

KAYU7NET: IDENTIFIKASI DAN EVALUASI F-MEASURE CITRA KAYU BERBASIS DEEP CONVOLUTIONAL NEURAL NETWORK (DCNN)

Iwan Muhammad Erwin^{*1}, Risnandar², Esa Prakasa³, Bambang Sugiarto⁴

^{1,2,3,4}Lembaga Ilmu Pengetahuan Indonesia
Email: ¹iwan005,²risn002,³esap001,⁴bamb044{¹@lipi.go.id}
^{*}Penulis Korespondensi

(Naskah masuk: 04 November 2019, diterima untuk diterbitkan: 25 November 2020)

Abstrak

Identifikasi kayu salah satu kebutuhan untuk mendukung pemerintah dan kalangan bisnis kayu untuk melakukan perdagangan kayu secara legal. Keahlian khusus dan waktu yang cukup dibutuhkan untuk memproses identifikasi kayu di laboratorium. Beberapa metodologi penelitian sebelumnya, proses identifikasi kayu masih dengan cara menggabungkan sistem manual menggunakan anatomi DNA kayu. Sedangkan penggunaan sistem komputer diperoleh dari citra penampang melintang kayu secara proses mikrokopis dan makroskopis. Saat ini, telah berkembang teknologi *computer vision* dan *machine learning* untuk mengidentifikasi berbagai jenis objek, salah satunya citra kayu. Penelitian ini berkontribusi dalam mengklasifikasi beberapa spesies kayu yang diperdagangkan menggunakan *Deep Convolutional Neural Networks* (DCNN). Kebaruan penelitian ini terletak pada arsitektur DCNN yang bernama Kayu7Net. Arsitektur Kayu7Net yang diusulkan memiliki tiga lapisan konvolusi terhadap tujuh spesies *dataset* citra kayu. Pengujian dengan merubah citra input menjadi berukuran 600×600, 300×300, dan 128×128 piksel serta masing-masing diulang pada *epoch* 50 dan 100. DCNN yang diusulkan menggunakan fungsi aktivasi ReLU dengan *batch size* 32. ReLU bersifat lebih konvergen dan cepat saat proses iterasi. Sedangkan *Fully-Connected* (FC) berjumlah 4 lapisan akan menghasilkan proses *training* yang lebih efisien. Hasil eksperimen memperlihatkan bahwa Kayu7Net yang diusulkan memiliki nilai akurasi sebesar 95,54%, *precision* sebesar 95,99%, *recall* sebesar 95,54%, *specificity* sebesar 99,26% dan terakhir, nilai *F-measure* sebesar 95,46%. Hasil ini menunjukkan bahwa arsitektur Kayu7Net lebih unggul sebesar 1,49% pada akurasi, 2,49% pada *precision*, dan 5,26% pada *specificity* dibandingkan penelitian sebelumnya.

Kata kunci: *identifikasi; kayu; computer vision; machine learning; DCNN; Kayu7Net; F-measure*

KAYU7NET: IDENTIFICATION AND F-MEASURE EVALUATION WOOD IMAGE BASED ON DEEP CONVOLUTION NEURAL NETWORKS (DCNN)

Abstract

Wood identification is one of the needs to support the government and the wood business community for a legally wood trading system. Special expertise and sufficient time are needed to process wood identification in the laboratory. Some previous research works show that the process of identifying wood combines a manual system using a wood DNA anatomy. While, the use of a computer system is obtained from the wood image of microscopic and macroscopic process. Recently, the latest technology has developed by using the machine learning and computer vision to identify many objects, the one of them is wood image. This research contributes to classify several the traded wood species by using *Deep Convolutional Neural Networks* (DCNN). The novelty of this research is in the DCNN architecture, namely Kayu7Net. The proposed of Kayu7Net Architecture has three convolution layers of the seven species wood image dataset. The testing changes the wood image input to 600×600, 300×300, and 128×128 pixel, respectively, and each of them repeated until 50 and 100 epoches, respectively. The proposed DCNN uses the ReLU activation function and batch size 32. The ReLU is more convergent and faster during the iteration process. Whereas, the 4 layers of *Fully-Connected* (FC) will produce a more efficient training process. The experimental results show that the proposed Kayu7Net has an accuracy value of 95.54%, a precision of 95.99%, a recall of 95.54%, a specificity of 99.26% and finally, an *F-measure* value of 95.46%. These results indicate that Kayu7Net is superior by 1.49% of accuracy, 2.49% of precision, and 5.26% of specificity compared to the previous work.

Keywords: *wood; identification; computer vision; machine learning; DCNN; Kayu7Net; F-measure*

1. PENDAHULUAN

Saat ini, Pusat Penelitian Informatika LIPI telah mengembangkan Alat Identifikasi Kayu Otomatis (AIKO) menggunakan *smartphone*. Untuk mendeteksi jenis kayu, langkah pertama perlu memasang lup dengan perbesaran enam puluh kali tepat pada kamera *smartphone*. Langkah kedua adalah mengambil citra kayu melalui aplikasi AIKO. Perbesaran sudah diatur oleh aplikasi sebesar 3,5 kali, sehingga total perbesaran adalah 210 kali. Selanjutnya aplikasi AIKO akan mengirimkan citra kayu ke *server* HPC LIPI. Citra kayu kemudian diidentifikasi dengan menggunakan model klasifikasi yang telah dilatih sebelumnya. Aplikasi layanan di *server* kemudian mengirim kembali hasil identifikasi citra kayu ke aplikasi di *smartphone*. Hasil yang ditampilkan pada aplikasi, selain informasi nama spesies kayu juga informasi lain seperti nama dagang kayu, nama latin kayu, berat jenis, kelas awet, kelas kuat, dan kegunaannya. Aplikasi AIKO ini masih terus ditingkatkan kemampuannya terutama akurasi identifikasi. Beberapa bagian salah identifikasi masih bisa terjadi, khususnya kayu yang mempunyai kemiripan visual pada citra penampang lintang (*cross-section*).

