



MULTI-SCALE CONVOLUTIONAL NEURAL NETWORKS UNTUK KLASIFIKASI CITRA TANAMAN AGLONEMA HIBRIDA

Priyanto¹, Mutaqin Akbar²

^{1,2}, Program Studi Informatika, Universitas Mercu Buana Yogyakarta

Jl. Jembatan Merah No.84C, Depok, Sleman, Daerah Istimewa Yogyakarta, Indonesia.

¹201110103@student.mercubuana-yogya.ac.id, ²mutaqin@mercubuana-yogya.ac.id

Abstract

There are so many types of aglonema ornamental plants that it is still difficult for aglonema lovers and farmers to classify several types of aglonema. One type of aglonema is red which is often called Aglonema rotundum. This type of red aglonema is the forerunner of the types of hybrid aglonema developed to date by botanical personnel. Dataset collection using a cellphone camera images will be taken from several angles and lighting both bright and dark, and the division of the ratio between data for pengujian and pelatihan and the second indirect collection using datasets obtained from the internet by taking pictures from Instagram or taking from the Kaggle dataset. The data that has been collected is 560 which will be grouped into 4 classes. The data will be cut first in the region of interest (ROI) to a size of 28x28 and then converted to gray degrees. The CNN model used consists of 4 convolutional layers with 3x3, four Maxpool merging layers with 2x2 size and one fully-connected layer and uses the Softmax activation function with 32 filters in each convolutional layer. In this study used 2 schemes with different filters scheme 1 with filters 16,32,64,128 and scheme 2 with filters 32,64,128,128 and obtained the best value in scheme 2. Both schemes use the ADAM optimizer using 480 training data where the number of each class is 120 data and epoch as much as 20 with a pelatihan rate of 0.0002. And the resulting error is 0.0004 with accuracy reaching 100% at the 20th epoch. While in the testing results with the proposed CNN model can get an error of 0.0447 with an accuracy achieved of 98.78%.

Keywords : CNN, Multiscale, Aglonema, Clasification.

Abstrak

Tanaman hias aglonema sangat banyak jenisnya sehingga masih sulit bagi pecinta dan petani aglonema untuk mengklasifikasi beberapa jenis aglonema. Salah satu jenis aglonema berwarna merah yang sering disebut Aglonema rotundum. Aglonema jenis merah ini menjadi cikal bakal dari jenis-jenis aglonema hibrida yang dikembangkan hingga saat ini oleh tenaga botani. Pengambilan dataset menggunakan kamera handphone gambar akan diambil dari beberapa angle dan pencahayaan baik terang maupun gelap, dan pembagian rasio antara data untuk pengujian dan pelatihan dan yang kedua pengambilan tidak langsung menggunakan dataset yang didapat dari internet dengan mengambil gambar dari instagram maupun mengambil dari dataset kaggle. Data yang telah dikumpulkan sebanyak 560 yang akan di kelompokkan menjadi 4 kelas. Data akan dipotong terlebih dahulu pada *region of interest*(ROI) menjadi ukuran 28x28 lalu dikonversi ke derajat keabuan. Model CNN yang dipakai terdiri dari 4 layer kovolusional dengan 3x3, empat layer penggabungan *Maxpool* dengan ukuran 2x2 dan satu lapisan fully-connected dan menggunakan fungsi aktivasi Softmax dengan jumlah filter 32 pada setiap layer konvolusi. Dalam Penelitian ini digunakan 2 skema dengan filter yang berbeda skema 1 dengan filter 16,32,64,128 dan skema 2 dengan filter 32,64,128,128 dan didapatkan nilai terbaik pada skema 2. Kedua skema tersebut menggunakan optimizer ADAM dengan menggunakan data 480 data pelatihan dimana jumlah setiap kelasnya sebanyak 120 data dan epoch sebanyak 20 dengan laju pelatihan 0,0002. Dan dihasilkan galat 0,0004 dengan akurasi mencapai 100% di epoch ke-20. Sedangkan pada hasil pengujian dengan model CNN yang di usulkan dapat memperoleh galat 0,0447 dengan akurasi yang di capai sebesar 98,78%.

