

PENGENALAN CITRA PENYAKIT DAUN PADI DI INDONESIA MENGUNAKAN METODE *XCEPTION* DAN *INCEPTIONV3*

Renaldy

Program Studi Teknik Informatika, Fakultas Teknologi Informasi, Universitas Tarumanagara,
Jln. Letjen S. Parman No. 1, Jakarta, 11440, Indonesia
e-mail: renaldy.535200036@stu.untar.ac.id

ABSTRAK

Padi merupakan bahan makanan pokok di Indonesia karena hampir seluruh rakyat Indonesia konsumsi nasi dari olahan padi yang menjadi beras. Di Indonesia terdapat masalah yang dihadapi oleh para petani, yaitu penyakit hawar daun bakteri atau penyakit daun padi. Masalah ini mengakibatkan fungsi fotosintesis pada daun padi terganggu, oleh karena itu tujuan penelitian ini untuk mengenali penyakit daun padi dari citra gambar menggunakan metode *Xception* dan *InceptionV3*. Terdapat 3 penyakit daun padi yang akan dikenali diantaranya blast, blight, dan tungro. Dari akurasi kedua model Convnet sudah sangat baik dalam meprediksi penyakit daun padi, model *Xception* yang memiliki akurasi yang lebih tinggi dari pada *InceptionV3*. *Xception* menghasilkan akurasi validasi sebesar 98% dan *InceptionV3* menghasilkan akurasi validasi sebesar 95%.

Kata kunci: Penyakit daun padi, citra gambar, *Xception*, *InceptionV3*.

ABSTRACT

Rice is a staple food in Indonesia because almost all Indonesians consume rice from processed rice which becomes rice. In Indonesia there is a problem faced by farmers, namely bacterial leaf blight or rice leaf disease. This problem causes the photosynthesis function of rice leaves to be disrupted, therefore the purpose of this research is to recognize rice leaf disease from images using Xception and InceptionV3 methods. There are 3 rice leaf diseases that will be recognized including blast, blight, and tungro. From the accuracy of the two Convnet models is very good in predicting rice leaf disease, the Xception model has a higher accuracy than InceptionV3. Xception produces a validation accuracy of 98% and InceptionV3 produces a validation accuracy of 95%.

Keywords: Rice leaf disease, image, *Xception*, *InceptionV3*.

1 PENDAHULUAN

Padi merupakan bahan makanan pokok di Indonesia karena hampir seluruh rakyat Indonesia konsumsi nasi dari olahan padi yang menjadi beras. Di Indonesia terdapat masalah yang dihadapi oleh para petani, yaitu penyakit hawar daun bakteri atau penyakit daun padi. Masalah ini mengakibatkan fungsi fotosintesis pada daun padi terganggu, oleh karena itu tujuan penelitian ini untuk mengenali penyakit daun padi dari citra gambar menggunakan metode *Xception* dan *InceptionV3*. Terdapat 3 penyakit daun padi yang akan dikenali diantaranya blast, blight, dan tungro. Penyakit blast atau dalam bahasa indonesia blas memiliki ciri - ciri bercak belah ketupat yang disebabkan oleh jamur *Pyricularia*, gejala serangan blast yaitu adanya patah pada percabangan malai (blas leher malai), nekrosis pada nekrosis pada daun memanjang dimulai dengan bentuk belah ketupat, ketika kulit buah dibuka terdapat miselium putih jamur. Di Indonesia penyakit *blight* atau umumnya disebut “kresek” merupakan penyakit yang dapat menyebabkan tanaman padi menjadi busuk. Tungro merupakan salah satu penyakit yang paling parah mempengaruhi panen padi di negara-negara Asia Tenggara. Penyakit tungro dapat mengurangi jumlah anakan dan hasil panen, sehingga tanaman tidak dapat mencapai potensi hasil maksimal. Tujuan penelitian ini untuk mengenali penyakit daun padi dari citra gambar menggunakan metode *Xception* dan *InceptionV3*.

