



Deteksi Blue Stain dan Jamur pada Kayu Sengon Menggunakan Segmentasi Warna dan CNN di Jepara

Laksamana Rajendra Haidar Azani Fajri ^{a*}, Imam Syafii ^b, Yusuf Wisnu Mandaya ^c,
Adhitya Purboyo ^d, Ryan Yunus ^e

^a laksamanarajendra@uinsuku.ac.id, Universitas Islam Negeri Sunan Kudus; Kudus Jawa Tengah

^b imamsyafii@uinsuku.ac.id, Universitas Islam Negeri Sunan Kudus; Kudus Jawa Tengah

^c yusufwisnumandaya@uinsuku.ac.id, Universitas Islam Negeri Sunan Kudus; Kudus Jawa Tengah

^d adhityapurboyo@uinsuku.ac.id, Universitas Islam Negeri Sunan Kudus; Kudus Jawa Tengah

^e ryanyunus@uinsuku.ac.id, Universitas Islam Negeri Sunan Kudus; Kudus Jawa Tengah

ABSTRACT

Blue stain and fungal growth are visual defects on wood surfaces that can reduce aesthetic quality, complicate grading, and in some cases indicate unfavorable storage or moisture conditions. Manual inspection depends on operator experience and is difficult to scale. This article proposes a computer-vision pipeline that combines color-based segmentation with a convolutional neural network (CNN) to detect healthy wood, blue stain, and fungal regions. Color information is transformed from RGB to HSV and YCrCb to exploit hue, saturation, and chrominance differences, followed by thresholding and morphological operations to obtain candidate regions. The candidate regions are cropped into fixed-size patches and classified using a lightweight CNN. The evaluation design uses precision, recall, F1-score, accuracy, Intersection over Union (IoU), and Dice coefficient so that both classification and spatial segmentation can be assessed. Public wood-defect data are used as a reference source for blue-stain samples, while fungal images require project-specific annotation because no experimental fungal dataset is available. This article is a research design; therefore, empirical result values are not yet presented and will be reported after the target dataset is tested.

Keywords: blue stain; fungi; wood defect; color segmentation; HSV; YCrCb; convolutional neural network; CNN

Abstrak

Blue stain dan pertumbuhan jamur merupakan cacat visual pada permukaan kayu sengon yang dapat menurunkan kualitas estetika, menyulitkan proses grading, dan pada kondisi tertentu menjadi indikator penyimpanan atau kelembapan yang kurang baik. Inspeksi manual sangat bergantung pada pengalaman operator dan sulit diterapkan secara konsisten pada volume produksi tinggi. Penelitian ini merancang alur computer vision yang menggabungkan segmentasi berbasis warna dengan Convolutional Neural Network (CNN) untuk memodelkan kayu sengon sehat, blue stain, dan area jamur. Citra RGB dikonversi ke ruang warna HSV dan YCrCb untuk memanfaatkan perbedaan hue, saturation, serta komponen krominansi. Setelah thresholding, mask diperbaiki menggunakan operasi morfologi, kemudian wilayah kandidat dipotong menjadi patch berukuran tetap dan diklasifikasikan menggunakan CNN ringan. Evaluasi dirancang menggunakan precision, recall, F1-score, accuracy, Intersection over Union (IoU), dan Dice coefficient sehingga kinerja klasifikasi dan ketepatan lokasi dapat dinilai secara bersamaan. Dataset publik cacat permukaan kayu sengon digunakan sebagai sumber rujukan citra blue stain, sedangkan citra jamur memerlukan anotasi khusus karena belum tersedia dataset eksperimen jamur. Artikel ini merupakan rancangan penelitian; oleh karena itu, nilai hasil empiris belum disajikan dan akan dilaporkan setelah pengujian pada dataset target dilakukan.

Kata Kunci: blue stain; jamur; cacat Kayu Sengon; segmentasi warna; HSV; YCrCb; convolutional neural network; CNN.