Contoh pengujian menggunakan aplikasi AIKO pada lima belas sampel menggunakan kayu *ramin*, hasilnya teridentifikasi sebagai *tenggayun* sebanyak 5 kali, *jabon* sebanyak 5 kali, dan *terentang ayam* sebanyak 2 kali. Sisanya teridentifikasi sebagai kayu *menjalin*, *kembang semangkok*, dan *terap* masing-masing sebanyak satu kali. Sedangkan untuk pengujian ke enam spesies kayu lainnya, proses dan hasilnya hampir sama dengan contoh pengujian pada spesies kayu *ramin*. Berdasarkan contoh pengujian ini maka ditentukan tujuh spesies kayu yang mempunyai kemiripan visual antara lain *ramin*, *jabon*, *kembang semangkok*, *menjalin*, *tenggayun*, *terentang ayam*, dan *terap*, yang menjadi objek penelitian ini.

Dalam aturan dunia ilmiah per kayuan, spesies kayu yang berbeda dari genus yang sama kadang-kadang memiliki sifat yang berbeda juga dengan yang diidentifikasi dengan bantuan pencahaya mikroskop pada fitur specimen yang diidentifikasi, baik secara anatomis (Bergman, dkk, 2010), (Pilotti, dkk, 2005) dan juga molekuler. Proses identifikasi kayu yang relatif baru dan canggih, sudah menggunakan *smarthphone* dan juga lensa makro (Tang, dkk, 2018a, 2018b). Para peneliti (Tang, dkk, 2018a, 2018b) telah menggunakan citra yang berasal dari lensa makro pembesaran sebesar dua puluh kali untuk mengidentifikasi data dari gambar kayu dan teknologi *Near-Infrared Spectroscopy* (NIR). Algoritma *machine learning* diterapkan untuk melakukan proses klasifikasi pola.

Klasifikasi kayu berdasarkan citra kayu dapat dilakukan dengan bantuan *computer vision*, yang terdiri atas kombinasi antara *image processing* dan *machine learning*, melalui pendekatan *deep learning*.

Dengan *computer vision* citra kayu diolah dengan berbagai fungsi pengolahan citra agar dapat menentukan tekstur dan fitur yang spesifik, sehingga citra kayu satu dengan yang lain dapat dibedakan. Tou dkk (2009) mengklasifikasi enam spesies kayu dengan menggunakan *Grey Level Co-occurrence Matrices* (GLCM) dan juga metode Gabor Filter. Kedua metode ini menghasilkan akurasi sebesar 85%. Xiang dkk (2016) mengidentifikasi cacat kayu menggunakan fitur *Local Binary Pattern* (LBP). Sementara itu, Sugiarto dkk (2017) menggabungkan *Histogram of Oriented Gradient* (HOG) dengan *Support Vector Machine* (SVM) untuk mengklasifikasi lima spesies kayu dengan akurasi sebesar 77,5%. Hadiwidjaja dkk (2019) membangun sistem identifikasi dua belas spesies kayu dengan menggunakan LBP dan transformasi *Hough* untuk ekstraksi pola, sedangkan SVM sebagai pengklasifikasi akhir. Akurasi yang dicapai pada metode ini beragam dari 33% hingga 100%.

Zhao dkk (2019) menggunakan *deep learning* untuk identifikasi kayu. *Dataset* citra kayu dilatih dan diklasifikasikan sesuai spesiesnya. Salah satu masalah yang harus dipecahkan dalam *deep learning* di antaranya untuk memperoleh data yang tepat dalam format yang tepat pula. Untuk mendapatkan data yang tepat, dapat bermakna mengumpulkan atau mengidentifikasikan data yang berhubungan dengan hasil yang ingin diraih atau diperkirakan. Proses verifikasi data yang dibangun harus sesuai dengan masalah yang ingin dipecahkan. Jika tidak memiliki data yang tepat, maka upaya untuk menyelesaikan masalah tersebut harus kembali ke tahap pengumpulan data citra kayu dari awal.

Dunia *deep learning* telah berkembang pesat dan dieksplorasi dengan beragam arsitektur *deep learning*. AlexNet, salah satu arsitektur *deep learning* pertama yang dikenalkan pertama kali oleh Geoffrey Hinton dkk. Ini merupakan arsitektur yang sederhana, tetapi cukup kuat untuk jalan bagi peneliti *deep learning* untuk mengembangkannya. Selanjutnya VGG Net dikembangkan oleh *Visual Graphics Group* di Oxford. GoogleNet dirancang oleh peneliti Google dan berhasil memenangkan ImageNet pada tahun 2014.

Convolutional Neural Network (CNN) merupakan arsitektur yang banyak digunakan untuk pengenalan objek. CNN merupakan variasi dari *Multi-Layer Perceptron* (MLP). Perbedaanannya adalah pada MLP titik-titik pada lapisan sesudahnya semuanya terhubung ke semua titik pada lapisan sebelumnya. Sedangkan pada CNN, titik-titik hanya terhubung ke beberapa titik tetangga pada lapisan sesudahnya. Hal ini berguna pada pengenalan objek dan digunakan untuk mempelajari piksel-piksel tetangga dari suatu citra untuk menentukan kelas objek.

