

Autentikasi Daun Herbal Menggunakan *Convolutional Neural Network* dan Raspberry Pi

(Authentication of Herbal Leaves Using Convolutional Neural Network and Raspberry Pi)

Haryono¹, Khairul Anam², Azmi Saleh³

Abstract—At this time, the leaf authentication method is widely used in the classification process of herbal plants. Basically, the leaf authentication method compares the image to be identified and the reference image created in the dataset. This paper aims to identify the leaves of herbal plants using an artificial intelligence method, namely Convolutional Neural Network (CNN) that is embedded on Raspberry Pi. CNN has an advantage that it does not require feature extraction, because in CNN, automatic feature extraction already exists. This paper uses seven types of leaves from different herbal plants. Leaf images are taken using a camera and processed by Raspberry Pi, which is integrated with CNN. Identification was carried out on seven types of herbal plants divided into two-thirds of training data and one-third of testing data. The identification process results will be validated with other data not included in the training data and testing data, as well as leaf data other than the seven types of leaves identified. The CNN method shows good results in the authentication process, with an accuracy rate of 93.62% for testing data offline and 91.04% for testing data online.

Intisari—Saat ini, metode autentikasi daun banyak digunakan dalam proses klasifikasi tanaman herbal. Pada dasarnya, metode autentikasi daun merupakan perbandingan antara gambar yang akan diidentifikasi dengan gambar referensi yang dibuat dalam dataset. Tujuan makalah ini adalah mengidentifikasi daun tanaman herbal menggunakan metode kecerdasan buatan, yaitu *Convolutional Neural Network* (CNN) yang ditanam pada Raspberry Pi. CNN memiliki keunggulan yaitu tidak memerlukan *feature extraction* karena di dalam CNN sudah terdapat *feature extraction* otomatis. Makalah ini menggunakan tujuh jenis daun dari tanaman herbal yang berbeda. Gambar daun diambil menggunakan kamera dan diproses oleh Raspberry Pi yang diintegrasikan dengan CNN. Identifikasi dilakukan pada tujuh jenis tanaman obat yang dibagi menjadi dua pertiga data *training* dan sepertiga data *testing*. Hasil dari proses identifikasi divalidasi dengan data lain yang tidak termasuk dalam data *training* dan data *testing*, serta data daun selain dari tujuh jenis daun yang diidentifikasi. Metode CNN menunjukkan hasil yang bagus dalam proses autentikasi dengan tingkat akurasi 93,62% untuk *testing* data secara *offline* dan 91,04 % untuk *testing* data secara *online*.

Kata Kunci— Autentikasi, *Convolutional Neural Network*, Daun Herbal, Raspberry Pi.

^{1,2,3} Jurusan Teknik Elektro Fakultas Teknik Universitas Jember, Jalan Kalimantan no.37 Kampus Tegalboto, Sumbersari, Jember, 68121 (telp: 0331-484977; fax: 0331-484977; e-mail: unmuh.haryo@gmail.com, khairul@unej.ac.id, azmi.teknikl@unej.ac.id)

I. PENDAHULUAN

Tanaman herbal merupakan tanaman yang dapat dimanfaatkan untuk alternatif penyembuhan penyakit secara alami. Sekitar 80% orang masih bergantung pada obat tradisional untuk tujuan pengobatan [1]. Salah satu bagian tanaman yang digunakan untuk kesehatan adalah daun. Tanaman herbal berperan sangat penting dalam menjaga kesehatan manusia [2]. Keberadaan tanaman herbal masih belum banyak diketahui oleh masyarakat. Hal ini disebabkan oleh banyaknya jenis tanaman obat [3], sehingga masyarakat sulit membedakan antara tanaman herbal dengan tanaman nonherbal, kecuali pada waktu-waktu tertentu, seperti ketika tanaman tersebut mekar atau berbuah. Untuk dapat membedakannya, dibutuhkan informasi yang cukup tentang tanaman herbal dan pengetahuan khusus dalam bidang tanaman herbal atau botani. Beberapa cabang ilmu biologi seperti *cell biology*, *molecular biology*, *phytochemistry*, atau *morphologic anatomy* memungkinkan seseorang membedakan jenis tanaman tanpa kendala waktu. Namun, bagi masyarakat, cabang ilmu tersebut dinilai masih kurang efisien dalam membedakan jenis tanaman. Hal tersebut dikarenakan tidak semua masyarakat memiliki pengetahuan serta keahlian dalam bidang ilmu tersebut [4]. Proses identifikasi secara manual membutuhkan waktu yang lama dan pengetahuan yang sudah ada sebelumnya [5]. Proses ini juga tergolong mahal [6] serta membutuhkan bantuan para ahli dalam identifikasi tanaman [7].

Seiring dengan perkembangan teknologi, telah banyak dilakukan penelitian untuk mengetahui jenis tanaman herbal, salah satunya adalah dengan cara melakukan identifikasi pada daun tanaman herbal tersebut. Daun memainkan peran utama dan merupakan bagian penting dari tanaman. Selain itu, daun lebih mudah didapatkan dibandingkan akar [8], karena akar adalah bagian yang tertanam di dalam tanah [9]. Identifikasi daun merupakan langkah utama dalam menentukan jenis tanaman, seperti pada tanaman herbal. Oleh sebab itu, dibutuhkan sistem pengenalan daun yang andal dan efisien untuk identifikasi tanaman herbal. Identifikasi tanaman yang cepat dan akurat sangat penting untuk pengelolaan keanekaragaman hayati yang efektif dan efisien [1]. Sebagian besar peneliti fokus pada identifikasi daun yang dalam proses identifikasinya banyak menggunakan metode klasifikasi. Hal ini bertujuan untuk mengetahui jenis tanaman herbal melalui identifikasi daun serta membantu pengguna dalam mengidentifikasi daun herbal tanpa pengetahuan khusus tentang botani.

