

# Penerapan Deep Learning pada Pengolahan Data Citra dan Klasifikasi Udang Vaname Menggunakan Algoritma Convolutional Neural Network

Sarah Astiti<sup>1\*</sup>, Nopriadi<sup>2</sup>, Willi Novrian<sup>3</sup>, Yusran Panca Putra<sup>3</sup>

<sup>1\*</sup> Fakultas Informatika, Sistem informasi, Institut Teknologi Telkom Purwokerto, Purwokerto, Indonesia

<sup>2</sup> Manajemen Informasi dan Komunikasi, Sekolah Tinggi Multi Media "MMTC" Yogyakarta, Yogyakarta, Indonesia

<sup>3</sup> Fakultas Teknik, Sistem Informasi, Universitas Bengkulu, Bengkulu, Indonesia

Email: <sup>1\*</sup>sarah@ittelkom-pwt.ac.id, <sup>2</sup>nopriadi.jamil@gmail.com, <sup>3</sup>willinovrian@unib.ac.id, <sup>4</sup>Yusranpanca@unib.ac.id

Email Penulis Korespondensi: <sup>1</sup>sarah@ittelkom-pwt.ac.id

Submitted: 26/06/2024; Accepted: 30/06/2024; Published: 30/06/2024

**Abstrak**—Pengolahan citra udang berbasis deep learning telah menjadi bidang penelitian yang berkembang pesat dalam beberapa tahun terakhir. Teknologi ini bertujuan untuk meningkatkan efisiensi dan akurasi dalam berbagai aplikasi terkait industri perikanan dan akuakultur, seperti pemantauan kesehatan udang, deteksi penyakit, pengklasifikasian spesies, serta penilaian kualitas dan kuantitas hasil panen. Berdasarkan pengamatan sampai hari ini penjual ikan dan pembeli dipasar kesulitan untuk membedakan udang vaname yang di budidayakan di kolam terpal dan kolam tanah. Penelitian ini bertujuan untuk menerapkan teknik deep learning untuk mengetahui klasifikasi hasil budidaya udang *Litopenaeus vannamei* pada kolam tanah dan kolam terpal. Untuk memudahkan penelitian ini penulis menggunakan metode klasifikasi dengan menerapkan dua arsitektur Convolutional Neural Network (CNN) yaitu Visual Geometry Group-16 (VGG-16) dan Residual Network-50 (ResNet-50). Untuk dataset yang digunakan dalam penelitian ini yaitu 2.080 gambar per kelas udang vanamei dari dua macam tambak udang. Adapun hasil dari penelitian ini yaitu learning rate sebesar 0,001 dan 0,0001 pada Stochastic Gradient Descent (SGD) dan Adaptive Moment Estimation (ADAM) optimizer untuk mengevaluasi efektivitasnya dalam pelatihan model. Model VGG-16 dan ResNet-50 dilatih dengan parameter kecepatan pembelajaran 0,0001, memanfaatkan fleksibilitas dan kontrol wajar yang disediakan oleh pengoptimal SGD. Nilai kecepatan pembelajaran yang lebih rendah dipilih untuk mencegah overfitting dan meningkatkan stabilitas pelatihan. Evaluasi model menunjukkan hasil yang menjanjikan, dengan kedua arsitektur mencapai akurasi 100% dalam mengklasifikasikan udang vanamei dari kolam tanah dan kolam terpal. Kesimpulan penelitian ini yaitu menonjolkan keunggulan penggunaan SGD dengan kecepatan pembelajaran 0,0001 versus 0,001 pada kedua arsitektur, kemudian dampak signifikan pemilihan pengoptimal dan kecepatan pembelajaran terhadap efektivitas pelatihan model dalam tugas klasifikasi gambar.

**Kata Kunci:** Deep Learning; Convolutional Neural Network (CNN); Udang; Tambak

**Abstract**—Deep learning-based shrimp image processing has become a rapidly growing research field in recent years. This technology aims to increase efficiency and accuracy in various applications related to the fishing and aquaculture industry, such as monitoring shrimp health, disease detection, species classification, and assessing the quality and quantity of harvested crops. Based on observations to date, fish sellers and buyers in the market have difficulty distinguishing vaname shrimp cultivated in tarpaulin ponds and earthen ponds. This research aims to apply deep learning techniques to determine the classification of *Litopenaeus vannamei* shrimp cultivation results in earthen ponds and tarpaulin ponds. To facilitate this research, the author uses a classification method by applying two Convolutional Neural Network (CNN) architectures, namely Visual Geometry Group-16 (VGG-16) and Residual Network-50 (ResNet-50). The dataset used in this research is 2,080 images per class of vanamei shrimp from two types of shrimp ponds. The results of this research are learning rates of 0.001 and 0.0001 on the Stochastic Gradient Descent (SGD) and Adaptive Moment Estimation (ADAM) optimizer to evaluate their effectiveness in model training. The VGG-16 and ResNet-50 models were trained with a learning rate parameter of 0.0001, taking advantage of the flexibility and reasonable control provided by the SGD optimizer. Lower learning rate values were chosen to prevent overfitting and increase training stability. Model evaluation showed promising results, with both architectures achieving 100% accuracy in classifying vanamei shrimp from ground and tarpaulin ponds. The conclusion of this research is to highlight the superiority of using SGD with a learning rate of 0.0001 versus 0.001 on both architectures, then the significant impact of optimizer selection and learning rate on the effectiveness of model training in image classification tasks.

