

IDENTIFIKASI TANAMAN OBAT INDONESIA MELALUI CITRA DAUN MENGUNAKAN METODE *CONVOLUTIONAL NEURAL NETWORK* (CNN)

Budi Setiyono ^{1*}, Muhammad Riv'an Arif ², Qonita Qurratu Aini ³, Theophil Henry Soegianto ⁴,
Jasti Ohanna ⁵, Ricky Andean Fernanda Gunawan ⁶, Ayu Putri Rizkia ⁷

^{1,2,3}Institut Teknologi Sepuluh Nopember, Surabaya, ^{4,5,6}Universitas Surabaya, Surabaya

⁷Universitas Islam Negeri, Malang

Email: ¹masbudisetiyono@gmail.com, ²rivan.arif@gmail.com, ³qaneeth29@gmail.com,
⁴theophil730730@gmail.com, ⁵justea.20w@gmail.com, ⁶rickyandean9901@gmail.com,
⁷puputrizkia97@gmail.com

*Penulis Korespondensi

(Naskah masuk: 16 Desember 2022, diterima untuk diterbitkan: 12 April 2023)

Abstrak

Indonesia memiliki sumber daya alam yang melimpah, salah satunya adalah berbagai jenis tanaman. Masyarakat Indonesia telah menggunakan tanaman sebagai obat tradisional sejak jaman dahulu. Pada saat ini, tingkat pengetahuan manusia dalam mengenali jenis tanaman obat semakin menurun, karena keterbatasan memori yang dimiliki oleh manusia. Varietas tanaman obat yang sangat banyak dan beragam menyebabkan masyarakat sulit mengidentifikasi jenis tanaman obat Indonesia. Penulis mengidentifikasi jenis tanaman herbal serta khasiatnya, khususnya untuk tanaman herbal yang ada di Indonesia. Metode *Convolutional Neural Network* (CNN) digunakan pada proses pengenalan tanaman herbal tersebut, karena metode ini cukup handal untuk pengenalan objek. Penulis menggunakan data citra daun sebagai data set yang diperoleh dari *Mendeley Data*. Penulis juga menggunakan data primer berupa data daun tanaman herbal yang diperoleh dari kampung herbal Surabaya. Tahap pertama adalah melakukan anotasi, melabeli serta menyamakan dimensi terhadap citra yang belum sama. Tahap kedua penulis melakukan *pre-training* untuk mendapatkan bobot yang akan digunakan sebagai input pada proses transfer learning menggunakan *EfficientNetV2* sebagai model dasar. Langkah terakhir adalah melakukan validasi menggunakan data uji. Penelitian ini menunjukkan bahwa, CNN berhasil digunakan untuk mengidentifikasi tanaman herbal. Pengujian menggunakan *confusion matrix* terhadap *data set* yang digunakan pada penelitian ini memperoleh nilai akurasi rata-rata 98%.

Kata kunci: tanaman herbal, identifikasi, CNN, confusion matrix, EfficientNetV2

IDENTIFICATION OF INDONESIAN MEDICINE PLANTS THROUGH LEAF IMAGE USING THE CONVOLUTIONAL NEURAL NETWORK (CNN) METHOD

Abstract

Indonesia has abundant natural resources, one of which is various types of plants. Indonesian people have used plants as traditional medicine since ancient times. At this time, human knowledge in recognizing the types of medicinal plants is decreasing due to humans' limited memory. The wide and varied varieties of medicinal plants make it difficult for the public to identify the types of Indonesian medicinal plants. In this study, the authors identified the types of herbal plants and their properties, especially for herbal plants in Indonesia. The Convolutional Neural Network (CNN) method is used in identifying these herbal plants because this method is quite reliable for object recognition. The author uses leaf image data as a data set obtained from Mendeley Data. In addition, the authors also use primary data on herbal plant leaves obtained from the Surabaya herbal village. The first stage is to annotate, label, and equate the dimensions of the images that still need to be the same. In the second stage, the authors conducted pretraining to obtain weights that would be used as input in the transfer learning process using EfficientNetV2 as the basic model. The final step is to validate using test data. This study shows that CNN is successfully used to identify herbal plants. Testing using the confusion matrix method for the data set used in this study obtained an average accuracy value of 98%.

