

Implementasi *Transfer Learning* dan *Multi-Channel CNN* Pada Penyakit Daun Padi

Armin Lawi¹, Eka Qadri Nuranti², Khawaritzmi Abdallah Ahmad³, Sri Astuti Thamrin⁴

¹ Institut Teknologi B.J. Habibie, Parepare, Indonesia

^{2,3} Program Studi Sistem Informasi, Universitas Hasanuddin, Makassar, Indonesia

⁴ Departemen Statistika, Universitas Hasanuddin, Makassar, Indonesia

¹armin@ith.ac.id, ²eka.qadri@ith.ac.id, ¹armin@unhas.ac.id, ³khawaritzmi@gmail.com, ⁴tuti@unhas.ac.id

Abstrak

Padi merupakan tanaman penghasil beras yang menjadi sumber makanan pokok di Indonesia. Produksi padi di Indonesia tahun 2021 mengalami penurunan sekitar 0,43% atau sebanyak 230.000 ton. Identifikasi penyakit daun padi merupakan salah satu solusi utama untuk meningkatkan produktivitas dan membantu dalam pemilihan pestisida. Salah satu metode yang dapat digunakan untuk mengidentifikasi adalah dengan melakukan metode klasifikasi menggunakan salah satu pendekatan dari artificial neural network yang banyak diterapkan pada pemrosesan citra yaitu Convolutional Neural Networks (CNN). Penelitian ini menggunakan model multi-channel berdasarkan two-channel CNN dan three-channel CNN dipadukan dengan model transfer learning dengan menggabungkan ResNet50, InceptionV3, Xception, dan VGG16 sebagai model dasar atau jaringan yang telah dilatih sebelumnya. Hasilnya, implementasi arsitektur transfer learning multi-channel CNN memiliki kinerja yang baik dengan akurasi training mencapai 100% dan akurasi testing masing-masing 95,83% pada dua dan tiga channel CNN. Nilai presisi, recall, dan f1-score pada model yang dihasilkan juga memiliki nilai di atas 0,85 hingga 1,0, dan nilai AUC pada kurva ROC untuk setiap kelas data citra penyakit padi yang digunakan mencapai 0,98 hingga 1,0. Secara umum, kinerja keseluruhan yang dihasilkan oleh model dari arsitektur pembelajaran transfer multichannel CNN lebih baik daripada model yang dihasilkan oleh arsitektur pembelajaran transfer sederhana.

Keywords: *Convolutional Neural Networks, Multi-channel Color Model, Rice Leaf Disease, Transfer Learning*

I. PENDAHULUAN

Beras merupakan salah satu sumber makanan pokok yang dikonsumsi oleh masyarakat Indonesia yang dihasilkan dari tanaman padi. Bahan tersebut tidak dapat tergantikan oleh bahan makanan pokok lainnya seperti jagung, gandum, kentang, dan sagu. Beras yang merupakan sumber karbohidrat utama bagi kebanyakan penduduk negara Asia. Sayangnya, menurut data yang dikeluarkan oleh Badan Pusat Statistik, perkembangan luas panen dan produksi padi di Indonesia mengalami penurunan pada tahun 2021 dibanding dengan tahun 2020. Penurunan luas lahan hingga bulan desember tahun 2021 menunjukkan penurunan sebesar 2,30% atau berkisar 0,25 juta hektar lahan. Hal ini juga sejalan dengan penurunan panen padi yaitu berkisar 0,43% atau setara dengan 0,23 juta ton padi [1].

Berbagai masalah yang dapat merusak padi adalah penyakit daun [2], [3]. Pengenalan penyakit daun padi biasanya dilakukan dengan mengamati secara langsung oleh para ahli, hal tersebut tentu memakan waktu yang lama dan rentan terjadi kesalahan [2]. Mengidentifikasi penyakit daun padi dapat dijadikan sebagai solusi dalam meningkatkan produktivitas dan dapat memudahkan dalam pemilihan pestisida yang sesuai [3]. Negara Indonesia merupakan negara agraris dengan Luas Sawah Nasional yang ditetapkan oleh Kementerian ATR/BPN pada tahun 2019 sebesar 7.463.948 Ha [1], dengan kondisi lahan yang luas tersebut tentu sangat sulit jika diidentifikasi dengan

pengamatan langsung. Berdasarkan hal tersebut metode yang dapat digunakan untuk mengidentifikasi secara cepat, tepat, dan tidak memakan waktu ialah dengan mendeteksi penyakit daun padi menggunakan media citra dengan metode klasifikasi [2], [3].