Beberapa peneliti telah melakukan penelitian yang berbeda dalam mengidentifikasi berbagai jenis daun herbal. Sebuah penelitian mengidentifikasi 54 gambar dari tiga tanaman *ficus* menggunakan *Support Vector Machine* (SVM) dan *Artificial Neural Network* (ANN) [10]. Sistem pengolahan gambar dalam metode ini terbagi menjadi tiga tahapan, yaitu *pre-processing*, *feature extraction*, dan *recognition*. Akurasi yang dihasilkan mencapai 83,3%. Penelitian lainnya mengklasifikasi daun herbal menggunakan metode SVM [11]. Dalam penelitian tersebut, *feature extraction* gambar dilakukan menggunakan teknik *Scale Invariant Feature Transform* (SIFT). Fitur SIFT yang digunakan mampu mengatasi transformasi *affine*, *noise*, dan perubahan pencahayaan. Selanjutnya, telah dilakukan juga klasifikasi lima jenis daun yang berbeda menggunakan *Laws' mask analysis* dan SVM sebagai *classifier* [12]. Akurasi yang diperoleh adalah 90,27%. Sebuah penelitian juga telah mengidentifikasi 32 gambar dari 24 tanaman di pulau Mauritius menggunakan metode *Random Forest* dengan teknik *10 cross validation* dengan akurasi mencapai 90,1% [13], sedangkan penelitian lainnya menggunakan *neuro-fuzzy* dan *feed forward back propagation multi-layer perception* untuk klasifikasi 28 jenis daun [14]. Telah dilakukan pula penelitian yang mengidentifikasi 200 daun *ayurvedic* dari 20 tanaman menggunakan *Known Leaf Image Database* [15]. Dalam penelitiannya, identifikasi dilakukan dengan membandingkan daun yang diambil menggunakan kamera dengan fitur daun yang telah dibuat dalam *dataset*. Selanjutnya, sebuah penelitian menggunakan SVM berdasarkan lima tekstur dan sepuluh bentuk untuk klasifikasi 240 daun tanaman herbal Cina [16].

Penelitian yang telah dilakukan sebelumnya menggunakan *machine learning* tradisional, sedangkan makalah ini fokus pada penggunaan metode yang berbeda, yaitu *Convolutional Neural Network* (CNN). Sebenarnya, metode CNN juga sudah banyak dilakukan oleh para peneliti, seperti dalam pengenalan dan klasifikasi daun tanaman menggunakan CNN [4]. Metode CNN dianggap lebih praktis dalam pemrosesan gambar. Penelitian tersebut hanya difokuskan untuk mengetahui jenis tanaman secara umum berdasarkan identifikasi daunnya. Penelitian lain mengidentifikasi tanaman herbal Thailand menggunakan CNN [17]. Kerangka dalam *feature extraction* menggunakan *Fast Region Convolution Neural Network* (Fast R-CNN) dan *Geometry Group Network* (VGGNet). Selanjutnya, dalam sebuah penelitian tentang pengenalan tanaman herbal Vietnam, digunakan *Deep Convolutional Features* [18]. Penelitian ini menggunakan model pembelajaran berbasis VGG16 yang terdiri atas lima blok dasar residu untuk *feature extraction* gambar. Namun, pada penelitian sebelumnya, arsitektur yang digunakan hanya berdasarkan warna, ukuran, tekstur, dan *grown-region similarity* [17], serta berdasarkan arsitektur CNN yang sudah tersedia, seperti VGGNet 16 [18]. Untuk mengembangkan penelitian tersebut, makalah ini mendesain arsitektur CNN dengan penambahan deteksi tepi dan bentuk, selain dari yang sudah dilakukan sebelumnya.

Berdasarkan uraian di atas, makalah ini diharapkan dapat mengatasi beberapa permasalahan, seperti kesulitan pengguna dalam membedakan daun herbal, proses *machine learning*

yang masih menggunakan *feature extraction* secara terpisah, dan mengganti proses identifikasi secara manual ke otomatis dengan sistem cerdas. Pada makalah ini, dilakukan autentikasi daun herbal menggunakan metode kecerdasan buatan, yaitu CNN yang ditanam pada Raspberry Pi. Salah satu keunggulan dari metode ini adalah tidak memerlukan *feature extraction*, karena di dalamnya terdapat proses *feature extraction* secara otomatis. CNN lebih efisien dalam proses identifikasi dan klasifikasi karena CNN mengasumsikan *input* berupa matriks gambar. Daun dari tanaman herbal yang diambil diproses dalam Raspberry Pi. Hasil dari proses identifikasi divalidasi dengan data lain yang tidak termasuk dalam *training* dan *testing* serta data daun selain dari jenis daun yang diidentifikasi. Makalah ini diharapkan mempermudah masyarakat dalam mengetahui jenis tanaman herbal melalui daun.

II. METODOLOGI

A. Diagram Blok Sistem

Gbr. 1 merupakan diagram blok sistem yang telah dirancang. Pada gambar tersebut terdapat tiga tahapan utama, yang terdiri atas *input*, proses, dan *output*.

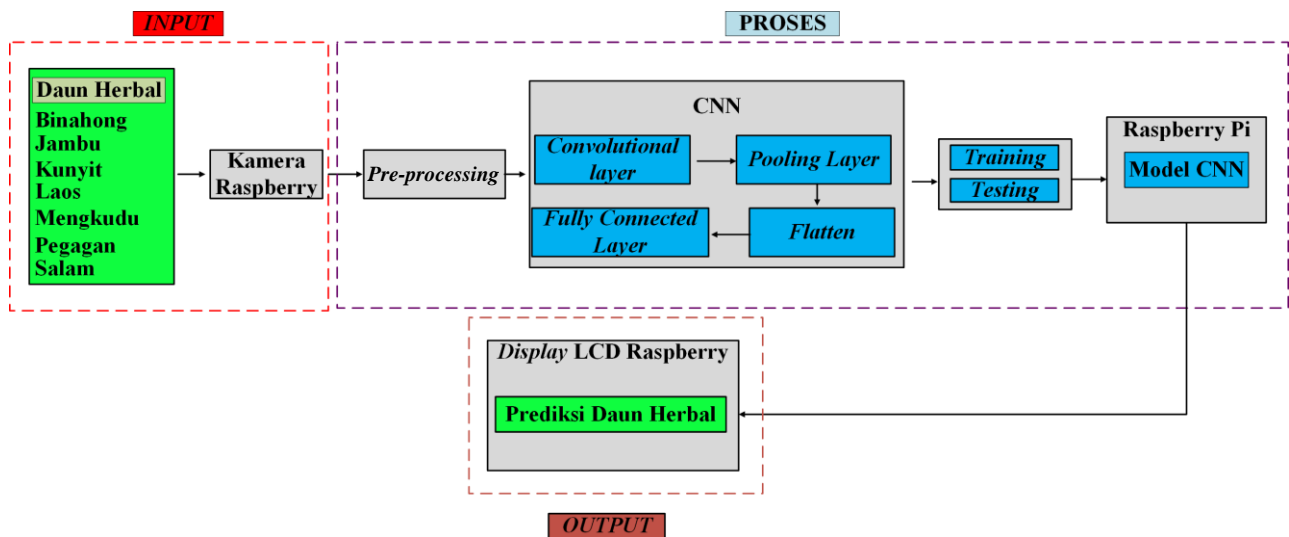
1) *Input*: Pada bagian *input* terdapat tujuh jenis daun herbal yang akan diidentifikasi. Proses identifikasi menggunakan kamera Raspberry yang terintegrasi dengan Raspberry Pi.

