

IMPLEMENTASI METODE CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI TANAMAN PADA CITRA RESOLUSI TINGGI

(*The Implementation of Convolutional Neural Network Method for Agricultural Plant Classification in High Resolution Imagery*)

Erlyna Nour Arrofiqoh dan Harintaka

Program Studi Teknik Geomatika, Departemen Teknik Geodesi, Fakultas Teknik, Universitas Gadjah Mada
Jl. Grafika No 2 Sinduadi, Mlati, Sleman, D.I. Yogyakarta, Indonesia
E-mail: erlyna.nour@gmail.com

Diterima (received): 10 April 2018; Direvisi (revised): 24 Mei 2018 ; Disetujui untuk dipublikasikan (accepted): 23 Juli 2018

ABSTRAK

Citra resolusi tinggi dari teknologi UAV (*Unmanned Aerial Vehicle*) dapat memberikan hasil yang baik dalam ekstraksi informasi sehingga dapat digunakan untuk *monitoring* dan *updating* data suatu wilayah. Pengambilan informasi dari citra dengan interpretasi visual sangat bergantung pada interpreter. Kendala utama interpretasi secara manual adalah saat melakukan pengenalan objek secara visual, khususnya pada objek tanaman pertanian. Kesalahan hasil asumsi interpreter dapat terjadi ketika citra yang diekstraksi memiliki objek yang kompleks dan memiliki karakter fisik yang hampir mirip apabila dilihat dari foto udara yang hanya memiliki band RGB (*Red, Green, dan Blue*). Penelitian ini mencoba mengimplementasikan pendekatan klasifikasi semantik secara otomatis yang dapat membedakan jenis tanaman sebagai alternatif pengenalan objek berdasarkan metode *deep learning* menggunakan *Convolutional Neural Network* (CNN). Metode CNN merupakan salah satu metode *deep learning* yang mampu melakukan proses pembelajaran mandiri untuk pengenalan objek, ekstraksi objek dan klasifikasi serta dapat diterapkan pada citra resolusi tinggi yang memiliki model distribusi nonparametrik. Pada penelitian ini, diterapkan algoritma CNN untuk membedakan jenis tanaman dengan memberikan label semantik dari objek jenis tanaman. Penelitian menggunakan 5 kelas jenis tanaman, yaitu kelas tanaman padi, bawang merah, kelapa, pisang, dan cabai. Proses *learning* jaringan menghasilkan akurasi 100% terhadap data *training*. Pengujian terhadap data validasi menghasilkan akurasi 93% dan akurasi terhadap data tes 82%. Hasil penelitian ini menunjukkan bahwa penggunaan metode CNN berpotensi untuk pendekatan pengenalan objek secara otomatis dalam membedakan jenis tanaman sebagai bahan pertimbangan interpreter dalam menentukan objek pada citra.

Kata kunci: *Convolutional neural network, deep learning, citra resolusi tinggi, klasifikasi*

ABSTRACT

High-resolution imagery from UAV (Unmanned Aerial Vehicle) technology can provide good results in extracting information for monitoring and updating data. Taking information from the image uses visual interpretation is highly dependent on the interpreter. The main obstacle when doing manual interpretation is visual object recognition, especially for object of agricultural plant. The assumption from the interpreter can have errors when the image have complex object and have similar physical characters when viewed from aerial photographs that only have RGB (Red, Green, and Blue) bands. This research tries to implement imagery extraction for the semantic classification in automatically approach that can distinguish plant type as an alternative of object recognition to help interpreter based on deep learning using Convolutional Neural Network (CNN). CNN method is one of the deep learning method which perform independent learning process for object recognition, object extraction and classification also can be applied in high resolution images which have nonparametric distribution model. In this study, CNN algorithm applied to labelling different plant type. Plant type that used in this study consist of 5 classes, such as coconut, rice, banana, red union and chili. Learning process obtained 100% accuracy toward training data. Testing on validation data produces accuracy 93% and test data produces accuracy 82%. The results showed that CNN method have potential in automatic object recognition to determine agricultural plant on the image.

Keywords: *Convolutional neural network, deep learning, high resolution imagery, classification*

PENDAHULUAN

Perkembangan teknologi penginderaan jauh yang pesat membuat citra resolusi tinggi semakin mudah untuk didapatkan, contohnya dengan teknologi UAV (*Unmanned Aerial Vehicle*). Teknologi UAV dapat menghasilkan foto udara dengan waktu yang cepat, biaya yang lebih murah, dan memungkinkan dilakukan kembali pada lokasi yang sama dengan waktu temporal yang singkat. Foto udara dari teknologi UAV dapat digunakan untuk *monitoring* dan *updating* data suatu wilayah (Giordan et al., 2017). Untuk keperluan pengambilan informasi, perlu dilakukan klasifikasi pada foto udara. Klasifikasi pada citra resolusi tinggi dilakukan dengan interpretasi visual. Interpretasi visual merupakan kombinasi antara intuisi, mata dan pikiran manusia untuk membuat keputusan dan penilaian terhadap suatu objek tertentu, dengan menggunakan pengalaman dan pengetahuan sebagai pedomannya (Tso & Mather, 2009).