Pendekatan yang sering digunakan untuk klasifikasi data citra adalah dengan menggunakan pendekatan *deep learning* dengan metode Artificial Neural Network [4]. Artificial Neural Network (ANN) adalah proses komputasi yang terinspirasi pada cara kerja sistem saraf bekerja (seperti otak manusia). Salah satu algoritma deep feedforward dari metode artificial neural network yang banyak diterapkan pada analisis citra adalah Convolutional Neural Networks atau biasa disingkat CNN [4]. Dalam beberapa kasus, jumlah data yang tersedia sangat sedikit dan terbatas. Metode CNN juga tidak cukup baik dalam mengeksekusi data *training* dengan jumlah sedikit [5]. Akibatnya model yang dihasilkan tidak sesuai harapan sehingga memberikan akurasi yang rendah. Mengatasi masalah sejumlah kumpulan data yang terbatas, pendekatan *transfer learning* melibatkan penerapan model yang telah dipelajari dari *dataset* yang lebih besar diterapkan ke *dataset* baru yang lebih sedikit [5], [6].

Pada tahapan *transfer learning* ini menggunakan file model yang telah dilatih sebelumnya dengan sejumlah besar gambar dari *computer vision dataset* (ImageNet). Kemudian dilakukan *fine-tuned* menggunakan gambar penyakit daun padi. Selanjutnya, setelah diperoleh model dari proses *transfer learning*, akan dilakukan pengembangan menggunakan arsitektur *multi-channel*

berdasarkan *two-channel* CNN dan *three-channel* CNN [7]. Oleh karena itu, dengan menggunakan metode ini akan diperoleh model klasifikasi penyakit daun padi dengan performansi yang baik meskipun menggunakan dataset citra yang terbatas.

Secara singkat, kontribusi kami pada penelitian ini adalah:

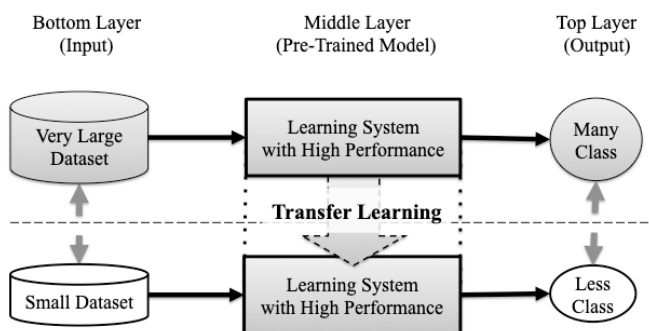
- Membangun model baru menggunakan transfer learning pada data citra yang terbatas
- Penerapan metode Multi-Channel Transfer Learning Convolutional Neural Network untuk mengklasifikasikan data citra penyakit daun padi.

II. KAJIAN LITERATUR

Literatur yang mendukung penelitian ini terdapat dua sub bagian yaitu transfer learning dan konsep multi-channel CNN. Berikut penjelasan terkait masing-masing sub bagian.

A. Transfer Learning

Transfer Learning merupakan metode dalam menggunakan kembali model atau pengetahuan yang telah dipelajari sebelumnya untuk meningkatkan pembelajaran untuk data baru [5], [6].