[1]

2. TINJAUAN LITERATUR

Ada beberapa penelitian dari artikel lain dengan topik penyakit daun padi. Pertama artikel dengan topik “Implementasi *Gray Level Cooccurrence Matrix* (GLCM) Untuk Klasifikasi Penyakit Daun Padi”, ditulis oleh Arif Akbarul Huda, Bayu Setiaji, Fajar Rosyid Hidayat. Penelitian ini bertujuan untuk memprediksi jenis bacterial leaf blight, brown spot, dan leaf smut penyakit daun padi. Model *Gray Level Cooccurrence Matrix* (GLCM) yang dibangun menghasilkan akurasi uji sebesar 66%. [2]

Topik penelitian selanjutnya adalah “Penerapan Algoritma *Convolutional Neural Network* Dan Arsitektur *MobileNet* Pada Aplikasi Deteksi Penyakit Daun Padi”, ditulis oleh Rizal Amegia Saputra, Sri Wasyanti, Adi Supriyatna, Dede Firmansyah Saefudin. Penelitian ini bertujuan untuk memprediksi 3 penyakit daun padi yaitu Bacterial leaf blight, Brown spot, Leaf smut. Model yang dibangun merupakan model MobilenetVI yang menghasilkan akurasi sebesar 83%. [3]

Topik lain dari Ulfah Nur Oktaviana dan Ricky Hendrawan, Alfian Dwi Khoirul Annas, Galih Wasis Wicaksono meneliti tentang “Klasifikasi Penyakit Padi berdasarkan Citra Daun Menggunakan Model Terlatih Resnet101”. Prediksi penyakit daun padi menggunakan Resnet101 yang menghasilkan akurasi uji 100%. [4]

Selanjutnya penelitian tentang “Klasifikasi Penyakit Daun Padi menggunakan *Random Forest* dan *Color Histogram*”, ditulis oleh Sarifah Agustiani, Yoseph Tajul Arifin, Agus Junaidi, Siti Khotimatul Wildah, Ali Mustopa. Model prediksi Random Forest untuk memprediksi penyakit daun padi mencapai 99.65%. [5]

Penelitian dari Retno Nugroho Whidhiasih dan Inna Ekawati meneliti tentang “Identifikasi Jenis Penyakit Daun Padi Menggunakan Adaptif *Neuro Fuzzy Inferene System* (ANFIS) Berdasarkan Tekstur”. Dalam kasus ini model ANFIS memiliki akurasi sebesar 98.5%. [6]

“Klasifikasi Penyakit Daun Padi Berdasarkan Hasil Ekstraksi Fitur GLCM Interval 4 Sudut” ditulis oleh Jani Kusanti, Noor Abdul Haris. Paper ini meneliti tentang penyakit daun padi dengan model GLCM Interval 4 Sudut, yang menghasilkan akurasi uji sebesar 80%. [7]

Kemudian topik “Klasifikasi Penyakit Tanaman Padi Menggunakan Model Deep Learning Efficientnet B3 Dengan Transfer Learning” ditulis oleh Endang Anggiratih, Sri Siswanti, Saly Kurnia Octaviani, Arumsari. Paper ini bertujuan membangun model klasifikasi untuk memprediksi penyakit daun padi menggunakan Efficient B3. Model ini mencapai akurasi 79.53% dengan teknik transfer learning. [8]

Selanjutnya penelitian dari Mohtar Khoiruddin, Apri Junaidi, Wahyu Andi Saputra tentang “Klasifikasi Penyakit Daun Padi Menggunakan *Convolutional Neural Network*”. Paper ini menggunakan metode *Convolution Neural Network* untuk memprediksi penyakit daun padi yang menghasilkan akurasi sebesar 98%. [9]

Topik penelitian selanjutnya adalah “Penerapan Metode *Learning Vector Quantization* Untuk Identifikasi Penyakit Padi Berdasarkan Bentuk Bercak Daun”, ditulis oleh Ery Murniyasih, Luluk Suryani. Penelitian ini bertujuan untuk mengklasifikasi penyakit daun padi menggunakan teknik learning vector quantization dan mendapatkan akurasi sebesar 73.33%. [10]

“Penerapan Metode Forward Chaining Untuk Mengidentifikasi Hama Dan Penyakit Tanaman Padi”, ditulis Lulu Nafisa, M. Nur Ikhsanto, and Sulistiyanto. Paper ini berfokus pada memprediksi penyakit daun padi, algoritma yang digunakan adalah *Forward Chaining* dan menghasilkan akurasi sebesar 100%. [11].

3. METODE PENELITIAN

1.1 Data Koleksi

Kumpulan data diunduh melalui situs kaggle dengan total data gambar sebanyak 240 gambar dengan masing - masing 80 gambar pada 3 kelas (*blast*, *blight*, dan *tungro*).