Kata kunci : CNN, Multiscale, Aglonema, Klasifikasi.



1. PENDAHULUAN

Tanaman Aglonema atau sering di sebut Sri Rejeki berasal dari daerah tropis dan subtropis seperti Asia. Jenis tanaman aglonema sangat banyak, masih sulit bagi pecinta dan petani aglonema untuk mengklasifikasi beberapa jenis aglonema karena banyak jenis aglonema baru hasil hibrida yang diciptakan oleh para ahli botani[1]. Ada 2 jenis kelompok tanaman aglonema yaitu aglonema spesies alam dan aglonema hibrida. Aglonema spesies alam sendiri terdiri dari 25 jenis dimana sebagian besar berwarna hijau dan sebagian bercorak. Salah satu jenis aglonema berwarna merah yang sering disebut *Aglonema rotundum*. Aglonema jenis merah ini menjadi tetua dari jenis-jenis aglonema hibrida yang dikembangkan hingga saat ini. Kelompok aglonema hibrida tercipta dari penilangan sehingga menciptakan corak corak warna yang beragam seperti merah cerah, kuning, dan orange[2]. Untuk mengenali jenis tanaman aglonema yang satu ini perlu mengetahui ciri-ciri dari masing-masing jenis tanaman aglonema. Namun bagi masyarakat yang belum mengetahui secara pasti ciri-ciri tanaman aglonema ini akan kesulitan membedakan jenisnya sehingga dapat menimbulkan kesalahan karena kesamaan bentuk, warna dan corak[1].

Deep Learning adalah sistem pembelajaran mesin menggunakan *Convolutional Neural Network* (CNN) Dimana sebuah komputer dapat menyesuaikan sifat dan tugas layaknya seorang manusia[3]. Dalam penerapannya CNN banyak digunakan dengan beberapa metode. Pada penelitiannya Yanuanga dkk[4] mengimplementasikan penggunaan CNN metode *Optical Character Recognition* (OCR) untuk mendeteksi plat nomor kendaraan. Penggunaan teknologi pemrosesan citra dan pengembangan model kecerdasan buatan sudah banyak dibahas seperti SVM (*Support Vector Machine*) dimana metode ini mencari ruang pemisah yang paling optimal dari sebuah kumpulan data dalam kelas yang berbeda-beda[5], ANN (*Artificial Neural Network*) sebuah sistem komputasi paralel masif yang terdiri dari sejumlah besar prosesor sederhana dengan banyak interaksi model ini terinspirasi oleh jaringan syaraf biologis dengan menggabungkan beberapa prinsip organisasi yang diyakini digunakan pada manusia[6]. KNN (K-

Nearest Neighbours) metode ini berpacu pada hasil ekstraksi fitur yang telah dilakukan pelatihan sebelumnya, metode ini memilih tetangga dari dataset pelatihan untuk menentukan nilai jarak yang terdekat atau nilai jarak terkecil sehingga menghasilkan keluaran klasifikasi[7] dan CNN (*Convolutional Neural Networks*) dikembangkan oleh Kunihiko Fukushima peneliti dari NHK Broadcasting Science Research Laboratories, Kinuta, Setagaya, Tokyo, Jepang dan menamainya NeoCognitron[8]. Kemudian skema tersebut disempurnakan oleh Yann LeCun dari AT&T Bell Laboratories di Holmdel, New Jersey, USA. LeCun berhasil menerapkan Model CNN dengan nama LeNet pada penelitiannya mengenai pengenalan angka dan tulisan tangan [9]. Pada tahun 2012, Dengan menerapkan CNN miliknya Alex Krizhevsky berhasil memenangkan kompetisi ImageNet Large Scale Visual Recognition Challenge 2012. Prestasi tersebut dapat membuktikan bahwa metode Deep Learning, khususnya CNN terbukti berhasil mengungguli metode Machine Learning lainnya seperti SVM pada kasus klasifikasi objek pada citra[10].