Kendala utama saat melakukan interpretasi secara manual adalah saat melakukan pengenalan objek secara visual, khususnya pada objek tanaman pertanian. Tanaman yang memiliki karakteristik fisik yang sama sulit untuk dibedakan apabila dilihat dari foto udara yang hanya memiliki band RGB. Dibutuhkan uji lapangan untuk memastikan jenis tanaman tersebut agar hasilnya akurat. Namun apabila jumlah tanaman yang sulit dibedakan banyak dan lokasi pemotretan jauh, hal tersebut menjadi kurang efisien. Oleh karena itu penelitian ini mencoba untuk melakukan pendekatan klasifikasi semantik secara otomatis sebagai alternatif pengenalan objek yang dapat membedakan jenis tanaman untuk bahan pertimbangan bagi interpreter saat melakukan klasifikasi sebelum dilakukan uji lapangan.

Yalcin & Razavi (2016) melakukan klasifikasi tanaman menggunakan metode CNN (*Convolutional Neural Network*). Penelitian tersebut menggunakan foto objek tanaman yang dipotret dari samping. Hasil penelitian tersebut menunjukkan bahwa metode CNN dapat melakukan klasifikasi lebih baik daripada metode SVM (*Support Vector Machine*). Metode CNN merupakan salah satu metode *deep learning* yang mampu melakukan proses pembelajaran mandiri untuk pengenalan objek, ekstraksi objek dan klasifikasi serta dapat diterapkan pada citra resolusi tinggi yang memiliki model distribusi nonparametrik (Zhang et al., 2018).

Penelitian ini mengimplemetasikan algoritma CNN untuk melakukan klasifikasi semantik dengan memberikan label semantik dari objek jenis tanaman. Kelas klasifikasi yang digunakan pada penelitian terdiri dari 5 kelas, yaitu kelas tanaman padi, cabai, bawang merah, pisang dan kelapa

yang diperoleh dari citra resolusi tinggi menggunakan teknologi UAV.

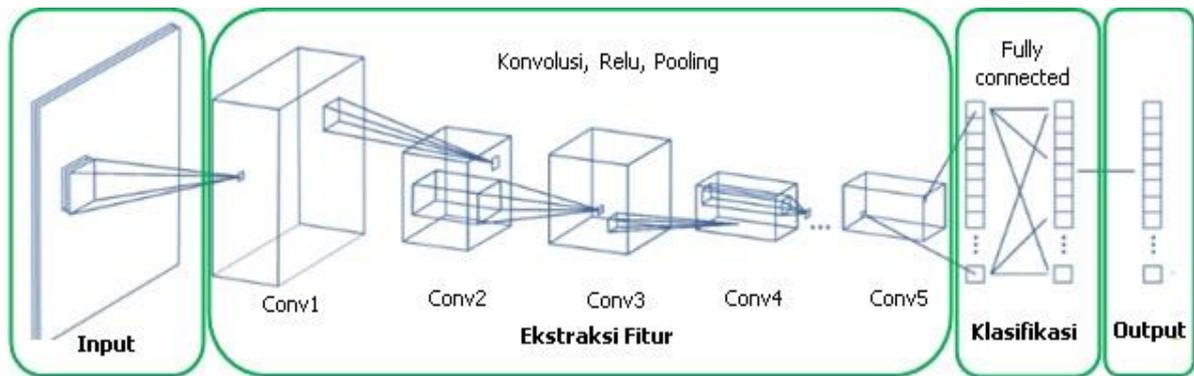
Pengujian terhadap implementasi metode CNN untuk membedakan jenis tanaman ini dilakukan pada *training* jaringan, kemudian jaringan tersebut diuji dengan data validasi. Jaringan yang telah diuji dengan data validasi kemudian diterapkan untuk memproses data tes. Pengujian dilakukan dengan metode *stratified cross validation* untuk mengukur akurasi berdasarkan matriks konfusi. Hasil kajian ini diharapkan bermanfaat sebagai pendekatan untuk membantu interpreter dalam menentukan objek yang sulit diinterpretasi secara visual. Sehingga diperoleh efisiensi dalam melakukan klasifikasi citra.

Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) termasuk dalam jenis *deep learning* karena kedalaman jaringannya. *Deep learning* adalah cabang dari *machine learning* yang dapat mengajarkan komputer untuk melakukan pekerjaan selayaknya manusia, seperti komputer dapat belajar dari proses *training* (Deng & Yu, 2013). CNN merupakan operasi konvolusi yang menggabungkan beberapa lapisan pemrosesan, menggunakan beberapa elemen yang beroperasi secara paralel dan terinspirasi oleh sistem saraf biologis (Hu et al., 2015). Pada CNN setiap neuron dipresentasikan dalam bentuk 2 dimensi, sehingga metode ini cocok untuk pemrosesan dengan input berupa citra (Maggiori et al., 2016). Arsitektur jaringan dengan menggunakan CNN ditunjukkan pada **Gambar 1**. Struktur CNN terdiri dari input, proses ekstraksi fitur, proses klasifikasi dan output. Proses ekstraksi dalam CNN terdiri dari beberapa lapisan tersembunyi atau *hidden layer*, yaitu lapisan konvolusi, fungsi aktivasi (ReLU), dan *pooling*. CNN bekerja secara hierarki, sehingga output pada lapisan konvolusi pertama digunakan sebagai input pada lapisan konvolusi selanjutnya. Pada proses klasifikasi terdiri dari *fully-connected* dan fungsi aktivasi (*softmax*) yang outputnya berupa hasil klasifikasi (Katole et al., 2015).