Penelitian sebelumnya, dilakukan oleh Krizhevsky dkk (2017) menggunakan *Deep*

Convolutional Neural Network (DCNN) untuk mengklasifikasi satu koma dua juta citra beresolusi tinggi. Arsitektur yang digunakan memiliki lima lapisan konvolusi, menghasilkan tingkat kesalahan pengujian sebesar 15,3%. Hu dkk (2019) menggunakan ResNet18 untuk mengklasifikasi kualitas, *grade* dan cacat (*defect*) produksi hasil olahan kayu (*lumber*) pada industri perikanan.

CNN melibatkan konvolusi dari beberapa fungsi lainnya, di antaranya konvolusi, sampling, aktivasi, dan *Fully-Connected*. Penelitian yang dilakukan oleh Lainez dkk (2018) telah mengidentifikasi tujuh spesies kayu dari Peru, dengan menggunakan arsitektur CNN dengan dua lapisan konvolusi dan menghasilkan akurasi sebesar 94,05%, *precision* sebesar 93,5%, dan *specificity* sebesar 94,0%.

Berdasarkan hasil penelitian sebelumnya yang dilakukan oleh Lainez dkk (2018) yang masih memiliki nilai akurasi, presisi, dan *specificity* yang masih perlu dioptimasi kembali, maka untuk meningkatkan nilai-nilai tersebut, diusulkan arsitektur Kayu7Net yang lebih optimal dengan menggunakan tiga lapisan konvolusi pada tujuh spesies *dataset* citra kayu. Kayu7Net dioptimasi dengan input citra kayu dengan ukuran yang bervariasi mulai dari 600×600, 300×300, dan 128×128 piksel. Iterasi pada *epoch* dilakukan sebanyak 50 dan 100 kali. Fungsi aktivasi ReLU pada Kayu7Net menggunakan *batch size* 32. *Fully-Connected* (FC) pada Kayu7net berjumlah 4 lapisan, sehingga diharapkan akan menghasilkan proses *training* yang lebih efisien.

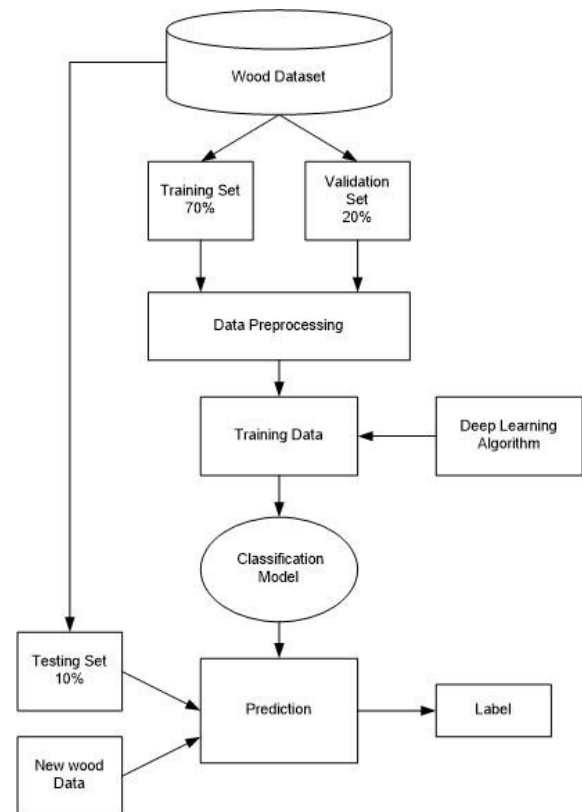
Pada penelitian ini sudah disusun kerangka penelitian sebagai berikut: permasalahan terkait identifikasi kayu pada bagian 1. Metode yang diusulkan pada Kayu7Net terdapat di bagian 2. Bagian 3 mengeksplorasi hasil penelitian dan pembahasannya. Bagian 4 berupa kesimpulan dan rencana penelitian lanjutan.

2. METODE KAYU7NET

Diagram alur metode penelitian Kayu7Net dapat dilihat pada Gambar 1. *Dataset* kayu dibagi menjadi tiga bagian, yaitu *training set* (data pelatihan), *validation set* (data validasi) dan *testing set* (data pengujian). Algoritma *deep learning* diwujudkan dalam Kayu7Net. Informasi hasil identifikasi kayu uji tertuang dalam label, berisi nama dagang kayu, nama latin kayu, berat jenis, kelas awet, kelas kuat dan juga kegunaannya.

2.1. Pembuatan *Dataset* Kayu

Faktor yang mempengaruhi kesalahan identifikasi kayu, antara lain *dataset* kayu yang digunakan untuk membangun model klasifikasi ternyata mengandung banyak citra yang tidak layak diidentifikasi. Faktor lainnya, *dataset* dibangun dengan jumlah citra kayu yang minim, seratus citra per spesies.



