

Klasifikasi Citra Bibit Tanaman Menggunakan *Convolutional Neural Network* dan *Improved Feature Pyramid Network*

MUHAMMAD ICHWAN, RIZKIKA SITI SYIFA

Program Studi Informatika, Institut Teknologi Nasional Bandung
Email: ichwan@itenas.ac.id

Received 4 Agustus 2022 | *Revised* 18 Agustus 2022 | *Accepted* 8 September 2022

ABSTRAK

Klasifikasi bibit tanaman bertujuan untuk membantu mempermudah pengendalian jenis tanaman. Tugas klasifikasi tanaman menggunakan metode manual rentan terhadap kesalahan manusia. Pada penelitian ini, CNN dan Improved FPN diimplementasikan untuk meningkatkan akurasi pada saat melakukan tugas klasifikasi. Peningkatan FPN dilakukan untuk meningkatkan kualitas informasi yang didapatkan fitur, dengan menerapkan Channel Attention Module dan Augmented Bottom-up Pathway. Arsitektur ResNet50 digunakan sebagai backbone konvolusi FPN untuk meningkatkan kemampuan FPN mengekstraksi fitur. CNN kemudian diterapkan pada setiap peta fitur FPN akhir untuk mengklasifikasikan data. Hasil pengujian menunjukkan model memiliki kinerja lebih baik ketika FPN ditingkatkan dengan Channel Attention Module dan Augmented Bottom-up Pathway dengan rasio pengurangan Channel Attention diatur ke nilai 4 dengan akurasi pengujian yaitu 93,11% dan skor F1 yaitu 93%.

Kata kunci: bibit tanaman, cnn, fpn, resnet50, channel attention module, augmented bottom-up pathway, klasifikasi citra

ABSTRACT

Plant seedlings classification aims to help facilitate plant species control. The plant classification task using manual methods is prone to human error. In this study, CNN and Improved FPN were implemented to increase accuracy when performing the classification task. The FPN improvement was done to improve the quality of information obtained by the features, by implementing Channel Attention Module and Augmented Bottom-up Pathway. ResNet50 architecture was used as the convolutional backbone in FPN to enhance the feature extraction capabilities. CNN was then applied to each of FPN final feature maps to classify the data. The test results showed that the model performed better when the FPN was improved with the Channel Attention Module and Augmented Bottom-up Pathway where the Channel Attention reduction ratio was set to 4 with test accuracy of 93.11% and F1 score of 93%.

Keywords: plant seedlings, cnn, fpn, resnet50, channel attention module, augmented bottom-up pathway, image classification

1. PENDAHULUAN

Tumbuhan merupakan salah satu sumber kehidupan yang memiliki peran penting di Bumi, karena berfungsi untuk mengatur keseimbangan ekologis maupun sebagai sumber makanan bagi makhluk hidup lain (**Mustafa et al., 2020**). Spesies tanaman yang ada pada Bumi bervariasi, maka tugas identifikasi dan klasifikasi tanaman dapat membantu dalam mengenali spesies tanaman yang berbeda (**Alimboyong et al., 2018**). Klasifikasi tanaman dapat dilakukan berdasarkan keseragaman sifat dan ciri dari tumbuhan (**Rai, 2018**).

Bibit tanaman adalah salah satu fase penting dalam kehidupan tanaman, di mana klasifikasi bibit ke dalam kategori yang berbeda sebelum ditanam dapat memungkinkan petani untuk mengontrol kondisi pertumbuhan tanaman (**Silva et al., 2013**). Namun, metode manual untuk klasifikasi spesies tumbuhan memerlukan banyak waktu dan rentan terhadap kesalahan manusia (**Pacifico et al., 2018**).

Pemrosesan citra dapat digunakan pada pengenalan dan klasifikasi spesies tanaman berbeda untuk mengatasi masalah metode manual dalam klasifikasi spesies tumbuhan (**Dyrmann et al., 2016**). Klasifikasi pada teknik pemrosesan citra dapat memanfaatkan metode *deep learning* untuk meniru kerja otak manusia dalam mengolah data dan melakukan pengambilan keputusan (**Ashqar et al., 2019**). Salah satu metode *deep learning* adalah *Convolutional Neural Network* (CNN), di mana jaringan dapat melakukan analisis fitur dan dikategorikan dengan akurat melalui proses pelatihan yang umumnya tidak dapat dilihat oleh mata manusia (**Patil, 2021**).

Feature Pyramid Network (FPN) adalah fitur ekstraktor dengan membantu jaringan mempelajari dan mendeteksi objek pada skala berbeda yang ada dalam gambar dengan menggunakan fitur yang disebut *bottom-up pathway* dan *top-down pathway* dengan koneksi lateral pada skala fitur yang berbeda (**Lin et al., 2017**). Pada jalur *bottom-up* FPN biasanya menggunakan arsitektur *deep learning* untuk meningkatkan kemampuan ekstraksi fitur, seperti *Residual Network* (ResNet), di mana ResNet dibedakan berdasarkan kedalaman lapisan jaringannya.

Fitur-fitur di lapisan bawah FPN melewati lapisan-lapisan jaringan untuk mencapai jaringan atas. Dari lapisan-lapisan itu memungkinkan adanya informasi tingkat bawah yang hilang, di mana fitur tingkat yang lebih rendah tersebut penting untuk pemrosesan gambar (**Nie et al., 2020**). Dengan demikian, maka pendekatan *augmented bottom-up pathway* dilakukan untuk memperpendek jalur informasi dan meningkatkan lokalisasi piramida fitur yang ada di tingkat rendah.