**Keywords:** Deep Learning; Convolutional Neural Network (CNN); Shrimp; Pond

## 1. PENDAHULUAN

Industri perikanan dan akuakultur memainkan peran penting dalam menyediakan sumber daya pangan bagi populasi di seluruh dunia [1]. Salah satu sektor di perikanan hari ini yang sedang di kembangkan oleh pemerintah adalah udang vaname [2], [3]. Dalam sektor perikanan, pengembangan udang vaname dinilai memiliki keunggulan yang signifikan dibandingkan dengan jenis udang lainnya [4]. Udang vaname (*Litopenaeus vannamei*), juga disebut udang putih atau udang kaki putih [5], adalah salah satu spesies udang yang paling banyak dibudidayakan di seluruh dunia [6]. Karena nilai ekonominya yang tinggi [7], udang ini memiliki permintaan yang terus meningkat di pasar global, [8]. Industri akuakultur udang vaname telah mengalami pertumbuhan yang signifikan seiring dengan peningkatan konsumsi makanan laut yang sehat dan berkelanjutan [9]. Udang vaname adalah pilihan yang bagus untuk budidaya udang karena pertumbuhannya yang cepat [10], tahan terhadap berbagai lingkungan, dan tahan terhadap penyakit [11].

Dalam pengolahan udang vaname terdapat 2 jenis kolam untuk budidaya yaitu kolam tanah dan kolam terpal. Kualitas air kolam tanah biasanya hanya diproses pada tahap awal, ketika warna air menjadi hijau tua, dan tidak diperiksa untuk parameter seperti oksigen terlarut, amonia, alkalinitas, pH, dan salinitas [12]. Pada kolam plastik atau terpal, pengolahan kualitas air biasanya dilakukan dengan kontrol yang ketat untuk parameter seperti pH air,

oksigen terlarut, suhu, dan alkalinitas [13]. Berdasarkan hal tersebut sampai hari ini penjual ikan dan pembeli dipasar kesulitan untuk membedakan udang vaname yang di budidayakan di kolam terpal dan kolam tanah. Untuk menjawab dan memberikan Solusi terhadap masalah tersebut penulis mencoba melakukan klasifikasi udang vannamei dengan menggunakan Teknik deep learning. Deep learning adalah cabang dari pembelajaran mesin yang berfokus pada penggunaan jaringan saraf tiruan dengan lapisan yang lebih dalam untuk memodelkan dan mempelajari representasi data yang kompleks [14]. Pada dasarnya, deep learning meniru cara otak manusia memproses data, memungkinkan komputer untuk mengenali pola dan fitur yang sulit dideteksi oleh algoritma tradisional [15]. Kemudian untuk memudahkan penelitian ini penulis menggunakan metode klasifikasi dengan menerapkan dua arsitektur Convolutional Neural Network (CNN) yaitu Visual Geometry Group-16 (VGG-16) dan Residual Network-50 (ResNet-50) .

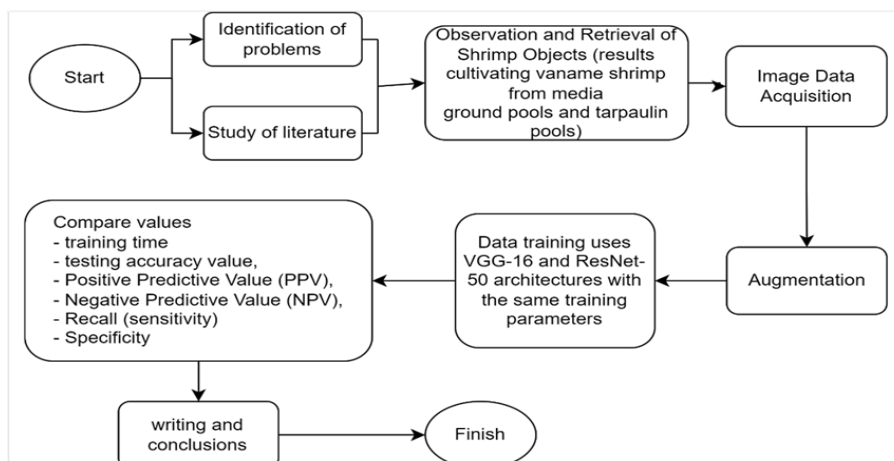
CNN sangat cocok untuk digunakan dalam klasifikasi udang karena kemampuannya untuk mengenali dan mengklasifikasikan pola kompleks dalam gambar [16]. Visual Geometry Group-16 (VGG-16) dan Residual Network-50 (ResNet-50) adalah dua arsitektur CNN yang sangat populer dan efektif untuk berbagai tugas klasifikasi gambar [17]. ResNet-50 menawarkan konsep pelatihan residual yang memungkinkan pelatihan jaringan yang lebih dalam tanpa mengalami masalah degradasi [18], sementara VGG-16 terkenal karena arsitekturnya yang sederhana dan memungkinkan identifikasi fitur gambar yang sangat akurat, Ini meningkatkan kinerja dan akurasi model [17].