Gambar 1. Diagram alur identifikasi kayu

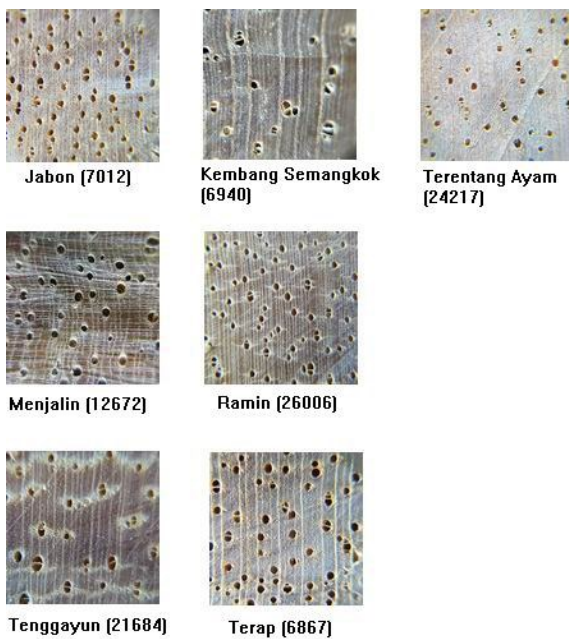
Beberapa kriteria ketidaklayakan pada citra kayu tersebut antara lain: tidak fokus, pori-pori kayu masih tertutup, pembuluh kayu tertutup, adanya goresan pisau yang tidak rata, permukaan kayu tidak rata dan gangguan cahaya saat pengambilan citra.



Gambar 2. Ketidaklayakan citra kayu untuk *dataset*


Beberapa contoh ketidaklayakan citra kayu ditunjukkan pada Gambar 2.

Sedangkan Gambar 3 memperlihatkan tujuh spesies kayu yang digunakan sebagai objek penelitian. Secara visual dapat terlihat bahwa ketujuh citra kayu tersebut sangat mirip, yang memiliki alur urat yang sejajar dengan pori-pori yang berukuran hampir sama dan tersebar merata.



Gambar 3. Citra tujuh spesies kayu pada perbesaran 210 kali

Citra kayu diambil dari penampang melintang yang dapat dilihat pada Gambar 4. Untuk mengambil citra, kayu terlebih dahulu harus disayat menggunakan pisau tajam. Tujuannya agar pori-pori dan pembuluh kayu terbuka, sehingga citra yang dihasilkan mewakili fitur dan tekstur spesies kayu tersebut. Begitu juga pada saat pengujian, kayu uji harus disayat dengan pisau tajam pada bagian penampang melintang.



Gambar 4. Penampang kayu yang diambil citranya adalah penampang melintang (cross-section)

Citra kayu yang digunakan dalam penelitian ini adalah citra makroskopik dengan perbesaran optik 60 kali dan perbesaran digital 3,5 kali. Dengan demikian, total perbesaran menjadi $60 \times 3,5 = 210$ kali. Ukuran citra bervariasi 1000×1000 piksel, 2160×2160 piksel dan 3456×3456 piksel. Contoh kayu untuk penelitian ini disediakan oleh Pusat Penelitian dan Pengembangan Hasil Hutan (P3HH) - Kementerian Lingkungan Hidup dan Kehutanan, Republik Indonesia.

Dataset I dalam penelitian ini terdiri dari tujuh *folder* yang diberi nama sesuai spesies kayu, antara lain jabon, kembang semangkok, menjalin, ramin, tenggayun, terap, dan terentang ayam. Citra kayu

sebanyak tujuh spesies diambil dari *dataset* lama, walaupun terdapat citra yang tidak layak seperti pada Gambar 2. Setiap spesies terdiri dari seratus citra kayu dengan ukuran 1000×1000 piksel. Tidak dilakukan *sorting* untuk memisahkan citra kayu yang layak atau tidak. *Dataset* ini selanjutnya disebut sebagai *dataset I* yang berisi tujuh ratus citra kayu. *Dataset I* ini dibagi menggunakan program pembagi dengan fungsi *random*, menjadi data pelatihan sebesar 70%, data validasi sebesar 20%, data pengujian sebesar 10% dan terpisah menjadi tiga *folder* yaitu *training*, *validation*, dan *testing*. Setiap *folder* berisi tujuh *subfolder* berdasarkan nama spesies kayu. Tabel 2 menunjukkan *dataset I*.

Tabel 2. *Dataset I* : tujuh spesies citra kayu

Spesies kayu	Jumlah Data			
	Training	Validation	Testing	Jumlah
Jabon (7012)	70	20	10	100
Menjalin (12672)	70	20	10	100
Kembang semangkok (6940)	70	20	10	100
Ramin (26006)	70	20	10	100
Tenggayun (21684)	70	20	10	100
Terentang ayam (24217)	70	20	10	100
Terap (6867)	70	20	10	100
Jumlah data				700

Dataset II dalam penelitian ini terdiri dari tujuh spesies yang diberi nama kode kayu, yaitu 12672, 21684, 24217, 26006, 6867, 6940, dan 7012. Setiap spesies kayu diambil citranya sebanyak dua ratus kali. Dengan mensortir secara manual dari dua ratus citra kayu, dimana citra yang tidak layak harus dihapus, menyisakan 153 sampai 182 citra pada masing-masing *folder*. *Dataset II* kayu dibagi menggunakan program pembagi dengan fungsi *random*, yang ditentukan pembagian 70% untuk data pelatihan, 20% untuk data validasi, 10% untuk data pengujian dan terpisah menjadi tiga *folder* yaitu *training*, *validation*, dan *testing*. Setiap *folder* berisi tujuh *subfolder* berdasarkan nama kode kayu. *Dataset II* ini berisi 1.173 citra kayu. *Dataset II* disajikan pada Tabel 3.

2.2. Tahap Pelatihan *Dataset Kayu*

Deep learning telah berkembang cukup pesat dan berbagai arsitektur telah banyak dikembangkan dan diuji. Pada penelitian ini, dibuat arsitektur DCNN yang terdiri atas tiga lapisan konvolusi dengan ReLU dan *max pooling*. Tersedia tiga lapisan *Fully-Connected* (FC) dengan fungsi aktivasi menggunakan *softmax*. Gambar 5 menunjukkan arsitektur yang digunakan pada Kayu7Net.