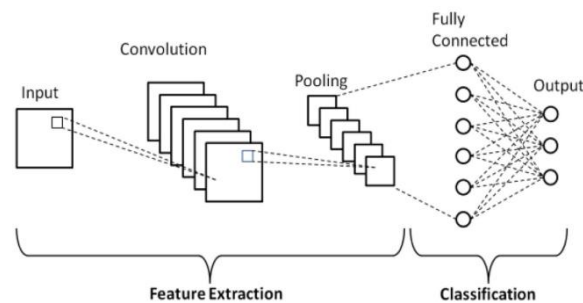
Selain *augmented bottom-up pathway*, *Channel Attention Module* diimplementasikan pada FPN untuk meningkatkan kontribusi *channel* fitur penting (**Yan et al., 2021**). *Channel attention module* bertujuan untuk meningkatkan kekuatan representasi arsitektur, dengan berfokus pada fitur *channel* yang penting (**Woo et al., 2018**).

Pada penelitian ini metode *Convolutional Neural Network* dan *Improved Feature Pyramid Network* dengan *backbone* ResNet50 akan digunakan untuk melakukan klasifikasi citra bibit tanaman, di mana *channel attention* dan teknik *augmented bottom-up pathway* akan diimplementasikan terhadap FPN dengan tujuan untuk meningkatkan kualitas informasi yang didapatkan dari fitur. Penelitian ini dilakukan untuk mengukur kinerja model pada klasifikasi citra bibit tanaman berdasarkan tingkat akurasi klasifikasi sistem.

2. METODE PENELITIAN

2.1. Convolutional Neural Network

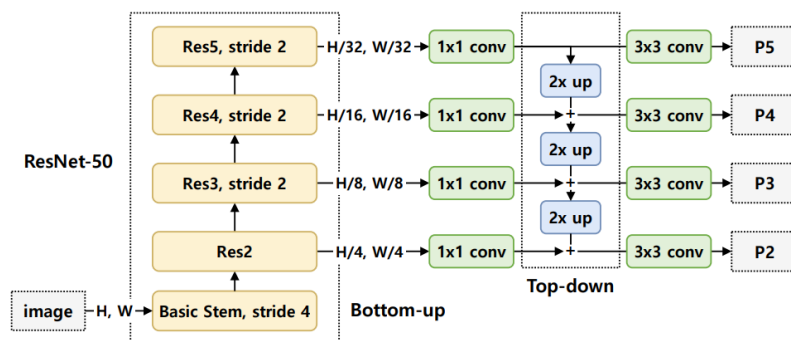
Convolutional Neural Network (CNN) adalah salah satu metode *deep learning* yang dapat digunakan untuk melakukan tugas klasifikasi citra. CNN terdiri dari tiga lapisan, yaitu (i) lapisan konvolusi yang berfungsi seperti *filter* untuk mengekstrak fitur dari *input*; (ii) lapisan *pooling* untuk menurunkan sampel peta fitur dan mengurangi jumlah parameter; (iii) lapisan *fully connected* di mana setiap *neuron* terhubung sepenuhnya dengan *layer* sebelumnya. Lapisan *fully connected* menggabungkan semua *input* untuk membuat *output* berupa kategori klasifikasi (Duong et al., 2020). Arsitektur CNN umum ditunjukkan pada Gambar 1, di mana terdapat proses ekstraksi fitur dan klasifikasi.



Gambar 1. Arsitektur CNN (Phung & Rhee, 2018)

2.2. Feature Pyramid Network

Feature Pyramid Network (FPN) adalah fitur ekstraktor yang mengambil citra sebagai *input* dan menampilkan *feature map* di berbagai level, dengan menggunakan konvolusi dan pembangunan piramida yang melibatkan *bottom-up pathway* dan *top-down pathway* (Lin et al., 2017). Gambar 2 menunjukkan arsitektur FPN dengan ResNet50.



Gambar 2. Arsitektur FPN Dengan ResNet50 (Lee et al., 2021)


Dari Gambar 2 dapat dilihat bahwa FPN menggunakan arsitektur ResNet50 sebagai *backbone* konvolusi. *Residual Network* (ResNet) adalah *framework* pembelajaran residual atau *residual learning* yang mendalam dan diusulkan oleh (He et al., 2016). Citra *input* di-*downsampling* dua kali dengan konvolusi 7×7 dan *stride 2*, dan 3×3 *max pooling* dengan *stride 2*. Hasil konvolusi oleh Res2-Res5 dikonvolusikan dengan konvolusi 1×1 . Selanjutnya di-*upsampling* dengan faktor 2 dan digabungkan dengan peta fitur hasil konvolusi 1×1 di bawahnya. Hasil penggabungan dikonvolusikan 3×3 untuk menghasilkan peta fitur akhir. Gambar 3 menunjukkan arsitektur ResNet.