1.2 Preprocessing

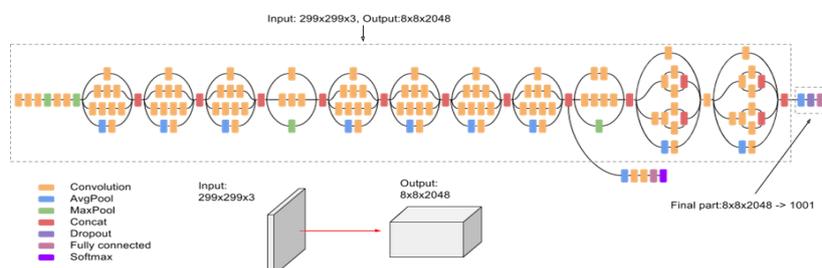
Data yang diunduh akan dilakukan augmentasi data untuk menambahkan variasi data. Ada beberapa teknik dalam augmentasi data diantaranya *horizontal flip*, *zoom (0.2)*, *rotation (10)*, *width (0.2)*, *height (0.2)* dan menghasilkan total data sebesar 1440 data gambar. Horizontal flip akan menghasilkan gambar yang terbalik seperti cermin, zoom akan menghasilkan pembesaran gambar sebesar 20%, rotation akan menghasilkan gambar yang dirotasi searah jarum jam sebesar 10 derajat, width akan menghasilkan pergeseran lebar gambar sebesar 20%, dan height menghasilkan pergeseran tinggi gambar sebesar 20% [12]. Data akan dibagi menjadi 2 bagian yaitu 80% latih dan 20% validasi, dan dinormalisasi setiap gambarnya dengan membagi nilai warna piksel dengan nilai 255. Setiap gambar di ubah ukurannya menjadi 112 x 112 dengan saluran warna RGB.

1.3 Model Development

Pada tahap selanjutnya, akan dibangun 2 arsitektur model yaitu InceptionV3 dan Xception dengan teknik transfer learning dengan tujuan agar model dapat dilatih dengan cepat dan lebih optimal untuk melakukan tugas klasifikasi penyakit daun padi. Pada layer model InceptionV3 akan dilakukan “freeze” dan memanggil layer terakhir pada setiap model dan kemudian akan dimasukan kedalam Fully Connected Layer. Dalam Fully Connected Layer dilakukan teknik dropout sebesar 20% sebanyak 2 layer agar model rentan terhadap overfitting. Setiap model akan dilakukan compile dengan optimizer Adam dengan learning rate $1 / 10^{-3}$, nilai loss categorical crossentropy, dan fokus pada kenaikan akurasi. Model dilatih sebanyak 20 epoch dan menghabiskan waktu latih selama 20 menit pada setiap model. [13]

1.3.1 InceptionV3

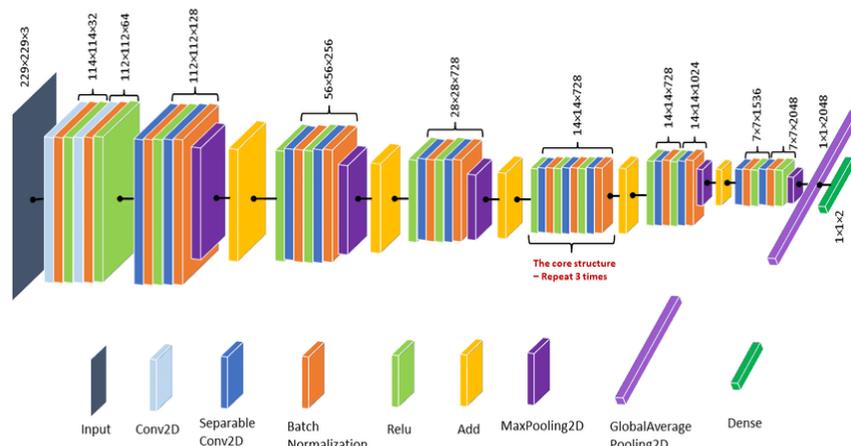
Model Inception-v3 merupakan pengembangan dari model *GoogLeNet*, yang juga dikenal sebagai model Inception-v1, yang dibuat pada tahun 2015. Dalam kategori klasifikasi gambar, model ini menempati posisi pertama dalam kompetisi *ImageNet Large Scale Visual Recognition Challenge (ILSVRC) 2014*. Setelah itu, normalisasi batch (BN) yang dikenal sebagai Inception-v2 diperkenalkan untuk menyempurnakannya. Setelah itu, dikembangkan lebih lanjut menjadi InceptionV3, yang, setelah menambahkan lebih banyak faktorisasi pada operasi konvolusi, menempati posisi runner-up pertama pada kompetisi *ImageNet Large Scale Visual Recognition contest Challenge (ILSVRC) 2015* untuk klasifikasi gambar dan mampu mengenali 1000 objek kelas ImageNet. Lima lapisan konvolusi dasar (batang) membentuk Inception-v3. Jenis padding yang valid untuk lapisan-lapisan ini adalah conv2d_0 hingga conv2d_4, dan setiap operasi konvolusi diikuti oleh BatchNormalization dan aktivasi ReLu. 11 modul inception yang terdiri dari modul mixed0 hingga mixed10 dengan tipe padding yang sama di setiap operasi konvolusi kemudian disajikan. Ke-11 blok modul Inceptionv3 memiliki faktorisasi konvolusi 1x1, 3x3, 1x1, 5x5, 1x7, dan 7x7. Ketiga, sebuah dataset yang cukup besar dari gambar ImageNet dengan 1000 kelas yang berbeda digunakan untuk melatih bagian klasifikasi dari model ini [14].