Tabel 3. *Dataset II* : tujuh spesies citra kayu

Spesies kayu	Jumlah Data			
	Trainin g	Validatio n	Testin g	Jumla h
7012 (Jabon)	129	37	16	182
12672 (Menjalin)	116	34	16	166
6940 (Kembang semangkok)	118	35	16	169
26006 (Ramin)	107	30	16	153
21684 (Tenggayun)	117	34	16	167
24217 (Terentang ayam)	118	35	16	169
6867 (Terap)	117	34	16	167
Jumlah data				1.173

Arsitektur ini terdiri dari lapisan dengan parameternya sebagai berikut :


- 1) Lapisan input : parameternya ditentukan oleh ukuran citra.
- 2) Tiga lapisan kombinasi konvolusi dan *pooling* : lapisan konvolusi pertama terdapat 64 filter berukuran 3x3 dengan *stride* 1, dan lapisan *maxPooling* dengan ukuran 2x2. Lapisan konvolusi kedua terdiri dari 32 filter berukuran 3x3 dengan *stride* 1 dan *maxPooling* dengan

ukuran 2x2. Lapisan konvolusi ketiga memiliki 16 filter berukuran 3x3 dengan *stride* 1 dan *maxPooling* dengan ukuran 2x2. Ketiganya menggunakan aktivasi ReLU.

- 3) Lapisan *Fully-Connected* : 1024, 256, 128, dan 7, sesuai dengan jumlah kelas yang diklasifikasi.

Jumlah data yang terbatas merupakan salah satu hambatan dalam menerapkan metode *deep learning*. Salah satu cara untuk mengatasinya yaitu dengan augmentasi citra. Cara ini dapat meningkatkan ukuran *dataset* tanpa menambahkan citra baru, sehingga dikenal juga sebagai data *generator*.

Idenya, walaupun ada duplikasi citra dengan berbagai variasi, namun tetap mempertahankan fitur kunci dari citra aslinya. Variasi pengolahan citra misalnya pola geser, rotasi, *flip* horizontal, *flip* vertikal, mengubah ukuran dan menambahkan distorsi. Pada pengenalan objek yang lebih kompleks maka diperlukan augmentasi citra yang lebih banyak. Namun demikian, prosesnya harus diperhatikan bahwa citra hasil augmentasi tidak boleh berbeda dengan citra yang akan diuji. Perlu diperkirakan model objek atau citra kayu yang akan diuji. Pada penelitian ini dipilih augmentasi model geser (*shear*), putar (*rotation*), dan mengubah ukuran (*resize*).



Gambar 5. Arsitektur Kayu7Net

2.3. Evaluasi *F-measure*

Untuk mengevaluasi kinerja suatu sistem klasifikasi dapat dihitung menggunakan *confusion matrix* (*F-measure*). Matriks ini menyajikan hasil prediksi dari sistem dan kondisi aktualnya. Untuk mewakili hasil proses klasifikasi oleh suatu sistem, menggunakan empat parameter, di antaranya yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). TP adalah data positif dan terprediksi benar oleh sistem. Misalnya, data asli berupa kayu dan terprediksi sebagai kayu. Sementara FN, data asli berupa positif dan terprediksi sebagai data negatif. Misalnya, data asli berupa kayu dan terprediksi sebagai non-kayu. TN adalah data negatif dan terprediksi sebagai data negatif. Misalnya, data asli berupa non-kayu dan terprediksi oleh sistem benar sebagai data non-kayu. FP adalah data negatif yang terprediksi sebagai data positif. Misalnya, data asli berupa non-

kayu tetapi sistem memprediksinya sebagai data kayu.

Selanjutnya, *F-measure* atau yang sering dikenal juga sebagai F1 akan mengukur pada bagian akurasi (*accuracy*), *precision*, *recall*, dan *specificity*. Akurasi merupakan tingkat kedekatan antara nilai prediksi terhadap nilai kenyataan. Sedangkan *precision* merupakan tingkat ketepatan antara informasi yang diminta dengan jawaban yang diberikan oleh sistem sebagaimana ditulis oleh Hasugian (2006), Powers (2007). *Recall* merupakan tingkat kemampuan sistem dalam menemukan kembali sebuah informasi yang relevan. *F-measure* merupakan perhitungan evaluasi dalam dalam informasi *retrieval* (temu kembali) yang mengkombinasikan *recall* dan *precision*. Adapun nilai *precision*, *recall*, *specificity*, *accuracy* dan *F-measure* dapat dihitung menggunakan rumus sebagai berikut

$$P = \frac{TP}{TP+FP} \quad (1)$$

$$R = \frac{TP}{TP+FN} \quad (2)$$

$$S = \frac{TN}{TN+FP} \quad (3)$$

$$A = \frac{TP+TN}{TP+TN+FP+FN} \quad (4)$$

$$F1 = \frac{2 \cdot P \cdot R}{P+R} \quad (5)$$

Di mana : P adalah *precision*, R adalah *recall*, S adalah *specificity*, A adalah akurasi, dan $F1$ adalah *F-measure*.

3. HASIL DAN PEMBAHASAN

Dalam penelitian ini eksekusi program dilakukan menggunakan fasilitas *High Performance Computing* (HPC) yang dimiliki dan dikelola oleh LIPI, dengan spesifikasi *hardware* Dell RX740 XD dengan jumlah *head node* 2, CPU 36 *core*, *memory* 384 GB, *storage* 14,4 TB dan 3 GPU *node*. *Software* menggunakan python 2.7.12 dengan *library* Keras dan Tensorflow dalam sistem operasi Linux.