| layer name | output size | 18-layer | 34-layer | 50-layer | 101-layer | 152-layer |
|------------|-------------|---|---|---|--|--|
| conv1 | 112×112 | 7×7, 64, stride 2 | | | | |
| conv2_x | 56×56 | 3×3 max pool, stride 2 | | | | |
| | | $\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$ | $\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$ | $\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$ | $\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$ | $\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$ |
| conv3_x | 28×28 | $\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$ | $\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$ | $\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$ | $\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$ | $\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$ |
| conv4_x | 14×14 | $\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$ | $\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$ | $\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$ | $\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$ | $\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$ |
| conv5_x | 7×7 | $\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$ | $\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$ | $\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$ | $\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$ | $\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$ |
| | 1×1 | average pool, 1000-d fc, softmax | | | | |
| FLOPs | | 1.8×10 ⁹ | 3.6×10 ⁹ | 3.8×10 ⁹ | 7.6×10 ⁹ | 11.3×10 ⁹ |

Gambar 3. Arsitektur ResNet (He et al., 2016)

2.3. Channel Attention Module

Channel Attention Module digunakan untuk menekan fitur *channel* yang tidak penting dan memperkuat fitur *channel* yang penting. Fitur yang diperoleh dari *channel* yang berbeda tidak semuanya memiliki kepentingan informasi yang sama; beberapa *channel* mungkin tidak berisi fitur target (Nie et al., 2020). Arsitektur *channel attention module* ditunjukkan pada Gambar 4.




Gambar 4. Arsitektur Channel Attention Module

Pada Gambar 4 ditunjukkan bahwa untuk melakukan *channel attention module*, dimensi spasial perlu dikompresi dari fitur *input* melalui *average pooling* dan *max pooling*, sehingga *input* menjadi vektor satu dimensi 1 x 1 x C. Selanjutnya dua fitur tersebut diteruskan ke dua lapisan *fully connected* untuk memodelkan korelasi antar *channel*. Kedua fitur *max pool* dan *average pool* yang telah melewati lapisan *fully connected* kemudian ditambahkan dengan *element-wise add*. Selanjutnya melakukan aktivasi menggunakan fungsi Sigmoid untuk mendapatkan bobot yang mewakili kontribusi fitur *input*. Yang terakhir adalah mengalikan fitur *input* dengan bobot untuk menghasilkan *output* peta fitur.

2.4. Augmented Bottom-up Pathway

Augmented Bottom-up Pathway merupakan teknik fitur ekstraksi yang berusaha memperpendek jalur informasi dan meningkatkan piramida fitur dengan lokalisasi akurat yang ada di level rendah, teknik fitur ekstraksi ini diusulkan oleh (Liu et al., 2018) pada metode *Path Aggregation Network* (PANet).

Klasifikasi Citra Bibit Tanaman menggunakan *Convolutional Neural Network* dan *Improved Feature Pyramid Network*

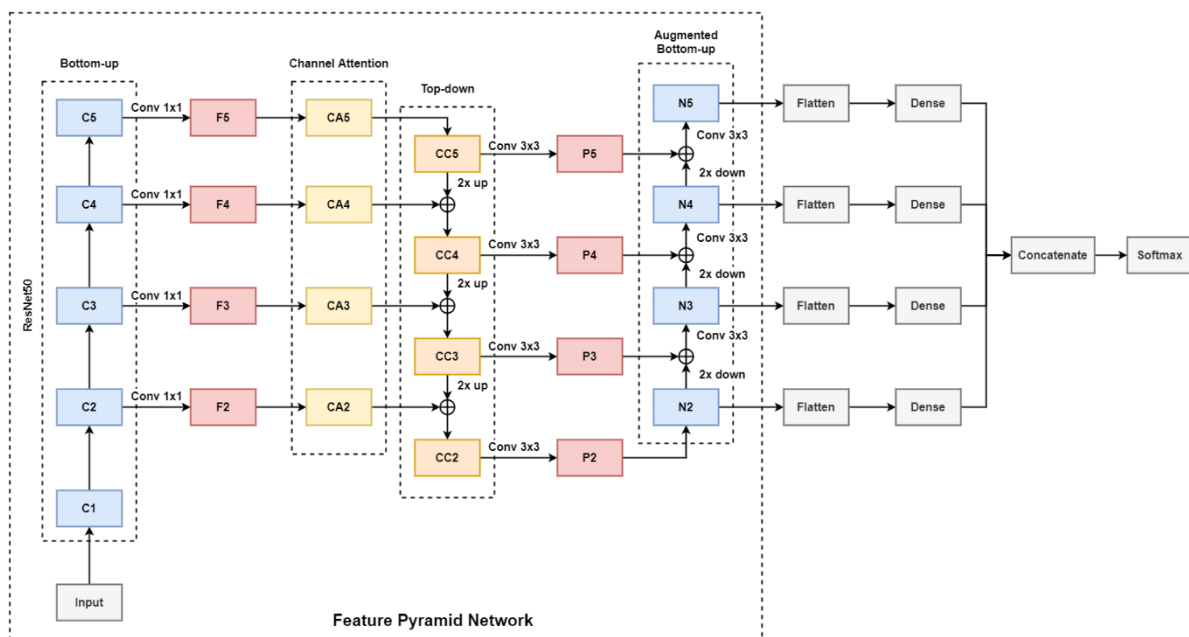


Gambar 5. Struktur Augmented Bottom-up Pathway (Liu et al., 2018)

Setiap peta fitur N_i dikonvolusikan 3×3 dengan *stride 2*, kemudian peta fitur ini digabungkan menggunakan *element-wise max* dengan P_{i+1} . Lalu setiap peta fitur yang telah digabungkan diproses dengan konvolusi 3×3 untuk menghasilkan N_{i+1} . Fungsi aktivasi ReLU ditambahkan pada setiap proses konvolusi.