1. PENDAHULUAN

Kayu sengon merupakan material yang banyak digunakan pada konstruksi, furnitur, dan berbagai produk bernilai tambah. Variasi alami serat, warna, kadar air, serta kondisi penyimpanan membuat inspeksi permukaan kayu sengon menjadi persoalan computer vision yang tidak sederhana. Berbagai cacat permukaan seperti knot, crack, resin, dan blue stain telah dipelajari dalam sistem inspeksi otomatis. Dataset besar dari VSB-Technical University of Ostrava, misalnya, menyediakan 20.275 citra permukaan kayu sengon dengan sepuluh tipe cacat dan anotasi semantic map maupun bounding box [1].

Blue stain merupakan salah satu cacat yang relatif halus karena bercampur dengan variasi warna alami kayu sengon. Studi Funck et al. menunjukkan bahwa informasi warna dapat penting untuk cacat yang subtle, termasuk blue stain, dan kinerja segmentasi dapat berubah sesuai ruang warna serta karakteristik citra [2]. Penelitian Van den Bulcke et al. juga menunjukkan bahwa analisis citra dapat digunakan untuk menilai dan mengkuantifikasi perubahan warna akibat blue stain pada kayu sengon [3].

Pada konteks industri penggergajian, Wolszczak et al. menerapkan penyaringan awal berbasis HSV untuk memilih area yang berpotensi mengandung blue stain, kemudian memfilternya berdasarkan karakteristik geometrik sebelum memasukkan patch 32×32 piksel ke jaringan saraf [4]. Pendekatan tersebut menunjukkan bahwa segmentasi atau pra-segmentasi berbasis warna dapat mengurangi ruang pencarian sebelum proses klasifikasi neural network.

Selain blue stain, keberadaan jamur pada permukaan kayu sengon perlu diperhatikan karena pertumbuhan awal dapat sulit dibedakan dari perubahan warna bahan atau kondisi kelembapan. Wang et al. pada 2026 menunjukkan bahwa pencitraan hyperspectral dan jaringan konvolusional dapat digunakan untuk membedakan tingkat pertumbuhan mold pada kayu sengon secara pixel-level [5]. Walaupun hyperspectral memberikan informasi spektral yang kaya, penggunaan kamera RGB biasa lebih sederhana untuk prototipe lapangan dan lebih mudah diimplementasikan pada sistem biaya rendah.

Berdasarkan kondisi tersebut, penelitian ini merumuskan pendekatan dua tahap: (1) segmentasi kandidat berdasarkan warna untuk memusatkan perhatian pada area abnormal, dan (2) klasifikasi patch menggunakan CNN untuk membedakan blue stain, jamur, dan kayu sengon sehat. Tujuannya adalah menghasilkan rancangan deteksi yang mudah direplikasi, ringan secara komputasi, dan menyediakan keluaran spasial berupa mask area cacat. Artikel ini disusun sebagai rancangan penelitian, sehingga belum menyajikan hasil eksperimen.

2. TINJAUAN PUSTAKA

2.1 Blue Stain pada Kayu Sengon

Blue stain adalah perubahan warna Kayu Sengon yang berhubungan dengan fungi pewarna Kayu Sengon. Pada inspeksi visual, pola warna kebiruan dapat menyerupai variasi warna alami, kotoran, atau cacat lain sehingga pendeteksian otomatis memerlukan informasi warna yang cukup. Literatur menunjukkan bahwa blue stain dapat dideteksi melalui pengolahan citra, hyperspectral imaging, dan neural network [3], [4], [6].

2.2 Jamur pada Permukaan Kayu Sengon

Jamur permukaan dapat muncul ketika kondisi suhu dan kelembapan mendukung pertumbuhan. Dalam citra RGB, tanda visualnya dapat berupa perubahan warna, bercak, atau tekstur. Penelitian terbaru pada hyperspectral wood imaging menunjukkan bahwa klasifikasi tingkat pertumbuhan mold dapat dilakukan secara pixel-level, namun generalisasi terhadap spesies Kayu Sengon, pencahayaan, dan tahap pertumbuhan tetap menjadi tantangan [5].