Pelatihan menggunakan Kayu7Net pada *dataset* I dengan perubahan ukuran citra input menjadi 600×600 piksel dengan *epoch* sebanyak 100. Proses *training* ini melibatkan 5.630.519 parameter dengan waktu komputasi 1 jam 34 menit 26 detik. Hasilnya diperoleh nilai akurasi *training* sebesar 99,84% dan akurasi validasi sebesar 84,92%. Selisih akurasi *training* dan akurasi validasi yang tinggi menunjukkan bahwa model klasifikasi sangat berpotensi *overfitting*. Hal ini dapat dibuktikan dengan pengujian menggunakan sepuluh citra uji untuk setiap spesies kayu menghasilkan kesalahan identifikasi sebanyak 30 kali dan identifikasi tepat sebanyak 40 kali. Akurasi pengujian menghasilkan

40/70 atau sebesar 57,14%. Perhitungan *F-measure* menghasilkan *precision* sebesar 65,96%, *recall* sebesar 57,14%, *specificity* sebesar 93,35% dan *F-measure* sebesar 56,87%.

Transfer learning menggunakan Kayu7Net pada *dataset* II dilakukan sebanyak enam kali, yaitu dengan ukuran citra input diubah menjadi 128×128 piksel, 300×300 piksel dan 600×600 piksel, masing-masing dicoba pada *epoch* 50 dan 100. Ukuran citra input yang lebih besar tentu saja berakibat jumlah parameter menjadi besar, dan waktu komputasi menjadi lebih lama.

Pada *transfer learning* dengan ukuran citra input 128 x 128 piksel, *file model* yang dihasilkan sebesar 1.864 Kb dan melibatkan 469.559 parameter. Pada proses *training* dengan ukuran citra input 300 x 300 piksel, *file model* yang dihasilkan sebesar 5.384 Kb dan melibatkan 1.370.679 parameter. Sedangkan untuk *training* dengan ukuran citra input 600x600 piksel *file model* yang dihasilkan sebesar 22.024 Kb dengan jumlah parameter mencapai 5.630.519 sebagaimana yang diperlihatkan pada Tabel 4.

Tabel 4 menunjukkan hasil yang diraih pada proses enam kali percobaan dan diperlihatkan juga *training time*, *train_acc* (akurasi *training*), *val_loss* (*loss validation*), *val_acc* (akurasi *validation*) dan *test_acc* (akurasi pengujian). *Training time* merupakan waktu yang diperlukan oleh sistem komputer untuk melakukan proses *training* sampai terbentuk model yang ideal. Tentu saja nilai *training time* paling lama terjadi saat *training* pada ukuran input cita kayu terbesar dan *epoch* terbesar pula. Berdasarkan hasil pada Tabel 4 dapat dijelaskan model ke-6 memiliki akurasi *training* sebesar 100% dan akurasi validasi sebesar 97,52%. Hal ini berarti model diharapkan dapat memberikan kinerja 97,52% pada *dataset* II. Sementara pada proses pengujian, akurasi yang diperoleh sebesar 95,54%.


Tabel 4. Hasil percobaan Kayu7Net menggunakan *dataset* II

	Input size	epoch	Training Time hh:mm:ss	Train Acc (%)	Val Loss (%)	Val Acc (%)	Test Acc (%)
1	128x128	50	0:35:14	98,59	14,97	96,53	41,96
2	128x128	100	1:28:33	99,84	5,16	98,64	15,18
3	300x300	50	0:52:09	100	2,52	99,15	75,0
4	300x300	100	1:41:35	100	7,97	98,64	87,5
5	600x600	50	1:16:21	100	12,35	97,69	91,07
6	600x600	100	2:32:17	100	11,95	97,52	95,54


Terbukti bahwa perubahan besar yang dilakukan pada *dataset* sangat mempengaruhi hasil akurasi pengujian dari 57,14% pada *dataset* I, menjadi 95,54% pada *dataset* II. Penggantian *dataset* kayu dengan mengganti dengan citra yang lebih baik, lebih fokus, pori-pori dan pembuluh kayu terlihat jelas. Citra kayu yang betul-betul dapat menggambarkan fitur penampang melintang kayu. *Dataset* II ini jumlah citranya juga lebih banyak dari *dataset* I, 1.173 dibandingkan dengan 700.

Grafik *progress* akurasi dan *loss train* terhadap *epoch* pada proses *training* menggunakan Kayu7Net dengan ukuran citra input 600×600 piksel ditunjukkan pada Gambar 6. Akurasi pelatihan dan validasi meningkat secara cepat pada tahap 10 *epoch* pertama, selanjutnya akan meningkat secara lambat. Mulai *epoch* ke-20 grafik terlihat mulai stabil. *Loss train* dan *loss validation* menurun secara cepat pada 10 *epoch* pertama. Pada 10 *epoch* kedua nilai *loss* menurun lebih lambat, dan dari *epoch* ke-20 mulai

stabil pada nilai terendahnya. Pada *epoch* >60 terlihat *loss validation* meningkat secara pelan.