2.5. Arsitektur CNN dan Improved FPN

(Rahimzadeh et al., 2021) mengimplementasikan FPN untuk mengklasifikasi citra CT-SCAN dengan ResNet50V2 dan Grad-CAM. Dengan pendekatan yang sama, arsitektur metode CNN dan Improved FPN sebagai fitur ekstraktor untuk klasifikasi citra bibit tanaman dibangun dan ditunjukkan pada Gambar 6 yang memperlihatkan bahwa pada citra *input* dilakukan proses ekstraksi fitur dengan Improved FPN yang hasil peta fiturnya kemudian dilakukan klasifikasi menggunakan lapisan *fully connected CNN*.



Gambar 6. Arsitektur CNN dan Improved FPN

Dari Gambar 6 maka langkah pertama dalam arsitektur CNN dan Improved FPN yaitu *input* citra dimasukkan ke ResNet50 untuk mendapatkan hasil berupa peta fitur C1-C5. Kedua, C2-C5 dikonvolusikan dengan *kernel* konvolusi berukuran 1×1 sehingga menghasilkan peta fitur F2 hingga F5. Peta fitur C1 tidak dikonvolusikan ke piramida karena jejak memorinya yang besar. Selanjutnya, pada peta fitur F2-F5 diterapkan metode *channel attention* untuk

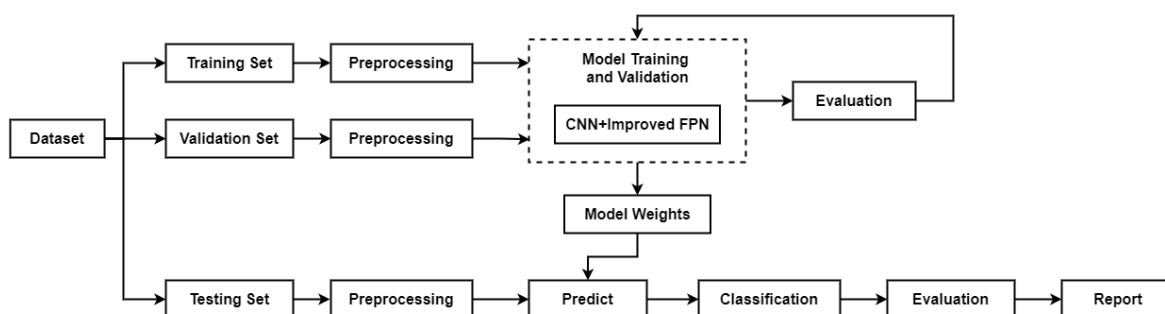
meningkatkan kontribusi *channel* peta fitur sehingga menghasilkan peta fitur CA2-CA5. Peta fitur CA5 kemudian masuk ke jalur *top-down* untuk di-*upsample* dengan faktor 2 sebagai CC5 dan digabungkan dengan peta fitur CA di tingkat bawahnya, dan dilakukan berulang hingga berhenti setelah mencapai CC2. Kemudian, peta fitur CC2-CC5 dikonvolusikan dengan *kernel* konvolusi berukuran 3x3 sehingga menghasilkan peta fitur P2-P5.

Setelah itu, fitur masuk ke jalur *augmented bottom-up*, di mana N2 merupakan P2 yang tidak dilakukan operasi apapun. N2 kemudian di-*downsample* menggunakan konvolusi dengan *kernel* berukuran 3x3 dan *stride* 2. Kemudian, dilakukan operasi *element-wise max* dengan P3 untuk penggabungan fitur. Hasil fusi fitur kemudian dikonvolusikan kembali dengan *kernel* konvolusi berukuran 3x3 untuk menghasilkan N3. Proses ini dilakukan berulang hingga mencapai fitur N5.

Pada peta fitur N2-N5 kemudian diterapkan operasi *flattening*, untuk mengubah peta fitur menjadi *array* 1 dimensi yang kemudian dimasukkan ke lapisan berikutnya. Selanjutnya, dilakukan klasifikasi kelas menggunakan lapisan *dense*, di mana jumlah lapisan *dense* sesuai dengan jumlah kelas, yaitu 12. Hasil klasifikasi setiap *level* kemudian digabungkan dengan menggunakan *concatenation* dan melalui fungsi aktivasi *softmax* untuk mendapatkan klasifikasi akhir.

2.6. Arsitektur Sistem

Arsitektur sistem klasifikasi citra bibit tanaman yang dilakukan dengan set pelatihan, set validasi, dan set pengujian ditunjukkan pada Gambar 7.



Gambar 7. Arsitektur Sistem

Dari Gambar 7 dapat dilihat bahwa sistem dimulai dengan membagi *dataset* ke dalam set pelatihan, set validasi, dan set pengujian. Selanjutnya dilakukan *preprocessing* pada setiap set. *Preprocessing* pertama adalah melakukan *resize* pada seluruh data sehingga data masukan berukuran 224 x 224. Selanjutnya pada set pelatihan dilakukan augmentasi data yaitu *flip* horizontal dan vertikal, serta rotasi. Set pelatihan dan set validasi kemudian digunakan untuk proses pelatihan dan validasi model menggunakan metode CNN dan *Improved FPN*. Bobot model hasil proses pelatihan dan validasi kemudian dilakukan evaluasi dengan mengukur akurasi dan *loss* lalu melakukan pelatihan dan validasi ulang untuk mendapatkan nilai akurasi dan *loss* terbaik hingga seluruh *epochs* selesai. Hasil proses pelatihan dan validasi berupa bobot model yang digunakan untuk melakukan prediksi pada set pengujian.