Dalam Penelitiannya Yann LeCun mengembangkan tidak hanya keluaran dari lapisan konvolusi terakhir yang menjadi masukan proses klasifikasi namun memasukkan setiap lapisan konvolusi dalam proses klasifikasi sehingga menyebabkan digunakannya fitur-fitur tingkat atas dan fitur-fitur tingkat bawah dalam proses klasifikasinya. Proses tersebut dinamai oleh Sermanet dan LeCun sebagai *multiscale*[11]. Oleh karena itu penelitian ini bertujuan untuk mengembangkan sebuah sistem klasifikasi citra tanaman aglonema dengan menggunakan CNN *multiscale*. Dengan menggabungkan teknologi pemrosesan citra dan kecerdasan buatan dan berharap menciptakan sebuah solusi yang akurat dan efisien untuk mengklasifikasi jenis-jenis tanaman aglonema.

2. TINJAUAN PUSTAKA

Penelitian mengenai Convolutional Neural Networks berbasis Multiscale guna Pengenalan Rambu Lalu Lintas di Indonesia masing - masing keluaran dari layer penggabungan *Maxpool* melewati sebuah proses perataan. Vektor yang dihasilkan kemudian digabungkan menjadi vektor yang ditampilkan di lapisan Concat.

Vektor tersebut kemudian dibagi menjadi 10 kelas menggunakan fungsi aktivasi softmax. Proses pelatihan model CNN menggunakan 1750 data pelatihan dengan parameter pelatihan yaitu pelatihan rate 0,005, jumlah epoch 20, dan jumlah filter 32 pada setiap convolutional layer sehingga mencapai akurasi pelatihan 100%. Nilai akurasi ini dapat dicapai dari epoch ke-11 hingga epoch terakhir yaitu epoch ke-20 dan didapat nilai galat 0,017 dan akurasi sebesar 99,67%[11].

Penelitian mengenai Klasifikasi Jenis Aglonema Berdasarkan Citra Daun Menggunakan Convolutional Neural Network (CNN) dapat berfungsi secara maksimal. Optimizer yang dipakai dan jumlah epoch dapat mempengaruhi proses pelatihan berdasarkan pengujian yang telah dilakukan. Dengan menggunakan Alexnet didapatkan nilai terbaik hingga 98.00 dengan jumlah epoch 15 dan menggunakan optimizer ADAM dan laju learning ratenya 0,0001. Menghasilkan nilai akurasi sebesar 96% dengan menggunakan 10 frame acak.[12].

Penelitian mengenai Dugaan Kanker Payudara menggunakan Metode CNN *Multi-Scale Input* dan *Multi-Feature Network* (CNN-G) dihasilkan dengan model yang dibuat dapat melakukan klasifikasi terhadap 4 kelas dan digunakan dalam melakukan diagnosis yang hasilnya dapat dijadikan sebagai prognosis untuk mendeteksi sel – sel pada jaringan normal dan yang terindikasi terkena kanker. Dengan memanfaatkan model CNN *multiscale* dan *multi-feature network* (CNN-G) didapatkan hasil akurasi 0,5375 terbukti meningkatkan tingkat keakurasian dibandingkan dengan model CNN Biasa yaitu CNN14, CNN42 dan CNN84[13].


Penelitian mengenai *Multiscale Convolutional Neural Networks with Attention for Plant Species Recognition*. Mengingat berbagai bentuk dan ukuran dari daun tanaman dan banyaknya jumlah berat parameter CNN, salah satu metode CNN yaitu MSCNN with attention (AMSCNN) dibangun untuk meningkatkan kemampuan ekstraksi fitur multi-scale dan diterapkan pada tanaman identifikasi spesies. Hasil percobaan pada dataset citra daun publik dataset citra daun memvalidasi bahwa metode yang diusulkan adalah efektif dan layak. Metode AMSCNN yang diusulkan melakukan konvolusi *multiscale* pada fitur yang diekstraksi dari lapisan konvolusi keempat dan kemudian melakukan fusi fitur dengan mekanisme perhatian,

sehingga dapat meningkatkan meningkatkan kinerja AMSCNN untuk mendeskripsikan citra daun[14].

