b>Akurasi</b>		<b>91%</b>		<b>75%</b>		<b>36%</b>		<b>40%</b>	

Berdasarkan Tabel 3.3, akurasi dari metode ELM pada data *training* diperoleh sebesar 91%, sedangkan data *testing* diperoleh akurasi 75%, sehingga model dari ELM cukup bagus untuk mengenali 20 jenis tanaman herbal. Adapun metode Multi-SVM, untuk data *training* diperoleh akurasi sebesar 36% dan *testing* 40%, sehingga model Multi-SVM tidak cocok untuk mengenali 20 jenis tanaman herbal. Selain itu, hasil dari akurasi *testing* atau pengujian lebih besar dibandingkan dengan pelatihan, dikarenakan data pelatihan yang sulit dipelajari oleh model.

#### 4. Identifikasi 30 Jenis Tanaman Herbal

Berikut hasil simulasi identifikasi tanaman herbal yang menggunakan 30 jenis data tanaman herbal yang dapat dilihat pada Tabel 3.4.

**Tabel 3.4.** Identifikasi tanaman herbal dengan 30 jenis data

No	Data	ELM				MSVM			
		Training		Testing		Training		Testing	
		Benar	Salah	Benar	Salah	Benar	Salah	Benar	Salah
1	Bayam Merah	10	0	2	1	10	0	3	0
2	Beluntas	8	2	2	1	8	2	2	1
3	Binahong	7	3	2	1	8	2	3	0
4	Daun Asam Jawa	10	0	2	1	8	2	3	0
5	Daun Bidara	8	2	2	1	8	2	2	1
6	Daun Jambu	7	3	3	0	7	3	2	1
7	Daun Kopi	7	3	1	2	6	4	0	3
8	Daun pare	7	3	3	0	3	7	0	3
9	Daun Pepaya	10	0	2	1	5	5	1	2
10	Daun Sirsak	8	2	1	2	3	7	0	3
11	Jelatang	7	3	2	1	2	8	1	2
12	Jeruk Nipis	8	2	2	1	3	7	0	3

13	Katuk	10	0	3	0	3	7	1	2
14	Kelor	7	3	2	1	1	9	0	3
15	Kemangi	10	0	1	2	0	10	0	3
16	Kratom	10	0	3	0	0	10	0	3
17	Kumis Kucing	7	3	3	0	0	10	0	3
18	Lidah Buaya	9	1	1	2	0	10	0	3
19	Mimba	9	1	3	0	0	10	0	3
20	Mint	8	2	1	2	0	10	0	3
21	Murbei	7	3	3	0	0	10	0	3
22	Pegagan	9	1	2	1	0	10	0	3
23	Peterseli	9	1	3	0	0	10	0	3
24	Sage	8	2	3	0	0	10	0	3
25	Salam	4	6	2	1	0	10	0	3
26	Sambiloto	4	6	2	1	0	10	0	3
27	Sembung	10	0	3	0	0	10	0	3
28	Sereh	7	3	2	1	0	10	0	3
29	Sirih	7	3	2	1	0	10	0	3
30	Teh Hijau	9	1	1	2	0	10	0	3
<b>Jumlah</b>		<b>241</b>	<b>59</b>	<b>64</b>	<b>26</b>	<b>75</b>	<b>225</b>	<b>18</b>	<b>72</b>
<b>Akurasi</b>		<b>80.33%</b>	<b>68.8%</b>			<b>25%</b>		<b>20%</b>	

Berdasarkan tabel 3.4, akurasi dari metode ELM pada data *training* diperoleh sebesar 80.33%, sedangkan data *testing* diperoleh akurasi 68.8%, sehingga model dari ELM cukup bagus untuk mengenali 30 jenis tanaman herbal. Adapun metode Multi-SVM, untuk data *training* diperoleh akurasi sebesar 25% dan *testing* 20%, sehingga model Multi-SVM sangat tidak cocok untuk mengenali 30 jenis tanaman herbal, karena dari data pelatihan saja, model Multi-SVM hanya mampu mempelajari 14 data, untuk selebihnya sudah tak bisa dikenali dengan benar oleh model.