Gambar 1 Arsitektur InceptionV3

1.3.2 Xception

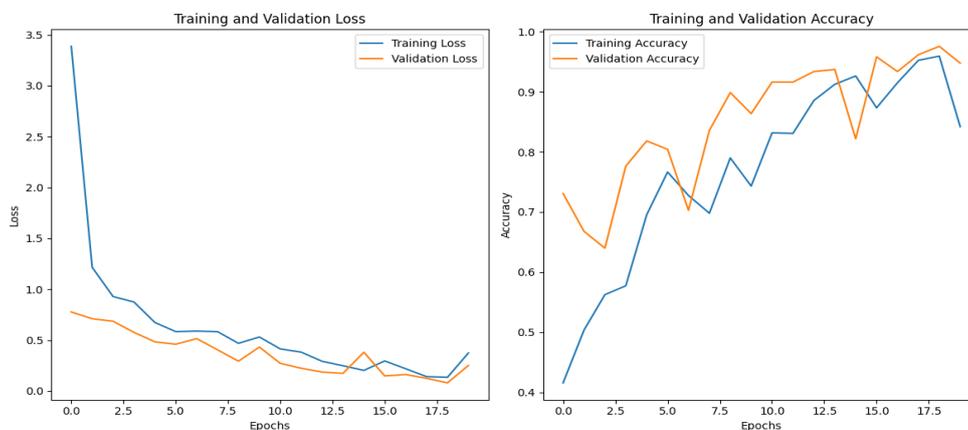
Xception (*Extreme Inception*) adalah arsitektur jaringan saraf tiruan (CNN) yang digunakan untuk klasifikasi gambar. Meskipun desain Xception didasarkan pada desain Inception, namun modifikasi yang signifikan telah dilakukan pada algoritma konvolusi. Dalam arsitektur Xception, sebuah gagasan yang dikenal sebagai "konvolusi yang dapat dipisahkan berdasarkan kedalaman" diperkenalkan. Proses konvolusi dibagi menjadi dua tahap konvolusi kedalaman dan konvolusi spasial, berkat konvolusi yang dapat dipisahkan menurut kedalaman. Konvolusi diterapkan secara terpisah ke setiap saluran input pada tahap pertama. Setelah itu, hasilnya dikenakan konvolusi spasial [15].



Gambar 2 Arsitektur Xception

4. HASIL DAN PEMBAHASAN

Model yang sudah dibangun akan di evaluasi dengan beberapa metode evaluasi seperti grafik latih dan validasi, grafik confusion matrix, dan metriks evaluasi. Tujuan grafik latih dan validasi untuk melihat apakah model optimal dan tidak terjadi overfitting. [16]