2.3 Segmentasi Warna

Segmentasi bertujuan memisahkan piksel atau wilayah yang memiliki karakteristik tertentu dari latar belakang. Untuk material Kayu Sengon, RGB dapat terpengaruh oleh intensitas cahaya sehingga ruang HSV dan YCrCb dapat membantu memisahkan informasi rona dan krominansi. Tahap segmentasi pada penelitian ini mencakup konversi ruang warna, thresholding, operasi opening-closing, penghapusan komponen kecil, dan pembentukan bounding box kandidat [2], [4].

2.4 Convolutional Neural Network

CNN mampu mempelajari fitur spasial melalui lapisan convolution, pooling, dan fully connected. Pada inspeksi Kayu Sengon, pendekatan CNN telah digunakan untuk klasifikasi cacat dan penghitungan

karakteristik kerusakan secara otomatis [7], [8]. Arsitektur yang digunakan dalam draf ini dibuat ringan agar sesuai dengan tahap klasifikasi patch setelah segmentasi warna.

2.5 Evaluasi

Evaluasi klasifikasi dilakukan menggunakan accuracy, precision, recall, dan F1-score. Karena penelitian juga menghasilkan mask area cacat, evaluasi spasial menggunakan IoU dan Dice coefficient. Untuk dataset yang tidak seimbang, macro F1 lebih informatif dibanding hanya accuracy karena memberikan bobot yang relatif setara pada setiap kelas.

3. METODOLOGI PENELITIAN

3.1 Sumber dan Bentuk Dataset

Sumber rujukan blue stain menggunakan dataset wood surface defects yang dipublikasikan Kodytek, Bodzas, dan Bilik. Dataset tersebut berisi 1.992 citra Kayu Sengon tanpa cacat dan 18.283 citra dengan cacat, terdiri dari sepuluh tipe defect. Blue stain tercatat pada 77 citra dengan 96 kemunculan defect [1]. Kondisi ini menunjukkan ketidakseimbangan kelas yang perlu diperhatikan dalam pelatihan CNN. Dataset tersedia bersama semantic map dan bounding box untuk kebutuhan segmentasi maupun lokalisasi [1].

Untuk kelas jamur, penelitian lapangan perlu menambahkan citra RGB yang telah diverifikasi oleh pengamat/ahli. Anotasi direkomendasikan dalam tiga kelas, yaitu sehat, blue stain, dan jamur. Karena file yang diunggah hanya berisi template jurnal dan tidak menyertakan citra eksperimen jamur, jumlah sampel jamur tidak diasumsikan pada draf ini.

Tabel 1. Rancangan kelas dan sumber data


Kelas	Definisi	Sumber	Anotasi
Sehat	Permukaan tanpa blue stain/jamur	Dataset Kayu Sengon atau foto lapangan	Mask latar
Blue stain	Pewarnaan biru/abu kebiruan akibat fungi pewarna Kayu Sengon	Kodytek et al. [1]	Semantic mask/bounding box
Jamur	Bercak atau koloni jamur permukaan	Citra lapangan/laboratorium	Pixel mask + label kelas

3.2 Pra-pemrosesan Citra

Setiap citra dinormalisasi ukuran, kemudian dilakukan penyesuaian intensitas dan augmentasi ringan berupa rotasi kecil, horizontal flip, crop acak, serta perubahan brightness dan saturation. Augmentasi digunakan untuk memperkaya variasi citra tanpa mengubah identitas kelas secara semantik [9].

3.3 Segmentasi Berbasis Warna

Citra RGB dikonversi ke HSV dan YCrCb. Candidate blue-stain mask dibentuk menggunakan kombinasi rentang hue, saturation, dan nilai luminance. Candidate fungal mask menggunakan kriteria krominansi dan saturation yang diperoleh dari data pelatihan. Nilai threshold tidak ditetapkan sebagai angka universal; threshold sebaiknya dipilih melalui validasi pada subset training karena karakteristik kamera, spesies Kayu Sengon, dan pencahayaan dapat mengubah distribusi warna. Setelah thresholding, mask diproses dengan morphological opening dan closing untuk mengurangi noise dan menutup celah.