Ada beberapa faktor yang menyebabkan model Multi-SVM tidak cocok dalam identifikasi tanaman herbal pada penelitian ini, diantaranya metode *preprocessing* yang tidak cocok dengan model Multi-SVM dan data yang terlalu sedikit baik pada *training* maupun data *testing* untuk bisa dikenali model, dikarenakan pada beberapa penelitian lain metode Multi-SVM hanya menggunakan 5 jenis atau 6 jenis macam data, tapi masing-masing data untuk data *training* bisa terdiri dari puluhan data begitu juga dengan data *testing*.

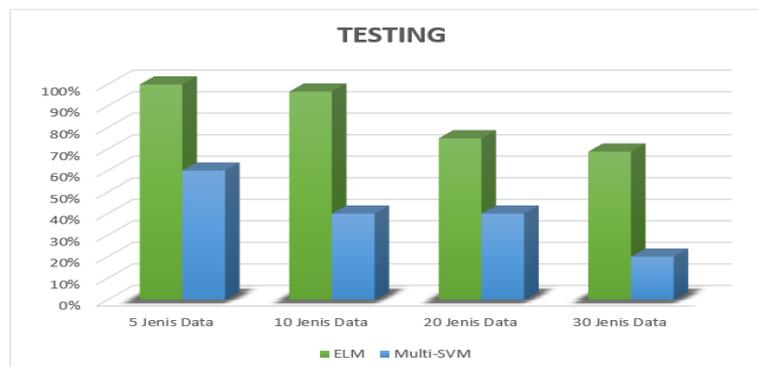
### 3.2.3 Perbandingan Akurasi Metode ELM dan Muti-SVM

Perbandingan akurasi antara metode ELM dan Multi SVM untuk data *training* dapat dilihat pada Gambar 3.6.



**Gambar 3.6.** Perbandingan akurasi pada data *training*.

Berdasarkan Gambar 3.6, dapat dilihat dari persentase akurasi masing-masing data, bahwa hasil identifikasi dengan metode ELM menghasilkan akurasi yang lebih tinggi dibandingkan dengan metode Multi-SVM, dimana rata-rata akurasi data *training* metode ELM diperoleh sebesar 93%, sedangkan Multi-SVM adalah 44%. Adapun perbandingan akurasi untuk data *testing* dapat dilihat pada Gambar 3.7.

**Gambar 3.7.** Perbandingan akurasi pada data *testing*.

Berdasarkan Gambar 3.7, hasil akurasi metode ELM juga lebih baik dibandingkan dengan metode Multi-SVM, dimana rata-rata akurasi untuk data *testing* pada metode ELM adalah 85%, sedangkan metode Multi-SVM adalah 40%. Oleh karena itu dalam penelitian ini metode ELM jauh lebih baik dibandingkan metode Multi-SVM.

#### 4. KESIMPULAN

1. Sebelum dilakukan identifikasi tanaman herbal, perlu dilakukan *preprocessing* terlebih dahulu. *Preprocessing* terdiri dari proses mengkonversi ruang warna citra RGB menjadi HSV, dimana dari citra HSV hanya mengekstrak komponen V (*value*), melakukan segmentasi citra menggunakan metode *thresholding* terhadap komponen *value* dan mengubahnya menjadi bentuk citra biner, melakukan *median filtering*, melakukan operasi morfologi dengan *filling holes* yang dilanjutkan dengan operasi morfologi area *opening* dan setelah itu operasi morfologi area *closing* untuk menyempurnakan hasil segmentasi, selanjutnya dilakukan ekstraksi ciri morfologi berdasarkan nilai *area*, *perimeter*, *eccentricity*, *major axis length*, dan *minor axis length*. Hasil dari ekstraksi ciri dijadikan nilai *input* pada proses identifikasi tanaman herbal dengan metode ELM dan metode Multi-SVM.
2. Untuk proses identifikasi dengan menggunakan ELM dan metode Multi-SVM ada dua tahapan yaitu *training* dan *testing*. Untuk identifikasi tanaman herbal menggunakan data *training* sebanyak 300 buah citra dan 90 data citra untuk proses *testing*. Kemudian untuk perhitungan akurasi dibagi dalam beberapa tahapan identifikasi yaitu identifikasi 5 jenis tanaman herbal, 10 jenis tanaman herbal, 20 jenis tanaman herbal, dan 30 jenis tanaman herbal, yang mana masing masing data *training* terdiri dari 10 data dan untuk data *testing* masing-masing terdiri dari 3 data.
3. Berdasarkan simulasi yang telah dilakukan, rata-rata akurasi metode ELM pada data *training* diperoleh 93%, sedangkan rata-rata akurasi metode Multi-SVM adalah 44%.