Keywords: herbal plants, identification, CNN, confusion matrix, EfficientNetV2

1. PENDAHULUAN

Indonesia merupakan negara yang terkenal keanekaragaman hayati. Terdapat sekitar 50 ribu

jenis tanaman di Indonesia dengan 7500 diantaranya dapat digunakan sebagai bahan obat tradisional (Lis Yuliatwati, 2018). Tanaman obat juga telah

digunakan oleh Bangsa Indonesia secara turun-temurun. Pernyataan tersebut dibuktikan oleh dokumen serat Primbon Jampi, Relief Candi Borobudur, dan Daun Lontar Husodo yang menceritakan seseorang meracik obat dengan bahan tanaman (Shofiah Sumayyah, 2015). Jika dibandingkan dengan konsumsi obat modern, penggunaan obat tradisional dianggap lebih aman sebagai pilihan alternatif penyembuhan karena menggunakan tanaman obat. Efek samping yang didapatkan oleh pengguna obat tradisional cenderung lebih aman dibandingkan obat modern. Meskipun dianggap lebih aman dibandingkan obat modern, konsumsi obat tradisional tetap perlu memperhatikan cara penggunaannya, ketepatan waktu konsumsi serta ketepatan pemilihan obat berdasarkan penyakit. Pada kenyataannya, sebagian besar masyarakat saat ini kurang mengenali ataupun mengetahui manfaat tanaman obat karena tingkat penyimpanan memori manusia yang terbatas (Shofiah Sumayyah, 2015). Faktor-faktor tersebut dapat berakibat bahwa ribuan tanaman di Indonesia berpotensi terbuang karena dianggap sebagai tanaman liar, sehingga tidak memaksimalkan potensi penggunaan dari tanaman tersebut. Budaya penggunaan tanaman obat tradisional dapat terkikis seiring berjalannya waktu akibat pengetahuan masyarakat yang semakin menurun.

Mengacu pada kondisi tersebut, diperlukan sebuah sistem yang dapat membantu masyarakat dalam menyediakan portal informasi mengenai tanaman obat Indonesia, sehingga dapat menambah pengetahuan dengan memberikan kemudahan dalam mengenali dan menemukan jenis tanaman obat. Penelitian ini menyajikan hasil implementasi dan analisis kinerja metode *Convolutional Neural Network* (CNN) untuk mengidentifikasi tanaman herbal, terutama tanaman herbal yang ada di Indonesia.

Beberapa peneliti telah menggunakan CNN sebagai metode untuk identifikasi obyek (Sardogan, Tuncer and Ozen, 2018; Guo and Dong, 2021; Hassan *et al.*, 2021) dengan hasil yang cukup bagus. Peneliti lain menggunakan *Convolutional Neural Network* (CNN) dan mengkolaborasikan dengan *deep learning* untuk mendeteksi obyek, meskipun dengan penambahan *deep*, akan menambah waktu komputasi (Lecun, Bengio and Hinton, 2015; Kim, Lee and Lee, 2016; Gnanaprakash, Kanthimathi and Saranya, 2021; Hakim and Fadhil, 2021).

Proses identifikasi jenis tanaman akan menggunakan *transfer learning* dengan EfficientNetV2-S sebagai model dasarnya. Penulis memilih model ini sebagai model dasar karena performanya yang kompetitif dibandingkan model-model klasifikasi gambar lainnya, dengan waktu *training* yang lebih cepat dan efisien. EfficientNetV2 dapat mencapai akurasi *top-1* sebesar 87.3% pada ImageNet ILSVRC2012, mengalahkan model ViT pada waktu itu, dengan

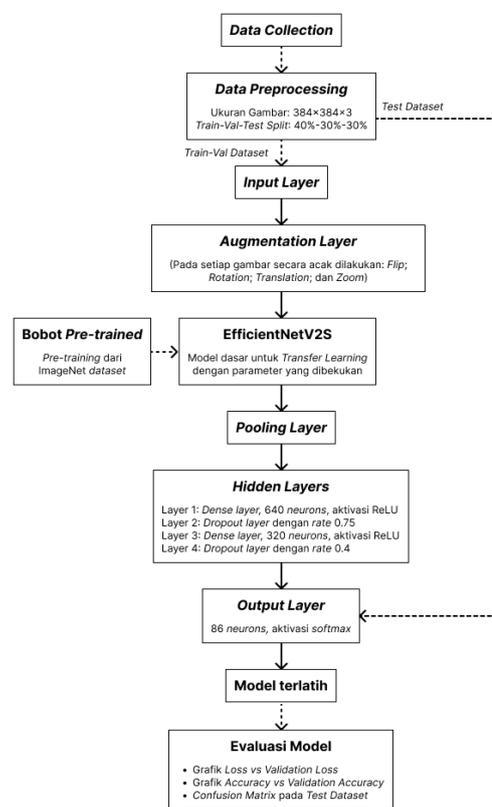
waktu *training* yang 5x-11x lebih cepat dengan menggunakan *hardware* komputasi yang sama (Tan and Le, 2019). *Dataset* yang digunakan pada penelitian ini adalah *dataset* gambar daun dengan jenis tanaman yang lebih beragam dan berasal dari sumber primer maupun sekunder.