2) *Proses*: Pada data gambar yang telah diambil dilakukan *pre-processing* terlebih dahulu sebelum masuk pada CNN. Tujuan dari *pre-processing* ini adalah untuk menghilangkan *noise*, memperjelas fitur data gambar, memperkecil ukuran gambar, dan mengubah data gambar daun herbal agar dapat diproses oleh CNN. Selanjutnya, data gambar diproses melalui *convolutional layer*, *pooling layer*, *flatten*, dan *fully connected layer*. Untuk memperoleh sistem pengenalan daun herbal yang cerdas dan akurat, perlu dilakukan *training* dan *testing* data melalui model CNN yang telah dibentuk dan kemudian ditanam pada Raspberry Pi. Raspberry Pi ini digunakan karena memiliki beberapa kelebihan, seperti menggunakan *micro SD card* untuk menyimpan data, baik itu data sistem operasi atau penyimpanan data jangka panjang. Selain itu, Raspberry Pi juga unggul pada grafis 3D dan mendukung *overvolting* dengan cara mengedit *file config.txt*-nya. Kemudian, Raspberry Pi memproses data *input* daun herbal untuk melakukan proses klasifikasi berdasarkan metode CNN yang telah ditanam.


3) *Output*: Pada bagian *output* terdapat sebuah LCD Raspberry Pi yang akan menampilkan hasil klasifikasi berupa prediksi gambar daun herbal, sehingga pengguna lebih mudah dalam mengetahui jenis daun herbal.

B. Metode Identifikasi Daun Herbal Menggunakan CNN

Daun memiliki banyak fitur, seperti bentuk, tekstur dan pola. Makalah ini fokus pada pengenalan daun herbal melalui warna, tekstur, ukuran, deteksi tepi, dan bentuknya menggunakan metode CNN. *Testing* menggunakan tujuh jenis tanaman herbal yang berbeda. Sebelum dimasukkan pada



Gbr. 1 Diagram blok sistem.



Gbr. 2 Rezi gambar.

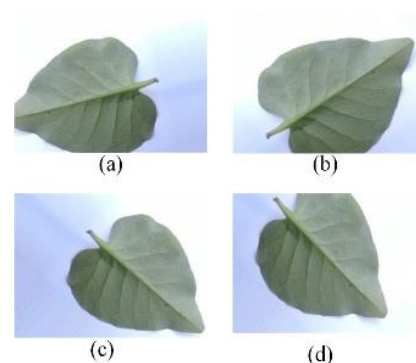
CNN, gambar mengalami *pre-processing* atau normalisasi data gambar terlebih dahulu.

1) *Rezi Gambar*: Tujuan dari *rezi* gambar adalah untuk mengurangi proses komputasi pada *Graphics Processing Unit* (GPU). Gbr. 2(a) menunjukkan *input* asli, sebelum dilakukan *resize*, yang akan digunakan dalam eksperimen, dengan ukuran 3.264×2.448 piksel. Gbr. 2(b) adalah hasil dari proses *resize* gambar, dengan ukuran 300×225 piksel.

2) *Teknik Multi Rotasi Gambar*: Teknik multi rotasi gambar ini bertujuan memperbanyak sampel bentuk data gambar dan meminimalkan kesalahan pada saat eksperimen. Gambar dirotasi sebanyak tiga kali menggunakan *auto rotate* pada program Python dengan sudut rotasi 45 derajat. Gbr. 3 adalah hasil proses *auto rotate* yang telah dilakukan. Gbr. 3(a) adalah gambar daun asli yang belum dirotasi, sedangkan Gbr. 3(b), Gbr. 3(c), dan Gbr. 3(d) adalah gambar hasil *auto rotate*.

3) *Pembelajaran Menggunakan Model CNN*: Pada tahap ini, gambar daun herbal yang sudah mengalami *pre-processing* dilatih untuk menghasilkan sistem pengenalan daun herbal yang baik dan benar. *Feature extraction* yang terdapat di dalam CNN melakukan *encoding* dari gambar yang telah diambil menjadi fitur berupa angka-angka yang merepresentasikan gambar tersebut.

Setelah gambar mengalami *pre-processing*, gambar diproses dalam CNN melalui fitur yang terdapat di dalamnya.

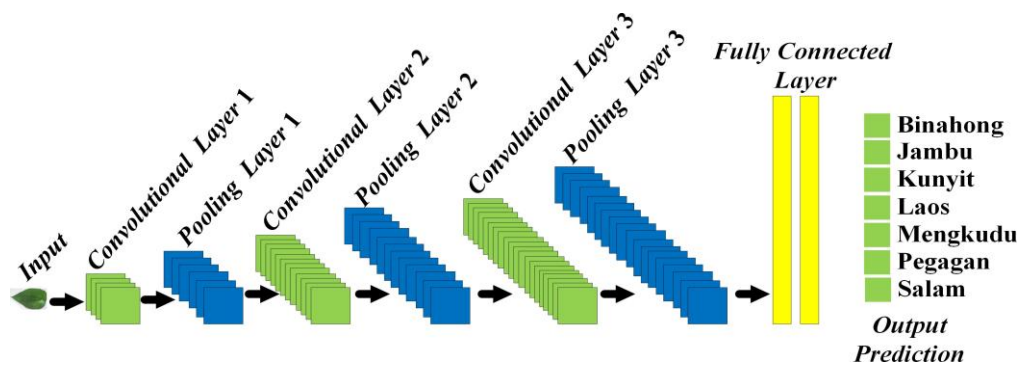


Gbr. 3 Teknik multi rotasi gambar.