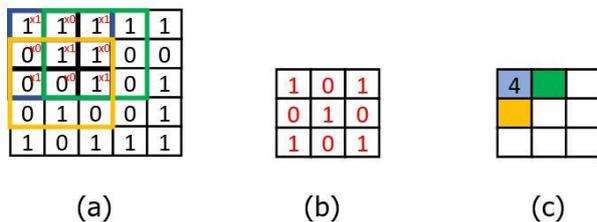
Lapisan Konvolusi

Lapisan konvolusi menggunakan filter untuk mengekstraksi objek dari citra input. Filter ini berisi bobot yang digunakan untuk mendeteksi karakter dari objek seperti tepi, kurva, atau warna. Konvolusi akan menghasilkan transformasi linear dari citra input yang sesuai dengan informasi spasial pada data. Filter diaplikasikan secara berulang sehingga menghasilkan serangkaian bidang *receptive*. Terdapat parameter yang dapat diubah untuk memodifikasi sifat tiap lapisan, yaitu

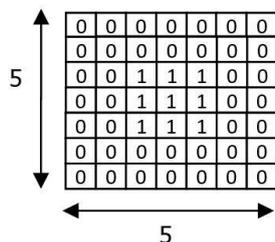


Sumber :Krizhevsky et al. (2012)
Gambar 1. Arsitektur CNN.

ukuran filter, *stride* dan *padding*. *Stride* mengontrol bagaimana filter diterapkan pada data input dengan bergerak sepanjang ukuran piksel yang telah ditentukan. *Padding* adalah penambahan ukuran piksel dengan nilai tertentu disekitar data input agar hasil dari bidang *receptive* tidak terlalu kecil sehingga tidak banyak informasi yang hilang. Nilai ini biasanya nol sehingga disebut dengan *zero padding*. Hasil dari bidang *receptive* berupa data tunggal. Output dari proses konvolusi ini dijadikan sebagai input untuk lapisan konvolusi selanjutnya (Castelluccio et al., 2015). Ilustrasi proses *stride* dan *padding* ditampilkan pada **Gambar 2** dan **Gambar 3**.



Gambar 2. Operasi konvolusi dengan *stride* 1 (a) Input data 5x5 (b) filter 3x3 (c) bidang receptive 3x3.



Gambar 3. Operasi *zero padding* 2 pada data 3x3.

Fungsi Aktifasi ReLU

ReLU (*Rectification Linear Unit*) merupakan operasi untuk mengenalkan nonlinearitas dan meningkatkan representasi dari model. Fungsi aktivasi ReLU adalah $f(x) = \max(0, x)$ (Heaton, 2015). Nilai output dari neuron bisa dinyatakan sebagai 0 jika inputnya adalah negatif. Jika nilai input adalah positif, maka output dari neuron adalah nilai input aktivasi itu sendiri (Kim et al., 2016).

Pooling

Pooling atau *subsampling* adalah pengurangan ukuran matriks. Terdapat dua macam *pooling* yang sering digunakan yaitu *average pooling* dan *max pooling* (Bejiga et al., 2017). Nilai yang diambil pada *average pooling* adalah nilai rata-rata sedangkan pada *max pooling* adalah nilai maksimal (Zhi et al., 2016).

Fully Connected Layer

Lapisan *fully connected layer* merupakan kumpulan dari proses konvolusi (Hijazi et al., 2015). Lapisan ini mendapatkan input dari proses sebelumnya untuk menentukan fitur mana yang paling berkorelasi dengan kelas tertentu. Fungsi dari lapisan ini adalah untuk menyatukan semua node menjadi satu dimensi (Albelwi & Mahmood, 2017).

Fungsi Aktivasi Softmax

Fungsi aktivasi *softmax* digunakan untuk mendapatkan hasil klasifikasi. Fungsi aktivasi menghasilkan nilai yang diinterpretasi sebagai probabilitas yang belum dinormalisasi untuk tiap kelas. Nilai kelas dihitung dengan menggunakan fungsi *softmax* (Vedaldi & Lenc, 2015), yang ditunjukkan oleh **Persamaan 1**.

$$y_{ijk} = \frac{e^{x_{ijk}}}{\sum_{t=1}^D e^{x_{ijt}}} \dots\dots\dots(1)$$

dimana:

y_{ijk} =vektor yang berisi nilai antara 0 dan 1.
 x =vektor yang berisi nilai yang didapatkan dari lapisan *fully-connected* terakhir.

Fungsi kesalahan klasifikasi dihitung dengan **Persamaan 2:**

$$l(x, c) = -\log \frac{e^{x_c}}{\sum_{k=1}^C e^{x_k}} = -x_c + \log \sum_{k=1}^C e^{x_k} (2)$$

dimana:

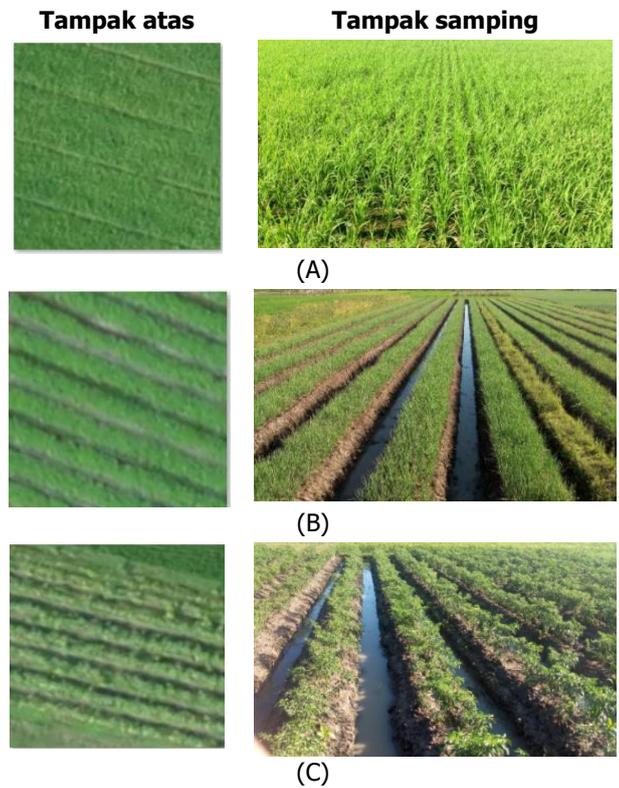
$l(x, c)$ =membandingkan prediksi (x) dan label (c).

x =vektor dari probabilitas akhir.
 $p(k) = xk,$
 $k = 1.$
 C =banyak kelas.

Untuk mengontrol *overfitting*, *pooling* layer digunakan untuk mengurangi representasi ukuran spasial dan mengurangi jumlah parameter. Lapisan *dropout* memberikan aturan untuk menghilangkan atau menjaga neuron dengan beberapa nilai probabilitas p yang bernilai antara 0 dan 1 (Srivastava et al., 2014). Lapisan *dropout* berguna untuk memudahkan penggolongan kelasnya.

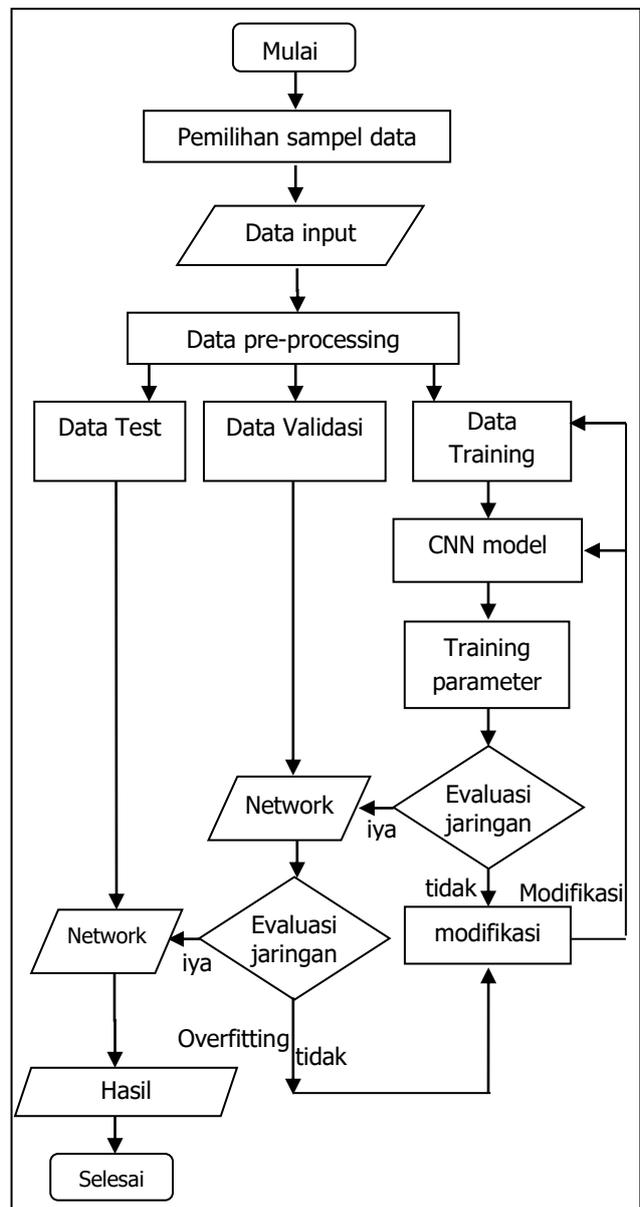
METODE

Pada penelitian ini data yang digunakan menggunakan foto udara hasil perekaman dengan menggunakan teknologi UAV dengan jenis kamera Canon PowerShot S100. Data diambil dari satu *scene* citra RGB dengan koreksi geometrik 4,64 mm seluas 311 ha dan resolusi spasial 6,5 cm. Lokasi penelitian berada di daerah Kretek, Daerah Istimewa Yogyakarta. Data meliputi foto dari 5 jenis tanaman, yaitu kelapa, pisang, padi, cabai dan bawang merah. Penampakan 5 jenis tanaman tersebut dapat dilihat pada **Gambar 4**. Penampakan pada gambar tersebut merupakan penampakan dari foto udara UAV sedangkan penampakan dari samping merupakan foto yang diambil di lapangan dengan menggunakan kamera. Pembuatan model CNN dilakukan dengan menggunakan software Matlab 2017b.



Gambar 4. Kelas jenis tanaman: (A) padi, (B) bawang merah, (C) cabe, (D) pisang, dan (E) kelapa.

Langkah Kerja



Gambar 5. Diagram alir penelitian.