Pemaparan penulisan penelitian ini konstruksi sebagai berikut: bagian pertama merupakan pendahuluan, yang berisi latar belakang. Bagian kedua akan diuraikan beberapa penelitian yang terkait dengan penelitian yang dilakukan oleh penulis. Bagian selanjutnya adalah metodologi untuk menyelesaikan permasalahan, sedangkan bagian akhir merupakan kesimpulan.

2. METODE PENELITIAN

Tahapan yang dilakukan pada penelitian ini secara garis besar diilustrasikan dalam Gambar 1. gambar yang digunakan berasal dari data primer dan sekunder dengan total 86 jenis tanaman. Data primer yang digunakan merupakan hasil foto daun 44 jenis tanaman dari Kampung Herbal Nginden, Surabaya dengan skala 1:1.

Data sekunder yang digunakan adalah data gambar daun 30 jenis tanaman dari penelitian (Roopashree S, 2020) dan 12 jenis tanaman dari penelitian (Adi, 2015). Total *dataset* gambar yang digunakan pada penelitian ini sebanyak 4260 gambar dengan jumlah masing-masing jenis tanaman berada dalam rentang 34 - 55 gambar



Gambar 1. Blok Diagram Penelitian

Contoh *dataset* dapat dilihat pada Gambar 2. *Dataset* akan di *training* untuk mendapatkan bobot, yang akan menjadi input pada proses *EfficientNetV2-S* bersama dengan *input layer*.



Gambar 2. Contoh *Dataset*

Sedangkan pada Tabel 1 diberikan nama jenis tanaman beserta jumlah data yang digunakan sebagai data percobaan.

Tabel 1. Jumlah Data Tiap Jenis Tanaman

Jenis Tanaman	Jumlah Data
Anredera cordifolia (Binahong)	49
Adenium obesum (Kamboja Jepang)	55
Anacardium occidentale (Jambu Mete)	55
Averrhoa bilimbi (Belimbing Sayur)	54
Amaranthus viridis (Bayam Hijau)	55
Amaranthus tricolor L. (Bayam Merah)	51
Amorphophallus paeoniifolius (Suweg)	48
Anthurium crystallinum (Kuping Gajah)	40
Andrographis paniculata (Sambiloto)	55
Artocarpus heterophyllus (Nangka)	55
Brassica juncea (Sesawi India)	34
Cananga odorata (Kenanga)	45
Basella alba (Bayam Malabar)	55
Bougainvillea spectabilis (Bunga Kertas)	43
Azadirachta indica (Mimba)	55
Boesenbergia rotunda (Kunci)	55
Carissa carandas (Buah Samarinda)	55
Caladium bicolor (Keladi Merah)	48
Capsicum annum (Cabai Merah)	47
Carica papaya (Pepaya)	42
Coleus scutellarioides (Iler)	55
Citrus amblycarpa (Jeruk Limau)	44
Cordyline fruticosa (Andong)	40
Datura metel (Kecubung)	55
Citrus limon (Lemon)	55
Cnidioscolus aconitifolius (Pepaya Jepang)	42
Citrus aurantiifolia (Jeruk Nipis)	55
Citrus sinensis (Jeruk Manis)	43
Clitoria ternatea (Telang Ternate)	47
Clinacanthus nutans (Dandang Gendis)	55
Dracaena reflexa (Nyanyian dari India)	48
Ficus auriculata (Ara Roxburgh)	50
Euphorbia tithymaloides (Sig-sag)	46

Jenis Tanaman	Jumlah Data
Ficus religiosa (Pohon Bodhi)	55
Epipremnum aureum (Sirih Gading)	53
Garcinia mangostana (Manggis)	55
Hibiscus rosa-sinensis (Bunga Sepatu)	43
Graptophyllum pictum (Daun Ungu)	45
Isotoma longiflora (Ki Tolod)	44
Jatropha curcas (Jarak Pagar)	44
Jatropha multifida L. (Pohon Yodium)	48
Melaleuca leucadendra (Kayu Putih)	42
Iresine herbstii aureoreticulata (Miana Mangkok Hijau)	55
Jasminum (Melati)	55
Kaempferia galanga (Kencur)	55
Ixora chinensis (Ixora Cina)	52
Mangifera indica (Mangga)	55
Mentha (Mint)	55
Philodendron Burle-marx (Philo Brekele)	45
Ocimum tenuiflorum (Ruku-ruku)	52
Nyctanthes arbor-tristis (Srigading)	40
Morinda citrifolia (Mengkudu)	44
Physalis angulata L. (Ciplukan)	50
Nerium oleander (Bunga Jepun)	55
Nephrolepis exaltata (Paku Pedang)	51
Orthosiphon aristatus (Kumis Kucing)	55
Muntingia calabura (Kersen)	55
Murraya koenigii (Salam Kojja)	55
Piper betle (Sirih)	54
Plectranthus amboinicus (Daun Jintan)	48
Punica granatum (Delima)	55
Piper ornatum (Sirih Merah)	46
Polyscias scutellaria (Mangkokan)	49
Premna serratifolia (Waung)	40
Psidium guajava (Jambu Biji)	55
Ruellia napifera (Gempur Batu)	39
Pluchea indica (Beluntas)	45
Pongamia pinnata (Malapari)	55
Strobilanthes crispa (Keji Beling)	55
Syngonium podophyllum (Singonium)	47
Syzygium malaccense (Jambu Bol)	50
Schefflera arboricola (Walisongo)	50
Santalum album (Cendana)	55
Stachytarpheta jamaicensis (Pecut Kuda)	55
Syzygium cumini (Jamblang)	39
Syzygium jambos (Jambu Mawar)	55
Syzygium polyanthum (Salam)	53
Tabernaemontana divaricata (Mondokaki)	55
Vitex trifolia (Legundi)	42
Ziziphus jujuba (Apel India)	55
Trigonella foenum-graecum (Kelabat)	36
Tinospora cordifolia (Bratawali)	46
Talinum paniculatum (Ginseng Jawa)	55
Ziziphus mauritiana (Bidara)	45
Gynura procumbens (Sambung Nyawa)	50
Gynura pseudochina (Sambung Nyawa Batik)	42
Total Gambar	4260