Gambar 1. Alur metode deteksi blue stain dan jamur berbasis segmentasi warna dan CNN


3.4 Ekstraksi Wilayah Kandidat

Komponen terhubung pada mask disaring berdasarkan luas minimum, rasio aspek, dan ukuran bounding box. Setiap kandidat diperluas dengan margin kecil agar konteks tekstur Kayu Sengon tetap tersedia, lalu


di-resize menjadi 64×64 piksel. Proses ini terinspirasi dari pendekatan inspeksi blue stain yang lebih dahulu melakukan pre-selection berbasis HSV dan geometri sebelum klasifikasi neural network [4].

3.5 Arsitektur CNN

CNN dirancang dengan tiga blok convolution. Setiap convolution diikuti fungsi aktivasi ReLU dan batch normalization, sedangkan max pooling digunakan untuk menurunkan dimensi spasial. Setelah blok konvolusi terakhir, Global Average Pooling (GAP) mengurangi jumlah parameter sebelum lapisan dense tiga kelas. Desain ini dipilih sebagai baseline ringan yang mudah ditransfer ke perangkat edge.



Gambar 2. Arsitektur CNN baseline untuk klasifikasi patch



Gambar 3. Arsitektur Jaringan Saraf Tiruan

Gambar tersebut mengilustrasikan diagram arsitektur Jaringan Saraf Tiruan, khususnya Convolutional Neural Network (CNN), yang dirancang untuk menjalankan tugas klasifikasi gambar. Pemrosesan data dimulai dari penerimaan gambar input RGB berukuran 64×64 piksel (dengan 3 saluran warna) yang kemudian diproses melalui serangkaian lapisan ekstraksi fitur. Jaringan ini menggunakan tiga Blok Konvolusi (Conv Block 1, 2, dan 3) dengan ukuran kernel 3×3 yang jumlah filternya terus meningkat dari 32, 64, hingga 128 filter, serta dilengkapi aktivasi ReLU dan Batch Normalization (BN) untuk mempelajari pola gambar secara bertahap. Selain itu, terdapat lapisan Max Pooling 1 dan 2 yang berfungsi mengurangi dimensi data sebesar 2×2 untuk menyaring dan menonjolkan fitur-fitur terpenting sekaligus mengefisienkan proses komputasi.

Setelah melalui tahapan ekstraksi fitur yang semakin kompleks, seluruh informasi yang telah dipelajari oleh model tersebut disatukan, seperti yang digambarkan oleh garis-garis panah yang melewati elemen berbentuk lensa. Kumpulan fitur dari berbagai tingkatan ini kemudian diteruskan ke tahap akhir, yaitu bagian "Klasifikasi Gambar". Pada tahap puncak ini, jaringan saraf tiruan akan menganalisis fitur-fitur dominan yang telah diekstrak sebelumnya untuk menebak dan mengelompokkan gambar input awal ke dalam salah satu dari 3 kelas atau kategori yang telah ditentukan.

Tabel 2. Konfigurasi CNN yang diusulkan

Lapisan	Konfigurasi	Output
Input	64×64×3 RGB	64×64×3
Conv Block 1	3×3, 32 filter, ReLU + BN	64×64×32
Max Pool 1	2×2	32×32×32
Conv Block 2	3×3, 64 filter, ReLU + BN	32×32×64
Max Pool 2	2×2	16×16×64
Conv Block 3	3×3, 128 filter, ReLU + BN	16×16×128
GAP + Dense	Global average pooling + Dense(3)	3 kelas

3.6 Strategi Pelatihan

Data dibagi menjadi training, validation, dan test set dengan memastikan tidak terjadi leakage antar citra dari papan Kayu Sengon yang sama. Pembagian 70:15:15 dapat digunakan sebagai konfigurasi awal. Optimizer Adam dipilih dengan learning rate awal 0,001 dan early stopping berdasarkan validation loss. Ketika distribusi kelas tidak seimbang, class weight atau focal loss dapat digunakan. Model terbaik dipilih berdasarkan macro F1 validasi, bukan accuracy semata.