Alur pengerjaan penelitian ini dimulai dari pemilihan data sampel yang digunakan sebagai input untuk data *training*, validasi dan pengujian/tes. Kemudian merancang jaringan dengan metode CNN untuk melakukan klasifikasi semantik pada objek tanaman. Rancangan jaringan CNN diaplikasikan dengan data *training*, agar komputer dapat belajar mengenali objek. Apabila pembelajaran jaringan diperoleh hasil yang baik dalam membedakan jenis objek tanaman, maka jaringan tersebut kemudian dilakukan uji coba terhadap data validasi. Apabila data validasi juga menunjukkan hasil yang baik maka jaringan dapat digunakan untuk klasifikasi pada data tes (**Gambar 5**).

Pengambilan Sampel untuk Data Input

Input data yang digunakan dalam jaringan ini berupa sampel gambar dari lima jenis tanaman, yaitu kelapa, pisang, cabai, bawang merah, dan padi yang diperoleh dari satu *scene* foto udara dengan menggunakan teknologi UAV. Data objek masing-masing kelas diambil secara *random* pada foto udara tersebut. Ukuran gambar sampel untuk pemrosesan jaringan adalah 227x227 piksel. Data untuk masing-masing kelas berjumlah 100 data sehingga keseluruhan data berjumlah 500 gambar. Data dari lima kelas tersebut dibagi menjadi tiga jenis kelompok data, yaitu data *training*, data validasi, dan data tes. Pembagian kelompok data untuk proses *training* sebesar 70%, data untuk proses validasi sebesar 20%, dan data untuk proses pengujian atau tes sebesar 10% dari total keseluruhan data.

Data *training* digunakan untuk melakukan proses pembelajaran jaringan, kemudian dievaluasi. Apabila akurasi pada proses *training* model jaringan belum baik maka perlu dilakukan modifikasi pada lapisan CNN, parameter jaringan dan pada sampel datanya. Apabila hasil akurasi sudah baik maka dilakukan proses selanjutnya yaitu pengujian dengan data validasi. Data validasi adalah data yang tidak digunakan pada proses *training*. Apabila akurasi dari data validasi ini kurang baik, mungkin terjadi *overfitting*, oleh karena itu jaringan perlu dimodifikasi lagi. Apabila hasilnya sudah baik maka dapat digunakan untuk memproses data tes. Data tes berisi sekumpulan sampel data yang ingin diketahui jenis klasifikasinya.

Arsitektur Jaringan CNN

Arsitektur jaringan pada penelitian ini menggunakan struktur dari Alexnet. Alexnet dikembangkan oleh (Krizhevsky et al., 2012) yang merupakan basis dari arsitektur CNN modern yang cukup sukses untuk *visual recognition*. Untuk mengatasi kekurangan pada proses *training* data citra resolusi tinggi, perlu pengaturan pada

beberapa lapisan dan mengeksplorasi parameter untuk training data agar model CNN dapat menampilkan performa yang baik dan mencegah gradien menjadi tidak stabil, khususnya pada jaringan yang dalam. Struktur model CNN disajikan pada **Tabel 1**. Jaringan terdiri dari lapisan input, 5 lapisan konvolusi, 3 *fully connected* layer, dan lapisan output.

Pada lapisan input, data yang digunakan adalah data *training*. Kemudian data input diproses pada lapisan konvolusi pertama dengan menggunakan *max pooling* dan fungsi aktivasi ReLU. Output pada lapisan konvolusi pertama dijadikan sebagai input pada proses konvolusi kedua. Proses konvolusi tersebut berlanjut sampai dengan konvolusi kelima. Kemudian hasil dari proses konvolusi dikumpulkan pada lapisan *fully connected*. Pada lapisan ini ditentukan fitur yang memiliki korelasi dengan kelas tertentu sehingga hasil akhir dari proses ini adalah fitur yang terklasifikasi dalam lima kelas.

Tabel 1. Struktur model CNN.

Lapisan	Ukuran piksel	Node
Input	227 x 227 x 3	
Conv1	11 x 11 x 3	96
Max Pool1	3 x 3	
Conv2	5 x 5 x 48	256
Max Pool2	3 x 3	
Conv3	3 x 3 x 256	384
Conv4	3 x 3 x 192	384
Conv5	3 x 3 x 192	256
Max Pool3	3 x 3	
FC6		4096
FC7		4096
FC8-n(class)		5
Output	227 x 227 x 3	

HASIL DAN PEMBAHASAN

Implementasi CNN

Terdapat tiga tahap dalam mengimplementasikan CNN, yaitu *training*, validasi dan tes. Tahap *training* adalah tahap utama untuk melatih jaringan mempelajari data input. Kemudian jaringan tersebut diuji pada data validasi. Apabila memberikan hasil yang baik, maka jaringan tersebut dapat digunakan untuk melakukan klasifikasi data dengan data tes.