2.1. Data Preprocessing

Data daun tanaman herbal yang telah diakuisisi, selanjutnya penulis melakukan anotasi dan pelabelan. Seluruh data gambar di-*resize* ke ukuran 384 x 384 x 3 dan dilakukan *split* dengan rasio *train-val-test*: 40%, 30%, 30%.

2.2. Convolutional Neural Network CNN

Convolutional Neural Network (CNN) merupakan pengembangan dari *Multilayer Perceptron* (MLP), yang didesain untuk mengolah data dua dimensi. CNN termasuk dalam kategori *Deep Neural Network* karena kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra.

CNN adalah salah satu jenis *neural network* yang biasa digunakan untuk mendeteksi dan mengenali object pada sebuah citra.

CNN sangat efektif dalam bidang klasifikasi dan pengenalan gambar yang memiliki beberapa lapisan konvolusi (He *et al.*, 2014). CNN pertama kali dikembangkan dengan nama *NeoCognitron* oleh Kunihiko Fukushima, seorang peneliti dari NHK Broadcasting Science Research Laboratories, Kinuta, Setagaya, Tokyo, Jepang (Fukushima, 1980)

Operasi konvolusi merupakan sebuah operasi matematika yang menghasilkan sebuah fungsi baru dari pengoperasian dua fungsi. Pada pengolahan citra digital berlaku operasi konvolusi diskrit, sebab nilai koordinat piksel citra digital bernilai diskrit. Bentuk operasi konvolusi pada fungsi diskrit sebagaimana terlihat pada persamaan (1).

$$h(x) = f(x) * g(x)$$

$$= \sum_{a=-\infty}^{\infty} f(a)g(x - a) \quad (1)$$

Konvolusi yang digunakan merupakan fungsi dua peubah, sehingga operasi konvolusi diskrit berbentuk sebagaimana pada persamaan (2).

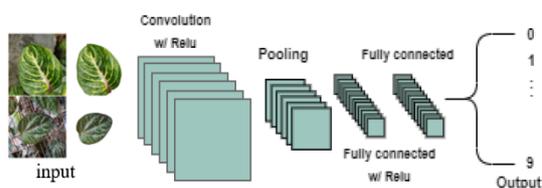
$$h(x) = f(x) * g(x) \quad (2)$$

$$= \sum_{a=-\infty}^{\infty} \sum_{b=-\infty}^{\infty} f(a, b)g(x - a, y - b) \quad (2)$$

dengan:

- * = operasi konvolusi
- a, b = peubah bantu (*dummy variable*)
- $f(x)$ = fungsi input
- $g(x)$ = kernel konvolusi (filter)
- $h(x)$ = hasil operasi konvolusi

CNN memiliki arsitektur yang terdiri dari beberapa tahap dan dapat dilatih. *Input* dan *output* merupakan beberapa *array* yang disebut sebagai *feature map*. Arsitektur CNN terdiri dari input, *convolution* + *ReLU*, *pooling*, *fully connected* dan menghasilkan *output* dari hasil CNN ini seperti yang ditunjukkan pada Gambar 2.