Gambar 3 Grafik latih dan validasi InterceptionV3

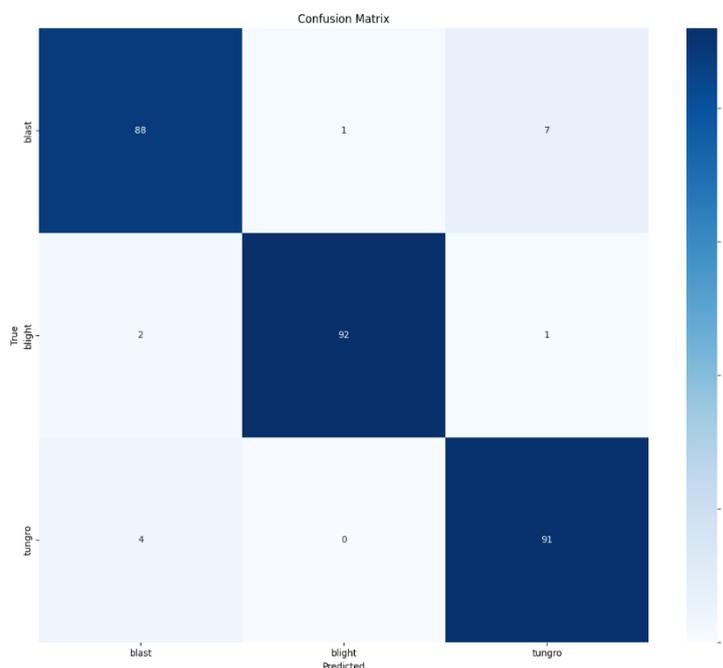
Gambar diatas merupakan grafik perbandingan antara loss latih dan validasi, serta akurasi latih dan validasi model InterceptionV3. Pada perbandingan loss bisa disimpulkan bahwa model dapat belajar dengan baik (garisnya seimbang dan stabil) dan akurasi model latih sebesar 95% dan akurasi validasi sebesar 95%.



Gambar 4 Grafik latih dan validasi Xception

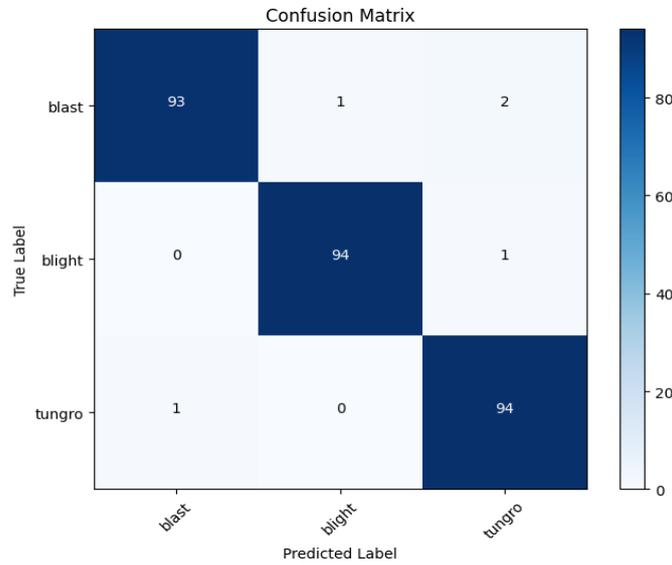
Gambar diatas merupakan grafik perbandingan antara loss latih dan validasi, serta akurasi latih dan validasi model Xception. Pada perbandingan loss bisa disimpulkan bahwa model dapat belajar dengan baik (garisnya seimbang, stabil, dan mendekati nilai 0) dan akurasi model Xception sangat baik mencapai 99.5% akurasi latih dan 98.2% akurasi validasi.

Metode confusion matrix atau biasa disebut error matrix merupakan alat ukur untuk melihat seberapa jauh model memprediksi benar atau salah.. Dalam confusion matrix terdapat 4 nilai jika target memiliki target hanya 2 kelas yaitu *True Positive*, *True Negative*, *False Positive*, dan *False Negative*. *True Positive* (TP) merupakan matriks untuk melihat berapa kali model memprediksi kelas positif dan aktualnya juga kelas positive. *True Negative* (TN) merupakan matriks untuk melihat berapa kali model memprediksi kelas negatif dan aktualnya juga kelas negatif. *False Positive* (FP) merupakan matriks untuk melihat berapa kali model memprediksi kelas positif dan aktualnya adalah kelas negatif. *False Negative* (FN) merupakan matriks untuk melihat berapa kali model memprediksi kelas negatif dan aktualnya adalah kelas positif [17].