Beberapa penelitian terdahulu menggunakan CNN yaitu pada [14], pada penelitian ini menggunakan CNN untuk mengekstrak fitur penting dari gambar dan menggunakan strategi klasifikasi gabungan, yang memungkinkan untuk memanfaatkan keunggulan masing-masing pengklasifikasi untuk meningkatkan kinerja udang vannamei secara keseluruhan. Kemudian pada penelitian [19], CNN memiliki kemampuan untuk mengekstrak fitur penting dari gambar secara otomatis tanpa membutuhkan ekstraksi fitur manual, yang merupakan salah satu keunggulan utamanya. Pada penelitian [20], CNN memulai dengan lapisan konvolusi, di mana filter konvolusi bergerak melintasi gambar masukan untuk menghasilkan peta fitur yang menonjolkan pola-pola penting. Lapisan konvolusi ini diikuti oleh lapisan pengumpulan, yang menyimpan data relevan sambil mengurangi dimensi spasial dari peta fitur yang dihasilkan. Setelah itu, peta fitur yang diubah menjadi vektor digunakan sebagai input untuk lapisan yang terhubung sepenuhnya, di mana model dapat melakukan tugas seperti klasifikasi [21]. Fungsi aktivasi di setiap lapisan, seperti ReLU, sangat penting karena memperkenalkan non-linearitas ke dalam model, yang memungkinkan CNN untuk mempelajari pola kompleks dari data gambar [22]. Dengan fitur-fitur tersebut, CNN dapat dengan akurat mengenali objek dalam gambar dan melakukan tugas yang lebih kompleks seperti deteksi objek dan segmentasi gambar. Kemudian Arsitektur VGG-16 dan ResNet-50 berhasil dalam berbagai aplikasi pengenalan gambar, memberikan keyakinan bahwa keduanya dapat menyelesaikan masalah klasifikasi yang rumit yang ditangani dalam penelitian ini [23]. Dalam hal kedalaman lapisan, VGG-16 dibangun lebih cepat daripada ResNet-50, yang dibangun dengan kedalaman 50 lapisan, sehingga waktu pelatihan akan terpengaruh oleh perbedaan ini [24]. Pemilihan hyperparameter sangat penting dalam proses pelatihan CNN. Dua komponen penting dalam proses pelatihan model dalam pembelajaran mendalam adalah pengoptimal dan kecepatan pembelajaran [25]. Oleh karena itu, penggunaan CNN dalam penelitian ini tidak hanya menawarkan solusi yang efektif untuk masalah klasifikasi gambar, tetapi juga memberikan kepercayaan yang kuat pada keakuratan dan keandalan hasil penelitian.

## 2. METODOLOGI PENELITIAN

### 2.1 Tahapan penelitian

Pada penelitian ini untuk memastikan bahwa penelitian ini berhasil dan memenuhi harapan, penulis melakukan beberapa langkah, seperti yang ditunjukkan pada gambar 1 di bawah ini:



**Gambar 1.** Tahapan Penelitian




undang menghadap ke kiri pada masing-masing kelas. Berikut adalah data hasil augmentasi gambar seperti tabel 1 dibawah ini:

**Tabel 1.** Hasil Data Augmentasi

Image	Soil Pond	Tarpaulin Pond
Original and Flip	520	520
5 Degrees	520	520
10 Degrees	520	520
15 Degrees	520	520
Amount	2.080 Image	2.080 Image

### 2.5 Convolutional Neural Network (CNN)

Berikut ini adalah proses struktur lapisan dari Algoritma CNN. Gambar 5 dibawah ini menunjukkan struktur dasar CNN. Lapisan konvolusi, pooling, dan terhubung penuh adalah bagian dari proses klasifikasi gambar masukan.



**Gambar 5.** Struktur Algoritma CNN

### 2.6 Grup Geometri Visual (VGG)-16 dan Jaringan Residual (ResNet)-50

Untuk penelitian ini, VGG-16 dan ResNet-50 digunakan Pemrosesan gambar, teknik pembelajaran transfer dengan menggunakan bobot yang telah dilatih sebelumnya, dan penyetelan parameter model seperti pengoptimal dan kecepatan pembelajaran adalah beberapa langkah pelatihan model. Hal ini akan dibahas lebih lanjut di bagian Hasil.

### 2.7 Evaluasi Matriks

Dalam sistem klasifikasi CNN, matriks evaluasi sangat penting karena memberikan metrik objektif untuk mengukur kinerja model dan mengacu pada kemampuan model untuk menjalankan sistem dengan baik. Persamaan 1, 2, 3, 4 dan 5 akan digunakan untuk mengevaluasi beberapa kinerja dalam penelitian ini. TP (Kasus Positif Asli) menunjukkan kasus yang diidentifikasi dengan benar sebagai positif, FP (Kasus Negatif Salah) menunjukkan kasus yang diidentifikasi dengan salah sebagai negatif, dan FN (Kasus Negatif Salah) menunjukkan kasus yang diidentifikasi dengan salah sebagai negatif.