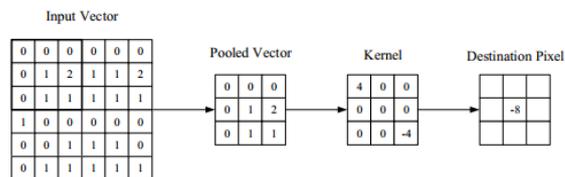


Gambar 3. Arsitektur CNN (Sahayaraj and Venkatachalapathy, 2019)

2.3. Convolutional Layer

Convolutional layer memiliki peran penting dalam pengoperasian CNN. *Convolutional layer* terdiri dari neuron yang tersusun sedemikian hingga membentuk sebuah kernel dengan ukuran tertentu. Kernel digunakan untuk melakukan ekstraksi fitur yang memiliki dimensi lebih kecil dari ukuran piksel citra. Kernel akan digeser keseluruh bagian citra dengan stride tertentu seperti yang ditunjukkan pada Gambar 4 yang setiap pergeserannya dilakukan operasi *dot*. Sehingga menghasilkan *output* yang disebut *feature map*. *Stride* adalah parameter yang

menentukan berapa jumlah pergeseran filter. Semakin kecil *stride* maka informasi yang didapatkan semakin detail tetapi tidak menjamin selalu memiliki performa yang baik.



Gambar 4. Representasi visual dari *convolutional layer*

3.4. Konstruksi dan Training Model

Data yang telah dilakukan *preprocessing* dengan input layer berupa data dengan ukuran 384 x 384 x 3, dilakukan *augmentasi* berupa *random flip*, *random rotation*, *random translation*, dan *random zoom*. Model arsitektur dasar yang digunakan untuk klasifikasi jenis tanaman adalah *EfficientNetV2-S*, sebagaimana tampak pada Gambar 5. Bobot awal yang digunakan pada proses *training* model *weights* menggunakan bobot dari *ImageNet*. Hasil yang didapatkan dari *pre-trained weights* digunakan pada model *EfficientNetV2-S* untuk klasifikasi tanaman. *Output* dari model ini adalah 86 units *Dense Layer* berupa *softmax* hasil probabilitas untuk tiap jenis tanaman.

```

Model: "model_2"
-----
Layer (type)                Output Shape              Param #
-----
input_4 (InputLayer)        [(None, 384, 384, 3)]    0
data_augmentation (Sequenti (None, 384, 384, 3)    0
al)
efficientnetv2-s (Functiona (None, 12, 12, 1280)    20331360
l)
global_average_pooling2d_2 (None, 1280)            0
(GlobalAveragePooling2D)
dense_6 (Dense)              (None, 640)              819840
dropout_4 (Dropout)          (None, 640)              0
dense_7 (Dense)              (None, 320)              205120
dropout_5 (Dropout)          (None, 320)              0
dense_8 (Dense)              (None, 86)               27606
-----
Total params: 21,383,926
Trainable params: 1,052,566
Non-trainable params: 20,331,360
    
```

Gambar 5. Arsitektur Model

2.4. Evaluasi Model dan Segmentasi Gambar dengan U2-Net

Pada tahap ini, dibuat visualisasi berupa *plotting* grafik akurasi dan *loss* untuk memudahkan dalam mengevaluasi model. Evaluasi model dilakukan menggunakan *Confusion Matrix* untuk melihat perbandingan hasil klasifikasi model dengan hasil yang sebenarnya. Sedangkan segmentasi pada gambar berupa penghilangan *background* dilakukan untuk mendapatkan citra daun saja dengan menggunakan U2-Net.

3. PENELITIAN TERKAIT

Pada penelitian ini, digunakan metode *Convolutional Neural Network* (CNN) dan *EfficientNetV2-S* sebagai model dasarnya. Penelitian sebelumnya yang dilakukan oleh Hasan (Hasan *et al.*, 2019) menjelaskan bahwa CNN lebih baik daripada metode morfologi konvensional untuk ekstraksi fitur pada spesies tanaman. Pada penelitian tersebut, dilakukan penelitian pengenalan daun dengan membandingkan metode ANN, SVM, dan CNN. Hasil dari penelitian tersebut menjelaskan bahwa CNN memiliki tingkat akurasi tertinggi sebesar 99% dibandingkan dengan ANN sebesar 94% dan SVM sebesar 91%. Penelitian oleh (Tan and Le, 2019) didapatkan hasil bahwa model-model *EfficientNet* menghasilkan performa yang baik dan mencapai akurasi *state-of-the-art* pada CIFAR-100 (91.7%), *Flowers* (98.8%) dan 3 *dataset transfer learning* lainnya dengan jumlah parameter yang lebih sedikit.

Peneliti lain menggunakan metode CNN untuk klasifikasi tanaman berdasarkan citra daun (Adi, 2015; Felix, Jeffry Wijaya, Stephen Putra Sutra, Pyter Wahyu Kosasih, 2015; Arrofiqoh and Harintaka, 2018). Penelitian mengenai aplikasi perangkat bergerak berbasis komputasi awan pernah dilakukan oleh Tirtana, A. dkk. yang mampu melakukan klasifikasi pada 20 jenis tanaman herbal (Arif Tirtana, Maria Gita Teresa Febriani, Dyas Irvan Masrui, 2015).

