

IMPLEMENTASI *CONVOLUTIONAL NEURAL NETWORK* UNTUK KLASIFIKASI TANAMAN RIMPANG SECARA VIRTUAL

DARMATASIA¹, A. MUHAMMAD SYAFAR²

^{1,2}Program Studi Teknik Informatika Fakultas Sains dan Teknologi
Universitas Islam Negeri Alauddin Makassar
E-mail: ¹darmatasia@uin-alauddin.ac.id, ²andi.syafar@uin-alauddin.ac.id

ABSTRAK

Penelitian ini mengimplementasikan *Convolutional Neural Network* untuk mengklasifikasi jenis tanaman rimpang yang memiliki bentuk dan warna yang hampir sama. Jenis tanaman rimpang yang diklasifikasi yaitu Kunyit, Jahe, Laos, Kencur, dan Kunci. Dalam penelitian ini terdapat 3 arsitektur *Convolutional Neural Network* yang digunakan yaitu MobileNet, InceptionV3, dan VGGNet. Hasil Penelitian menunjukkan bahwa arsitektur MobileNet dan InceptionV3 memperoleh akurasi yang sama yaitu sebesar 98%. Meskipun demikian, arsitektur MobileNet memiliki waktu komputasi yang lebih cepat. Adapun arsitektur VGG19 memperoleh akurasi sebesar 88%. Hasil penelitian menunjukkan bahwa metode yang digunakan dapat membedakan berbagai jenis tanaman rimpang dengan cukup baik meskipun dengan jumlah data yang sedikit. Penelitian ini diharapkan dapat memudahkan masyarakat atau orang awam yang masih sulit dalam membedakan tanaman rimpang.

Kata Kunci: Tanaman Rimpang; *Convolutional Neural Network*; Klasifikasi

I. PENDAHULUAN

Indonesia merupakan salah satu negara yang kaya akan rempah-rempah, salah satunya yaitu rimpang. Tanaman rimpang merupakan tumbuhan yang memiliki umbi atau akar dengan daging yang tebal dan seringkali dimanfaatkan sebagai bahan baku di berbagai sektor industri, termasuk farmasi, kosmetik, makanan, dan minuman. Selain digunakan sebagai bahan baku industri, tanaman rimpang juga sering dimanfaatkan sebagai obat tradisional untuk mengobati berbagai macam penyakit. Bahkan dalam kehidupan sehari-hari, tanaman rimpang seringkali digunakan sebagai bumbu dapur. Beberapa contoh tanaman rimpang yang populer adalah jahe, kunyit, temulawak, lengkuas, dan kencur.

Tanaman rimpang memiliki bentuk dan warna yang hampir sama sehingga sulit dibedakan terutama oleh orang awam (Mayasari et al., 2022). Bagi sebagian masyarakat yang terbiasa berinteraksi dengan tanaman rimpang misalnya petani atau pedagang, membedakan tanaman rimpang mungkin bukanlah sesuatu yang sulit. Namun sebagian masyarakat seperti remaja atau masyarakat di perkotaan pada umumnya, masih sulit membedakan beberapa tanaman rimpang misalnya antara jahe dan lengkuas atau kunyit dan temulawak (Batubara et al., 2020). Berdasarkan survei yang dilakukan di SMKN 9 Bandung memperoleh hasil bahwa terdapat sekitar 47% siswa masih belum dapat mengenali bumbu dan rempah pada saat melakukan pengolahan makanan (Hikmatulloh et al., 2017).

Tanaman rimpang dapat digunakan sebagai obat herbal yang merupakan obat alternatif untuk menghindari efek samping pada obat-obatan yang mengandung bahan kimia. Tanaman rimpang dapat digunakan dalam obat herbal seperti jamu. Bahkan pada saat masa pandemi Covid-19, tanaman rimpang seperti jahe banyak digunakan sebagai alternatif pengobatan secara alami (Arifin et al., 2021).

Perkembangan teknologi informasi yang semakin pesat termasuk di bidang *Computer Vision* dan *Machine Learning* memungkinkan untuk dikembangkan sebuah sistem yang dapat mengenali dan mengklasifikasi jenis tanaman rimpang. Hal tersebut dapat memudahkan masyarakat atau orang awam dalam membedakan berbagai jenis tanaman rimpang yang memiliki bentuk dan warna yang mirip.