## 3. HASIL DAN PEMBAHASAN

### 3.1 Pelatihan Model Klasifikasi VGG-16 dan ResNet-50

Untuk melatih model klasifikasi, pembelajaran transfer Pytorch digunakan di Google Colab Pro. Parameter pelatihan yang digunakan adalah Epoch 100, Batch Size 2, Loss Function Cross-Entropy, Momentum 0.9, Optimizer Adam, dan SGD, yang dipadukan dengan tingkat pembelajaran masing-masing 0.001 dan 0.0001. Model menggunakan pembelajaran transfer pada tahap pelatihan. Tabel 2 menunjukkan waktu pelatihan model VGG-16 dan ResNet-50 dengan pengoptimal Adam dan SGD.

**Tabel 2.** Waktu Pelatihan Model VGG-16 dan ResNet-50 dengan pengoptimal Adam dan SGD.


Optimizer	Learning Rate (lr)	VGG-16	ResNet-50
Adam	0.001	256 m 47 s	202 m 13 s
	0.0001	248 m 39 s	209 m 35 s
SGD	0.001	165 m 58 s	177 m 16 s
	0.0001	186 m 27 s	169 m 44 s

Pada percobaan pelatihan model VGG-16, waktu pelatihan menjadi 256 menit 47 detik dengan kecepatan pembelajaran ADAM 0,001. Ketika kecepatan pembelajaran ADAM diturunkan menjadi 0,0001, waktu pelatihan berkurang sedikit menjadi 248 menit 39 detik. Pelatihan yang lebih efisien dilakukan dengan SGD dengan rate (lr) 0,001. Waktu pelatihan hanya 165 menit 58 detik, tetapi ketika rate (lr) SGD diturunkan menjadi 0,0001, waktu pelatihan menjadi 186 menit 27 detik. Untuk pelatihan, ADAM dengan kecepatan pembelajaran 0,001 membutuhkan waktu 202 menit 13 detik pada model ResNet-50, sedangkan ADAM dengan kecepatan pembelajaran 0,0001 membutuhkan waktu serupa, yaitu 209 menit 35 detik. Untuk SGD, rate learning (lr) 0,001 membutuhkan waktu 177

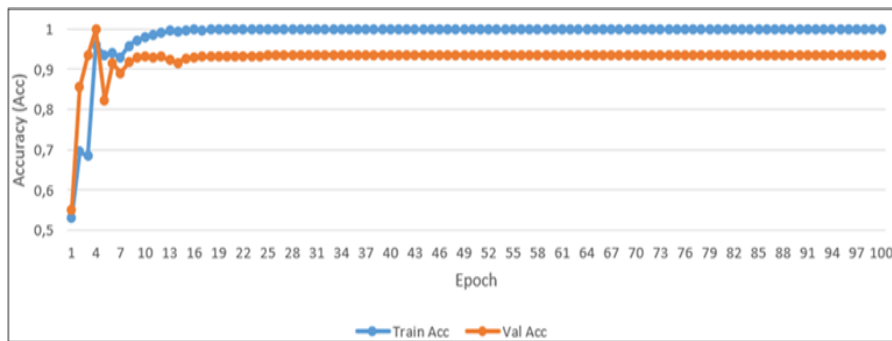
menit 16 detik, sedangkan rate learning (lr) 0,0001 membutuhkan waktu 169 menit 44 detik. Dapat disimpulkan bawah penurunan tingkat pembelajaran ADAM untuk VGG-16 tidak meningkatkan waktu pembelajaran secara signifikan, sedangkan SGD menambah waktu pembelajaran. Penyesuaian kecepatan pembelajaran untuk ResNet-50 tidak berdampak signifikan pada waktu pelatihan. Berikut ini adalah gambar 6, 7, 8, 9, 10, 11, 12 dan 13 menunjukkan grafik pelatihan model VGG-16 dan ResNet-50 dengan pengoptimal Adam dan SGD.




**Gambar 6.** Validasi Arsitektur VGG-16 dengan Akurasi Kurva dan Pengoptimal Adam dan Kecepatan Pembelajaran 0,001



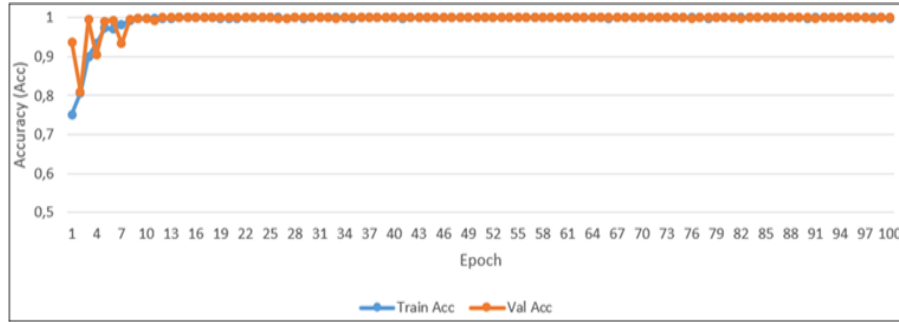
**Gambar 7.** Validasi Arsitektur VGG-16 dengan Akurasi Kurva dan Pengoptimal Adam dan Kecepatan Pembelajaran 0,0001