Gbr. 4 merupakan struktur dari *convolutional network* dari sistem yang dibuat. *Feature extraction* di dalam CNN melakukan *encoding* dari gambar yang telah diambil menjadi fitur berupa angka-angka yang merepresentasikan gambar tersebut. *Feature extraction* terdiri atas *convolutional layer* dan *pooling layer*. *Convolutional layer* terdiri atas neuron yang tersusun sedemikian rupa, sehingga membentuk sebuah filter gambar dengan panjang dan tinggi atau piksel. Pada setiap *convolutional layer*, semua bagian dari gambar daun diekstraksi dengan langkah-langkah kesamaan komplementer, seperti kesamaan warna, tekstur, dan bentuk, sesuai dengan *feature map* pada *convolutional layer* [17].

$$FM_{(i,j)}^{(m)} = \tanh \left(b^{(m)} + \sum_{r1=0}^n \sum_{c1=0}^n C_{(r1,c1)}^{(m)} * I_{((r1+i),(c1+j))} \right) \tag{1}$$

dengan *FM* merupakan *feature map*; *c* adalah *convolutional layer filter* atau jumlah filter yang digunakan dalam proses konvolusi; *I* merupakan *input* gambar yang diproses dalam konvolusi; *m* adalah jumlah indeks pada *feature patterns*; *n* merupakan panjang baris pada *convolutional layer filter*; *i*



Gbr. 4 Struktur Convolutional Neural Network.

merupakan indeks baris pada *feature map*; *j* adalah indeks kolom pada *feature map*; *r1* merupakan indeks panjang baris yang digunakan pada *convolutional layer filter*; dan *c1* adalah indeks panjang kolom pada *convolutional layer filter*.

Setelah proses *convolutional layer* selesai, tahap selanjutnya adalah *pooling layer*. Tujuan *pooling layer* adalah mengurangi dimensi ketika *downsampling* dan mengatasi *overfitting*, sehingga proses komputasi semakin cepat karena parameter yang harus diperbarui semakin sedikit.

$$FM_{(i,j)}^{(m1)} = \tanh \left(b^{(m1)} + \sum_{i=3j}^{3nj+2} \sum_{j=3j}^{3nj+2} p^{(m1)} * FM1_{(i,j)}^{(m1)} \right). \quad (2)$$

Persamaan (2) merupakan proses *pooling layer* yang terdapat *pooling layer filter bias*, dengan *b* merupakan jumlah *bias* yang digunakan pada filter *pooling layer p*; *i* adalah indeks baris yang digunakan dalam *feature map*; *j* adalah indeks kolom pada *feature map*; *m* merupakan indeks jumlah *feature pattern* yang digunakan dalam proses *pooling layer*; dan *n* adalah panjang baris dari *feature map*.

Tahap selanjutnya adalah *fully connected layer*, yang memiliki beberapa *hidden layer*, *activation function*, *output layer*, dan *loss function*. Tahap ini menghasilkan *output* berupa prediksi dari data yang sudah diproses.

$$O^{(i)} = \tanh \left(b^{(i)} + \sum_{k=0}^{nk-1} W_{(k)}^{(i)} * N_{(k)} \right) \quad (3)$$

dengan *O* merupakan *neuron output layer* yang digunakan dalam proses *fully connected layer*; *w* adalah bobot dari *output layer*; *i* adalah jumlah indeks pada *neuron output layer*; *n* adalah jumlah *neuron output layer*, dan *N* adalah *neuron* dari *hidden layer*.

Setelah proses *feature extraction* selesai, proses selanjutnya adalah *output prediction*, yang melakukan proses klasifikasi gambar dan *output* dari klasifikasi ini berupa prediksi dari gambar daun herbal yang telah diproses oleh CNN.

C. Model Convolutional Neural Network

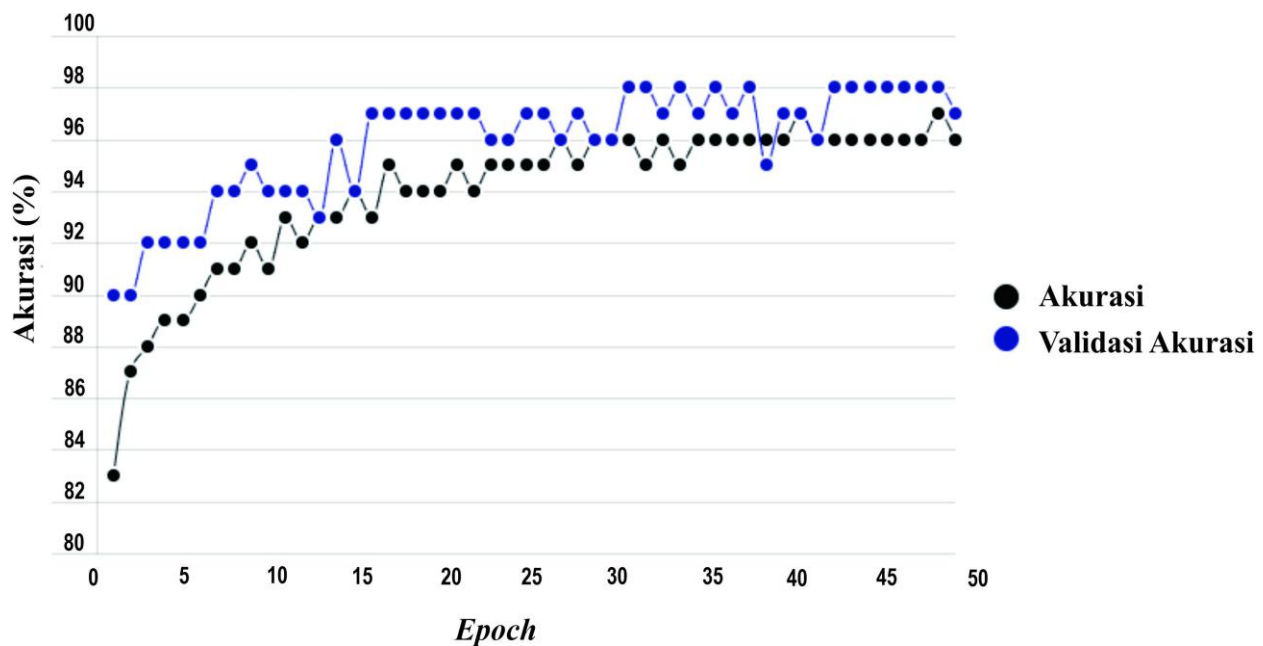
Dari Tabel I dapat dijelaskan bahwa dalam model CNN yang dibentuk, dimensi *input* gambar menggunakan $300 \times 225 \times 3$ *channel* RGB, kemudian dilanjutkan dengan konvolusi pada *layer* pertama dengan *kernel* 3×3 serta filter 32 *layer* menggunakan *ReLU activation*, dengan tujuan mengambil