Adapun rata-rata akurasi pada data *testing* untuk metode ELM adalah 85%, sedangkan metode Multi-SVM adalah 40%, sehingga identifikasi tanaman herbal dengan metode ELM menghasilkan akurasi yang lebih tinggi bila dibandingkan dengan metode Multi-SVM.

## UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Direktorat Riset, Teknologi, dan Pengabdian Kepada Masyarakat, Direktorat Jenderal Pendidikan Tinggi, Riset dan Teknologi, Kementerian Pendidikan, Kebudayaan, Riset dan Teknologi Republik Indonesia atas hibah yang diberikan pada tahun anggaran 2024. Selanjutnya ucapan terima kasih kepada Lembaga Penelitian dan Pengabdian kepada Masyarakat (LPPM) Universitas Annuqayah yang telah memfasilitasi berbagai kegiatan terkait program hibah kompetitif nasional. Ucapan terima kasih juga disampaikan kepada semua pihak yang telah membantu merampungkan penelitian ini.

## DAFTAR PUSTAKA

- [1] Bishop, C., M., 2006. *A Review of Pattern Recognition and Machine Learning*, Springer, <https://doi.org/10.53759/7669/jmc202404020>.
- [2] Borman, R., I., Rossi, F. & Jusman, Y., Rahni, A., A., A, Putra, S., D. & Herdiansah, A., 2021. Identification of Herbal Leaf Types Based on Their Image Using First Order Feature Extraction and Multiclass SVM Algorithm. *2021 1st International Conference Electronic and Electrical Engineering and Intelligent System (ICE3IS)*. 1230, 12–17. <https://doi.org/10.1109/ice3is5410>
- [3] Fikriya, Z., A., Irawan, M., I. & Soetrisno, S., 2017. Implementasi Extreme Learning Machine untuk Pengenalan Objek Citra Digital. *Jurnal Sains dan Seni ITS*, Vol. 6, No. 1, <https://doi.org/10.12962/j23373520.v6i1.21754>.
- [4] Haryono., Anam, A. & Saleh, A., 2020. Autentikasi Daun Herbal Menggunakan Convolutional Neural Network dan Raspberry Pi. *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, Vol. 9, No. 3, 278–286. <https://doi.org/https://doi.org/10.22146/v9i3.302>.
- [5] Hilmiyah, F., 2017. Prediksi Kinerja Mahasiswa Menggunakan Support Vector Machine untuk Pengelola Program Studi di Perguruan Tinggi (Studi Kasus: Program Studi Magister Statistika ITS). *Tesis*. Departemen Manajemen Teknologi Bidang Keahlian Manajemen Teknologi Informasi Fakultas Bisnis Dan Manajemen Teknologi Institut Teknologi Sepuluh Nopember, Surabaya
- [6] Huang, G., Zhu, Q. & Siew, C., 2004. Extreme learning machine: a new learning scheme of feedforward neural networks, *2004 IEEE International Joint Conference on Neural Networks (IEEE Cat. No.04CH37541)*, Vol. 2, 985–990, <https://doi.org/10.1109/ijcnn.2004.1380068>
- [7] Huang, G., Zhu, Q. & Siew, C., 2006. Extreme learning machine: Theory and applications. *Neurocomputing*, Vol. 70, 489–501. <https://doi.org/10.1016/j.neucom.2005.12.126>.
- [8] Huérfano-Maldonado, Y., Mora, M., Vilches, K., Hernández-García, R., Gutiérrez, R., & Vera, M., 2023. A comprehensive review of extreme learning machine on medical imaging. *Neurocomputing*, Vol. 556, 126618. <https://doi.org/10.1016/j.neucom.2023.126618>
- [9] Ifandi, S., Jumari. & Widodo, S., W., A., 2015. Keanekaragaman Jenis Tumbuhan Obat Masyarakat Suku Kaili di Dusun Tompu Kecamatan Sigi Biromaru Kabupaten Sigi Sulawesi Tengah. *Prosiding Seminar Nasional Biologi II*, 27–31.