3.7 Metrik Evaluasi

Tabel 3. Metrik evaluasi

Metrik	Persamaan/Definisi	Interpretasi
Accuracy	$(TP+TN)/(TP+TN+FP+FN)$	Proporsi prediksi benar
Precision	$TP/(TP+FP)$	Ketepatan prediksi positif
Recall	$TP/(TP+FN)$	Kemampuan menangkap kelas cacat
F1-score	$2 \cdot \text{Precision} \cdot \text{Recall} / (\text{Precision} + \text{Recall})$	Keseimbangan precision dan recall
IoU	$ P \cap G / P \cup G $	Kesamaan mask prediksi dan ground truth
Dice	$2 P \cap G / (P + G)$	Overlap mask yang lebih toleran pada objek kecil

3.8 Prosedur Eksperimen

- Kumpulkan dan verifikasi citra Kayu Sengon sehat, blue stain, dan jamur;
- Anotasi area cacat secara pixel-level;
- Bagi data berdasarkan papan/sampel, bukan hanya berdasarkan file citra;
- Tentukan threshold warna pada training set;
- Hasilkan mask kandidat dan ekstrak patch 64×64;
- Latih CNN dengan class weighting atau focal loss bila diperlukan;
- Evaluasi pada test set yang belum pernah dilihat model;
- Analisis false positive/false negative untuk setiap jenis cacat.

4. HASIL DAN PEMBAHASAN

4.1 Hasil Perancangan Sistem

Rancangan sistem menghasilkan dua keluaran utama. Keluaran pertama adalah mask kandidat yang menunjukkan lokasi piksel yang memenuhi kriteria warna. Keluaran kedua adalah kelas hasil CNN untuk setiap kandidat: sehat, blue stain, atau jamur. Integrasi ini mempertahankan keunggulan segmentasi warna yang relatif ringan sekaligus memberi CNN tanggung jawab untuk membedakan pola yang secara warna masih ambigu.

Secara konseptual, segmentasi warna berfungsi sebagai penyaring awal. Pendekatan ini relevan untuk blue stain karena penelitian Wolszczak et al. menunjukkan bahwa area kandidat dapat dipilih di ruang HSV sebelum proses klasifikasi neural network [4]. Pada saat yang sama, penelitian Funck et al. menegaskan bahwa informasi warna dapat meningkatkan kemampuan membedakan defect yang halus pada permukaan Kayu Sengon [2].

4.2 Analisis Kelebihan dan Keterbatasan

Kelebihan utama metode adalah modularitas. Threshold warna dapat diubah tanpa melatih ulang CNN, sedangkan CNN dapat diperbarui ketika sampel baru tersedia. Selain itu, proses pre-segmentation mengurangi jumlah patch yang harus diklasifikasikan sehingga berpotensi menurunkan beban komputasi.

Keterbatasannya adalah ketergantungan terhadap pencahayaan dan karakteristik permukaan Kayu Sengon. Warna blue stain dapat bertumpang tindih dengan resin, noda, atau variasi serat. Jamur awal juga dapat sangat samar. Karena itu, threshold warna yang terlalu ketat berisiko meningkatkan false negative, sedangkan threshold yang terlalu longgar menghasilkan banyak false positive. Kondisi ini memperkuat pentingnya validasi pada data yang benar-benar merepresentasikan lingkungan operasi.

4.3 Format Pelaporan Hasil Eksperimen

Karena dataset eksperimen jamur dan hasil training belum disertakan bersama dokumen sumber, nilai numerik berikut sengaja tidak diisi dan tidak boleh dianggap sebagai hasil penelitian. Tabel disediakan sebagai format final untuk diisi setelah pengujian dilakukan.