Penelitian ini bertujuan untuk mengklasifikasi 5 jenis tanaman rimpang dengan bentuk yang mirip yaitu kunyit, jahe, laos, kunci dan kencur. Penelitian diharapkan dapat memudahkan masyarakat yang masih sulit membedakan beberapa jenis tanaman rimpang yang memiliki bentuk dan warna yang hampir sama.

Penelitian ini mengimplementasikan algoritma *deep learning* yaitu *Convolutional Neural Network* (CNN) untuk mengklasifikasi jenis tanaman rimpang. Salah satu penelitian telah mengimplementasikan CNN untuk mengklasifikasi bumbu dapur dan rempah yaitu penelitian yang dilakukan oleh (Wulandari et al., 2020). Penelitian tersebut memperoleh akurasi sebesar 88.89% dalam mengklasifikasi tiga jenis bumbu


dapur dan rempah yaitu ginseng, jahe, dan lengkuas. SqueezeNet digunakan oleh (Indrani et al., 2020) untuk mengklasifikasi 9 jenis tanaman rimpang yaitu Bangle, Jahe, Kunyit Kuning, Kencur, Lengkuas, Temu Kunci, Temu Ireng, Temu Mangga, dan Temulawak dengan akurasi yang diperoleh sebesar 81%.

Penelitian serupa juga telah dilakukan oleh (Mawaddah et al., 2022) menggunakan *Support Vector Machine* untuk mengklasifikasi 3 jenis tanaman rimpang yaitu jahe, kunyit, dan lengkuas dengan tingkat akurasi yang diperoleh sebesar 78%. *Support Vector Machine* juga digunakan dalam penelitian (Maimunah & Arumi, 2019) dengan akurasi yang diperoleh sebesar 87.5% untuk mengklasifikasi 3 jenis tanaman rimpang yaitu temulawak, temu hitam dan temu mangga. Peneliti menggunakan ekstraksi fitur warna.

Convolutional Neural Network memiliki banyak arsitektur diantaranya MobileNet, AlexNet, ResNet, Inception, dan arsitektur lainnya. Pada penelitian ini, peneliti akan mengimplementasikan dan membandingkan beberapa arsitektur dari CNN diantaranya yaitu MobileNet, InceptionV3, dan VGG19.

II. METODE PENELITIAN

Penelitian ini terdiri 4 tahapan yaitu pengumpulan data, *Pre-processing* data, Pembangunan Model, dan Evaluasi Model sebagaimana yang dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Penelitian

A. Pengumpulan Data


Data yang digunakan dalam penelitian ini diperoleh dari (Diqi, 2022). *Dataset* terdiri dari 5 kelas yaitu kunyit, kencur, kunci, laos dan jahe yang masing-masing kelas terdiri dari 90 citra data *training* dan 10 citra untuk data *testing*. Berikut adalah contoh citra pada setiap kelas.



Gambar 2. Contoh Dataset (a). Jahe; (b). Kunyit; (c). Kencur; (d). Kunci; (e). Laos

B. Pre-Processing

Citra pada *dataset* berukuran 300x300 piksel. Pada penelitian ini dilakukan *resize* citra *input* menjadi 224x224 untuk mengurangi dimensi citra. Pada penelitian ini juga dilakukan augmentasi citra karena jumlah citra yang terbatas. Augmentasi yang dilakukan yaitu seperti rotasi citra. Contoh citra hasil rotasi dapat dilihat pada Gambar 3.



Gambar 3. Hasil Rotasi dengan skala 15

C. Pembangunan Model

Pembangunan model dilakukan dengan cara melatih model menggunakan *dataset* yang telah dikumpulkan. Setelah melatih model selanjutnya dilakukan evaluasi untuk mengetahui performa model yang telah dibangun. Pada penelitian ini, model dilatih menggunakan algoritma *Convolutional Neural Network* dengan

membandingkan 3 arsitektur dari CNN yang cukup populer yaitu MobileNet, InceptionV3, dan VGG19. Setelah melatih model, selanjutnya dilakukan pengujian untuk menguji tingkat keakuratan model yang telah dibangun dalam mengklasifikasi jenis tanaman rimpang.