(a). akurasi vs *epoch* pada citra input 600×600 piksel




(b). *loss* vs *epoch* pada citra input 600×600 piksel

Gambar 6. *Progress* akurasi dan *loss* pada Kayu7Net dengan ukuran citra 600×600 piksel



(a). akurasi vs *epoch* pada citra input 300×300 piksel



(b). *loss* vs *epoch* pada citra input 300×300 piksel

Gambar 7. *Progress* akurasi dan *loss* pada Kayu7Net dengan ukuran citra 300×300 piksel

Sedangkan *progress* akurasi dan *loss training* terhadap *epoch* pada proses *training* menggunakan Kayu7Net dengan ukuran citra kayu 300×300 piksel, ditunjukkan pada Gambar 7, yang memiliki pola yang


sama seperti pada grafik *progress training* dengan citra input 600×600 piksel. Pada tahap 10 *epoch* pertama akurasi *training* dan validasi meningkat secara cepat, selanjutnya akan meningkat secara

lambat dan terlihat stabil mulai epoch ke-20. Sementara, *loss training* dan *loss validation* menurun secara cepat pada 10 *epoch* pertama. Nilai *loss* menurun lebih lambat pada 10 *epoch* kedua, dan dari epoch 20 mulai stabil pada nilai terendahnya. Pada *epoch* >50 terlihat *loss validation* meningkat secara pelan, hal ini menunjukkan terjadinya *overfitting*.


Gambar 8 menunjukkan *progress* akurasi dan *loss* terhadap *epoch* pada proses *training* menggunakan Kayu7Net dengan ukuran citra kayu 128×128 piksel, Polanya sedikit berbeda jika dibandingkan pada grafik *progress training* dengan citra input 300×300 dan 600×600 piksel. Selisih antara nilai *training* dan *validation* sangat tinggi, menunjukkan tingkat *overfitting* tinggi pula. Hal ini dapat dilihat pula dari Tabel 4, hasil *testing* akurasi yang sangat rendah yang mencapai nilai sebesar 15,18%.

Pengujian model klasifikasi dilakukan dengan memberikan enam belas buah citra kayu per spesies yang disimpan di *folder testing*. Jadi terdapat $16 \times 7 = 112$ citra yang diujikan dalam folder ini. Pengujian dilakukan enam kali, mulai dari model ke-1 hingga model ke-6. Hasil pengujian ini ditampilkan pada Tabel 4.

Tabel 4 menunjukkan model ke-1 dan ke-2 yang memiliki kinerja yang sangat buruk, dengan skor F1 lebih kecil dari 50%. Sementara model ke-3 dan ke-4 memiliki kinerja yang lebih baik dari model sebelumnya, dengan skor F1 sebesar 74,33% dan 87,49%. Model ke-5 dan ke-6 memiliki performa yang sangat baik, dengan skor lebih dari 90% untuk semua parameter.



(a). akurasi vs *epoch* pada citra input 128×128 piksel




(b). *loss* vs *epoch* pada citra input 128×128 piksel

Gambar 8. *Progress* akurasi dan *loss* pada Kayu7Net dengan ukuran citra 128×128 piksel

Tabel 5. Kinerja model klasifikasi, model ke-1 s.d. 6

Performa (%)	Model klasifikasi					
	1	2	3	4	5	6
Precision	41,24	5,34	86,87	90,17	92,12	95,99
Recall	41,96	15,18	75,00	87,50	91,07	95,54
Specificity	90,33	85,86	95,83	97,92	98,51	99,26
F1	34,71	5,59	74,33	87,49	91,30	95,46

Tabel 5 dapat direpresentasikan pada Gambar 9, yang memperlihatkan model ke-6 dengan kinerja paling baik.



Gambar 9. Grafik kinerja model klasifikasi, model ke-1 s.d. ke-6

Tabel 6. Matriks *confusion* hasil pengujian pada model ke-6

	Prediksi						
	12672	21684	24217	26006	6867	6940	7012
Aktual	12672	16					
	21684		16				
	24217			16			
	26006				16		
	6867					16	
	6940		1		1	14	
	4012		1	2			13

Tabel 7. *Precision* (P), *Recall* (R), *Specificity* (S) dan F1

	12672	21684	24217	26006	6867	6940	7012	Rata2
P	100	100	88,89	88,89	94,12	100	100	95,99
R	100	100	100	100	100	87,5	81,25	95,54
S	100	100	97,92	97,92	98,96	100	100	99,26
F1	100	100	94,12	94,12	96,97	93,33	89,65	95,46

Tabel 8. Evaluasi *cross-validation* pada model ke-6

Batch	Train accuracy (%)	Val loss (%)	Val accuracy (%)	Test accuracy (%)
A	100	11,95	97,52	95,54
B	100	8,00	97,62	96,43
C	100	7,81	97,45	96,43
D	100	21,72	95,59	94,64
E	100	13,27	97,45	95,54

Berdasarkan Tabel 5, dapat dilihat bahwa akurasi terbesar yaitu 95,54% diperoleh pada model ke-6. Hasil pengujian pada model ke-6 disajikan dalam bentuk *confusion matrix* pada Tabel 6.