Gambar 5 Grafik confusion matrix InceptionV3

Grafik diatas merupakan grafik confusion matrix InceptionV3. Sebanyak 93 kali model memprediksi blast dan aktualnya juga blast, 92 kali model memprediksi blight dan aktualnya juga blight, 91 kali model memprediksi tungro dan aktualnya adalah tungro, 1 kali model memprediksi blight dan aktualnya adalah blast, 7 kali model memprediksi tungro dan aktualnya adalah blast, 2 kali model memprediksi blast dan aktualnya adalah blight, 1 kali model memprediksi tungro dan aktualnya adalah blight, 4 kali model memprediksi blast dan aktualnya adalah tungro, dan 0 kali model memprediksi blight dan aktualnya tungro.



Gambar 6 Grafik confusion matrix Xception

Grafik diatas merupakan grafik confusion matrix Xception. Sebanyak 93 kali model memprediksi blast dan aktualnya juga blast, 94 kali model memprediksi blight dan aktualnya juga blight, 94 kali model memprediksi tungro dan aktualnya adalah tungro, 1 kali model memprediksi blight dan aktualnya adalah blast, 2 kali model memprediksi tungro dan aktualnya adalah blast, 0 kali model memprediksi blast dan aktualnya adalah blight, 1 kali model memprediksi tungro dan aktualnya adalah blight, 1 kali model memprediksi blast dan aktualnya adalah tungro, dan 0 kali model memprediksi blight dan aktualnya tungro.

Metode metriks evaluasi digunakan untuk melihat nilai presisi, recall, dan f1-score. Dimulai dengan mendeklarasikan variabel prediksi target dari ketiga model, dan memanggil fungsi classification report untuk menampilkan output matriks evaluasi. Presisi merupakan metode yang menghitung rasio antara jumlah prediksi positif dibagi dengan total prediksi positif [18], recall merupakan nilai sensitivitas yang mengukur sejauh mana model benar dalam memprediksi semua kasus positif [19], f1-score merupakan nilai rata – rata antara presisi dan recall [20].

```

Classification Report:
      precision    recall  f1-score   support

   blast         0.94     0.92     0.93         96
   blight         0.99     0.97     0.98         95
   tungro         0.92     0.96     0.94         95

 accuracy              0.95         286
 macro avg              0.95     0.95     0.95         286
 weighted avg           0.95     0.95     0.95         286
    
```

Gambar 7 Classification report InceptionV3

Gambar diatas menunjukkan bahwa model InceptionV3 sangat baik dalam memprediksi penyakit daun padi. Nilai presisi pada kelas blast sebesar 94%, kelas blight sebesar 99%, dan kelas tungro sebesar 92%. Nilai recall pada kelas blast sebesar 92%, kelas blight sebesar 97%, dan kelas tungro sebesar 96%. Nilai f1-score pada kelas blast sebesar 93%, kelas blight sebesar 98%, dan kelas tungro sebesar 94%.

5. KESIMPULAN

Dari akurasi kedua model Convnet sudah sangat baik dalam meprediksi penyakit daun padi, model Xception yang memiliki akurasi yang lebih tinggi dari pada InceptionV3. Xception menghasilkan akurasi validasi sebesar 98% dan InceptionV3 menghasilkan akurasi validasi sebesar 95%.

6. UCAPAN TERIMA KASIH

Penulis berterimakasih kepada pemilik dataset penyakit daun padi di kaggle dengan pemilik akun bernama Tedi Setiadi, dan juga penulis mengucapkan terimakasih kepada penulis jurnal lainnya sebagai bahan refrensi jurnal ini. Terakhir penulis ingin berterimakasih kepada para dosen dan teman-teman yang telah membantu penulis sampai di titik ini.