Gambar 1. Mekanisme kerja transfer learning

Langkah-langkah kerja *transfer learning* dalam penelitian ini adalah sebagai berikut:

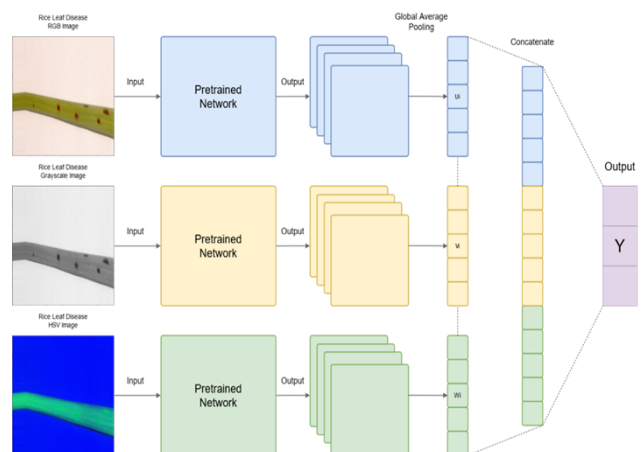
1. Hapus terlebih dahulu atau hapus lapisan atas jaringan yang telah dilatih sebelumnya, lapisan ini tidak dapat digunakan dalam proses klasifikasi gambar daun padi karena menggunakan 1000 kelas dari *dataset* ImageNet.
2. Mengganti lapisan atas pada jaringan *pretraining* yang digunakan dengan lapisan atas yang telah dibuat agar sesuai dengan jumlah kelas penyakit daun padi.
3. Membekukan bobot dari lapisan bawah jaringan yang telah dilatih sebelumnya untuk mempertahankan nilai di dalamnya yang berguna selama proses pelatihan.
4. Dilakukan penyusunan dan pelatihan lebih lanjut terhadap model yang dihasilkan dalam proses pelatihan.

5. Setelah itu bobot lapisan bawah dicairkan untuk menerapkan *fine tuning*. Kemudian model tersebut dilatih ulang dengan *learning rate* yang rendah.

B. Multi-Channel CNN

Arsitektur *multi-channel* CNN merupakan model jaringan *convolutional* yang merupakan penyempurnaan dari model CNN tradisional yang saat ini banyak diterapkan pada pengolahan citra [8], [9], seperti analisis sidik jari, analisis citra medis, pengenalan wajah, dan lain-lain. Jaringan *two-channel* memungkinkan *channel* pertama dan *channel* kedua untuk mengekstrak *feature vectors* melalui dua jaringan. Kemudian *loss function* diterapkan pada dua *feature vectors* di lapisan terakhir dan jaringan *training* digabungkan, sehingga meningkatkan nilai presisi dari model yang terbentuk [10]–[12].

Arsitektur Multi-Channel CNN yang digunakan dalam artikel ini adalah *two-channel* dan *three-channel* input. *Two-channel* CNN dalam hal ini merupakan *double-channel* CNN merupakan peningkatan berdasarkan dua jaringan cabang. Fitur-fitur tersebut digabungkan dalam lapisan CNN yang terhubung penuh, yang merupakan pendekatan yang berbeda dari membandingkan fitur-fitur jaringan dua cabang. *Multiple channel* CNN digunakan untuk pengenalan area penyakit dan klasifikasi citra dengan intensional yang berbeda. *Multi-Channel* CNN, dua jaringan saraf independen. Bobot dari *convolution layer* dan *pooling layer* juga independen. Pada *fully connected layer*, fitur-fiturnya digabungkan dan *loss function* diturunkan berdasarkan fitur gabungan gambar RGB dan gambar *Grayscale* untuk *two-channel* dan model warna HSV ditambahkan untuk *three-channel* CNN yang dapat dilihat pada gambar 2.



Gambar 2. Arsitektur Multi-channel Convolutional Neural Network

III. METODE PENELITIAN

Terdapat empat sub bagian dalam menjelaskan metode penelitian ini yaitu dataset yang digunakan, menjelaskan praproses dataset, proses training dan evaluasi performa model training.

A. Dataset

Data yang digunakan dalam penelitian ini adalah data citra dari “Rice Leaf Diseases Dataset” yang diunduh dari <http://archive.ics.uci.edu/ml/datasets/Rice+Leaf+Diseases>. Format gambar adalah JPEG dengan latar belakang putih. Data citra berada dalam model warna RGB yang terdiri dari 3 kelas yaitu *Brown Spot*, *Leaf Smut*, dan *Bacterial Blight*. Jumlah gambar pada setiap kelas adalah 40 gambar sehingga total ada 120 gambar.