Pada set pengujian yang telah dilakukan *preprocessing*, sistem akan melakukan prediksi menggunakan bobot model yang telah dilatih dan divalidasi untuk menghasilkan klasifikasi.

Hasil klasifikasi kemudian akan dievaluasi dan menampilkan *report* klasifikasi berupa akurasi, presisi, *recall*, dan skor F1.

2.7. Metrik Evaluasi

Metrik evaluasi digunakan untuk mengukur efektivitas hasil pengklasifikasi yang dihasilkan pada tahap pengujian (Sahli, 2020). Pada perhitungan metrik evaluasi, terdapat *true positive* (tp) dan *true negative* (tn) yang menunjukkan instans yang diprediksi oleh pengklasifikasi dengan benar. Selain itu, terdapat *false positive* (fp) dan *false negative* (fn) yang menunjukkan instans yang salah diklasifikasikan (**Shobha & Rangaswamy, 2018**).

Akurasi: Akurasi (acc) mengukur rasio prediksi yang benar dengan jumlah total instans yang dievaluasi. Representasi matematis akurasi ditunjukkan pada Persamaan (1).

$$acc = \frac{tp+tn}{tp+fp+tn+fn} \quad (1)$$

Presisi dan *recall*: Presisi dan *recall* digunakan untuk mengukur seberapa akurat hasil untuk setiap kategori. Presisi (p) digunakan untuk mengukur pola positif yang diprediksi dengan benar dari total pola prediksi di kelas positif. Sedangkan *recall* (r) digunakan untuk mengukur pecahan dari pola positif yang diklasifikasikan dengan benar. Representasi matematis presisi dan *recall* ditunjukkan pada Persamaan (2) dan Persamaan (3).

$$p = \frac{tp}{tp+fp} \quad (2)$$

$$r = \frac{tp}{tp+fn} \quad (3)$$


F-Score: F-Score (F1) merupakan rata-rata harmonik antara nilai presisi dan *recall*. Representasi matematis F-score ditunjukkan pada Persamaan (4).

$$F_1 = \frac{2 \times p \times r}{p+r} \quad (4)$$

3. HASIL DAN PEMBAHASAN

3.1. Deskripsi *Dataset*

Dataset yang digunakan merupakan hasil pengumpulan data yang dilakukan oleh (**Giselsson et al., 2017**) dengan tujuan untuk mendukung peneliti dan mendorong pengembangan teknik pengenalan spesies tanaman pada industri pertanian. Kumpulan data ini terdiri dari total 5.539 citra tanaman RGB yang terbagi ke dalam 12 kelas spesies tanaman dengan resolusi fisik sekitar 10 piksel per mm. Seluruh kelas spesies pada *dataset* ini dipilih untuk melakukan klasifikasi karena memiliki kemiripan bentuk fisik daunnya, mengingat klasifikasi tanaman dapat dilakukan berdasarkan keseragaman sifat dan ciri fisik tumbuhan (**Rai, 2018**). Gambar 8 menunjukkan sampel citra *dataset* per kelas spesies.



Gambar 8. Sampel Citra Dataset Per Kelas Spesies

3.2. Pemrosesan Awal *Dataset*

Pada seluruh citra *dataset* dilakukan pemrosesan awal (*preprocessing*) yang dimulai dari pembagian data ke dalam tiga set, yaitu data pelatihan, validasi, dan pengujian dengan rasio masing-masing sebesar 70%, 15%, dan 15%. Seluruh data kemudian di-*resize* menjadi berukuran 224 x 224. Pada data latih kemudian dilakukan teknik augmentasi yang meliputi *flip* horizontal dan vertikal, dan rotasi untuk meningkatkan variasi data. Tabel 1 menunjukkan jumlah pembagian data ke dalam set pelatihan, validasi, dan pengujian.

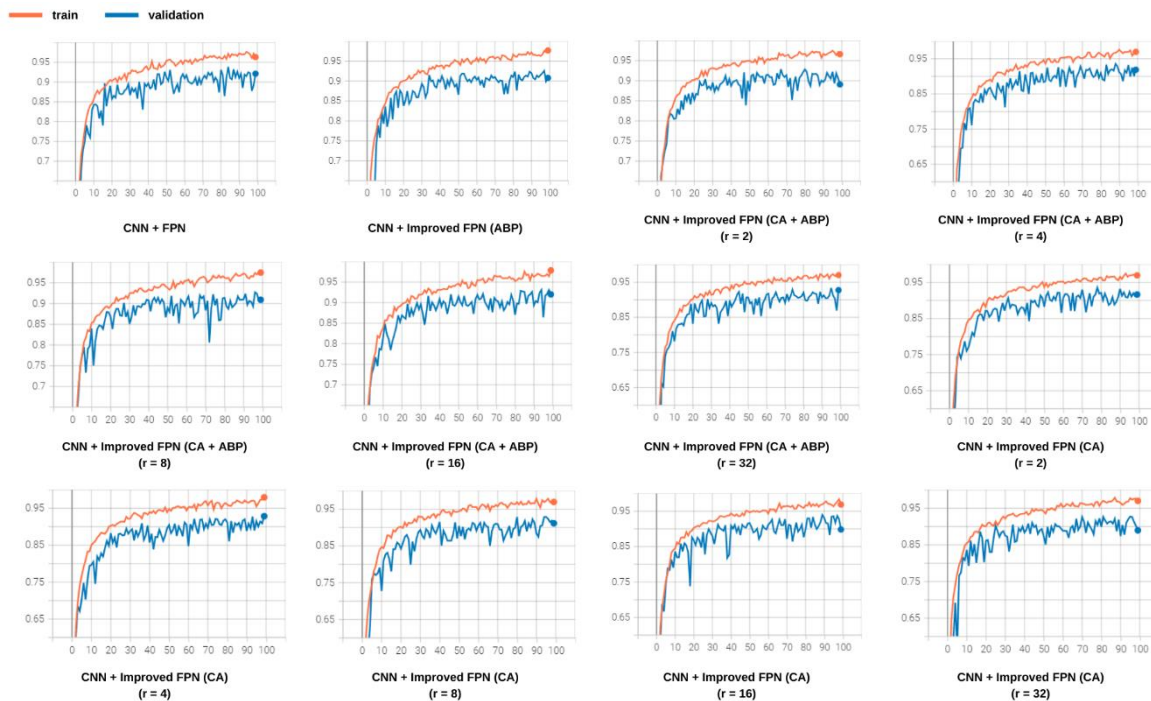
Tabel 1. Pembagian Data ke Dalam Set Pelatihan, Validasi, dan Pengujian