Data Latih (Data Training)

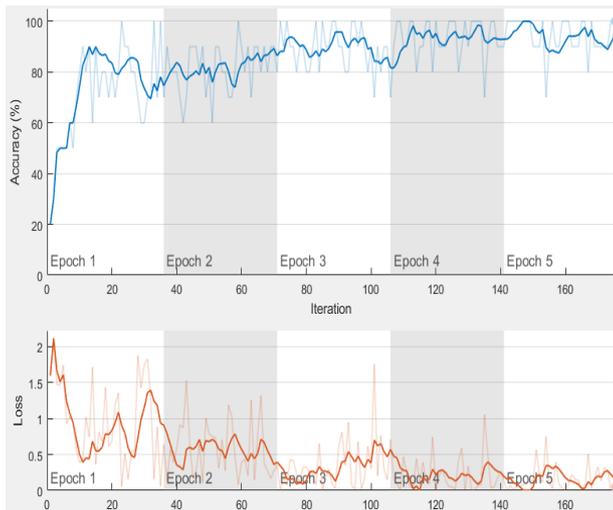
Data latih yang digunakan adalah 70% dari total keseluruhan data sehingga didapat data latih sebanyak 350 gambar dengan masing-masing kelas sebanyak 70 sampel. Komputasi dilakukan menggunakan mode single GPU. Proses *training* menggunakan parameter sebagai berikut:

learning rate : 0,0001
mini-batch size : 10
MaxEpochs : 5

Hasil *training* disajikan pada **Tabel 2**. *Training* jaringan memberikan akurasi yang baik. Grafik dari akurasi dan kesalahan proses *training* disajikan pada **Gambar 6**.

Tabel 2. Hasil *training* jaringan CNN.

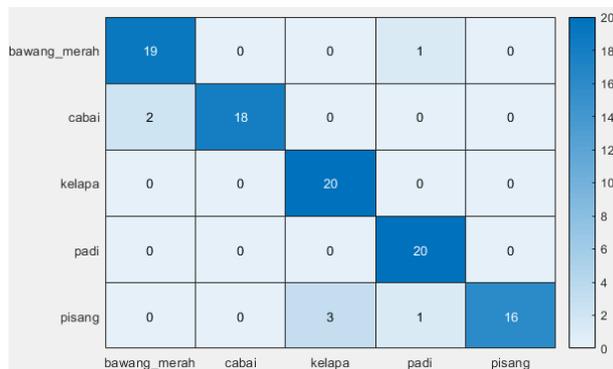
Epoch	Iterasi	Waktu (s)	Error	Accuracy
1	1	44	1,5915	20,00%
2	50	35,47	0,7838	80,00%
3	100	65,42	0,3052	90,00%
5	150	97,62	0,1115	90,00%
5	175	111,11	0,0480	100,00%



Gambar 6. Grafik akurasi dan kesalahan *training*.

Data Validasi

Proses validasi jaringan menggunakan 100 data untuk menguji jaringan dengan masing-masing kelas sebanyak 20 sampel. Data tersebut tidak diikuti dalam proses *training*. Dari proses ini didapatkan akurasi yang baik yaitu 93.00% dengan jumlah data yang benar sebanyak 93. Pada **Gambar 7** disajikan matriks konfusi data validasi.

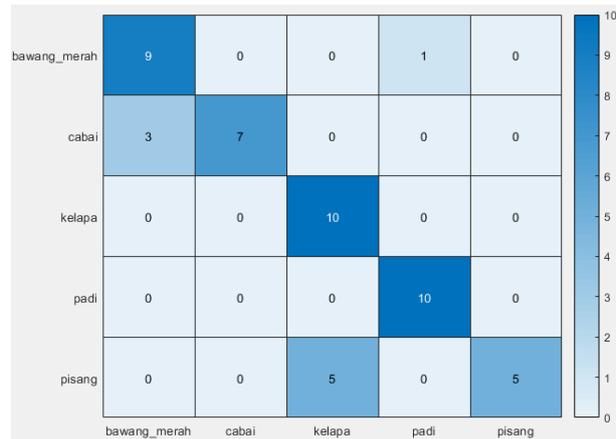


Gambar 7. Matriks konfusi dari data validasi.

Data Tes

Interpreter dapat memasukkan sampel data yang ingin diketahui jenis klasifikasinya pada jaringan, kemudian jaringan akan mengeluarkan label jenis tanaman berdasarkan data yang

dimasukkan. Hasil label klasifikasi yang keluar dari jaringan dapat untuk bahan pertimbangan interpreter dalam menentukan jenis objek tanaman yang sulit dibedakan secara visual. Pada penelitian ini skenario data tes menggunakan 50 data dengan masing-masing kelas sebanyak 10 sampel. Pengujian ini menghasilkan akurasi 82% dengan jumlah objek yang benar sebanyak 41 data. Hasil akurasi klasifikasi pada data tes digambarkan pada **Gambar 8** dan hasil klasifikasi semantik pada data tes disajikan pada **Gambar 9**.



Gambar 8. Matriks konfusi dari data tes.



(A)



(B)

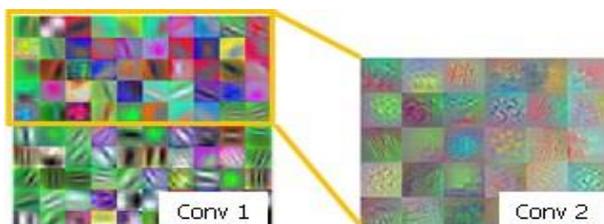
Gambar 9. Hasil klasifikasi semantik pada data tes (A) dan sampel data tes pada foto UAV (B).