Hasil pengujian menunjukkan bahwa total pengujian sebanyak 112 kali, salah mengklasifikasi sebanyak 5 kali dan klasifikasi yang tepat sebanyak 107 kali. Jadi, nilai akurasinya sebesar 107/112 (95,54%). Ada pun hasil perhitungan kinerja model ke-6 pada spesies kayu dengan menggunakan persamaan (1), (2), (3), dan (4), disajikan pada Tabel 7. Hasil yang diperoleh memperlihatkan *precision* sebesar 95,99%, *recall* sebesar 95,54%, *specificity* sebesar 99,26% dan F1 sebesar 95,46%. Pengujian *cross-validation* pada model ke-6 menunjukkan bahwa model ini nilai akurasi dari *validation* sebesar $\pm 97\%$ dan *testing* sebesar $\pm 95\%$ sebagaimana diperlihatkan pada Tabel 8. Nilai yang relatif sama pada batch A sampai dengan E menunjukkan bahwa arsitektur Kayu7Net sudah bekerja dengan baik.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa Kayu7Net memiliki kinerja yang baik, di mana penambahan jumlah *dataset* dan memperbaiki kualitas citra kayu sangat meningkatkan akurasi sistem identifikasi ini, dari 57,14% menjadi sebesar 95,54%. Kinerja terbaik Kayu7Net menggunakan *dataset* II dicapai pada model ke-6 untuk input citra kayu ukuran 600 x 600 piksel dan epoch 100. Perhitungan kinerja model ke-6 menunjukkan hasil *precision* sebesar 95,99%, *recall* sebesar 95,54%, *specificity* sebesar 99,26% dan *F-measure* sebesar 95,46%.

Penelitian lanjutan yang akan dilakukan adalah pengembangan arsitektur dan model pada Kayu7Net generasi berikutnya, khususnya pada kasus penambahan jumlah spesies kayu. Selain itu,

pengembangan fungsi aktivasi pada lapisan *Fully-Connected* (FC) perlu dieksplorasi menggunakan fungsi aktivasi selain ReLU. Pertimbangan ukuran *batch size* menjadi fokus penelitian selanjutnya juga.

5. UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih atas penyediaan fasilitas *High Performance Computing* LIPI yang digunakan dalam mengembangkan metode Identifikasi kayu. Ucapan terima kasih juga diberikan kepada Pusat Penelitian dan Pengembangan Hasil Hutan (P3HH), Balai Litbang dan Inovasi, Kementerian Lingkungan Hidup dan Kehutanan dalam hal penyediaan koleksi kayu dalam rangka pelaksanaan Program Insinas 2017 dan 2018 Kementerian Riset dan Teknologi, Republik Indonesia.

DAFTAR PUSTAKA

- BERGMAN, R., dkk, 2010, Structure and Function of Wood in Wood Handbook: Wood as An Engineering Material, Forest Products Laboratory, pp. 3-16.
- HADIWIDJAJA, M.L., dkk, 2019, Developing Wood Identification System by Local Binary Pattern and Hough Transform Method, Journal of Physics : Conference Series, pp 1-12.
- HASUGIAN, J., Penelusuran Informasi Secara Online: Perlakuan terhadap Seorang Pencari Informasi sebagai Real user, Jurnal Studi Perpustakaan dan Informasi, vol. 2, no. 1, pp. 1-13.
- HEISS, A.G., dan MARINOVA, E., 2009, A New Interactive Identification Tool for Woods from The Balkans, The Aegean and

- Adjacent Regions (Poster). Conference: XXXe Rencontres internationales d'archéologie et d'histoire d'AntibesAt: Juan-les-Pins.
- HU, J., dkk, 2019, Deep Learning for Use in Lumber Classification Tasks, Wood Science and Technology, Springer Berlin Heidelberg, <https://doi.org/10.1007/s00226-019-01086-z>.
- KRIZHEVSKY, A., SUTSKEVER, I., dan HINTON, G.E., 2017, ImageNet Classification with Deep Convolutional Neural Networks, Communications of The ACM, Vol. 60, No 6, pp. 84-90.
- LAINEZ, M.P.E.A., BUSTAMANTE, S.G.H., dan ORELLANA, G.S., 2018, Deep Learning Applied to Identification of Commercial Timber Species from Peru, IEEE XXV International Conference on Electronics, Electrical Engineering and Computing (INTERCON).
- PILOTTI, M., GERVASI, F., dan BRUNETTI, A., 2005, Molecular Identification of Fomitiporia Mediterranea and Eutypa lata/Libertella blepharis in Platanus Acerifolia, Journal of Phytopathology vol. 153, no. 4, pp. 193-202
- POWERS, D.M., 2007, Evaluation: from Precision, Recall and F-Factor to ROC, Informedness, Markedness & Correlation, Technical Report SIE, Adelaide, pp. 1-24.
- SAFDARI, V., dkk, 2008, Identification of Iranian Commercial Wood with Hand Lens, Pakistan Journal of Botany, vol. 40, no. 5, pp. 1851-1864,
- SUGIARTO, B., dkk, 2017, Wood Identification based on Histogram of Oriented Gradient (HOG) Features and Support Vector Machine (SVM) Classifier, 2nd International Conference on Information Technology, Information systems and Electrical Engineering (ICITISEE), Yogyakarta, pp. 337-341.
- TANG, X.J., dkk, 2017, Rapid and Robust Automated Macroscopic Wood Identification System using Smartphone with Macro-lens, rXiv preprint arXiv:1709.08154.
- TANG, X.J., dkk, 2018, MyWood-ID: Automated Macroscopic Wood Identification System using Smartphone and Macro-lens, ACM Proceedings of the 2018 International Conference on Computational Intelligence and Intelligent Systems (CIIS), pp. 37-43.
- TOU, Y., TAY, Y.H., dan LAU, P.Y., 2009, A Comparative Study for Texture Classification Techniques on Wood Species Recognition Problem, Fifth International Conference on Natural Computation, pp. 8-12.
- XIANG, Z.Y., dkk, 2016, Identification of Wood Defect Based on LBP Features, Proceeding of The 35th The Chinese Control Conference, Chengdu, pp. 4202-4205.
- ZHAO, Z.Q., dkk, 2019, Object Detection With Deep Learning: A Review, IEEE Transaction on Neural Network and Learning Systems, pp. 1-21.