U2-Net digunakan untuk segmentasi citra pada sisi aplikasi. Arsitektur model untuk segmentasi daun pada gambar yang diambil user adalah menggunakan U2-Net. Dalam *salient object detection*, model U2-Net mencapai performa yang kompetitif dibanding 20 metode *state-of-the-art* lainnya (Xuebin Qin, Zichen Zhang, Chenyang Huang, Masood Dehghan, 2015).

4. HASIL DAN PEMBAHASAN

4.1. Segmentasi dan Evaluasi Model

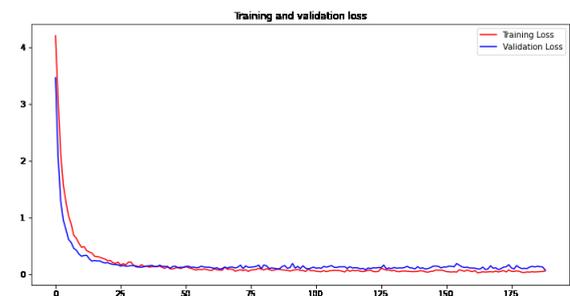
Pada Gambar 6 disajikan beberapa contoh hasil segmentasi daun dengan menggunakan U2-Net. Sedangkan berdasarkan hasil percobaan, setelah dilakukan 189 *epoch* diperoleh model dengan *validation loss* sebesar 0.0703 dan *validation accuracy* sebesar 98.02%. Untuk evaluasi *train dataset*, diperoleh *loss* sebesar 0.0546 dan *accuracy* sebesar 98.33%. Untuk evaluasi *test dataset*, diperoleh *loss* sebesar 0.0711 dan *accuracy* sebesar 98.18%. Grafik *loss* dan *accuracy* (*train vs. validation*) disajikan pada Gambar 7 dan 8. Tren *accuracy* dan *loss* dari hasil *training* menunjukkan nilai yang stabil pada *epoch* 30 dan seterusnya.

Evaluasi model *test dataset* menggunakan *confusion matrix*. Berdasarkan *confusion matrix* tersebut, terlihat bahwa diagonal utama matriks memiliki nilai *heat map* yang tinggi dibandingkan elemen-elemen lainnya. Hal tersebut menunjukkan

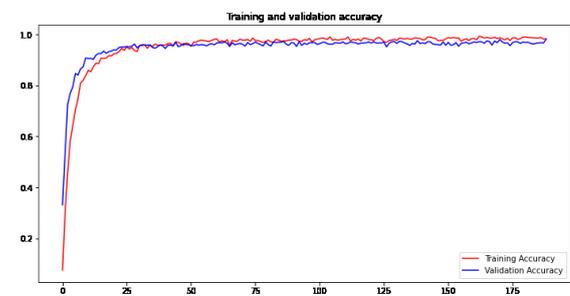
bahwa model dapat mengklasifikasi *test dataset* dengan sangat baik, dikarenakan hampir semua gambar terklasifikasi dengan benar.



Gambar 6. Hasil segmentasi daun miana mangkok hijau, sirih merah, papaya dan sirih cina dengan menggunakan U2-Net



Gambar 7. Grafik training vs. validation loss



Gambar 8. Grafik training vs. validation accuracy

Beberapa contoh hasil evaluasi *precision*, *recall*, dan *F1-score* tiap jenis tanaman disajikan pada Tabel 1. Secara keseluruhan, diperoleh nilai akurasi rata-rata

0.98, rata-rata makro 0.98 (pada semua kolom), dan rata-rata tertimbang 0.98 (pada semua kolom).

Tabel 2. Contoh hasil evaluasi *precision*, *recall*, dan *F1-score*

Jenis Tanaman	Precision	Recall	F1-score	Support
Adenium obesum (Kamboja Jepang)	1.00	1.00	1.00	16
Amaranthus tricolor L. (Bayam Merah)	1.00	1.00	1.00	15
Amaranthus viridis (Bayam Hijau)	1.00	1.00	1.00	16
Amorphophallus paeoniifolius (Suweg)	1.00	1.00	1.00	14
Anacardium occidentale (Jambu Mete)	1.00	1.00	1.00	16
Andrographis paniculata (Sambiloto)	0.94	1.00	0.97	16
Anredera cordifolia (Binahong)	1.00	1.00	1.00	15

Ada beberapa jenis tanaman dengan nilai *precision* maupun *recall* lebih rendah daripada jenis tanaman lainnya, yang meliputi: *Gynura procumbens* (Sambung Nyawa); *Premna serratifolia* (Waung); *Punica granatum* (Delima); dan *Santalum album* (Cendana). Nilai-nilai *precision*, *recall*, dan *F1-Score* yang rendah dari jenis tanaman tersebut tertera pada Tabel 2, yang bernilai antara 0.6 - 0.86. Hal ini disebabkan karena kualitas citra yang kurang baik serta pengaruh pengaruh pencahayaan.