B. Praproses Dataset

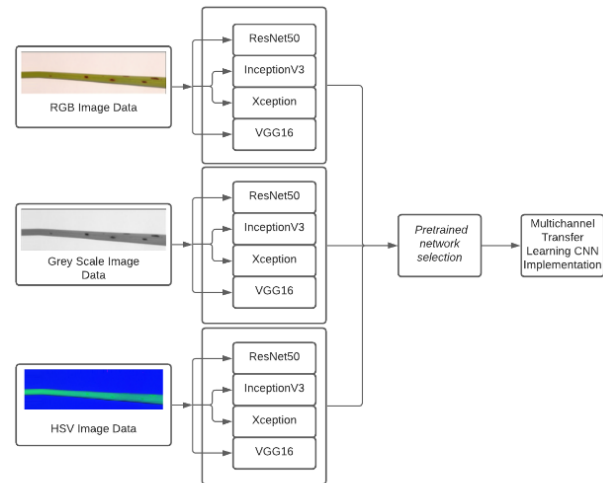
Dataset yang disediakan merupakan data mentah sehingga perlu melakukan praproses terlebih dahulu. Terdapat empat tahapan praproses yang dilakukan yaitu:

1. Mengubah Ukuran Gambar
Menyesuaikan ukuran citra dengan *input* dari masing-masing arsitektur yang digunakan sebagai *pretrained network*. Arsitektur InceptionV3 dan Xception menggunakan ukuran gambar 299×299 piksel, dan untuk arsitektur ResNet50 dan VGG16 ukuran gambar disesuaikan menjadi 224×224 piksel.
2. Normalisasi Data
Selanjutnya adalah mengubah citra menjadi array atau matriks. Representasi citra dalam bentuk matriks menghasilkan nilai untuk setiap piksel yang mewakili intensitas cahaya pada citra dalam bentuk angka dengan skala 0-255. Skala pada matriks tersebut kemudian diubah skalanya menjadi skala 0-1. Tahapan ini juga dinamakan tahapan normalisasi.
3. Pisahkan data *training* dan testing
Jumlah citra pada setiap model warna adalah 120, kemudian data latih dan data uji/validasi dibagi. Perbandingan sebaran data rel dan data uji adalah 4 : 1 atau 80% data rel dan 20% data uji dari total data. Sehingga setiap jumlah citra *training* adalah 96 citra dan data testing adalah 24 citra untuk setiap citra model warna. Rasio pembagian data ini dilakukan dengan mempertimbangkan jumlah gambar yang sedikit sehingga diperlukan data *training* dengan porsi 80% dari seluruh data.
4. Duplikasi Warna (RGB, *Grayscale*, dan HSV)
Tahap *preprocessing* pertama dilakukan dengan menduplikasi dataset dengan model warna yang sebelumnya hanya RGB menjadi model warna RGB, *Grayscale*, dan HSV. Jumlah gambar yang digandakan adalah 120 gambar untuk setiap model warna sehingga total gambar adalah 360 gambar.

C. Proses Training

Dataset citra penyakit daun padi dengan model warna RGB, HSV, dan Grayscale diaplikasikan pada setiap *pretraining network* Xception, InceptionV3, ResNet50, dan VGG16 seperti yang ditunjukkan pada Gambar 1, sehingga diperoleh akurasi dari setiap jaringan *pre-training*. Selanjutnya performansi dari masing-masing model yang dihasilkan dipilih berdasarkan performansi terbaik dari masing-masing model warna pada *dataset*.

Dilatih dengan performa terbaik dari setiap dataset skala RGB dan *Grayscale* untuk two-channel CNN serta skala RGB, HSV, dan *Grayscale* untuk three-channel CNN digabungkan dalam lapisan yang terhubung penuh dengan metode penggabungan (*concatenate*) atau *feature fusion* yang kemudian diklasifikasikan menggunakan ini model. Alur proses terlihat seperti pada Gambar 3 [10].



