

Identifikasi Citra untuk Membedakan Uang Asli dan Palsu Menggunakan Algoritma Convolutional Neural Network (CNN)

Prihastuti Harsani^{1*}, Maulana Muhammad², Teguh Puja Negara³ 

¹ Program Studi Ilmu Komputer, Universitas Pakuan, Bogor, Indonesia

² Divisi Programming, PT. beIT Inovasi Tiwikrama, Bogor, Indonesia

³ Departemen Fisika, IPB University, Bogor, Indonesia

ARTICLE INFO

Article history:

Received March 17, 2024

Accepted July 13, 2024

Available online July 25, 2024

Kata Kunci:

Convolutional Neural Network, Keaslian Uang, Identifikasi Citra, Uang Palsu

Keywords:

Convolutional Neural Network, Keaslian Uang, Identifikasi Citra, Uang Palsu



This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

Copyright © 2024 by Author. Published by Universitas Pendidikan Ganesha.

ABSTRAK

Peredaran uang palsu di Indonesia terus meningkat seiring dengan kemajuan teknologi dan masih minimnya keaslian uang dengan menggunakan komputer. Sehingga penelitian ini dilakukan bertujuan untuk membangun sistem pendeteksi keaslian uang dengan menggunakan metode *Convolutional Neural Network* (CNN). Jenis penelitian yang digunakan adalah penelitian Eksperimen kuantitatif berbasis pada *Hardware Programming*. Instrumen yang digunakan untuk membangun algoritma metode CNN dan pengembangan Web adalah perangkat lunak *Visual Studio Code* dan bahasa pemrograman *Python*. Metode CNN digunakan untuk mengklasifikasikan uang asli dan palsu berdasarkan gambar. Eksperimen dilakukan dengan menggunakan dataset uang kertas yang mempunyai 2 kelas yaitu uang asli sebanyak 1.015 dan uang palsu sebanyak 1.126. Proses penentuan asli dan palsu dilakukan beberapa proses, yaitu: akuisisi data, seleksi data, prapemrosesan data, transformasi, dan pemodelan. Sebelum melakukan proses pembuatan model, data perlu diubah ukurannya menjadi 224x224 piksel untuk model GoogleNet, 256x256 untuk model AlexNet, dan 200x200 untuk model yang dimodifikasi. Model yang dimodifikasi dirancang untuk membandingkan hasil dari GoogleNet dan AlexNet, dengan mengurangi lapisan dan menyesuaikan parameter dengan data yang ada. Analisis data dilakukan dengan cara membandingkan hasil perhitungan nilai *training loss*, *validation loss*, akurasi pelatihan, dan akurasi validasi pada variasi nilai *epoch*, *pixel*, dan *learning rate* untuk ketiga model. Hasil terbaik diperoleh dengan parameter yang digunakan pada tahap uji yaitu nilai *epoch* 50, *pixel* 244x244, dan *learning rate* 0.001, dengan pembagian jumlah data latih dan data uji yaitu 70% dan 30%. Berdasarkan parameter tersebut didapatkan hasil dari *training loss* sebesar 4%, *validation loss* sebesar 69,9%, *training accuracy* sebesar 97,8% dan *validation accuracy* sebesar 82,65%. Hasil tersebut merupakan hasil terbaik dari 3 arsitektur yang dibandingkan, dan dari berbagai jenis pengujian.

ABSTRACT

The circulation of counterfeit money in Indonesia continues to increase along with technological advances and the lack of authenticity of money using computers. So, this study was conducted to build a money authenticity detection system using the Convolutional Neural Network (CNN) method. The type of research used is quantitative Experimental research based on Hardware Programming. The instruments used to build the CNN method algorithm and Web development are Visual Studio Code software and Python. The CNN method is used to classify real and fake money based on images. The experiment used a dataset of banknotes with two classes, namely 1,015 real money and 1,126 phony money. The process of determining genuine and fake is carried out in several methods: data acquisition, data selection, data preprocessing, transformation, and modelling. Before creating the model, the data needs to be resized to 224x224 pixels for the GoogleNet model, 256x256 for the AlexNet model, and 200x200 for the modified model. The modified model is designed to compare the results of GoogleNet and AlexNet by reducing layers and adjusting parameters to existing data. Data analysis was performed by comparing the calculation results of training loss, validation loss, training accuracy, and validation accuracy on variations in epoch, pixel, and learning rate values for the three models. The best results were obtained with the parameters used in the test stage, namely an epoch value of 50, pixels 244x244, and a learning rate of 0.001, with the division of the number of training data and test data being 70% and 30%. Based on these parameters, the results of the training loss were 4%, validation loss 69.9%, training accuracy 97.8% and validation accuracy 82.65%. These are the best results of the three architectures compared to various types of testing.

1. PENDAHULUAN

Pengadaan dan peredaran uang palsu merupakan masalah serius karena merupakan tindak pidana yang melanggar pasal 244 & 245 Kitab Undang-Undang Hukum Pidana (KUHP) dan pasal 11 Undang-Undang No.7 Tahun 2011 (Saputra, R et al., 2022; Siregar & Ishaq, 2023). Penyebaran uang palsu tidak hanya

*Corresponding author.