Tabel 3. Hasil evaluasi dengan nilai *precision* dan *recall* rendah

Jenis Tanaman	Precision	Recall	F1-score	Support
<i>Gynura procumbens</i> (Sambung Nyawa)	1.00	0.60	0.75	15
<i>Premna serratifolia</i> (Waung)	1.00	0.75	0.86	12
<i>Punica granatum</i> (Delima)	0.92	0.69	0.79	16
<i>Santalum album</i> (Cendana)	0.76	1.00	0.86	16

4.2. Hasil Eksperimen

Eksperimen dengan citra tanaman riil dilakukan sebanyak 1019 percobaan. Diberikan *threshold* sebesar 70% dan diperoleh hasil 460 gambar terdeteksi benar, 417 gambar tidak terdeteksi

(tingkat kepastian di bawah 70%) dan terdeteksi dengan kelas yang salah sebanyak 142 gambar. Performa klasifikasi yang sangat baik pada *test dataset* tidak selaras dengan hasil eksperimen secara riil pada aplikasi. Hal ini mungkin terjadi karena adanya perbedaan domain gambar pada *test dataset* dengan gambar yang diambil pada aplikasi. Aplikasi tersebut mengambil gambar daun yang masih menempel pada tanaman. Gambar tersebut memiliki banyak *noise* pada *background* gambar, yang selanjutnya disegmentasi menggunakan model U2-Net. *Test dataset* pada penelitian merupakan gambar daun yang sudah dipetik dan difoto pada *background* yang putih polos. Adanya perbedaan domain tersebut mungkin menjadi salah satu penyebab dari hasil eksperimen yang tidak sesuai ekspektasi. Beberapa sampel hasil percobaan disajikan dalam Gambar 8.



Gambar 8. Hasil eksperimen menggunakan aplikasi pada citra tanaman riil

Hasil eksperimen tersebut menunjukkan bahwa model CNN yang telah dilatih cukup baik dalam mengenali tanaman. Pada beberapa jenis tanaman seperti bratawali, model tersebut kurang *robust* dalam membedakan tanaman tersebut dengan tanaman yang mirip, seperti Sirih. Model ini juga kurang *robust* dalam hal pencahayaan dimana tingkat pencahayaan pada daun yang difoto cukup berpengaruh pada hasil deteksi aplikasi.

5. KESIMPULAN

Metode *Convolutional Neural Network* dengan model dasar EfficientNetV2-S berhasil diterapkan dalam aplikasi untuk melakukan klasifikasi pada 86 jenis tanaman herbal. Model tersebut cukup baik dalam dalam mengklasifikasikan jenis tanaman herbal pada *dataset* yang telah diberikan. Hasil

evaluasi pada *test dataset* memperoleh nilai akurasi rata-rata 98%. Namun, karena adanya perbedaan antara domain gambar pada *test dataset* dengan gambar yang diambil pada aplikasi, hasil performa yang dihasilkan tidak selaras dengan hasil evaluasi pada *test dataset*. Pada hasil eksperimen dengan citra tanaman riil menggunakan aplikasi, diperoleh 460 gambar terdeteksi benar, 417 gambar tidak terdeteksi (tingkat konfidensi di bawah 70%) dan terdeteksi dengan kelas yang salah sebanyak 142 gambar.

6. UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada DRPM, ITS, DIKTI dan Google yang telah membiayai penelitian ini dengan nomor kontrak dari DIKTI 285/ES/PG.02.00.PT/2022 dan Surat Perjanjian Kerjasama dengan Google yang ditandatangani pada tanggal 15 Juli 2022