Tabel 4. Format hasil klasifikasi CNN (isi setelah eksperimen)

Kelas	Precision	Recall	F1-score	Support
Sehat	—	—	—	—
Blue stain	—	—	—	—
Jamur	—	—	—	—
Macro average	—	—	—	—

Tabel 5. Format hasil segmentasi (isi setelah eksperimen)

Kelas	IoU	Dice	Area Error (%)
Blue stain	—	—	—
Jamur	—	—	—
Rata-rata	—	—	—

4.4 Analisis Sensitivitas Threshold Warna

Pengujian threshold sebaiknya dilakukan dengan beberapa konfigurasi. Untuk setiap konfigurasi, catat jumlah area kandidat, precision mask, recall mask, serta waktu pemrosesan per citra. Konfigurasi terbaik tidak selalu menghasilkan jumlah piksel terbanyak; threshold yang baik adalah yang mempertahankan area cacat relevan sekaligus mengurangi gangguan seperti serat Kayu Sengon, resin, dan noda.

Tabel 6. Format uji sensitivitas threshold

Konfigurasi	Parameter HSV/YCrCb	Precision Mask	Recall Mask	Waktu/Citra
T1	—	—	—	—
T2	—	—	—	—
T3	—	—	—	—
Terpilih	—	—	—	—

4.5 Perbandingan dengan Pendekatan Terkait

Pendekatan yang diusulkan berada di antara sistem rule-based murni dan end-to-end deep learning. Dibanding thresholding murni, CNN dapat memanfaatkan tekstur dan konteks lokal untuk menolak kandidat yang warnanya mirip tetapi bukan blue stain atau jamur. Dibanding detektor end-to-end seperti YOLO, arsitektur ini lebih sederhana dan cocok sebagai baseline penelitian yang ingin mengisolasi kontribusi segmentasi warna.

Penelitian terdahulu pada cacat Kayu Sengon menunjukkan bahwa CNN dapat digunakan untuk klasifikasi kerusakan Kayu Sengon [7], [8], sedangkan sistem YOLO untuk inspeksi permukaan Kayu Sengon telah mencapai performa tinggi pada dataset tertentu [10]. Namun, tujuan artikel ini bukan memaksimalkan mAP object detector, melainkan merancang pipeline yang eksplisit pada tahap segmentasi warna sehingga lokasi cacat dapat dianalisis secara spasial.

4.6 Implikasi Implementasi

Pada implementasi industri, kamera perlu dikalibrasi, jarak kamera terhadap papan dijaga relatif konstan, dan pencahayaan dibuat seragam. Background yang kontras juga membantu mengurangi false positive. Sistem dapat diimplementasikan sebagai pipeline Python/OpenCV untuk segmentasi dan TensorFlow/PyTorch untuk CNN. Hasil akhir dapat divisualisasikan sebagai overlay mask pada citra asli dan ringkasan luas area cacat per papan.

Untuk kebutuhan inspeksi real-time, beberapa optimasi dapat dipertimbangkan: mengurangi ukuran input, menggunakan depthwise separable convolution, melakukan quantization, dan menjalankan inference hanya pada kandidat hasil segmentasi. Strategi ini konsisten dengan kebutuhan sistem inspeksi industri yang menekankan kecepatan sekaligus repeatability [4].

5. KESIMPULAN DAN SARAN

Penelitian ini merancang metode deteksi blue stain dan jamur pada Kayu Sengon dengan menggabungkan segmentasi warna dan Convolutional Neural Network. Segmentasi dilakukan menggunakan informasi HSV dan YCrCb untuk memperoleh wilayah kandidat, kemudian operasi morfologi dan penyaringan komponen digunakan untuk merapikan mask. Area kandidat selanjutnya diklasifikasikan dengan CNN menjadi kelas sehat, blue stain, atau jamur. Rancangan evaluasi mencakup metrik klasifikasi dan metrik segmentasi sehingga keluaran model dapat dinilai dari sisi ketepatan kelas maupun ketepatan lokasi.

Literatur menunjukkan bahwa pendekatan berbasis warna relevan untuk blue stain dan cacat Kayu Sengon yang halus, sementara CNN mampu meningkatkan kemampuan klasifikasi terhadap variasi tekstur dan tampilan permukaan [2], [4], [7]. Dataset wood-surface defects yang tersedia publik juga menyediakan semantic map dan bounding box yang dapat dijadikan sumber data blue stain [1]. Untuk jamur, diperlukan penambahan citra RGB yang dianotasi dan diverifikasi karena file sumber penelitian ini tidak menyediakan dataset eksperimen tersebut.