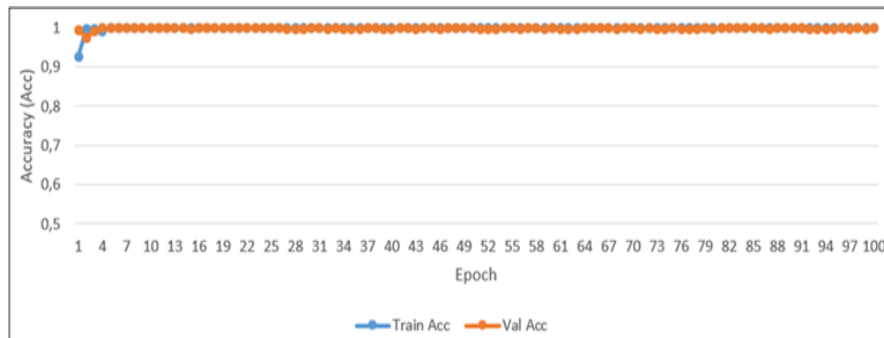
**Gambar 8.** Arsitektur VGG-16 Akurasi Kurva dan Validasi Validasi dengan Pengoptimal SGD dan Kecepatan Pembelajaran 0,001




**Gambar 9.** Akurasi Validasi Arsitektur VGG-16 dan Akurasi Kereta Kurva dengan Pengoptimal SGD dan Kecepatan Pembelajaran 0,0001



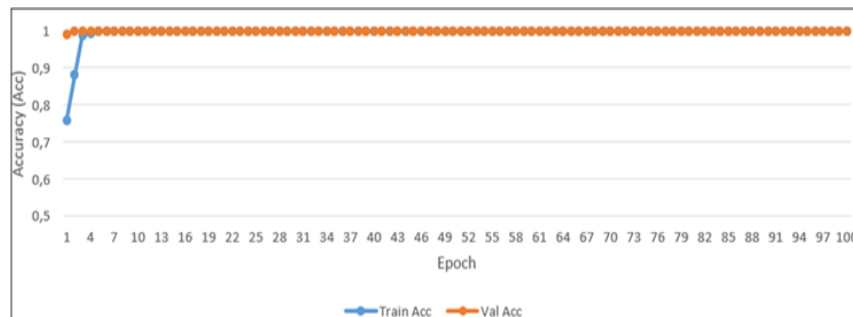
**Gambar 10.** Pengoptimal Adam dan Kecepatan Pembelajaran 0,001, Kurva melatih akurasi dan akurasi validasi Arsitektur ResNet-50.



**Gambar 11.** Akurasi Validasi Arsitektur ResNet-50 dan Akurasi Kereta Kurva dengan Pengoptimal Adam dan Kecepatan Pembelajaran 0,0001



**Gambar 12.** Akurasi dan Validasi Arsitektur Kereta Kurva ResNet-50 dengan Pengoptimal Adam dan Kecepatan Pembelajaran 0,0001



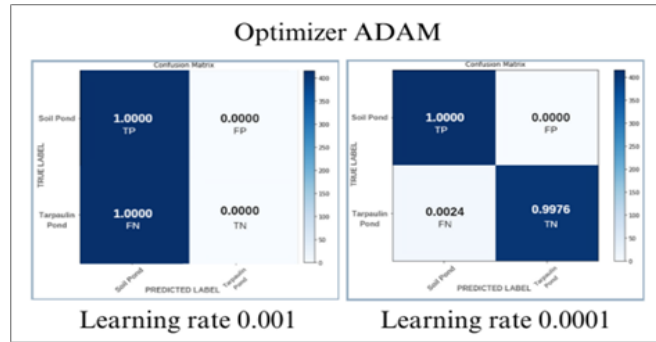
**Gambar 13.** Akurasi Validasi Arsitektur ResNet-50 dan Akurasi Kereta Kurva dengan Pengoptimal SGD dan Kecepatan Pembelajaran 0,0001

Dalam gambar 6–13, garis biru menunjukkan nilai akurasi kereta dan garis oranye menunjukkan akurasi validasi. Hasil pelatihan VGG-16 dengan Adam optimizer dan rate learning (lr) 0.001 dan 0.0001 ditunjukkan pada Gambar 6 dan 7. Gambar 6 menunjukkan bentuk grafik yang sangat buruk dengan garis 0,5, sedangkan Gambar 7 menunjukkan peningkatan kualitas grafik dengan rate learning 0.0001. Nilai train acc dan val acc sangat selaras pada Gambar 8, ketika menggunakan VGG-16 dengan pengoptimal SGD dan lr 0,001. Namun, pada Gambar 9, garis train acc dan val acc disandingkan pada tahap awal pelatihan. Grafik train acc dan val acc cenderung menyatu secara dekat pada Gambar 10 hingga 13, yang menggunakan arsitektur ResNet-50 dengan berbagai kombinasi pengoptimal dan kecepatan pembelajaran. Akibatnya, dapat disimpulkan bahwa data akurasi validasi sangat mirip dengan data akurasi pelatihan. Ini menunjukkan bahwa model dapat digeneralisasi selama validasi, menunjukkan proses pelatihan yang