- [10] Jeon, W., S. & Rhee, S., Y., 2017. Plant Leaf Recognition Using A Convolution Neural Network. *International Journal of Fuzzy Logic and Intelligent Systems*, Vol 17, No. 1, 26–34. <https://doi.org/10.5391/IJFIS.2017.17.1.26>
- [11] Kaya, A., Keceli, A., S., Catal, C., Yalic, H., Y., Temucin, H. & Tekinerdogan B., 2019. Analysis Of Transfer Learning For Deep Neural Network Based Plant Classification Models. *Computurs and Electronics in Agriculture*, 20-29. <https://doi.org/10.1016/j.compag.2019.01.041>.
- [12] Kemenkes RI. 2015. *100 Top tanaman obat indonesia*. Badan Penelitian dan Pengembangan Kesehatan, Jakarta.
- [13] Mercaldo, F., Brunese, L., Martinelli, F., Santone, A. & Cesarelli, M., 2023. Experimenting with Extreme Learning Machine for Biomedical Image Classification. *Applied Sciences*. <https://doi.org/10.3390/app13148558>
- [14] Mustafa, M., S., Husin, Z., Tan, W., K., Mavi, M., F. & Farook, R., S., M., 2020. Development of automated hybrid intelligent system for herbs plant classification and early herbs plant disease detection. *Neural Computing and Applications*. <https://doi.org/10.1007/s00521-019-04634-7>.
- [15] Pamungkas, A. Klasifikasi Jenis Kendaraan Menggunakan Algoritma Extreme Learning Machine. Pemrograman Matlab, <https://pemrogramanmatlab.com/2019/04/03/klasifikasi-jenis-kendaraan-menggunakan-algoritma-extreme-learning-machine/> [14 Juni 2024].
- [16] Putra, A., P., Mulyana, I., Maryana, S. & Susanti, F. 2019. Implementasi Multiclass Support Vector Machine Pada Sistem Rekomendasi Obat Berdasarkan Gejala Penyakit. *Seminar Nasional Sains Teknologi dan Inovasi Indonesia (SENASTINDO AAU)*, Vol. 1, No. 1, 211-222.
- [17] Rajani, S. & Veena, V., M., 2018. Study on Identification and Classification of Medicinal Plants. *International Journal of Advances in Science Engineering and Technology*, Vol. 6, 13-18.
- [18] Rumandan, R., J., Nuraini, R., Sadikin, N. & Rahmanto, Y., 2022. Klasifikasi Citra Jenis Daun Berkhasiat Obat Menggunakan Algoritma Jaringan Syaraf Tiruan Extreme Learning Machine. *Journal of Computer System and Informatics (JoSYC)*, Vol. 4, No. 1, 145-154. <https://doi.org/10.47065/josyc.v4i1.2586>.
- [19] Saputra, S., K. & Perangin-Angin, M., I., 2018. Klasifikasi Tanaman Obat Berdasarkan Ekstraksi Fitur Morfologi Daun Menggunakan Jaringan Syaraf Tiruan. *Jurnal Informatika*, Vol. 5, No. 2:169–174. <https://doi.org/10.31311/ji.v5i2.3770>.
- [20] Sarifah, L., Khotijah, S. & Khaliqah, M., 2023. Identification Of Hijaiyah Letters Image Using Extreme Learning Machine Method. *Jurnal Matematika, Statistika dan Komputasi*, Vol. 20, No. 1, 90-101. <https://doi.org/10.20956/j.v20i1.27158>.
- [21] Sari, W., S., & Sari, C., A., 2023. Multi-SVM Dalam Identifikasi Bunga Berbasis Ekstraksi Ciri Orde Satu. *InComTech: Jurnal Telekomunikasi dan Komputer*, Vol. 13, No. 1, 18-27. <https://doi.org/10.22441/incomtech.v13i1.15012>.
- [22] Setiyono, B., Arif, M., R., Aini, Q., Q., Soegianto, T., H., Ohanna, J., Gunawan, R., A., F. & Rizkia, A., P., 2013. Identifikasi Tanaman Obat Indonesia Melalui Citra Daun Menggunakan Metode Convolutional Neural Network (CNN). *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, Vol. 10, No. 2, 385-392. <https://doi.org/10.25126/jtiik.20231026809>.