Tahap lanjutan yang disarankan adalah melaksanakan eksperimen pada dataset target, memilih threshold berdasarkan training set, melatih CNN dengan pembobotan kelas, serta menguji robustness terhadap perubahan pencahayaan, spesies Kayu Sengon, orientasi serat, dan kadar kelembapan. Selain itu, perbandingan dengan transfer learning seperti MobileNetV2, EfficientNet, atau model deteksi/segmentasi modern dapat dilakukan setelah baseline pipeline stabil.

Catatan integritas hasil: angka performa pada Tabel 4–6 belum diisi karena tidak ada dataset jamur atau log eksperimen yang dilampirkan pada dokumen sumber. Mengisi angka secara hipotetis akan mengubah draf metode menjadi klaim eksperimen yang tidak terverifikasi. Oleh karena itu, tabel disiapkan sebagai template pelaporan hasil yang dapat diisi setelah penelitian dijalankan.

DAFTAR PUSTAKA

- [1] P. Kodytek, A. Bodzas, and P. Bilik, “A large-scale image dataset of wood surface defects for automated vision-based quality control processes,” *F1000Research*, vol. 10, p. 581, 2021/2022, doi: 10.12688/f1000research.52903.2.
- [2] J. W. Funck, Y. Zhong, D. A. Butler, C. C. Brunner, and J. B. Forrer, “Image segmentation algorithms applied to wood defect detection,” *Computers and Electronics in Agriculture*, vol. 41, no. 1–3, pp. 157–179, 2003, doi: 10.1016/S0168-1699(03)00049-8.
- [3] J. Van den Bulcke, J. Van Acker, and M. Stevens, “Image processing as a tool for assessment and analysis of blue stain discolouration of coated wood,” *International Biodeterioration & Biodegradation*, vol. 56, no. 3, pp. 178–187, 2005, doi: 10.1016/j.ibiod.2005.07.004.
- [4] P. Wolszczak, G. Kotnarowski, A. Małek, and G. Litak, “Training of a Neural Network System in the Task of Detecting Blue Stains in a Sawmill Wood Inspection System,” *Applied Sciences*, vol. 14, no. 9, p. 3885, 2024, doi: 10.3390/app14093885.
- [5] H. Wang, D. Zhao, and J. Zhao, “Innovative convolutional neural networks and high-quality hyperspectral datasets for non-destructive detection of early mold in wood,” *Scientific Reports*, 2026, doi: 10.1038/s41598-026-68820-z.
- [6] I. Burud, L. R. Gobakken, A. Flø, K. Kvaal, and T. K. Thiis, “Hyperspectral imaging of blue stain fungi on coated and uncoated wooden surfaces,” *International Biodeterioration & Biodegradation*, vol. 88, pp. 37–43, 2014, doi: 10.1016/j.ibiod.2013.12.002.

- [7] R. Ehtisham et al., “Computing the characteristics of defects in wooden structures using image processing and CNN,” *Automation in Construction*, vol. 158, p. 105211, 2024, doi: 10.1016/j.autcon.2023.105211.
- [8] T. He, Y. Liu, Y. Yu, Q. Zhao, and Z. Hu, “Application of deep convolutional neural network on feature extraction and detection of wood defects,” *Measurement*, vol. 152, p. 107357, 2020, doi: 10.1016/j.measurement.2019.107357.
- [9] C. Shorten and T. M. Khoshgoftaar, “A survey on image data augmentation for deep learning,” *Journal of Big Data*, vol. 6, no. 1, pp. 1–48, 2019.
- [10] F. Akhyar, L. Novamizanti, and T. Riantiarni, “Sistem Inspeksi Cacat pada Permukaan Kayu Sengon menggunakan Model Deteksi Obyek YOLOv5,” *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 10, no. 4, 2022, doi: 10.26760/elkomika.v10i4.990.