Gambar 3. Arsitektur Model Transfer Learning Three-Channel CNN

Tabel 1. Performance Rank Model Warna dan Arsitektur CNN

Performance Rank	Color Model		
	RGB	Grayscale	HSV
1	InceptionV3	Xception	Xception
2	Xception	InceptionV3	InceptionV3
3	VGG16	VGG16	VGG16
4	ResNet50	ResNet50	ResNet50

Setelah melakukan proses pelatihan pada semua model warna yang dikombinasikan dengan *pretraining network* Xception, InceptionV3, VGG16, dan ResNet50, maka dihasilkan urutan performa seperti yang ditunjukkan pada Tabel 1. Urutan performa diukur dari seberapa baik model yang dihasilkan oleh masing-masing arsitektur dalam melakukan klasifikasi gambar penyakit daun padi dalam tiga kelas dengan menggunakan ukuran akurasi, *recall*, *precision*, *f1-score*, dan AUC-ROC.

Berdasarkan urutan performansi yang diperoleh pada Tabel 1, untuk *transfer learning multi-channel* CNN dengan *two-channel* CNN digunakan *pretrained network* InceptionV3 pada model warna RGB dan Xception pada model warna *Grayscale*. Pada arsitektur *transfer learning multi-channel* CNN dengan *three-channel*, jaringan yang telah dilatih InceptionV3 digunakan untuk model warna RGB, Xception untuk model warna grayscale, dan Xception untuk model warna HSV.

D. Evaluasi Performansi

Model yang dihasilkan dari proses *training* akan menghasilkan beberapa hasil performansi yang kemudian

dievaluasi pada setiap model citra RGB, HSV, dan *Grayscale* menggunakan *confusion matrix*[13], presisi, recall, akurasi, f-skor dan kurva AUC-ROC. Kurva ROC diplot dengan *True Positive Rate* (TPR) terhadap *False Positive Rate* (FPR) dimana TPR berada pada sumbu y dan FPR berada pada sumbu x.

Tabel 2. *Multiclass Confusion Matrix*

	Classes	ACTUAL Class		
		Brown Spot	Leaf Smut	Bacterial Blight
PREDICTED Class	Brow Spot	T_{BS}	$F_{BS LS}$	$F_{BS BB}$
	Leaf Smut	$F_{LS BS}$	T_{LS}	$F_{LS BB}$
	Bacterial Bligh	$F_{BB BS}$	$F_{BB LS}$	T_{BB}

Tabel 2, T_x menyatakan jumlah data yang diprediksi benar sama dengan kelas sebenarnya x , dan $F_{x|y}$ menunjukkan jumlah data yang diprediksi salah di kelas x padahal seharusnya di kelas y ($F_{x|y}$ dibaca: Prediksi salah di x yang diketahui sebenarnya ada di y). Berdasarkan nilai-nilai ini dalam *confusion matrix*, kita dapat mengevaluasi ukuran kinerja berikut.

$$Precision_x = \frac{T_x}{T_x + \sum_y F_{x|y}} \quad (1)$$

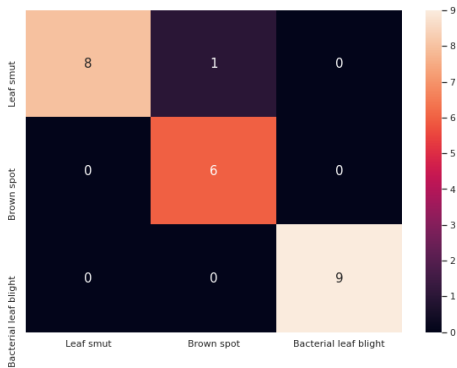
$$Recall_x = \frac{T_x}{T_x + \sum_y F_{y|x}} = \frac{T_x}{N_x} \quad (2)$$

$$Accuracy = \frac{\sum_x T_x}{\sum_x T_x + \sum_x \sum_y F_{y|x}} = \frac{\sum_x T_x}{N} \quad (3)$$


$$F1 - score = 2 \cdot \frac{precision \cdot recall}{precision + recall} \quad (4)$$

IV. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil penelitian secara detail. Hasil penelitian dapat dilengkapi dengan tabel, grafik, gambar, atau diagram. Bagian pembahasan memaparkan hasil pengolahan data, menambahkan analisa secara logis, serta mengaitkan dengan sumber referensi yang relevan.