1) *Convolutional Neural Network*

Convolutional Neural Network (CNN) terinspirasi oleh struktur korteks visual pada hewan, yang terdiri dari sel-sel yang merespons rangsangan visual spesifik di wilayah retina yang terlokalisasi, dan yang terhubung secara hierarkis untuk membentuk representasi *input* visual yang kompleks (Lecun Yann and Y. Bengio, 1998).

Dalam CNN, data *input* biasanya berupa gambar, yang diproses oleh serangkaian lapisan konvolusional, yang masing-masing menerapkan serangkaian filter ke gambar *input*, mengekstraksi fitur pada skala dan orientasi yang berbeda. Keluaran dari setiap lapisan konvolusi biasanya dilewatkan melalui fungsi aktivasi *non-linier*, seperti *Rectified Linear Unit* (ReLU), yang memasukkan *non-linier* ke dalam model dan memungkinkannya mempelajari pola yang lebih kompleks.

2) *MobileNet*

MobileNet adalah jenis arsitektur pembelajaran mendalam yang dirancang khusus untuk perangkat seluler dan perangkat tertanam yang dikembangkan oleh peneliti Google Andrew G. Howard, Menglong Zhu, Bo Chen, Dmitry Kalenichenko, dkk pada tahun 2017 (Howard et al., 2017).

Tujuan dari MobileNet adalah menyediakan model pembelajaran mendalam (*deep learning*) yang ringan dan efisien yang dapat dijalankan pada perangkat dengan sumber daya terbatas seperti *smartphone*, kamera pintar, dan drone. Inovasi utama MobileNet adalah penggunaan konvolusi yang dapat dipisahkan secara mendalam, yang mengurangi jumlah parameter dan perhitungan yang diperlukan oleh CNN konvensional, dengan tetap mempertahankan tingkat akurasi yang serupa.

Arsitektur MobileNet menggunakan konvolusi *pointwise*, yang menerapkan filter 1x1 ke *output* dari konvolusi *depthwise*, untuk menggabungkan fitur *channel-wise* dan menghasilkan *output* akhir. Dengan menggunakan konvolusi yang dapat dipisahkan secara mendalam, MobileNet mampu mencapai tingkat efisiensi parameter yang tinggi, namun tetap menghasilkan hasil yang akurat.

3) VGG19

VGG19 adalah arsitektur pembelajaran mendalam yang dikembangkan oleh *Visual Geometry Group* (VGG) di Universitas Oxford pada tahun 2014. VGG memiliki arsitektur yang sederhana sehingga mudah untuk diimplementasikan (Simonyan & Zisserman, 2015).

VGG19 memiliki 19 layer, yang terdiri dari 16 *convolutional layer* dan 3 *fully connected layer*. 13 lapisan konvolusional pertama memiliki filter 3x3 dengan *stride* 1 piksel, sedangkan 3 lapisan konvolusional terakhir memiliki filter 3x3 dengan *stride* 2 piksel, sehingga dapat mengurangi dimensi spasial keluaran.

Salah satu fitur penting dari VGG19 adalah penggunaan filter yang sangat kecil (3x3) dibandingkan dengan arsitektur populer lainnya seperti AlexNet dan ResNet, yang sering menggunakan filter yang lebih besar. Ukuran filter yang kecil ini menghasilkan jaringan yang lebih kompleks dan lebih dalam, yang lebih baik dalam mempelajari fitur kompleks dalam data masukan.

4) InceptionV3

InceptionV3 adalah arsitektur pembelajaran mendalam yang dikembangkan oleh peneliti Google Christian Szegedy, Vincent Vanhoucke, Sergey Ioffe, Jonathon Shlens, dan Zbigniew Wojna pada tahun 2015 yang dikenal karena penggunaan modul yang disebut blok *Inception* (Szegedy et al., 2016).