TABEL I
MODEL CONVOLUTIONAL NEURAL NETWORK

Layer	Tipe	Output Shape	Parameter
Conv2d_1	Conv2D	(None, 298, 223, 32)	896
Activation_1	Activation	(None, 298, 223, 32)	0
Maxpooling2d_1	Maxpooling	(None, 149, 111, 32)	0
Conv2d_2	Conv2D	(None, 147, 109, 64)	18.496
Activation_2	Activation	(None, 147, 109, 64)	0
Maxpooling2d_2	Maxpooling	(None, 73, 54, 64)	0
Conv2d_3	Conv2D	(None, 71, 52, 128)	73.856
Activation_3	Activation	(None, 71, 52, 128)	0
Maxpooling2d_3	Maxpooling	(None, 35, 26, 128)	0
Flatten_1	Flatten	(None, 116480)	0
Dense_1	Dense	(None, 64)	7.454.784
Activation_4	Activation	(None, 64)	0
Dropout_1	Dropout	(None, 64)	0
Dense_2	Dense	(None, 7)	455
Activation_5	Activation	(None,7)	0
Total parameter			7.548.487
Trainable parameter			7.548.487
Non-trainable parameter			0

node tertinggi untuk diteruskan pada konvolusi berikutnya, sehingga *output* yang dihasilkan adalah $298 \times 223 \times 32$ *layer*. Jumlah *node* pada konvolusi pertama adalah 65.416 dengan jumlah parameter yang dihasilkan $((3 \times 3 \times 3) + 1 \text{ bias}) \times 32$ filter = 896 parameter. Setelah dilakukan konvolusi pertama, maka dilanjutkan dengan *pooling layer* 1 dengan filter 32 *layer*. Pada proses *pooling*, parameter tidak perlu dihitung karena setiap 2×2 piksel dihitung 1×1 piksel, sehingga *input shape* yang awalnya 298×223 piksel menjadi 149×111 piksel.

Setelah proses konvolusi pertama dan *pooling layer* 1 selesai, dilanjutkan dengan konvolusi kedua menggunakan filter 64 *layer* dengan *kernel* 3×3 , sehingga dimensi *output* menjadi $147 \times 109 \times 64$ *channel*. Jumlah *node* yang dihasilkan pada konvolusi kedua ini adalah 15.515, dengan jumlah parameter yang dihasilkan $((3 \times 3 \times 32) + 1 \text{ bias}) \times 64$ filter = 18.496 parameter. Proses selanjutnya adalah *pooling layer* 2. Proses *pooling layer* 2 sama dengan proses *pooling layer* 1, hanya saja *pooling layer* 2 menggunakan filter 64 *layer*. *Input shape* yang dihasilkan pada *pooling layer* 2 ini adalah 73×54 piksel.

Gbr. 5 Grafik akurasi dan validasi akurasi data *training*.

Kemudian setelah proses konvolusi kedua dan *pooling layer 2* selesai, proses selanjutnya adalah konvolusi ketiga dan *pooling layer 3*. Pada konvolusi ketiga digunakan filter 128 *layer* dan *kernel* 3×3 , sehingga *output shape* yang dihasilkan adalah $71 \times 52 \times 128$ *layer*, dengan jumlah parameter yang dihasilkan adalah $((3 \times 3 \times 64) + 1 \text{ bias}) \times 128$ filter = 73.856 parameter. Jumlah *node* yang dihasilkan pada konvolusi ketiga adalah 3.450. Setelah konvolusi ketiga selesai, proses selanjutnya adalah *pooling layer 3*. *Pooling layer 3* ini menggunakan filter 128 *layer*. *Input shape* yang dihasilkan pada *pooling layer 3* adalah 35×26 *pixels*. Setelah dilakukan konvolusi dan *pooling layer* sebanyak tiga kali, akan dihasilkan *flatten layer* yang akan mengonversi hasil *pooling layer* terakhir (*pooling layer 3*) menjadi nilai vektor, sehingga dihasilkan nilai vektor $35 \times 26 \times 128 = 116.480$. Nilai vektor yang dihasilkan ini yang akan masuk pada CNN. Setiap nilai *flatten* dihasilkan dari proses konvolusi (*nodes*). Hasil dari *flatten* dimasukkan satu per satu pada *dense* dengan jumlah 64 unit. Jumlah parameter yang dihasilkan adalah $(116480 + 1 \text{ bias}) \times 64 = 7.454.784$ parameter. Proses selanjutnya adalah *dropout* untuk 64 unit *dense* dan akan diproses kembali untuk proses *dense* sebanyak tujuh klasifikasi.

III. HASIL DAN PEMBAHASAN

Makalah ini menggunakan tujuh jenis daun herbal untuk kebutuhan data dalam proses autentikasi. Data daun yang diambil adalah daun binahong, jambu, kunyit, laos, mengkudu, pegagan, dan daun salam. Pada setiap jenis daun herbal di ambil 450 sampel data yang terbagi menjadi dua pertiga data *training* dan sepertiga data *testing*.

A. Pembuatan Data Training dan Data Testing

Data *training* dibuat berdasarkan algoritme klasifikasi sehingga terbentuk model klasifikasinya. Tujuan dari model ini adalah sebagai representasi pengetahuan pada saat

TABEL II
PERBANDINGAN DATA *TRAINING* DAN DATA *TESTING*


No	Jenis Daun Herbal	Jumlah	Data Training	Data Testing
1	Binahong	450	300	150
2	Jambu	450	300	150
3	Kunyit	450	300	150
4	Laos	450	300	150
5	Mengkudu	450	300	150
6	Pegagan	450	300	150
7	Salam	450	300	150
Jumlah		3.150	2.100	1.050

memprediksikan hasil. Semakin banyak data *training*, semakin bagus model dalam memahami daun herbal. Data *testing* dibuat dengan tujuan mengetahui akurasi model klasifikasi dalam melakukan klasifikasi secara benar. Perbandingan antara data *training* dan data *testing* ditunjukkan pada Tabel II.