| Nama Spesies | Pelatihan (70%) | Validasi (15%) | Pengujian (15%) | Jumlah |
|---------------------------|------------------------|-----------------------|------------------------|---------------|
| Black-grass | 216 | 46 | 47 | 309 |
| Charlock | 316 | 67 | 69 | 452 |
| Cleavers | 234 | 50 | 51 | 335 |
| Common Chickweed | 499 | 106 | 108 | 713 |
| Common wheat | 177 | 37 | 39 | 253 |
| Fat Hen | 376 | 80 | 82 | 538 |
| Loose Silky-bent | 533 | 114 | 115 | 762 |
| Maize | 179 | 38 | 40 | 257 |
| Scentless Mayweed | 424 | 91 | 92 | 607 |
| Shepherd's Purse | 191 | 41 | 42 | 274 |
| Small-flowered Cranesbill | 403 | 86 | 87 | 576 |
| Sugar Beet | 324 | 69 | 70 | 463 |
| TOTAL | 3872 | 825 | 842 | 5539 |

3.3. Pelatihan Model

Pelatihan dan pemrograman dilakukan menggunakan GPU Tesla P100-PCIE 16 GB dari *Google Colaboratory* dengan *library Keras* dan *backend Tensorflow*. Model yang telah dibangun kemudian dilatih dengan 100 *epochs* dan dikelompokkan dengan *batch size* sebesar 32. Perhitungan *loss function* dilakukan menggunakan *categorical cross-entropy*, dan *Adam Optimizer* dengan *learning rate* sebesar 0,00005 diterapkan untuk melakukan optimisasi. Grafik hasil pelatihan dan validasi seluruh *epochs* pada setiap model terhadap akurasi ditunjukkan pada Gambar 9.

Klasifikasi Citra Bibit Tanaman menggunakan *Convolutional Neural Network* dan *Improved Feature Pyramid Network*



Gambar 9. Grafik Pelatihan dan Validasi Terhadap Akurasi

Dari Gambar 9 dapat dilihat bahwa grafik akurasi validasi pada model CNN + *Improved FPN* (CA + ABP) dengan rasio pengurangan 4 lebih stabil dibandingkan dengan rasio pengurangan yang lain. Dari hasil pelatihan model, didapatkan akurasi pelatihan tertinggi ada pada model CNN + *Improved FPN* (CA) dengan rasio pengurangan 16 yaitu sebesar 98,17% dan akurasi pelatihan terendah ada pada model CNN + *Improved FPN* (CA + ABP) dengan rasio pengurangan 2 yaitu sebesar 96,90%. Akurasi validasi tertinggi ada pada model CNN + *Improved FPN* (CA) dengan rasio pengurangan 16 yaitu sebesar 93,94% dan akurasi validasi terendah ada pada model CNN + *Improved FPN* (ABP) yaitu sebesar 92,61%.

3.4. Pengujian Model

Pengujian dilakukan dengan menggunakan set pengujian dan bobot model hasil pelatihan dan validasi. Hasil pengujian rasio diukur berdasarkan tingkat akurasi, presisi, *recall*, F1 dan total parameter yang ditunjukkan pada Tabel 2.

Tabel 2. Hasil Pengujian Model

| Model | Rasio | Akurasi | Presisi | <i>Recall</i> | F1 | Total Parameter |
|--------------------------|-------|---------|---------|---------------|-----|-----------------|
| CNN + FPN | - | 91,81% | 92% | 91% | 91% | 39.386.620 |
| CNN + Improved FPN (ABP) | - | 92,76% | 92% | 92% | 92% | 42.927.100 |
| CNN + Improved FPN (CA) | 2 | 90,50% | 90% | 90% | 90% | 39.913.980 |
| CNN + Improved FPN (CA) | 4 | 92,16% | 92% | 92% | 91% | 39.651.324 |
| CNN + Improved FPN (CA) | 8 | 92,28% | 92% | 92% | 92% | 39.519.996 |