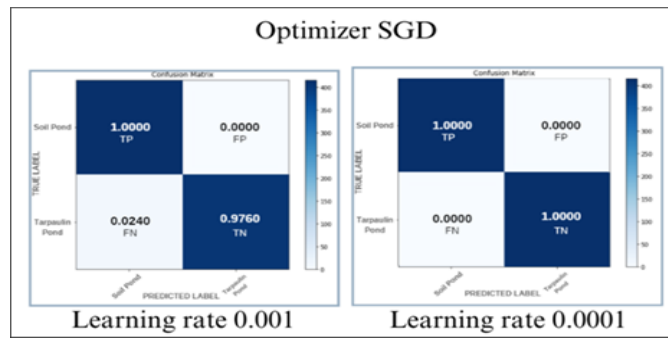
sangat sukses.

### 3.2 Matriks Pengujian dan Evaluasi

Untuk memastikan bahwa model cukup baik untuk menguji data baru, diuji dengan data uji yang belum pernah digunakan sebelumnya setelah memperoleh nilai akurasi dan kehilangan pada saat pelatihan model. Berikut ini adalah Gambar 14 hingga 17 menunjukkan nilai matriks konfusi menggunakan rate pembelajaran 0,0001 dan 0.001.



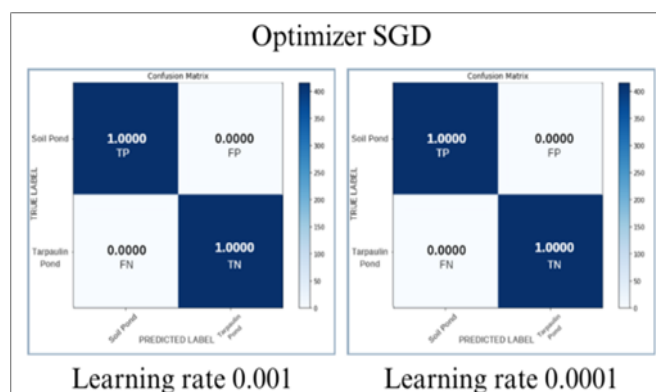
Gambar 14. Hasil uji Matrix Confusion VGG-16 dengan Adam Optimizer



Gambar 15. Hasil uji Matrix Confusion VGG-16 dengan Optimizer SGD



Gambar 16. Hasil uji Confusion Matrix ResNet-50 menggunakan Optimizer Adam (a) lr 0,001; (b) lr 0,0001.



Gambar 17. Hasil uji matrix confusion dengan Optimizer SGD di ResNet-50 (a) lr 0,001; (b) lr 0,0001. Berikut ini adalah tabel 3 dari evaluasi matrik seperti yang terlihat pada tabel 3 dibawah ini:

Tabel 3. Evaluasi Matrik

Measures	VGG-16 ResNet-50		VGG-16 ResNet-50		VGG-16 ResNet-50		VGG-16 ResNet-50	
	lr = 0.001		lr = 0.001		lr = 0.001		lr = 0.001	
Accuracy	0.5	0,9988	0,9980	1	0,9880	1	1	1
PPV	1	1	1	1	1	1	1	1
NPV	0	0,9976	0,9970	1	0,9760	1	1	1
Sensitivity	1	0,9976	0,9970	1	0,9760	1	1	1
Specificity	-	1	1	1	1	1	1	1

Berdasarkan hasil evaluasi metrik yang terdapat pada tabel 13 berdasarkan gambar 14 sampai dengan gambar 17, penelitian ini memperoleh skor tertinggi saat menggunakan pengoptimal SGD dan rate pembelajaran 0,0001. Dengan demikian dapat disimpulkan bahwa hasil produksi udang akan berbeda tergantung pada jenis air yang digunakan.

#### 4. KESIMPULAN

Berdasarkan Analisa yang dilakukan menggunakan algoritma CNN tentang budidaya udang vaname dari kolam tanah dan terpal dengan penggunaan dua arsitektur Convolutional Neural Network (CNN), VGG-16 dan ResNet-50, bersama dengan pengoptimal Adam dan SGD, serta dua variasi kecepatan pembelajaran (0,001 dan 0,0001), didapatkan hasil penelitian yaitu penggunaan SGD optimizer dengan learning rate 0,0001 menghasilkan tingkat akurasi sempurna 100% pada kedua arsitektur VGG-16 dan ResNet-50. Penelitian ini dapat memberikan dasar untuk pengembangan teknologi pengenalan gambar yang lebih baik yang dapat meningkatkan produktivitas dan keberlanjutan dalam budidaya udang. Hasil evaluasi model yang menggunakan arsitektur CNN, variasi pengoptimal, dan kecepatan pembelajaran menunjukkan hasil yang menjanjikan dan sangat akurat. Rekomendasi untuk pengembangan aplikasi praktis, seperti website atau aplikasi telepon, akan membantu temuan penelitian menjadi lebih mudah digunakan oleh masyarakat umum dan meningkatkan kegunaannya dalam penelitian yang akan datang.