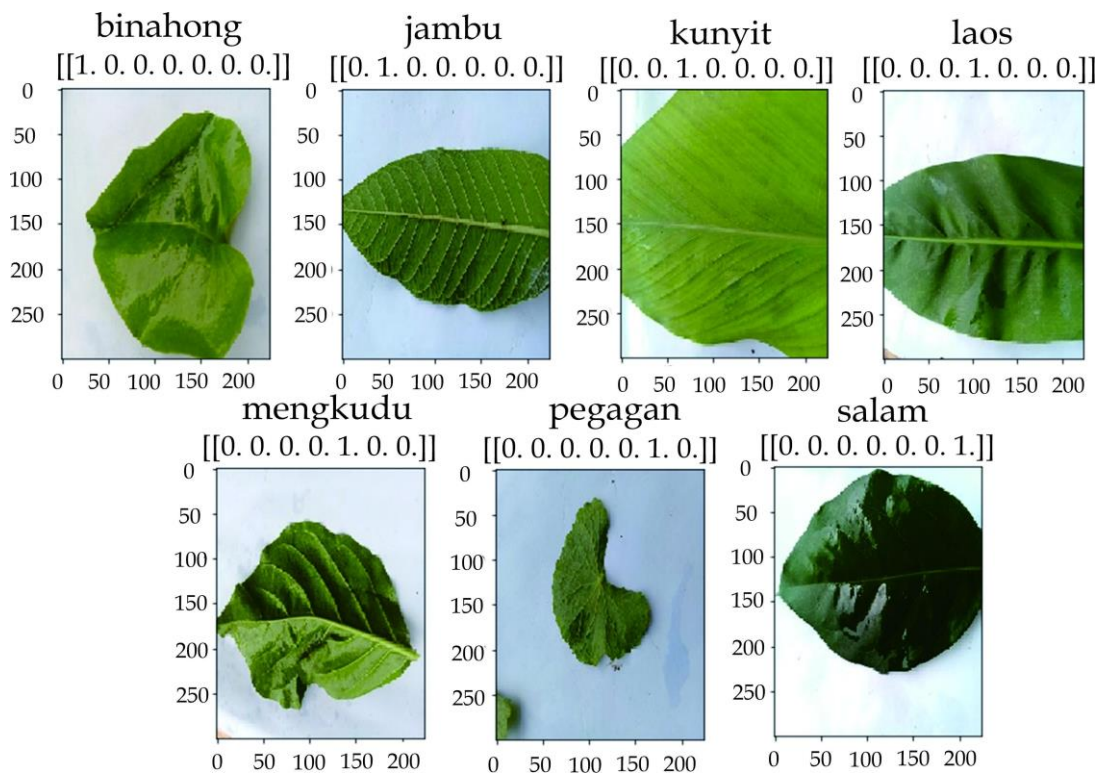
Jumlah data yang diambil dari tujuh jenis daun herbal adalah 3.150 data, yang terbagi menjadi data *training* sebanyak 2.100 dan data *testing* sebanyak 1.050. Data tersebut akan diolah dengan model CNN.

B. Training Data

Jumlah data *training* yang terdiri atas 2.100 akan diolah dengan menggunakan model CNN. Pada Gbr. 5 terlihat bahwa pada *epoch 1* sampai dengan *epoch 5* nilai akurasi antara 83,25% sampai 89,75%. Pada *epoch 6* sampai 50 tampak peningkatan nilai akurasi, antara 90,48% sampai 97,25%. Berdasarkan hasil tersebut, dapat diambil rata-rata tingkat akurasi pada saat *training* data dengan menjumlahkan akurasi dari 50 *epoch*, kemudian dibagi dengan jumlah *epoch* yang digunakan, sehingga diperoleh rata-rata tingkat akurasi pada saat *training* adalah 94,45%. Pemilihan jumlah *epoch* tersebut



Gbr. 6 Grafik loss dan validasi loss data training.



Gbr. 7 Testing data secara offline.

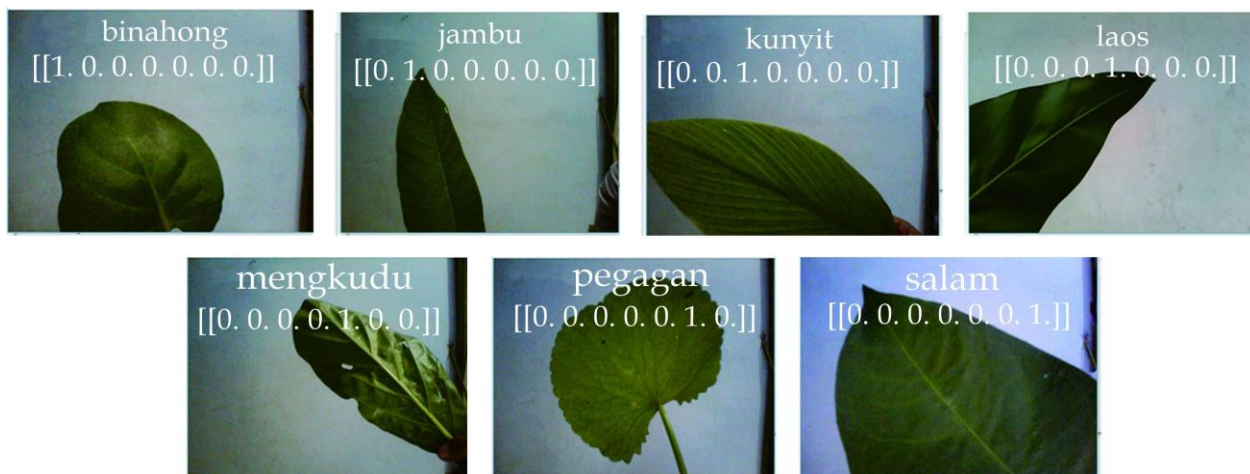
didasarkan pada beberapa percobaan dengan tujuan menghindari *overfitting* dan *underfitting* untuk mendapatkan tingkat akurasi yang baik.