Penelitian mengenai “*A Multiscale CNN-CRF Framework for Environmental Microorganism Image Segmentation*”, oleh Jinghua Zhang, dkk mengusulkan metode segmentasi bertingkat untuk tugas segmentasi EM, yang meliputi segmentasi tingkat piksel dan segmentasi tingkat patch. Dalam segmentasi tingkat piksel, mereka mengusulkan mU-Net-B3 dengan denseCRF untuk segmentasi EM. Dalam evaluasi hasil segmentasi yang dihasilkan oleh metode yang diusulkan ini, nilai indeks evaluasi Dice, Jaccard, Recall, Accuracy, dan Volume Overlap Error (VOE) berturut-turut. Dibandingkan dengan U-Net, empat indeks pertama meningkat masing-masing sebesar 1,89%, 2,32%, 4,84%, dan 0,14%, dan indeks terakhir menurun sebesar 2,32%. Selain itu, dibandingkan dengan metode mereka sebelumnya, kinerja hasil segmentasi meningkat secara signifikan[15].



3. METODOLOGI PENELITIAN

Terdapat beberapa alur dalam penelitian ini tahap pertama studi literatur tentang jenis jenis tanaman aglonema tahapan kedua pengumpulan dataset tahapan selanjutnya dari data yang terkumpul akan dilakukan preprocessing pemangkasan dan pengubahan ukuran pixel data juga akan di pisahkan sesuai kelas dan akan dibagi menjadi data pelatihan dan data pengujian. Persiapan selanjutnya pembuatan model CNN Multi-Scale sampai akurasi terbaik di dapatkan. Tahapan penelitian akan disajikan dalam gambar 1.



Gambar 1. Flowchart Alur Penelitian

Tabel 1. Contoh Dataset

Jenis Aglonema	Contoh 1	Contoh 2	Contoh 3	Contoh 4
Dud Anjamani				
Pride Of Sumatra				
Red Legacy				
Suksom				

3.1. Pengumpulan dan Analisa Dataset

Adapun tahapan penelitian dimulai dengan mengumpulkan dataset citra bunga aglonema dari beberapa jenis. Proses pengumpulan data telah dilakukan dengan beberapa metode yaitu pengambilan gambar menggunakan kamera handphone gambar akan diambil dari beberapa angel dan pencahayaan baik terang maupun gelap, dan pembagian rasio antara data untuk pengujian dan pelatihan dan yang kedua pengambilan tidak langsung menggunakan dataset yang didapat dari internet dengan mengambil gambar dari instagram maupun mengambil dari dataset kaggle. Pada dataset yang di teliti berfokus pada jenis aglonema berwarna merah. Dari data yang telah di ambil terdapat 4 jenis aglonema yang akan diteliti yaitu *Dud Anjamani*, *Pride Of Sumatra*, *Red Legacy* dan *Suksom* dari keempat jenis aglonema tersebut tertera pada *tabel 1*.


3.2. Preprocessing Data

Selanjutnya, tiap citra aglonema dikumpulkan pada sebuah folder yang berbeda berdasarkan jenisnya, untuk mempersiapkan data yang telah diperoleh. Setelah data siap, proses selanjutnya yaitu preprocessing gambar, dengan memotong gambar pada bagian yang menjadi pusat *region of interest* (ROI). Dengan

ukuran piksel 128 x 128. Kemudian akan dilakukan pengecilan ukuran gambar menjadi 28x28. Langkah selanjutnya adalah mengubah warna pada color *Red Green Blue* (RGB) ke ruang warna derajat keabuan (*Grayscale*)[11]. Pada langkah selanjutnya, akan membuat aksitektur CNN dengan menggunakan metode *multiscale* kemudian, dataset pelatihan digunakan untuk melakukan pengujian model CNN. Proses pengujian ini akan menggunakan optimizer *Adaptive Moment Estimation* (ADAM). Selanjutnya, nilai validasi terbaik akan digunakan dalam klasifikasi citra daun aglonema[12].