Blok *Inception* dirancang untuk secara efisien menangkap fitur lokal dan global dalam data *input*, dengan melakukan serangkaian konvolusi

dengan filter dengan ukuran berbeda dan *pooling* secara paralel, dan menggabungkan *output*. Di InceptionV3, blok Inception digunakan dalam berbagai konfigurasi di seluruh jaringan, dengan ukuran filter dan *pooling* yang berbeda, untuk menangkap fitur pada skala dan tingkat abstraksi yang berbeda. InceptionV3 memiliki 48 lapisan, termasuk 10 blok *Inception*.

D. Evaluasi

Model yang telah dibangun dievaluasi menggunakan *confusion matrix*, akurasi, presisi, *recall*, dan waktu komputasi.

III. HASIL DAN PEMBAHASAN

Model dibangun dengan menggunakan CNN dengan arsitektur sebagai berikut:

A. Arsitektur MobileNet

Parameter yang digunakan dalam membangun arsitektur MobileNet yaitu *learning rate*: 0.001, jumlah *epoch*: 25, *Batch Size*: 32, bobot menggunakan bobot ImageNet, dan *optimizer* menggunakan Adam *optimizer*. Pada layer terakhir dari MobileNet dilakukan penyesuaian dengan menambahkan 1 *hidden layer* dengan jumlah *neuron* 128, fungsi aktivasi menggunakan ReLU, dan *dropout* sebesar 0.2 untuk mencegah *overfitting*.

```

Flatten (Flatten)      (None, 1024)      0
dense_2 (Dense)       (None, 128)      131200
dropout_1 (Dropout)   (None, 128)      0
dense_3 (Dense)       (None, 5)        645
=====
Total params: 3,360,709
Trainable params: 131,845
Non-trainable params: 3,228,864

```

Gambar 4. Penyesuaian Arsitektur MobileNet

B. Arsitektur VGG19

Arsitektur VGG19 menggunakan parameter yang sama dengan arsitektur MobileNet. Adapun jumlah parameter keseluruhan pada arsitektur VGG19 dapat dilihat pada Gambar 5.


```

Flatten (Flatten)      (None, 512)      0
dense_4 (Dense)        (None, 128)      65664
dropout_2 (Dropout)    (None, 128)      0
dense_5 (Dense)        (None, 5)        645
-----
Total params: 20,090,693
Trainable params: 66,309
Non-trainable params: 20,024,384
    
```

Gambar 5. Penyesuaian Arsitektur VGG19

C. Arsitektur InceptionV3

Arsitektur InceptionV3 menggunakan parameter yang sama dengan arsitektur MobileNet dan VGG19. Adapun jumlah parameter keseluruhan pada arsitektur InceptionV3 dapat dilihat pada Gambar 6.

```

Flatten (Flatten)      (None, 2048)     0      ['average_pooling2d_11[0][0]']
dense_4 (Dense)        (None, 128)     262272  ['flatten[0][0]']
dropout_2 (Dropout)    (None, 128)     0      ['dense_4[0][0]']
dense_5 (Dense)        (None, 5)       645    ['dropout_2[0][0]']
-----
Total params: 22,045,701
Trainable params: 242,917
Non-trainable params: 21,802,784
    
```

Gambar 6. Penyesuaian Arsitektur InceptionV3

Berikut adalah perbandingan hasil akurasi, presisi, *recall*, dan waktu komputasi pada setiap arsitektur yang digunakan.

Tabel 1. Perbandingan Performa Arsitektur CNN

Arsitektur	Akurasi	Presisi	<i>Recall</i>
MobileNet	98%	98%	98%
InceptionV3	98%	98%	98%
VGG 19	88%	89%	88%

Berdasarkan Tabel 1, dapat dilihat bahwa arsitektur MobileNet dan InceptionV3 memperoleh akurasi yang sama yaitu sebesar 98%. Adapun arsitektur VGG19 memperoleh akurasi sebesar 88%.

Tabel 2. Perbandingan Waktu Komputasi

Arsitektur	Waktu Komputasi (second)
MobileNet	643
InceptionV3	1.576
VGG 19	7.706

Berdasarkan Tabel II, dapat dilihat bahwa arsitektur MobileNet memperoleh waktu komputasi yang paling sedikit yaitu 625 detik. Hal ini sesuai dengan tujuan pengembangannya yaitu ringan dan efisien. Meskipun arsitektur InceptionV3 juga memperoleh akurasi yang sama dengan MobileNet namun membutuhkan waktu komputasi dua kali lipat lebih lama dibandingkan dengan arsitektur MobileNet.