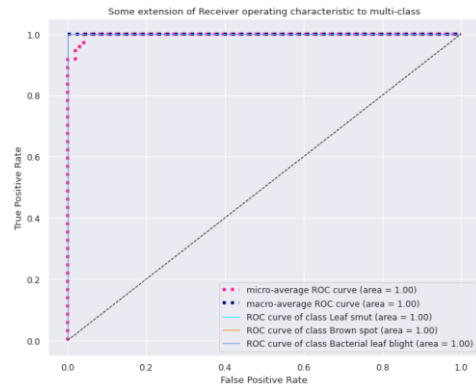
a. *two-channel*



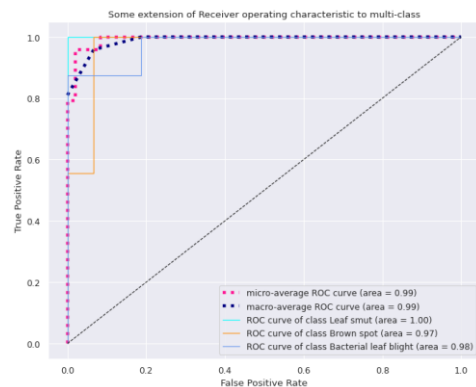
b. *three-channel*

Gambar 4. *Confusion matrix* dari model menggunakan arsitektur *transfer learning Multi-channel CNN*

Confusion matrix pada gambar 4 yang dihasilkan dari model *transfer learning two-channel CNN* dan model *transfer learning three-channel CNN* juga sangat baik, dimana hanya terdapat 1 data salah dalam proses klasifikasi yaitu sampel citra pada data uji kelas *smut leaf* yang diklasifikasikan terhadap kelas *brown spot* pada *two-channel* dan sampel pada penyakit *bacterial leaf blight* yang diklasifikasikan ke dalam kelas *brown spot* pada arsitektur *three-channel*. Ini menunjukkan kinerja yang sangat baik pada kedua model *transfer learning multi-channel CNN* dalam mengklasifikasikan gambar penyakit daun padi.



a. *two-channel*



b. *three-channel*

Gambar 5. Kurva AUC-ROC yang dihasilkan dari model menggunakan arsitektur *transfer learning Multi-channel CNN*

Kurva AUC-ROC pada gambar 5 yang dihasilkan model arsitektur *transfer learning two-channel* CNN terlihat sangat baik, dimana keseluruhan nilai AUC-ROC untuk setiap kelas penyakit daun padi mencapai nilai 1,0. Begitu juga dengan model arsitektur *transfer learning* CNN dengan *three-channel* CNN yang memiliki nilai AUC-ROC sangat baik yaitu pada setiap kelas data citra penyakit daun padi yang digunakan mencapai diatas 0,95.