3.3. Arsitektur CNN

CNN diperkenalkan pada tahun 1889 oleh Yann LeCun dkk[16] algoritma terlatih ini memahami konten gambar dan bekerja dengan baik dalam pengenalan gambar, klasifikasi gambar, segmentasi gambar, dan tugas serupa. [17]. CNN adalah jaringan saraf tiruan yang menerapkan pelatihan yang diawasi. CNN dilatih menggunakan kumpulan data yang terdiri dari masukan dan target. Target dikaitkan dengan masukan. Tujuan ini digunakan oleh CNN untuk menentukan seberapa baik kinerja pelatihan, dan juga digunakan sebagai acuan untuk menyesuaikan nilai bobot guna mengurangi nilai



**Gambar 2.** Arsitektur CNN Multi-Scale

kesalahan yang diperoleh[18]. CNN memiliki beberapa lapisan: *input* (lapisan masukan), lapisan konvolusi, maxpool (lapisan pooling), *flatten*, *concat*, *softmax* (lapisan), dan terakhir keluaran (lapisan keluaran), seperti dijelaskan pada Gambar 3.

Lapisan pertama CNN disebut lapisan konvolusional. Konvolusi adalah bentuk matematika yang menggabungkan dua sinyal menjadi sinyal ketiga. [19]. Sinyal ke satu yaitu sinyal input, yang ke dua dalam CNN yaitu filter dan yang terakhir yaitu sinyal *output*. Pada lapisan konvolusional, sinyal masukan untuk pengolahan citra adalah citra skala abu-abu, namun kemungkinan citra berwarna tidak dikesampingkan. Menggunakan sekumpulan filter dengan nilai tak terbatas yang merupakan parameter. Jumlah filter yang digunakan adalah parameter, dan tidak ada batasan pada nilainya, namun biasanya 8, 16, 32, 128, dst. Ukuran filter yang digunakan bermacam-macam, biasanya adalah 3x3, 5x5, 7x7, 9x9, dst. Ilustrasi proses konvolusi ditunjukkan pada Gambar 3.

Dalam arsitektur CNN yang diusulkan yang ditunjukkan pada Gambar 1, 4 lapisan konvolusional berukuran 3x3 diterapkan. Dalam arsitektur ini akan menggunakan dua skema penggunaan filter dan akan dipilih pada nilai akurasi terbaik. Skema pertama menggunakan filter 16, 32, 64, 128 dan skema kedua menggunakan filter 32, 64, 128, 128. Filter yang menggunakan ukuran 3x3. Pada Gambar 3 merupakan merupakan ilustrasi proses konvolusi. Pada arsitektur CNN Multi-Scale akan diterapkan 4 lapisan konvolusi dengan ukuran 3x3 seperti ilustrasi pada Gambar 3.

Pada ilustrasi Gambar 4, Keluaran dari lapisan konvolusional kemudian melewati lapisan kedua, yaitu lapisan penggabungan. Lapisan kedua bertujuan untuk mencapai invarian spasial. Dalam hal ini, dapat dicapai dengan mengurangi resolusi matriks dengan menghilangkan elemen dengan nilai terkecil dari elemen yang berdekatan secara spasial[18]. Atau dengan cara mencari nilai reratanya. Dalam

**Gambar 3.** Proses Konvolusi**Gambar 4.** Proses Penggabungan

proses penggabungan ini mengambil nilai tertinggi dan mengabaikan nilai terkecil (maxpool). Dalam proses ini menggunakan jendela 2x2 untuk mengambil nilai ketetanggaan spasial sehingga menyebabkan *output* lapisan gabungan matriks yang berukuran setengah dari lapisan sebelumnya atau lapisan masukan yang bisa dilihat pada ilustrasi Gambar 3. Urutan pooling layer berada setelah convolutional layer, sehingga terdapat empat pooling layer pada arsitektur CNN Multi-Scale.

Output dari lapisan yang digabungkan menjadi input dari lapisan *fully-connected*. Namun sebelumnya dilakukan proses perataan untuk mengubah keluaran lapisan yang digabungkan menjadi vektor yang berfungsi sebagai masukan ke lapisan *fully-connected*. Keluaran dari setiap lapisan yang digabungkan melewati proses perataan, dan keluaran dari lapisan terakhir yang digabungkan bukanlah satu-satunya masukan dari lapisan *fully-connected*, Seperti ilustrasi pada Gambar 2.