DAFTAR PUSTAKA

- ADI, M. D. C. K. 2015. *Pengenalan Daun Tanaman Obat Menggunakan Jaringan Syaraf Tiruan Backpropagation*, MEANS (Media Informasi Analisa dan Sistem). doi: 10.54367/means.v4i2.542.
- ARIF TIRTANA, MARIA GITA TERESA FEBRIANI, DYAS IRVAN MASRUI, A. A. A. (2015) *Herbify: Aplikasi Perangkat Bergerak Berbasis Komputasi Awan Untuk Mengidentifikasi Tanaman Herbal Indonesia Menggunakan Cnn Model Xception*, *Jurnal Ilmiah Educatio: Pendidikan dan Informatika*. doi: 10.21107/educat.v8i1.11650.
- ARROFIQOH, E. N. AND HARINTAKA, H. (2018) 'Implementasi Metode Convolutional Neural Network Untuk Klasifikasi Tanaman Pada Citra Resolusi Tinggi', *Geomatika*, 24(2), p. 61. doi: 10.24895/jig.2018.24-2.810.
- FELIX, JEFFRY WIJAYA, STEPHEN PUTRA SUTRA, PYTER WAHYU KOSASIH, P. S. (2015) *Implementasi Convolutional Neural Network Untuk Identifikasi Jenis Tanaman Melalui Daun*, *Jurnal SIFO Mikroskil*. doi: 10.55601/jsm.v21i1.672.
- FUKUSHIMA, K. (1980) 'Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position', *Biological Cybernetics*, 36(4), pp. 193–202. doi: 10.1007/BF00344251.
- GNANAPRAKASH, V., KANTHIMATHI, N. AND SARANYA, N. (2021) 'Automatic number plate recognition using deep learning', *IOP Conference Series: Materials Science and Engineering*, 1084(1), p. 012027. doi: 10.1088/1757-899x/1084/1/012027.
- GUO, J. AND DONG, Y. (2021) 'Object Interaction Detection Based on Convolutional Neural Network', *ACM International Conference Proceeding Series*, pp. 1686–1689. doi: 10.1145/3495018.3495465.
- HAKIM, H. AND FADHIL, A. (2021) 'Survey: Convolution Neural networks in Object Detection', *Journal of Physics: Conference Series*, 1804(1). doi: 10.1088/1742-6596/1804/1/012095.
- HASAN, M. *et al.* (2019) 'Comparative analysis of SVM, ann and cnn for classifying vegetation species using hyperspectral thermal infrared data', *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 42(2/W13), pp. 1861–1868. doi: 10.5194/isprs-archives-XLII-2-W13-1861-2019.
- HASSAN, S. M. *et al.* (2021) 'Identification of plant-leaf diseases using cnn and transfer-learning approach', *Electronics (Switzerland)*, 10(12). doi: 10.3390/electronics10121388.
- HE, K. *et al.* (2014) 'Spatial pyramid pooling in deep convolutional networks for visual recognition', *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 8691 LNCS(PART 3), pp. 346–361. doi: 10.1007/978-3-319-10578-9_23.
- KIM, J., LEE, J. K. AND LEE, K. M. (2016) 'Deeply-recursive convolutional network for image super-resolution', *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2016-Decem, pp. 1637–1645. doi: 10.1109/CVPR.2016.181.
- LECUN, Y., BENGIO, Y. AND HINTON, G. (2015) 'Deep learning', *Nature*, 521(7553), pp. 436–444. doi: 10.1038/nature14539.
- LIS YULIAWATI, A. P. R. (2018) *Emil Salim: 7.500 Tanaman Obat Ada di Indonesia Artikel ini sudah tayang di VIVA.co.id pada hari Rabu, 24 Oktober 2018 - 17:46 WIB Judul Artikel: Emil Salim: 7.500 Tanaman Obat Ada di Indonesia Link Artikel: <https://www.viva.co.id/berita/nasional>, Viva news. Available at: <https://www.viva.co.id/berita/nasional/1087573-emil-salim-7-500-tanaman-obat-ada-di-indonesia> (Accessed: 7 October 2022).*
- ROOPASHREE S, A. J. 2020. *Medicinal Leaf Dataset*, *Mendeley Data*. doi: 10.17632/nnytj2v3n5.1.
- SAHAYARAJ, K. K. A. AND

- VENKATACHALAPATHY, K. (2019) 'An automatic vehicle type classification and counting based on deep learning in traffic environment', *International Journal of Recent Technology and Engineering*, 7(5), pp. 101–106.
- SARDOGAN, M., TUNCER, A. AND OZEN, Y. 2018. Plant Leaf Disease Detection and Classification Based on CNN with LVQ Algorithm', *UBMK 2018 - 3rd International Conference on Computer Science and Engineering*, pp. 382–385. doi: 10.1109/UBMK.2018.8566635.
- SHOFIAH SUMAYYAH, N. S. 2015. *Obat Tradisional : Antara Khasiat dan Efek Sampingnya*, *Farmasetika.com (Online)*. doi: 10.24198/farmasetika.v2i5.16780.
- TAN, M. AND LE, Q. V. 2019. EfficientNet: Rethinking model scaling for convolutional neural networks', *36th International Conference on Machine Learning, ICML 2019*, 2019-June, pp. 10691–10700.
- XUEBIN QIN, ZICHEN ZHANG, CHENYANG HUANG, MASOOD DEGHAN, O. R. Z. AND M. J. 2015. *U2-Net: Going deeper with nested U-structure for salient object detection*, *Pattern Recognition*. doi: 10.1016/j.patcog.2020.107404.