Pada Gbr. 6 diperlihatkan bahwa nilai *loss* yang dihasilkan di bawah 50%, sedangkan nilai *loss* yang mampu divalidasi adalah di bawah 30%. Hasil tersebut menunjukkan bahwa nilai *loss* pada proses *training* adalah di bawah 30%. Semakin kecil nilai *loss* yang dihasilkan, semakin besar nilai akurasi.

Hal ini dipengaruhi oleh banyaknya data yang digunakan pada saat *training*.

C. Testing Data

Testing data bertujuan untuk menguji hasil *training* yang telah dilakukan. Proses *testing* data dilakukan dengan menjalankan model *testing* data yang sudah dibuat dalam CNN. *Testing* data menghasilkan klasifikasi daun herbal

Gbr. 8 *Testing* data secara *online*.TABEL III
HASIL *TESTING* DATA SECARA *OFFLINE*

Jenis Daun	Prediksi								Akurasi (%)
	Binahong	Jambu	Kunyit	Laos	Mengkudu	Pegagan	Salam	Tidak Terdeteksi	
Binahong	141	0	1	0	0	3	0	5	94
Jambu	0	139	0	3	1	0	5	2	92,67
Kunyit	0	0	143	1	0	0	2	4	95,33
Laos	0	2	3	141	1	0	2	1	94
Mengkudu	0	2	0	0	136	0	6	6	90,67
Pegagan	2	0	0	0	1	139	0	8	92,67
Salam	0	3	0	1	0	0	144	2	96

TABEL IV
HASIL *TESTING* SECARA *ONLINE*

Jenis Daun	Prediksi								Akurasi (%)
	Binahong	Jambu	Kunyit	Laos	Mengkudu	Pegagan	Salam	Tidak Terdeteksi	
Binahong	139	0	0	2	0	5	1	3	92,67
Jambu	2	130	0	1	2	0	5	10	86,57
Kunyit	0	0	144	2	0	0	0	8	96
Laos	0	4	6	127	0	0	7	6	84,67
Mengkudu	1	5	0	0	140	0	1	3	93,33
Pegagan	6	1	0	0	0	135	3	5	90
Salam	0	3	0	4	0	0	141	2	94

sesuai dengan *dataset* yang telah dibuat. *Output* dari klasifikasi data ini berupa prediksi dan nama gambar daun herbal yang diuji. Prediksi dan nama gambar akan muncul pada *display* ketika data yang diuji sesuai dengan *dataset* pada proses *training* data. *Testing* dilakukan dengan dua tahapan, yaitu *testing* secara *offline* dan *testing* secara *online*.

Testing secara *offline* dilakukan dengan cara menguji setiap sampel data daun herbal yang ada dalam data *testing* menggunakan fitur *testing* data dalam CNN. Gbr. 7 memperlihatkan hasil *testing* secara *offline*. *Testing* data yang telah dilakukan menunjukkan hasil yang bagus, yaitu setiap daun dapat terdeteksi dengan baik dan benar.

Hasil *testing* secara *offline* pada Tabel III memberikan penjelasan bahwa dari 150 data *testing* pada setiap jenis daun herbal, diketahui pada daun binahong yang mampu terdeteksi dengan benar adalah 141, daun jambu 139, daun kunyit 143, daun laos 141, daun mengkudu 136, daun pegagan 139, dan pada daun salam yang mampu terdeteksi dengan benar adalah

144. Hasil tersebut menunjukkan bahwa pada setiap jenis daun herbal, yang mampu terdeteksi dengan benar lebih banyak daripada yang terdeteksi salah. Berdasarkan hasil tersebut, diketahui rata-rata tingkat akurasi pada *testing offline* adalah 93,62%.

Testing secara *online* dilakukan dengan mengidentifikasi setiap jenis daun herbal yang akan diuji secara langsung menggunakan kamera Raspberry untuk mendeteksi daun yang diuji. Gbr. 8 menunjukkan hasil *testing* secara *online*. Jika gambar yang diambil sesuai dengan *dataset* yang telah dibuat dalam CNN, maka prediksi dari jenis daun yang diuji akan tampil pada *display*. Dari hasil *testing* data *testing* yang dilakukan, *testing* secara *online* menunjukkan hasil yang bagus. Setiap jenis daun yang diuji menunjukkan prediksi yang benar sesuai dengan jenis daun herbal yang diuji.

Hasil *testing* secara *online* pada Tabel IV memberikan penjelasan bahwa dari 150 data *testing* pada setiap jenis daun herbal, diketahui pada daun binahong yang mampu terdeteksi

TABEL V
PERBANDINGAN DENGAN PENELITIAN SEBELUMNYA

No	Penelitian	Tahun	Tujuan	Metode	Akurasi (%)
1	[10]	2017	Mengembangkan sistem otomatis <i>baseline</i> yang efisien, menggunakan <i>image processing</i> berdasarkan pengenalan pola untuk mengidentifikasi tiga spesies tanaman <i>ficus</i> .	ANN dan SVM	83,30
2	[12]	2019	Mengategorikan tipe daun yang berbeda dari tanaman obat menggunakan sistem klasifikasi dengan bantuan komputer.	<i>Laws' mask analysis</i> dan SVM	90,27
3	[13]	2017	Mengidentifikasi daun tanaman menggunakan kamera <i>smartphone</i> berdasarkan panjang, lebar, garis lingkaran, dan warna.	<i>Random Forest</i>	90,10
4	[16]	2016	Mengidentifikasi tanaman obat yang berbeda berdasarkan sepuluh bentuk dan lima tekstur karakteristik.	SVM	93,30
5	[17]	2019	Mengidentifikasi tanaman herbal Thailand.	CNN	>80,00
6	Makalah ini	2020	Mengidentifikasi daun tanaman herbal menggunakan metode kecerdasan buatan dengan menggunakan tiga proses konvolusional.	CNN	93,62 pada <i>testing offline</i> dan 91,04 pada <i>testing online</i>

dengan benar adalah 139, daun jambu 130, daun kunyit 144, daun laos 127, daun mengkudu 140, daun pegagan 135, dan pada daun salam yang mampu terdeteksi dengan benar adalah 141. Berdasarkan hasil tersebut, diperoleh rata-rata tingkat akurasi pada saat *testing* data secara *online* adalah 91,04 %. Hasil *testing* data secara *online* sedikit berbeda dengan *testing* data secara *offline*. Hal ini dipengaruhi oleh latar belakang atau *background* serta pencahayaan saat *testing*. *Testing* data dilakukan di tempat dengan pencahayaan cukup.