DAFTAR PUSAKA

- [1] Akhmad Gazali, Akhmad Rizali, Hairu Suparto, Jumar, Noorkomala Sari, Noorlaila, Hikma Ellya, Nukhak Nufita Sari, Riza Adrianoor Saputra, Muhammad Imam Nugraha, Ronny Mulyawan, Merry Awalia, Sitti Wahidaturahmah, "Pengabdian kepada Masyarakat: Pengenalan Penyakit Tanaman Padi dan Teknik Pengendaliannya di Desa Bentok Darat, Bati-bati, Kalimantan Selatan", Lumbung Inovasi
- [2] Arif Akbarul Huda, Bayu Setiaji, Fajar Rosyid Hidayat, "Implementasi Gray Level Cooccurrence Matrix (GlcM) Untuk Klasifikasi Penyakit Daun Padi", Jurnal Pseudocode.
- [3] Rizal Amegia Saputra, Sri Wasyianti, Adi Supriyatna, Dede Firmansyah Saefudin "Penerapan Algoritma Convolutional Neural Network Dan Arsitektur MobileNet Pada Aplikasi Deteksi Penyakit Daun Padi", JURNAL SWABUMI.
- [4] Ulfah Nur Oktaviana, Ricky Hendrawan, Alfian Dwi Khoirul Annas, Galih Wasis Wicaksono, "Klasifikasi Penyakit Padi berdasarkan Citra Daun Menggunakan Model Terlatih Resnet101", JURNAL RESTI.
- [5] Sarifah Agustiani, Yoseph Tajul Arifin, Agus Junaidi, Siti Khotimatul Wildah, Ali Mustopa, "Klasifikasi Penyakit Daun Padi menggunakan Random Forest dan Color Histogram", Jurnal Komputasi.
- [6] Retno Nugroho Whidhiasih, Inna Ekawati, "Identifikasi Jenis Penyakit Daun Padi Menggunakan Adaptif Neuro Fuzzy Inferene System (ANFIS) Berdasarkan Tekstur", Sinergi.
- [7] Jani Kusanti, Noor Abdul Haris, "Klasifikasi Penyakit Daun Padi Berdasarkan Hasil Ekstraksi Fitur GLCM Interval 4 Sudut", Jurnal Informatika: Jurnal Pengembangan IT (JPIT).
- [8] Endang Anggiratih, Sri Siswanti, Saly Kurnia Octaviani, Arumsari, "Klasifikasi Penyakit Tanaman Padi Menggunakan Model Deep Learning Efficientnet B3 Dengan Transfer Learning", Jurnal Ilmiah Sinus (JIS).
- [9] Mohtar Khoiruddin, Apri Junaidi, Wahyu Andi Saputra, "Klasifikasi Penyakit Daun Padi Menggunakan Convolutional Neural Network", Journal of Dinda.
- [10] Ery Murniyasih, Luluk Suryani, "Penerapan Metode Learning Vector Quantization Untuk Identifikasi Penyakit Padi Berdasarkan Bentuk Bercak Daun", Jurnal Elektro Luceat.
- [11] Lulu Nafisa, Nur Ikhsanto, Sulistiyanto, "Penerapan Metode Forward Chaining Untuk Mengidentifikasi Hama Dan Penyakit Tanaman Padi", Jurnal IRobot (*International Research on Big-Data and Computer Technology*).
- [12] Afshin Gholamy, Vladik Kreinovich, Olga Kosheleva, "Why 70/30 or 80/20 Between *Training and Testing Sets: A Pedagogical Explanation*" UTEP-CS-18-09.

- [13] Fuzhen Zhuang, Zhiyuan Qi, Keyu Duan, Dongbo Xi, Yongchun Zhu, Hengshu Zhu, Hui Xiong, Fellow, and Qing He, “A Comprehensive Survey on Transfer Learning”, arXiv.
- [14] Institut Teknologi Nasional
- [15] Natinai Jinsakul, Cheng-Fa Tsai, Chia-En Tsai, Pensee Wu, “Enhancement of Deep Learning in Image Classification Performance Using Xception with the Swish Activation Function for Colorectal Polyp Preliminary Screening”, E Mathematics.
- [16] Rahmadhani Yusuf, Arif Akbarul Huda, “Deteksi Emosi Wajah Menggunakan Metode Backpropagation”, JACIS : *Journal Automation Computer Information System*.
- [17] J. T. TOWNSEND, “Theoretical analysis of an alphabetic confusion matrix”, *Psychonomic Journals.Inc. Austill, Texas*
- [18] Cyril Goutte, Eric Gaussier, “A Probabilistic Interpretation of Precision, Recall and”, *ResearchGate*.
- [19] Reda Yacoub, Reda Yacoub, “Probabilistic Extension of Precision, Recall, and F1 Score for More Thorough Evaluation of Classification Models”, *Computational Linguistics*.
- [20] Amalia Lague, Alejandro Carrasco, Alejandro Martin, Ana de las Heras, “The impact of class imbalance performance metrics based on the binary confusion matrix,” *Pattern Recognition*.