Tabel 3. Hasil evaluasi kinerja untuk 3 kelas penyakit daun padi

Color Model	Pretrained Network	Rice Leaf Disease	Precision	Recall	F1-score
RGB	Xception	Leaf smut	1.00	1.00	1.00
		Brown spot	0.62	1.00	0.77
		Bacterial leaf	1.00	0.62	0.77
	InceptionV3	Leaf smut	1.00	0.80	0.89
		Brown spot	0.78	1.00	0.88
		Bacterial leaf	1.00	1.00	1.00
	ResNet50	Leaf smut	0.30	1.00	0.46
		Brown spot	0.00	0.00	0.00
		Bacterial leaf	0.75	0.38	0.50
	VGG16	Leaf smut	1.00	1.00	1.00
		Brown spot	0.71	1.00	0.83
		Bacterial leaf	1.00	0.50	0.67
Grayscale	Xception	Leaf smut	1.00	1.00	1.00
		Brown spot	0.83	1.00	0.91
		Bacterial leaf	1.00	0.75	0.86
	InceptionV3	Leaf smut	0.75	1.00	0.86
		Brown spot	0.88	0.70	0.78
		Bacterial leaf	0.75	0.75	0.75
	ResNet50	Leaf smut	0.25	1.00	0.40
		Brown spot	0.00	0.00	0.00
		Bacterial leaf	0.00	0.00	0.00
	VGG16	Leaf smut	0.67	1.00	0.80
		Brown spot	0.67	0.80	0.73
		Bacterial leaf	1.00	0.38	0.55
HSV	Xception	Leaf smut	1.00	1.00	1.00
		Brown spot	1.00	1.00	1.00
		Bacterial leaf	1.00	1.00	1.00
	InceptionV3	Leaf smut	0.67	1.00	0.80
		Brown spot	0.78	0.70	0.74
		Bacterial leaf	0.83	0.62	0.71
	ResNet50	Leaf smut	0.29	1.00	0.44
		Brown spot	0.67	0.20	0.31
		Bacterial leaf	0.00	0.00	0.00
	VGG16	Leaf smut	0.67	1.00	0.80
		Brown spot	0.75	0.60	0.67
		Bacterial leaf	0.57	0.50	0.53
<i>Two Channel Transfer Learning</i> CNN		Leaf smut	1.00	0.89	0.94
		Brown spot	0.86	1.00	0.92
		Bacterial leaf	1.00	1.00	1.00
<i>Three Channel Transfer Learning</i> CNN		Leaf smut	1.00	1.00	1.00
		Brown spot	0.90	1.00	0.95
		Bacterial leaf	1.00	0.88	0.93

Model yang dihasilkan dari beberapa percobaan menggunakan arsitektur *simple transfer learning* dan juga *multi-channel transfer learning* CNN menghasilkan hasil prediksi yang dapat dilihat pada Tabel 2. Evaluasi dilakukan dengan menggunakan 24 sampel pada data *training*. Untuk presisi, *recall*, dan *f1-score* dalam implementasi *simple transfer learning* sangat baik kecuali untuk arsitektur *transfer learning* yang menggunakan *pretrained network* ResNet50. Prediksi klasifikasi citra penyakit daun padi buruk tersebut dapat dinyatakan adanya ketidaksesuaian antara arsitektur ResNet50 dengan *dataset* citra penyakit daun padi yang digunakan. Sedangkan jaringan *pretrained* lainnya (Xception, InceptionV3 dan VGG16) menunjukkan nilai performansi model yang dihasilkan memiliki presisi, *recall*, dan *f1-skor* kinerja yang cukup baik.

Tabel 4. Hasil akurasi model

Color Model	Pretrained Network	Validation Accuracy (%)	Validation Loss
RGB	Xception	87,5	0.562
	InceptionV	91,67	0.2283
	ResNet50	37,5	1.1124
	VGG16	83,33	0.5056
Grayscale	Xception	91,67	0.4686
	InceptionV	79,17	0.4196
	ResNet50	25	1.1097
	VGG16	70,83	0.7302
HSV	Xception	100	0.0712
	InceptionV	75	0.4886
	ResNet50	33,33	1.0969
	VGG16	66,67	0.6756
<i>Two-channel Transfer Learning</i> CNN		95,83	0.1445
<i>Three-channel Transfer Learning</i> CNN		95,83	0.1937

Untuk implementasi pembelajaran *multi-channel* transfer CNN menghasilkan model dengan performansi yang sangat baik. Nilai presisi, *recall*, dan *f1-score* yang dihasilkan semuanya di atas 0,85 atau 85% untuk 3 kelas penyakit daun padi yang diuji. Selain itu, dengan merujuk pada Tabel 4 dapat dilihat performa model *multi-channel* untuk *two-channel* dan *three-channel* menunjukkan akurasi yang sama yaitu 95,83%. Berdasarkan hal tersebut dapat dikatakan bahwa model yang diajukan pada penelitian ini sangat baik dalam setiap pengukuran performa model dalam melakukan klasifikasi penyakit daun padi.