| Model | Rasio | Akurasi | Presisi | Recall | F1 | Total Parameter |
|-------------------------------|--------------|----------------|----------------|---------------|------------|------------------------|
| CNN + Improved FPN (CA) | 16 | 91,57% | 91% | 92% | 91% | 39.454.332 |
| CNN + Improved FPN (CA) | 32 | 91,09% | 91% | 91% | 91% | 39.421.500 |
| CNN + Improved FPN (CA + ABP) | 2 | 92,64% | 90% | 91% | 90% | 43.454.460 |
| CNN + Improved FPN (CA + ABP) | 4 | 93,11% | 93% | 92% | 93% | 43.191.804 |
| CNN + Improved FPN (CA + ABP) | 8 | 92,76% | 93% | 92% | 92% | 43.060.476 |
| CNN + Improved FPN (CA + ABP) | 16 | 92,4% | 92% | 92% | 92% | 42.994.812 |
| CNN + Improved FPN (CA + ABP) | 32 | 91,33% | 91% | 89% | 90% | 42.961.980 |

Dari Tabel 2 diketahui bahwa hasil pengujian terbaik adalah pada model CNN + *Improved FPN (CA + ABP)* dengan rasio pengurangan *Channel Attention* bernilai 4, di mana akurasi mencapai sebesar 93,11% dan skor F1 mencapai 93%. Sedangkan akurasi terendah pada model CNN + *Improved FPN (CA)* dengan rasio 2 yaitu sebesar 90,5% dan skor F1 terendah pada CNN + *Improved FPN (CA + ABP)* dengan rasio 2 dan 32, dan CNN + *Improved FPN (CA)* dengan rasio 2 yaitu sebesar 90%. Selain model CNN + *Improved FPN (CA)* dengan rasio 2, seluruh model mendapatkan akurasi pengujian lebih tinggi daripada model CNN + FPN.

Nilai presisi terbaik adalah pada model CNN + *Improved FPN (CA + ABP)* dengan rasio pengurangan bernilai 4 dan 8, yaitu sebesar 93%. Sedangkan nilai presisi terendah adalah pada CNN + *Improved FPN (CA + ABP)* rasio 2 dan CNN + *Improved FPN (CA)* rasio 2 yaitu 90%. Nilai *recall* tertinggi adalah pada model CNN + *Improved FPN (ABP)*, model CNN + *Improved FPN (CA + ABP)* dengan rasio pengurangan bernilai 4, 8, dan 16, dan model CNN + *Improved FPN (CA)* rasio 4, 8, dan 16 yaitu sebesar 92%. Sedangkan nilai *recall* terendah adalah ketika rasio pengurangan bernilai 32 yaitu 89%. Dengan demikian, hasil pengujian keseluruhan terbaik adalah pada model CNN + *Improved FPN (CA + ABP)* dengan rasio pengurangan bernilai 4. Tabel 3 menunjukkan hasil pengujian model CNN + *Improved FPN (CA + ABP)* dengan rasio pengurangan 4 berdasarkan kelas spesies.

Tabel 3. Hasil Pengujian Model Berdasarkan Kelas Spesies

| Nama Spesies | Presisi | Recall | F1 |
|---------------------------|----------------|---------------|-----------|
| Black-grass | 0,60 | 0,64 | 0,62 |
| Charlock | 0,99 | 0,96 | 0,97 |
| Cleavers | 0,96 | 0,96 | 0,96 |
| Common Chickweed | 0,98 | 0,98 | 0,98 |
| Common wheat | 0,95 | 0,90 | 0,92 |
| Fat Hen | 0,99 | 0,95 | 0,97 |
| Loose Silky-bent | 0,85 | 0,86 | 0,85 |
| Maize | 0,95 | 1,00 | 0,98 |
| Scentless Mayweed | 0,94 | 0,97 | 0,95 |
| Shepherd's Purse | 0,95 | 0,93 | 0,94 |
| Small-flowered Cranesbill | 1,00 | 0,95 | 0,98 |

| Nama Spesies | Presisi | Recall | F1 |
|---------------------|----------------|---------------|-------------|
| Sugar Beet | 0,97 | 1,00 | 0,99 |
| Rata-rata | 0,93 | 0,92 | 0,93 |

Dari Tabel 3 diketahui bahwa presisi terendah ada pada kategori 'Black-grass' sebesar 0,60 dan presisi tertinggi ada pada kategori 'Small-flowered Cranesbill' sebesar 1,00. *Recall* terendah ada pada kategori 'Black-grass' sebesar 0,64 dan *recall* tertinggi ada pada kategori 'Maize' dan 'Sugar Beet' sebesar 1,00. Dengan demikian, skor F1 terendah ada pada kategori 'Black-grass' sebesar 0,62 dan skor F1 tertinggi ada pada kategori 'Sugar Beet' sebesar 0,99.

4. KESIMPULAN

Pada penelitian ini dilakukan klasifikasi pada citra bibit tanaman dengan metode CNN dan *Improved FPN*, di mana peningkatan FPN dilakukan dengan menambahkan *Channel Attention Module* dan *Augmented Bottom-up Pathway*. Percobaan dilakukan dengan menggunakan 12 model dengan pengaturan berbeda, dan dari 7 model dengan *Improved FPN* memiliki akurasi lebih tinggi dari model tanpa *Improved FPN*. Dari grafik akurasi pelatihan dan validasi, grafik yang paling stabil didapatkan oleh model CNN dan *Improved FPN* dengan *Channel Attention Module* dan *Augmented Bottom-up Pathway* dan rasio pengurangan 4. Pada hasil pengujian didapatkan akurasi terbaik pada CNN dan *Improved FPN* dengan *Channel Attention Module* dan *Augmented Bottom-up Pathway* dan rasio pengurangan 4 yaitu sebesar 93,11%, model ini mendapatkan skor F1 tertinggi yaitu sebesar 93%. Dari hasil pengujian model tersebut berdasarkan kelas spesies data, didapatkan rata-rata skor F1 tertinggi pada kelas 'Sugar Beet' yaitu 0,99 dan rata-rata skor F1 terendah pada kelas 'Black-grass' yaitu 0,62.