#### REFERENCES

- [1] A. Putra, M. Fauzi, M. G. E. Kristiani, and F. Hapsari, "HASIL PRODUKSI DAN ANALISIS USAHA PEMBESARAN UDANG VANAME (*Litopenaeus vannamei*) DI PT. SUMBER ALAM SEGARA, KECAMATAN BELINYU, KABUPATEN BANGKA," *Fish. Wallacea J.*, vol. 4, no. 1, pp. 10–18, 2023, doi: 10.55113/fwj.v4i1.1691.
- [2] A. Fikriyah, D. Febrianti, M. C. Undu, Y. Nurliani, and A. Khumaidi, "PERKEMBANGAN DAN PERTUMBUHAN LARVA UDANG VANAME (*Litopenaeus vannamei*) DI DUA PANTI PEMBENIHAN UDANG DI SITUBONDO: STUDI KASUS," *J. Perikan. Unram*, vol. 13, no. 1, pp. 123–135, 2023, doi: 10.29303/jp.v13i1.446.
- [3] M. H. R. Alauddin and A. Putra, "Kajian Daya Dukung Lingkungan Dalam Budidaya Udang Vaname," *J. Kelaut. dan Perikan. Terap.*, vol. 1, p. 103, 2023, doi: 10.15578/jkpt.v1i0.12214.
- [4] H. Ariadi and T. Mujtahidah, "ANALISIS PERMODELAN DINAMIS KELIMPAHAN BAKTERI *Vibrio* sp. PADA BUDIDAYA UDANG VANAME (*Litopenaeus vannamei*)," *J. Ris. Akuakultur*, vol. 16, no. 4, p. 255, 2022, doi: 10.15578/jra.16.4.2021.255-262.
- [5] A. Wafi, H. Ariadi, M. Fadjar, M. Mahmudi, and S. Supriatna, "Model Simulasi Panen Parsial Pada Pengelolaan Budidaya Intensif Udang Vannamei (*Litopenaeus vannamei*)," *Samakia J. Ilmu Perikan.*, vol. 11, no. 2, pp. 118–126, 2020, doi: 10.35316/jsapi.v11i2.928.
- [6] H. Ariadi, B. D. Madusari, and D. Mardhiyana, "ANALISIS PENGARUH DAYA DUKUNG LINGKUNGAN BUDIDAYA TERHADAP LAJU PERTUMBUHAN UDANG VANAME (*L. vannamei*)," *EnviroScienteeae*, vol. 18, no. 1, p. 29, 2022, doi: 10.20527/es.v18i1.12976.
- [7] M. Fauzi, M. G. E. Kristiani, F. Hapsari, and A. Putra, "Hasil Produksi dan Analisis Usaha Pembesaran Udang Vanname (*Litopenaeus vannamei*) di PT. Sumber Alam Segara Kecamatan Belinyu Kabupaten Bangka," *J. Ilmu Perikan.*, vol. 4, no. 1, pp. 10–18, 2023, doi: 10.55113/fwj.v4i1.1691.
- [8] E. A. Prama, M. Akbarurrasyid, W. P. Astiyani, V. T. Prajayanti, and M. Anjarsari, "PENGARUH PEMBERIAN MERK PAKAN YANG BERBEDA PADA BUDIDAYA UDANG VANAME (*litopenaeus vannamei*) DI PT. BIRU LAUT NUSANTARA, KABUPATEN PANGANDARAN, PROVINSI JAWA BARAT," *Marlin*, vol. 4, no. 1, p. 11, 2023, doi: 10.15578/marlin.v4i1.2023.11-21.
- [9] S. Anwar and A. Abdurrohman, "Pemanfaatan Teknologi Internet of Things Untuk Monitoring Tambak Udang Vaname Berbasis Smartphone Android Menggunakan Nodemcu Wemos D1 Mini," *Infotronik J. Teknol. Inf. dan Elektron.*, vol. 5, no. 2, p. 77, 2020, doi: 10.32897/infotronik.2020.5.2.484.
- [10] D. Aulia *et al.*, "ANALISIS KELAYAKAN USAHA BUDIDAYA UDANG VANAME (*Litopenaeus vannamei*) SISTEM BUSMETIK DI SERANG, BANTEN Business Feasibility Analysis of Vaname Shrimp (*Litopenaeus vannamei*) Cultivation with BUSMETIK System in Serang, Banten," *J. Agroristek* |, vol. 6, no. 1, p. 15, 2023, [Online]. Available: <https://journal.unigha.ac.id/index.php/JAR/indexDOI:https://doi.org/10.47647/jar>.
- [11] D. P. Arini, T. Osawa, and I. W. Arthana, "Dampak Perubahan Iklim Terhadap Budidaya Udang Vaname Di Pesisir Kabupaten Banyuwangi, Jawa Timur," *J. Perikan. Unram*, vol. 13, no. 1, pp. 307–319, 2023, doi: 10.29303/jp.v13i1.475.
- [12] M. Rahim, "Budidaya Udang Vaname (*Litopenaeus Vannamei*) Super Intensif Dengan Padat Tebar Berbeda Menggunakan Sistem Zero Water Discharge," *JFMR-Journal Fish. Mar. Res.*, vol. 5, no. 3, 2021, doi: 10.21776/ub.jfmr.2021.005.03.12.