Proses klasifikasi dilakukan pada *output* dari output proses perataan pada lapisan *fully-connected*. Proses klasifikasi memerlukan fungsi

aktivasi yang memungkinkan Anda memilih dari berbagai opsi, termasuk *linier*, *step*, *ramp*, *sigmoid*, *hiperbolik*, *Gaussian*, *softmax*, dll. Fungsi aktivasi Softmax digunakan di pesawat. Fungsi *softmax* menghitung distribusi probabilitas kelas yang ada[20]. Setelah diperoleh hasil probabilitas, maka kesalahan perhitungan dihitung berdasarkan target yang dituju dapat menggunakan fungsi untuk mencapai kesalahan lintas entropi. Prediksi dapat dikonfirmasi dengan memeriksa kesalahan kecil. Dengan menyesuaikan parameter-parameter yang ada pada CNN *Multiscale*, diperoleh nilai error sekecil mungkin. Penurunan gradien dan arah perubahan gradien selama penurunan gradien digunakan untuk mengatur dan menyesuaikan nilai bobot. Proses pengujian menggunakan dua pengoptimal untuk menentukan nilai validasi optimal. Dan hasil nilai akurasi terbaik didapat dengan menggunakan Optimizer ADAM pada skema 2 melatih CNN. Ilustrasi hasil pelatihan bisa dilihat pada Tabel 2 dan hasil penurunan gradien pada Gambar 4 dan Gambar 5.

4. HASIL DAN PEMBAHASAN

Pembahasan ini dibagi menjadi dua subbagian yaitu Pelatihan dan Pengujian. Bahasa pemrograman *Python* dengan perpustakaan *Tensorflow* akan digunakan.



A. Pelatihan

Dalam proses pelatihan ini parameter yang digunakan menggunakan laju pelatihan 0,0002 dengan epoch sebanyak 20 dan melatih filter dan bias konvolusional serta bobot dan bias lapisan fully-connected. Menggunakan arsitektur CNN dengan 4 lapisan konvolusi diikuti dengan lapisan penyatuan *Maxpool*. Dengan filter 32 di setiap layar konvolusi dengan ukuran 3x3. Dan pada lapisan penggabungan *Maxpool*, akan digunakan fungsi matrix 2x2. Semua keluaran tingkat penggabungan *Maxpool* melalui proses perataan. Setelah itu vektor-vektor yang dihasilkan digabungkan menjadi vektor yang terjadi pada lapisan Concat. Dengan menggunakan fungsi aktivasi *Softmax* vektor akan di klasifikasikan dalam 4 kelas.

Dengan GPU yang digunakan pelatihan ini dengan optimizer ADAM pada skema ke dua memerlukan waktu 15 menit pada 20 epoch dengan rata-rata 46 detik pada setiap epoch nya. Data yang digunakan dalam pelatihan ini sebanyak 480 data dengan 120 data setiap kelasnya. Skema pertama menghasilkan nilai galat 0,8043 dengan akurasi 66,25% dan didapat akurasi pada epoch ke 6 dan stabil hingga epoch ke-20. Pada hasil skema ke 2 ini terlihat bahwa nilai galat dapat stabil turun dari 0.9384 pada epoch pertama dengan akurasi 66,25% sampai 0,0004 pada epoch 20 dengan akurasi 100%. Pada model CNN skema 2 memiliki hasil terbaik yang mampu mencapai nilai akurasi 100% pada epoch 4 dan sudah mulai konvergen sampai epoch terakhir lebih baik dari skema pertama dimana nilai akurasi mencapai nilai 100% pada epoch 6 seperti yang disajikan pada Tabel 2.

Tabel 2 Hasil Pelatihan

Epoch	Skema 1		Skema 2	
	Galat	Akurasi (%)	Galat	Akurasi (%)
1	0.8043	66,25	0,9384	66,25
2	0.2511	90,83	0,2036	92,08
3	0.0831	98,12	0,0872	97,29
4	0.0756	99,37	0,0172	100
5	0.0166	99,37	0,0042	100
6	0.0047	100	0,0018	100
7	0.0022	100	0,0009	100
8	0.0013	100	0,0007	100
9	0,0009	100	0,0004	100
10	0,0005	100	0,0002	100
11	0,0003	100	0,0001	100
12	0,0002	100	0,0008	100
13	0,0001	100	0,0006	100
14	0,0001	100	0,0004	100
15	0,0008	100	0,0002	100
16	0,0009	100	0,0001	100
17	0,0005	100	0,0001	100
18	0,0003	100	0,0008	100
19	0,0002	100	0,0005	100
20	0,0001	100	0,0004	100