V. KESIMPULAN

Berdasarkan hasil percobaan pemrosesan data citra penyakit daun padi dengan total 120 citra pada implementasi arsitektur pembelajaran transfer *multi channel* CNN menunjukkan performansi yang sangat baik dengan akurasi 95,83% pada masing-masing dari *two-*

channel dan three-channel CNN. Nilai presisi, recall, dan f1-score pada model yang dihasilkan transfer learning multi-channel CNN juga memiliki nilai baik di atas 0,85 hingga 1,0 dan nilai AUC pada kurva ROC pada setiap kelas data citra penyakit padi yang digunakan mencapai 0,98 hingga 0,98. 1.0. Secara umum, kinerja keseluruhan yang dihasilkan oleh model dari arsitektur pembelajaran transfer multi-channel CNN lebih baik daripada model yang dihasilkan oleh arsitektur pembelajaran transfer sederhana menggunakan pretrained network Xception, InceptionV3, dan VGG16.

UCAPAN TERIMA KASIH

Ucapan terima kasih ditujukan kepada Institut Teknologi B.J. Habibie dan Universitas Hasanuddin atas kolaborasinya dalam pelaksanaan kegiatan penelitian.

REFERENSI

- [1] I. N. Khasanah and K. Astuti, *Luas Panen dan Produksi Padi di Indonesia 2021*, 05100.2203., vol. 2021. Badan Pusat Statistik.
- [2] S. Ramesh and D. Vydeki, "Recognition and classification of paddy leaf diseases using Optimized Deep Neural network with Jaya algorithm," *Information Processing in Agriculture*, vol. 7, no. 2, pp. 249–260, Jun. 2020, doi: 10.1016/j.inpa.2019.09.002.
- [3] M. S. G. Premi, R. Narmadha, and T. Bernatin, "A Brief Survey on Diseases of Paddy Plant," *J. Pharm. Sci.*, vol. 11, p. 5, 2019.
- [4] N. Milosevic, *Introduction to Convolutional Neural Networks: With Image Classification Using PyTorch*. Berkeley, CA: Apress, 2020. doi: 10.1007/978-1-4842-5648-0.
- [5] S. Bali and S. S. Tyagi, "Evaluation of transfer learning techniques for classifying small surgical dataset," in *2020 10th International Conference on Cloud Computing, Data Science & Engineering (Confluence)*, Noida, India, Jan. 2020, pp. 744–750. doi: 10.1109/Confluence47617.2020.9058207.
- [6] J. R. Rajayogi, G. Manjunath, and G. Shobha, "Indian Food Image Classification with Transfer Learning," in *2019 4th International Conference on Computational Systems and Information Technology for Sustainable Solution (CSITSS)*, Bengaluru, India, Dec. 2019, pp. 1–4. doi: 10.1109/CSITSS47250.2019.9031051.
- [7] S. Misra, S. Jeon, S. Lee, R. Managuli, I.-S. Jang, and C. Kim, "Multi-Channel Transfer Learning of Chest X-ray Images for Screening of COVID-19," p. 12, 2020.
- [8] C. Albon, *Machine learning with Python cookbook: practical solutions from preprocessing to deep learning*, First edition. Sebastopol, CA: O'Reilly Media, 2018.
- [9] S. Indolia, A. K. Goswami, S. P. Mishra, and P. Asopa, "Conceptual Understanding of Convolutional Neural Network- A Deep Learning Approach," *Procedia Computer Science*, vol. 132, pp. 679–688, 2018, doi: 10.1016/j.procs.2018.05.069.
- [10] Jionghui Jiang, Xi'an Feng, Fen Liu, Yingying Xu, and Hui Huang, "Multi-Spectral RGB-NIR Image Classification Using Double-Channel CNN," Jan. 2019, vol. 7, pp. 20607–20613. doi: 10.1109/ACCESS.2019.2896128.
- [11] E. Q. Nuranti, E. Yulianti, and H. S. Husin, "Predicting the Category and the Length of Punishment in Indonesian Courts Based on Previous Court Decision Documents," *Computers*, vol. 11, no. 6, p. 88, May 2022, doi: 10.3390/computers11060088.
- [12] I. Goodfellow, Y. Bengio, and A. Courville, *Deep learning*. Cambridge, Massachusetts: The MIT Press, 2016.
- [13] M. Sokolova and G. Lapalme, "A systematic analysis of performance measures for classification tasks," *Information Processing & Management*, vol. 45, no. 4, pp. 427–437, Jul. 2009, doi: 10.1016/j.ipm.2009.03.002.