- [13] M. Yulisti, I. Mulyawan, R. H. Deswati, and E. S. Luhur, "Dampak Sertifikasi Cbib Terhadap Efisiensi Teknis Pada Budidaya Tambak Udang Vannamei," *J. Sos. Ekon. Kelaut. dan Perikan.*, vol. 16, no. 1, p. 89, 2021, doi: 10.15578/jsekp.v16i1.9775.
- [14] REZA FAISAL, RIDWAN A. KAMBAU, and M. HASRUL H, "Perhitungan Otomatis Ukuran Udang Vaname Menerapkan Object Detection Dengan Convolutional Neural Network Menggunakan Metode Bidirectional Feature Pyramid Network," *J. INSTEK (Informatika Sains dan Teknol.*, vol. 9, no. 1, pp. 141–147, 2024, doi: 10.24252/instek.v9i1.46420.
- [15] T. Hendrawati *et al.*, "Penerapan Deep Learning Dalam Pengenalan Endek Bali Menggunakan Convolutional Neural Network," *J. Media Inform. Budidarma.*, vol. 7, pp. 2118–2127, 2023, doi: 10.30865/mib.v7i4.6721.
- [16] M. T. A. Syech Ahmad and B. Sugiarto, "Implementasi Convolutional Neural Network (CNN) untuk Klasifikasi Ikan Cupang Berbasis Mobile," *Digit. Transform. Technol.*, vol. 3, no. 2, pp. 712–723, 2023, doi: 10.47709/digitech.v3i2.3245.
- [17] I. Muslem R and T. Johan, "Klasifikasi citra ikan menggunakan algoritma convolutional neural network dengan arsitektur VGG-16," *Kaji. Ilm. Inform. dan Komput.*, vol. 4, no. 2, pp. 978–983, 2023, doi: 10.30865/klik.v4i2.1209.
- [18] Abdul Jalil Rozaqi, M. R. Arief, and A. Sunyoto, "Implementation of Transfer Learning in the Convolutional Neural Network Algorithm for Identification of Potato Leaf Disease," *Procedia Eng. Life Sci.*, vol. 1, no. 1, 2021, doi: 10.21070/pels.v1i1.820.
- [19] F. Charli, H. Syaputra, M. Akbar, S. Sauda, and F. Panjaitan, "Implementasi Metode Faster Region Convolutional Neural Network (Faster R-CNN) Untuk Pengenalan Jenis Burung Lovebird," *J. Inf. Technol. Ampera.*, vol. 1, no. 3, pp. 185–197, 2020, doi: 10.51519/journalita.volume1.issuue3.year2020.page185-197.
- [20] A. Mulyanto, E. Susanti, F. Rossi, W. Wajiran, and R. I. Borman, "Penerapan Convolutional Neural Network (CNN) pada Pengenalan Aksara Lampung Berbasis Optical Character Recognition (OCR)," *J. Edukasi dan Penelit. Inform.*, vol. 7, no. 1, p. 52, 2021, doi: 10.26418/jp.v7i1.44133.
- [21] H. Qonita, P. W. Laksono, and Y. Priyandari, "Implementasi Deep Learning Menggunakan Metode Convolutional Neural Network untuk Mendeteksi Kehalalan pada Kosmetik," *Performa Media Ilm. Tek. Ind.*, vol. 22, no. 1, p. 67, 2023, doi: 10.20961/performa.22.1.76650.
- [22] F. Paraijun, R. N. Aziza, and D. Kuswardani, "Implementasi Algoritma Convolutional Neural Network Dalam Mengklasifikasi Kesegaran Buah Berdasarkan Citra Buah," *Kilat.*, vol. 11, no. 1, pp. 1–9, 2022, doi: 10.33322/kilat.v10i2.1458.
- [23] D. M. Wonohadidjojo, "Perbandingan Convolutional Neural Network pada Transfer Learning Method untuk Mengklasifikasikan Sel Darah Putih," *Ultim. J. Tek. Inform.*, vol. 13, no. 1, pp. 51–57, 2021, doi: 10.31937/ti.v13i1.2040.
- [24] Bella Dwi Mardiana, Wahyu Budi Utomo, Ulfah Nur Oktaviana, Galih Wasis Wicaksono, and Agus Eko Minarno, "Herbal Leaves Classification Based on Leaf Image Using CNN Architecture Model VGG16," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 7, no. 1, pp. 20–26, 2023, doi: 10.29207/resti.v7i1.4550.
- [25] F. Ramadhani, A. Satria, and S. Salamah, "Implementasi Algoritma Convolutional Neural Network dalam Mengidentifikasi Dini Penyakit pada Mata Katarak," *sudo J. Tek. Inform.*, vol. 2, no. 4, pp. 167–175, 2023, doi: 10.56211/sudo.v2i4.408.