Pada hasil pengujian data tes, kesalahan terbanyak terdapat pada pengklasifikasian pohon pisang. Tanda kotak berwarna kuning pada **Gambar 9** menunjukkan kesalahan klasifikasi pada objek pohon pisang. Jaringan memprediksi objek tanaman pisang sebagai tanaman kelapa. Dari 10 data sampel tanaman pisang di lapangan, 5 diantaranya diprediksi sebagai tanaman kelapa. Jaringan sulit membedakan objek tersebut karena kedua tanaman tersebut memiliki karakter fisik yang hampir sama pada foto UAV.

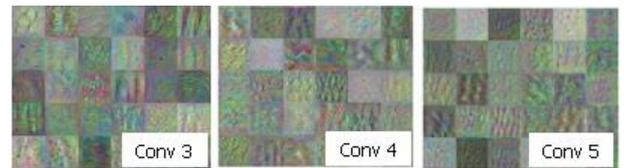
Visualisasi Lapisan

Metode CNN merupakan model yang kompleks. Pengetahuan mengenai operasi dan perilaku jaringan dalam mencapai performa yang baik, kurang mendapatkan pemahaman yang jelas bagaimana jaringan dapat bekerja. Oleh karena itu perlu *trial and error* dalam menentukan parameter-parameter jaringan agar didapat hasil yang baik. Perlu pengamatan selama proses *training* berlangsung. Pengamatan *training* pada tiap lapisan dapat dilakukan dengan cara memvisualisasikannya. Bobot dari proses konvolusi atau *fully-connected* layer dapat divisualisasikan untuk menaksir bagaimana baiknya model dapat dilatih. Model *training* yang baik biasanya memiliki filter yang halus dan kontinu dimana model *overfitting* akan ditampilkan pola dengan banyak *noise* (Zeiler & Fergus, 2014).

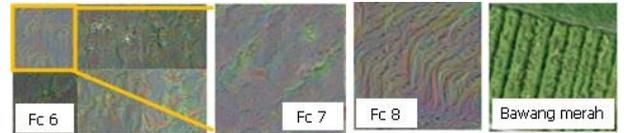
Visualisasi proses *training* pada tiap lapisan dilakukan dengan cara memproyeksikan kembali fitur aktivasi ke awal proses *training* jaringan. Pada **Gambar 10** merupakan visualisasi proses *training* pada lapisan konvolusi pertama dan lapisan konvolusi kedua. Pada konvolusi pertama dilakukan proses awal ekstraksi informasi yang berupa informasi tepi, bentuk kurva, dan warna. Proses ekstraksi informasi yang semakin dalam dilakukan oleh lapisan konvolusi kedua, lapisan konvolusi ketiga, lapisan konvolusi keempat dan lapisan konvolusi kelima. Visualisasi proses *training* pada lapisan ini disajikan pada **Gambar 11**. Penyatuan dari keseluruhan *node* dilakukan oleh lapisan *fully-connected* untuk menentukan *node* mana yang paling berkorelasi dengan kelas tertentu. Pada **Gambar 12** disajikan visualisasi lapisan *fully-connected* keenam, ketujuh, dan kedelapan. Pada lapisan *fully-connected* kedelapan ditentukan jenis kelas yang paling sesuai.



Gambar 10. Visualisasi lapisan konvolusi pertama dan konvolusi kedua.



Gambar 11. Visualisasi lapisan konvolusi ketiga, keempat, dan kelima.



Gambar 12. Visualisasi lapisan *fully-connected* keenam, ketujuh, dan kedelapan.

KESIMPULAN

Hasil implementasi metode CNN untuk klasifikasi semantik jenis tanaman pada citra resolusi tinggi yang diperoleh dari teknologi UAV menunjukkan bahwa arsitektur CNN dapat mengklasifikasikan lima jenis tanaman secara otomatis dengan memberikan label pada data. Evaluasi kerja terhadap arsitektur jaringan CNN pada data tes menghasilkan akurasi 82%. Untuk skenario data tes dengan jumlah masing-masing kelas sebanyak sepuluh sampel, metode CNN dapat memberikan hasil yang cukup baik dalam melakukan proses pengenalan objek dan klasifikasi tanaman, namun masih terdapat kesalahan. Kesalahan prediksi paling banyak terdapat pada kelas pisang yang diprediksi sebagai kelas kelapa. Dari tampilan citra UAV yang memiliki koreksi geometrik 4,64 mm ini, bentuk fisik kedua objek tersebut memiliki karakteristik penampakan yang mirip dan jarak kedua objek berdekatan sehingga menyebabkan jaringan salah memprediksi. Ketersediaan objek jenis tanaman dalam jumlah banyak pada foto udara yang dipakai untuk pemrosesan jaringan dan kondisi dari foto udara yang bebas dari *noise* juga berpengaruh dalam mendapatkan data sampel untuk proses *training*. Pada penelitian ini data diambil dari citra RGB yang masih dalam satu *scene* pada arah sudut datang matahari yang sama sehingga *color balancing* dapat terjaga dan citra dalam keadaan bebas awan untuk meminimalisir kesalahan terhadap bayangan yang dapat mempengaruhi nilai intensitas objek, mengingat UAV mengudara dibawah ketinggian awan.