**Gambar 4.** Hasil Galat & Akurasi Skema 1**Gambar 5.** Hasil Galat & Akurasi Skema 2

B. Pengujian

Pada proses pengujian ini menggunakan data uji sebanyak 80 data, dimana terdapat 20 data uji setiap kelasnya dan menggunakan data yang berbeda dengan data pelatihan. Model CNN terdiri dari bobot dan bias yang dapat generalisasi data pelatihan dan berupaya mengenali 80 buah data pengujian. Nilai error sebesar 0,0447 ditentukan dari data pelatihan yang dijalankan pada model CNN multiscale dan berbanding lurus dengan nilai akurasi yang mencapai 98,78% dimana nilai akurasi tersebut lebih unggul dari nilai akurasi pada penelitian sebelumnya seperti yang disajikan pada Tabel 4.

Tabel 3. Hasil Pengujian

Skema 1		Skema 2	
Galat	Akurasi (%)	Galat	Akurasi (%)
0,044	98,78	0,044	98,78

Tabel 4 Perbandingan Hasil

Metode	Akurasi (%)
CNN[12]	98,00
CNN diusulkan	98,78

5. KESIMPULAN DAN SARAN

Klasifikasi citra tanaman Aglonema hibrida menggunakan model Multiscale Convolutional Neural Network telah di sajikan. Pada 2 sketsa yang telah di pelatihan dan pengujian hasil yang di dapatkan keduanya lebih unggul dari hasil penelitian sebelumnya. Dari kedua skema hasil terbaik di dapatkan pada skema ke 2 pada proses pelatihan dengan 480 data pelatihan dengan 120 data setiap kelasnya dan 80 data pengujian dengan 20 data setiap kelasnya dan menggunakan parameter laju pelatihan 0,0002 dengan jumlah epoch 20 dan dengan jumlah filter 32 akurasi pelatihan untuk setiap lapisan konvolusional adalah 100% yang di capai mulai dari epoch ke-4 hingga epoch terakhir epoch ke-20. Sedangkan pada skema pertama hasil akurasi 100% didapat pada epoch ke-6 hingga epoch terakhir yaitu epoch ke-20 dengan hasil pelatihan menunjukkan hasil yang sama dengan nilai galat 0,044% dan nilai akurasi 98,78% seperti yang disajikan pada tabel 3. Kedua skema tersebut menggunakan optimizer ADAM. Hasil akurasi pelatihan tersebut dapat mengungguli penelitian sebelumnya tentang klasifikasi tanaman aglonema yang disajikan pada Tabel 4. Penelitian selanjutnya juga dapat mempertimbangkan untuk menggunakan beberapa citra aglonema yang lebih bervariasi untuk masukan dalam model CNN.

DAFTAR PUSTAKA

- [1] N. Syahidan, S. Rati, S. Lubis, N. Fadillah, T. Informatika, dan U. Samudra, "Klasifikasi Tanaman Aglonema Dengan Fitur Ekstraksi Gray Level Co-Occurrence Matrix Dan K-Nearest Neighbor", [Daring]. Tersedia pada: <https://ejurnalunsam.id/index.php/jitko> m/
- [2] M. Subono dan A. Andoko, *Meningkatkan Kualitas Aglonema Sang Ratu Pembawa Rezaki*. Indonesia: PT ArgoMedia Pustaka, 2004.
- [3] I. W. Prastika, E. Zuliarso, J. T. Lomba, J. No, dan S. 50241, "Deteksi Penyakit Kulit