Tabel V menunjukkan hasil perbandingan dari berbagai penelitian yang sudah dilakukan sebelumnya dengan penelitian pada makalah ini. Pada penelitian yang telah dilakukan sebelumnya, rata-rata masih digunakan metode *machine learning*, sedangkan makalah ini mencoba menyempurnakan penelitian sebelumnya dengan menggunakan metode *deep learning*.

IV. KESIMPULAN

Metode CNN yang diterapkan mampu mengenali jenis daun herbal dengan benar. Akurasi pada saat *training* data adalah 94,45%, sedangkan pada saat *testing* data diketahui akurasi 93,62% untuk *testing* data secara *offline* dan 91,04 % untuk *testing* data secara *online*. Hasil *testing* data secara *offline* sedikit berbeda dengan *testing* secara *real time* atau *online*. Hal ini dipengaruhi oleh latar belakang atau *background* serta pencahayaan pada saat *testing*. *Testing* data secara *online* pada makalah ini dilakukan pada pencahayaan yang cukup.

REFERENSI

[1] H.A. Atabay, "Article a Convolutional Neural Network with a New Architecture Applied on Leaf Classification," *IIOAB J.*, Vol. 7, No. 5, hal. 326–331, 2016.
 [2] P.S. Helode, K.H. Waise, dan M.U. Karande, "An Online Secure Social Networking with Friend Discovery System," *Int. J. Innov. Res. Comput. Commun. Eng.*, Vol. 5, No. 4, hal. 8198–8205, 2017.
 [3] N.K.A. Wirdiani dan A.A.K.O. Sudana, "Medicinal Plant Recognition of Leaf Shape Using Localized Arc Pattern Method," *Int. J. Eng. Technol.*, Vol. 8, No. 4, hal. 1847–1854, 2016.

[4] W.-S. Jeon dan S.-Y. Rhee, "Plant Leaf Recognition Using a Convolution Neural Network," *Int. J. Fuzzy Log. Intell. Syst.*, Vol. 17, No. 1, hal. 26–34, 2017.
 [5] M.S. Mustafa, Z. Husin, W.K. Tan, M.F. Mavi, dan R.S.M. Farook, "Development of Automated Hybrid Intelligent System for Herbs Plant Classification and Early Herbs Plant Disease Detection," *Neural Comput. Appl.*, Vol. 32, No. 15, hal. 11419–11441, 2019.
 [6] A. Kaya, A.S. Keceli, C. Catal, H.Y. Yalic, H. Temucin, dan B. Tekinerdogan, "Analysis of Transfer Learning for Deep Neural Network Based Plant Classification Models," *Comput. Electron. Agric.*, Vol. 158, hal. 20–29, 2019.
 [7] S. Rajani dan M. Veena, "Study on Identification and Classification of Medicinal Plants," *Int. J. Adv. Sci. Eng. Technol.*, Vol. 6, No. 2, hal. 13–18, 2018.
 [8] Z. Ibrahim, N. Sabri, dan N.N.A. Mangshor, "Leaf Recognition Using Texture Features for Herbal Plant Identification," *Indones. J. Electr. Eng. Comput. Sci.*, Vol. 9, No. 1, hal. 152–156, 2018.
 [9] S.V. Kendre dan P.J.N. Nandimath, "Tree Species Identification and Its Disease using Machine Learning," *Int. J. Sci. Res. Eng. Trends*, Vol. 5, No. 6, hal. 2160–2165, 2019.
 [10] K.S. Jye, S. Manickam, S. Malek, M. Mosleh, dan S.K. Dhillon, "Automated Plant Identification Using Artificial Neural Network and Support Vector Machine," *Front. Life Sci.*, Vol. 10, No. 1, hal. 98–107, 2018.
 [11] P. Poudel, S. Kumar, V.S. Philip, P. Kishore, dan R.S., "Robust Recognition and Classification of Herbal Leaves," *Int. J. Res. Eng. Technol.*, Vol. 5, No. 4, hal. 146–149, 2016.
 [12] D. Puri, A. Kumar, J. Virmani, dan Kriti, "Classification of Leaves of Medicinal Plants Using Laws' Texture Features," *Int. J. Inf. Technol.*, hal. 1-12, 2019, DOI: 10.1007/s41870-019-00353-3.
 [13] A. Begue, V. Kowlessur, U. Singh, F. Mahomoodally, dan S. Pudaruth, "Automatic Recognition of Medicinal Plants using Machine Learning Techniques," *Int. J. Adv. Comput. Sci. Appl.*, Vol. 8, No. 4, hal. 166–175, 2017.
 [14] A.M. Ravishankar dan M. Mohanapriya, "Classification of Name Based on Leaf Recognition Using BT and ED Algorithm," *Int. J. Comput. Appl. Technol. Res.*, Vol. 5, No. 4, hal. 191–197, 2016.
 [15] V.C. Nithu, L. Philip, dan J. Deepa, "An Embedded System for Identification and Confirmation of Ayurvedic Plant Using Known Leaf Image Database," *Int. J. Res. Eng. Technol.*, Vol. 6, No. 2, hal. 153–159, 2017.
 [16] H.X. Kan, L. Jin, dan F.L. Zhou, "Classification of Medicinal Plant Leaf Image Based on Multi-Feature Extraction," *Pattern Recognit. Image Anal.*, Vol. 27, No. 3, hal. 581–587, 2017.

- [17] L. Mookdarsanit dan P. Mookdarsanit, "Thai Herb Identification with Medicinal Properties Using Convolutional Neural Network," *Suan Sunandha Sci. Technol. J.*, Vol. 6, No. 2, hal. 34–40, 2019.
- [18] A.H. Vo, H.T. Dang, B.T. Nguyen, dan V.H. Pham, "Vietnamese Herbal Plant Recognition Using Deep Convolutional Features," *Int. J. Mach. Learn. Comput.*, Vol. 9, No. 3, hal. 363–367, 2019.