DAFTAR RUJUKAN

- Alimboyong, C. R., Hernandez, A. A., & Medina, R. P. (2018). Classification of Plant Seedling Images Using Deep Learning. *TENCON 2018 - 2018 IEEE Region 10 Conference*, 1839–1844. <https://doi.org/10.1109/TENCON.2018.8650178>
- Ashqar, B. A. M., Abu-Nasser, B. S., & Abu-Naser, S. S. (2019). Plant seedlings classification using deep learning. *International Journal of Academic Information Systems Research (IJAISR)*, 7–14.
- Duong, L. T., Nguyen, P. T., di Sipio, C., & di Ruscio, D. (2020). Automated fruit recognition using EfficientNet and MixNet. *Computers and Electronics in Agriculture*, 171, 105326. <https://doi.org/10.1016/j.compag.2020.105326>
- Dyrmann, M., Karstoft, H., & Midtiby, H. S. (2016). Plant species classification using deep convolutional neural network. *Biosystems Engineering*, 151, 72–80. <https://doi.org/10.1016/j.biosystemseng.2016.08.024>

- Giselsson, T. M., Jørgensen, R. N., Jensen, P. K., Dyrmann, M., & Midtiby, H. S. (2017). A public image database for benchmark of plant seedling classification algorithms. *ArXiv Preprint ArXiv:1711.05458*.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Lee, I., Kim, D., Wee, D., & Lee, S. (2021). An Efficient Human Instance-Guided Framework for Video Action Recognition. *Sensors*, *21*(24), 8309. <https://doi.org/10.3390/s21248309>
- Lin, T.-Y., Dollár, P., Girshick, R., He, K., Hariharan, B., & Belongie, S. (2017). Feature pyramid networks for object detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2117–2125.
- Liu, S., Qi, L., Qin, H., Shi, J., & Jia, J. (2018). Path Aggregation Network for Instance Segmentation. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 8759–8768. <https://doi.org/10.1109/CVPR.2018.00913>
- Mustafa, M. S., Husin, Z., Tan, W. K., Mavi, M. F., & Farook, R. S. M. (2020). Development of automated hybrid intelligent system for herbs plant classification and early herbs plant disease detection. *Neural Computing and Applications*, *32*(15), 11419–11441. <https://doi.org/10.1007/s00521-019-04634-7>
- Nie, X., Duan, M., Ding, H., Hu, B., & Wong, E. K. (2020). Attention Mask R-CNN for Ship Detection and Segmentation From Remote Sensing Images. *IEEE Access*, *8*, 9325–9334. <https://doi.org/10.1109/ACCESS.2020.2964540>
- Pacifico, L. D. S., Macario, V., & Oliveira, J. F. L. (2018). Plant Classification Using Artificial Neural Networks. *2018 International Joint Conference on Neural Networks (IJCNN)*, 1–6. <https://doi.org/10.1109/IJCNN.2018.8489701>
- Patil, A. (2021). Image Recognition using Machine Learning. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3835625>
- Phung, V. H., & Rhee, E. J. (2018). A deep learning approach for classification of cloud image patches on small datasets. *Journal of Information and Communication Convergence Engineering*, *16*(3), 173–178. <https://doi.org/10.6109/jicce.2018.16.3.173>
- Rahimzadeh, M., Attar, A., & Sakhaei, S. M. (2021). A fully automated deep learning-based network for detecting COVID-19 from a new and large lung CT scan dataset. *Biomedical Signal Processing and Control*, *68*, 102588. <https://doi.org/10.1016/j.bspc.2021.102588>
- Rai, I. N. (2018). *Dasar-Dasar Agronomi*. Percetakan Pelawa Sari.

- Sahli, H. (2020). An Introduction to Machine Learning. In *TORUS 1 – Toward an Open Resource Using Services* (pp. 61–74). Wiley.
<https://doi.org/10.1002/9781119720492.ch7>
- Shobha, G., & Rangaswamy, S. (2018). *Machine Learning* (pp. 197–228).
<https://doi.org/10.1016/bs.host.2018.07.004>
- Silva, L. O. L. A., Koga, M. L., Cugnasca, C. E., & Costa, A. H. R. (2013). Comparative assessment of feature selection and classification techniques for visual inspection of pot plant seedlings. *Computers and Electronics in Agriculture*, *97*, 47–55.
<https://doi.org/10.1016/j.compag.2013.07.001>
- Woo, S., Park, J., Lee, J.-Y., & Kweon, I. S. (2018). *CBAM: Convolutional Block Attention Module* (pp. 3–19). https://doi.org/10.1007/978-3-030-01234-2_1
- Yan, D., Li, G., Li, X., Zhang, H., Lei, H., Lu, K., Cheng, M., & Zhu, F. (2021). An Improved Faster R-CNN Method to Detect Tailings Ponds from High-Resolution Remote Sensing Images. *Remote Sensing*, *13*(11), 2052. <https://doi.org/10.3390/rs13112052>