Adapun grafik perolehan akurasi pada setiap *epoch* pada tahap pelatihan menggunakan arsitektur MobileNet dapat dilihat pada Gambar 6.



Gambar 6. Grafik Akurasi pada Setiap *Epoch*

IV. KESIMPULAN

Penelitian ini telah mengimplementasikan algoritma *Convolutional Neural Network* untuk klasifikasi jenis tanaman rimpang yang terdiri dari 5 kelas yaitu kunyit, jahe, laos, kencur, dan kunci. Hasil penelitian menunjukkan bahwa arsitektur MobileNet dan InceptionV3 memperoleh akurasi yang sama yaitu 98%. Meskipun demikian, arsitektur InceptionV3 membutuhkan waktu komputasi yang lebih lama untuk mencapai akurasi tersebut.

Penelitian ini menggunakan *dataset* dengan jumlah yang sedikit. Untuk penelitian selanjutnya, diperlukan lebih banyak *dataset* sehingga dapat meningkatkan performa

akurasi klasifikasi. Selain itu, pada penelitian ini hanya dapat mengklasifikasi 5 jenis tanaman rimpang, pada penelitian selanjutnya dapat ditambahkan jenis tanaman rimpang lain yang memiliki bentuk yang hampir sama.

DAFTAR PUSTAKA

- Arifin, A., Hendyli, J., & Herwindiati, D. E. (2021). Klasifikasi Tanaman Obat Herbal Menggunakan Metode Support Vector Machine. *Computatio: Journal of Computer Science and Information Systems*, 5(1), 25–35.
- Batubara, N. P., Widiyanto, D., & Chamidah, N. (2020). Klasifikasi rempah rimpang berdasarkan ciri warna rgb dan tekstur glcm menggunakan algoritma naive bayes. *Informatik: Jurnal Ilmu Komputer*, 16(3), 156–163.
- Diqi, M. (2022). *Tanaman Umbi*. <https://www.kaggle.com/datasets/diqitalize/tanaman-umbi>
- Hikmatulloh, E., Lasmanawati, E., & Setiawati, T. (2017). Manfaat Pengetahuan Bumbu Dan Rempah Pada Pengolahan Makanan Indonesia Siswa Smkn 9 Bandung. *Media Pendidikan, Gizi, Dan Kuliner*, 6(1).
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). *MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications*. <https://doi.org/https://doi.org/10.48550/arXiv.1704.04861>
- Indrani, K., Khrisne, D., & Suyadnya, I. (2020). Android based application for rhizome medicinal plant recognition using squeezeNet. *J Electr Electron Inform*, 4(1), 10–14.
- Lecun Yann and Y. Bengio. (1998). Convolutional Networks for Images, Speech, and Time-Series. *The Handbook of Brain Theory and Neural Network*, 255-258.
- Maimunah, M., & Arumi, E. R. (2019). Use of Support Vector Machine to Classify Rhizomes Based on Color. *Journal of Physics: Conference Series*, 1381(1), 12031. <https://doi.org/10.1088/1742-6596/1381/1/012031>
- Mawaddah, S., Mufid, M. R., Basofi, A., Fiyanto, A., Aditama, D., & Nurlaila, N. (2022). *Rhizome Image Classification Using Support Vector Machine BT - Proceedings of the International Conference on Applied Science and Technology on Social Science 2021 (iCAST-SS 2021)*. 990–993. <https://doi.org/10.2991/assehr.k.220301.164>
- Mayasari, M., Mulyana, D. I., & Yel, M. B. (2022). Komparasi klasifikasi jenis tanaman rimpang menggunakan principal component analysis, support vector machine, k-nearest neighbor dan decision tree. *Jtik (Jurnal Teknik Informatika Kaputama)*, 6(2), 644–655.
- Simonyan, K., & Zisserman, A. (2015). *Very Deep Convolutional Networks for Large-Scale Image Recognition*.