- Wajah Menggunakan Tensorflow Dengan Metode Convolutional Neural Network,” *Jurnal Manajemen informatika & Sistem Informasi*, vol. 4, no. 2, 2021, [Daring]. Tersedia pada: <http://e-journal.stmiklombok.ac.id/index.php/misi>
- [4] Y. Galahartlambang, T. Khotiah, Zahrudin Fanani, dan Afifatul Aprilia Yani Solekhah, “Deteksi Plat Nomor Kendaraan Otomatis Dengan Convolutional Neural Network Dan OCR Pada Tempat Parkir ITB Ahmad Dahlan Lamongan,” *Jurnal Manajemen Informatika dan Sistem Informasi*, vol. 6, no. 2, hlm. 114–122, Jun 2023, doi: 10.36595/misi.v6i2.754.
- [5] T. Dwi Novianto, I. Made Susi Erawan, L. Riset Mekanisasi Pengolahan Hasil Perikanan, Y. K. Jl Imogiri Barat, dan D. Yogyakarta, “Perbandingan Metode Klasifikasi pada Pengolahan Citra Mata Ikan Tuna”.
- [6] N. Gupta, “Network and Complex Systems Artificial Neural Network,” vol. 3, no. 1, 2013, [Daring]. Tersedia pada: www.iiste.org
- [7] H. Khotimah, N. Nafi’iyah, dan Masruroh, “Klasifikasi Kematangan Buah Mangga Berdasarkan Citra HSV dengan KNN,” *ELTI Jurnal Elektronika, Listrik dan Teknologi Informasi Terapan*, vol. 2, hlm. 1–7, Des 2019.
- [8] K. Fukushima, “Biological Cybernetics Neocognitron: A Self-organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position,” 1980.
- [9] L. Cun dkk., “Handwritten Digit Recognition with a Back-Propagation Network.”
- [10] W. S. Eka Putra, “Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) pada Caltech 101,” *Jurnal Teknik ITS*, vol. 5, no. 1, Mar 2016, doi: 10.12962/j23373539.v5i1.15696.
- [11] M. Akbar, A. S. Purnomo, dan S. Supatman, “Multi-Scale Convolutional Networks untuk Pengenalan Rambu Lalu Lintas di Indonesia,” *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, vol. 11, no. 3, hlm. 310–315, Des 2022, doi: 10.32736/sisfokom.v11i3.1452.
- [12] Y. Purna Irawan dan I. Susilawati, “Klasifikasi Jenis Aglonema Berdasarkan Citra Daun Menggunakan Convolutional Neural Network (CNN).”
- [13] G. Prameswari Natakusumah, “Implementasi Metode CNN Multi-Scale Input dan Multi-Feature Network untuk Dugaan Kanker Payudara,” 2022. [Daring]. Tersedia pada: <http://publishing-widyagama.ac.id/ejournal-v2/index.php/>
- [14] X. Wang, C. Zhang, dan S. Zhang, “Multiscale Convolutional Neural Networks with Attention for Plant Species Recognition,” *Comput Intell Neurosci*, vol. 2021, 2021, doi: 10.1155/2021/5529905.
- [15] J. Zhang dkk., “A Multiscale CNN-CRF Framework for Environmental Microorganism Image Segmentation,” *Biomed Res Int*, vol. 2020, 2020, doi: 10.1155/2020/4621403.
- [16] Y. Lecun, L. Bottou, Y. Bengio, P. Haffner, dan E. Bottou, “Gradient-based Learning Applied To Document Recognition - Proceedings of the IEEE,” *Proceedings of the IEEE*, vol. 86, no. 11, 1998, doi: 10.1109/5.726791i.
- [17] A. Khan, A. Sohail, U. Zahoor, dan A. S. Qureshi, “A survey of the recent architectures of deep convolutional neural networks,” *Artif Intell Rev*, vol. 53, no. 8, hlm. 5455–5516, 2020, doi: 10.1007/s10462-020-09825-6.
- [18] D. Scherer, A. Müller, dan S. Behnke, “Evaluation of Pooling Operations in Convolutional Architectures for Object Recognition.” [Daring]. Tersedia pada: <http://www.ais.uni-bonn.de>
- [19] A. P. Engelbrecht, *Computational intelligence: an introduction, 2nd ed.* Chichester, England; Hoboken, NJ: John Wiley & Sons. 2007.
- [20] S. W. Smith, *The scientist and engineer’s guide to digital signal processing.* San Diego, Calif.: California Technical Pub. 1999.