Jumlah data *training* dapat mempengaruhi akurasi jaringan. Semakin banyak data *training* maka jaringan akan semakin banyak belajar sehingga ketelitian akan semakin baik. Namun diperlukan peralatan komputasi yang besar untuk melakukan proses *training* jaringan pada data yang banyak. Penelitian ini hanya menentukan klasifikasi semantik untuk membantu interpreter dalam menentukan jenis objek tanaman. Interpreter memasukkan sampel data objek yang ingin

diketahui klasifikasinya, kemudian jaringan memberikan jawaban nama objek tersebut. Sehingga dapat membantu interpreter yang tidak mengetahui kondisi jenis tanaman di lapangan sebagai bahan pertimbangan dalam melakukan digitasi objek pertanian.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada PPRT BIG yang telah mengizinkan penggunaan data UAV untuk penelitian ini.

DAFTAR PUSTAKA

- Albelwi, S., & Mahmood, A. (2017). A Framework for Designing the Architectures of Deep Convolutional Neural Networks. *Entropy*, *19*, 242.
- Bejiga, M. B., Zeggada, A., Nouffidj, A., & Melgani, F. (2017). A convolutional neural network approach for assisting avalanche search and rescue operations with UAV imagery. *Remote Sensing*, *9*(2). <https://doi.org/10.3390/rs9020100>
- Castelluccio, M., Poggi, G., Sansone, C., Verdoliva, L. (2015). Land Use Classification in Remote Sensing Images by Convolutional Neural Networks. Diambil dari <https://arxiv.org/pdf/1508.00092.pdf>
- Deng, L., & Yu, D. (2013). Deep Learning: Methods and Applications. *Foundations and Trends® in Signal Processing*, *7*(3-4), 197-387. <https://doi.org/10.1136/bmj.319.7209.0a>
- Giordan, D., Manconi, A., Remondino, F., & Nex, F. (2017). Use of unmanned aerial vehicles in monitoring application and management of natural hazards. *Geomatics, Natural Hazards and Risk*, *8*(1), 1-4. <https://doi.org/10.1080/19475705.2017.1315619>
- Heaton, J. (2015). *Artificial Intelligence for Humans: Deep learning and neural networks of Artificial Intelligence for Humans Series*. Createspace Independent Publishing Platform.
- Hijazi, S., Kumar, R., & Rowen, C. (2015). Image Recognition Using Convolutional Neural Networks. *Cadence Whitepaper*, 1-12.
- Hu, F., Xia, G. S., Hu, J., & Zhang, L. (2015). Transferring deep convolutional neural networks for the scene classification of high-resolution remote sensing imagery. *Remote Sensing*, *7*(11), 14680-14707. <https://doi.org/10.3390/rs71114680>
- Katole, A. L., Yellapragada, K. P., Bedi, A. K., Kalra, S. S., & Siva Chaitanya, M. (2015). Hierarchical Deep Learning Architecture for 10K Objects Classification. *Computer Science & Information Technology (CS & IT)*, (September), 77-93. <https://doi.org/10.5121/csit.2015.51408>
- Kim, J., Sangjun, O., Kim, Y., & Lee, M. (2016). Convolutional Neural Network with Biologically Inspired Retinal Structure. *Procedia Computer Science*, *88*, 145-154. <https://doi.org/10.1016/j.procs.2016.07.418>
- Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Proceedings of the Twenty-Sixth Annual Conference on Neural Information Processing Systems. Lake Tahoe, NY, USA, 3-8 December 2012*, 1097-1105.
- Maggiore, E., Tarabalka, Y., Charpiat, G., & Alliez, P. (2016). Convolutional Neural Networks for Large-Scale Remote-Sensing Image Classification. *IEEE Transactions on Geoscience and Remote Sensing*, *55*(2), 645-657. <https://doi.org/10.1109/TGRS.2016.2612821>
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, *15*, 1929-1958. <https://doi.org/10.1214/12-AOS1000>
- Tso, B., & Mather, P. M. (2009). *Classification Methods for Remotely Sensed Data, Second Edition*. CRC Press Taylor & Francis Group. Boca Raton.
- Vedaldi, A., & Lenc, K. (2015). MatConvNet: Convolutional Neural Networks for MATLAB. In *Proceedings of the 23rd ACM International Conference on Multimedia* (hal. 689-692). New York, NY, USA: ACM. <https://doi.org/10.1145/2733373.2807412>
- Yalcin, H., & Razavi, S. (2016). Plant classification using convolutional neural networks. *2016 Fifth International Conference on Agro-Geoinformatics (Agro-Geoinformatics)*, 1-5. <https://doi.org/10.1109/Agro-Geoinformatics.2016.7577698>
- Zeiler, M. D., & Fergus, R. (2014). Visualizing and Understanding Convolutional Networks. In D. Fleet, T. Pajdla, B. Schiele, & T. Tuytelaars (Ed.), *Computer Vision -- ECCV 2014* (hal. 818-833). Cham: Springer International Publishing.
- Zhang, C., Sargent, I., Pan, X., Gardiner, A., Hare, J., & Atkinson, P. M. (2018). VPRS-Based Regional Decision Fusion of CNN and MRF Classifications for Very Fine Resolution Remotely Sensed Images. *IEEE Transactions on Geoscience and Remote Sensing*, 1-15. <https://doi.org/10.1109/TGRS.2018.2822783>
- Zhi, T., Duan, L. Y., Wang, Y., & Huang, T. (2016). Two-stage pooling of deep convolutional features for image retrieval. In *2016 IEEE International Conference on Image Processing (ICIP)* (hal. 2465-2469). <https://doi.org/10.1109/ICIP.2016.7532802>