E-mail addresses: teguhpuja@apps.ipb.ac.id (Teguh Puja Negara)

berdampak pada kerugian finansial bagi individu maupun perusahaan, tetapi juga dapat mengganggu kepercayaan masyarakat terhadap sistem keuangan. Ketika uang palsu tersebar luas, keyakinan masyarakat terhadap nilai mata uang serta kemampuan pemerintah untuk menjaga kestabilan ekonomi dapat terguncang. Hal ini dapat berujung pada meningkatnya inflasi, melemahnya daya beli masyarakat, dan menimbulkan kerugian yang signifikan bagi para pelaku usaha yang tanpa sadar menerima uang palsu sebagai alat transaksi. Peningkatan peredaran uang palsu disebabkan oleh teknologi percetakan, kemudahan memperoleh informasi tentang cara membuat uang palsu di internet, dan perkembangan teknologi printer berwarna (Dimas, 2021; Wardani et al., 2024). Oleh karena itu penting untuk kita cermat dalam mengenali uang asli dan uang palsu. Karakteristik keaslian uang kertas rupiah dapat ditentukan secara konvensional melalui inspeksi visual, sentuhan, dan pencahayaan. Namun, penggunaan panca indera dalam menentukan keaslian uang kertas dianggap tidak efisien karena penilaian setiap individu bersifat subyektif (Atmojo, 2020; Horst et al., 2021). Perkembangan teknologi telah menyebabkan pergeseran dari deteksi keaslian uang berbasis penglihatan manusia ke penglihatan komputer, sehingga lebih akurat untuk melihat karakteristik yang tidak terlihat. seperti tinta tak terlihat yang hanya ada pada uang asli (Widianto et al., 2023). Salah satu cara untuk mendeteksi keaslian uang adalah berbasis citra, sehingga mudah diinterpretasikan oleh manusia atau mesin komputer, dengan objek uang bisa berupa foto (Balakrishnan et al., 2023; Hamidah et al., 2022). Penggunaan komputer meningkat pesat seiring dengan perkembangan internet, yang sangat penting digunakan untuk menyelesaikan berbagai masalah saat ini, terutama membangun sistem pendeteksi keaslian uang berbasis citra.

Penelitian tentang pemrosesan citra telah dilakukan dengan menggunakan beberapa metode, diantaranya berdasarkan fitur warna Merah, Hijau, Biru (RGB) menggunakan *K-Nearest Neighbor* (KNN). Pada penelitian tersebut, dari 16 data uji menunjukkan 15 objek uang kertas berhasil dideteksi dengan benar. Akurasi yang dihasilkan sebesar 93,7% dengan nilai $K=5$. Hasil yang diperoleh dari metode ini kurang representatif karena jumlah data uji yang masih sedikit. Penelitian lain dilakukan dengan berbasis citra menggunakan *Local Binary Patterns* (LBP) (Miladiyah. et al., 2019; Pratama, A et al., 2020) Sampel yang digunakan dalam penelitian ini adalah pecahan 50.000 dan 100.000 rupiah. Dari hasil penelitian ini, rata-rata akurasi dari total 120 data uji dengan masing-masing 30 data set pecahan asli 50.000, 30 data set pecahan palsu 50.000, dan 30 data set pecahan asli 100.000 serta 30 data set pecahan palsu 100.000 adalah 95% dengan nilai $k=1$. Namun, LBP standar beroperasi pada jendela ukuran tetap (biasanya 3×3). Keterbatasan ini kemungkinan tidak dapat menangkap informasi tekstur secara efektif pada skala yang berbeda, yang mengarah pada kinerja yang buruk pada tekstur dengan skala yang bervariasi. Penelitian lain adalah menggunakan metode *Artificial Neural Network* (ANN) pada penentuan keaslian uang (Kaya et al., 2016; Wong, 2020). Dalam penelitian tersebut, empat parameter input, satu lapisan tersembunyi dengan 10 neuron dan satu output telah digunakan untuk ANN. Proses klasifikasi 1372 unit data dengan menggunakan ANN menghasilkan regresi latih sebesar 0.99914, regresi uji sebesar 0.99786 dan regresi validasi sebesar 0.9953. Namun, metode ANN memiliki beberapa kelemahan, diantaranya ANN memerlukan sejumlah besar data berlabel untuk dilatih secara efektif dan pelabelan data bisa membutuhkan waktu dan biaya. Peneliti lain menggunakan snapshot berbasis algoritma *Hyperspectral Imaging* (HSI), yang mengkonversi citra RGB menjadi citra HSI (Firat et al., 2023; Makundan et al., 2023). Pada penelitian ini, tiga sampel uang kertas 100 NTD palsu. Hasil penelitian menunjukkan bahwa uang kertas dapat dengan mudah dibedakan berdasarkan nilai rata-rata abu-abu (MGV) dalam panjang gelombang yang lebih pendek, antara 400 nm dan 500 nm dengan tingkat kepercayaan 90%. Kelemahan metode ini jika menggunakan panjang gelombang yang lebih panjang dan menambahkan pengujian dengan tambahan uang kertas polimer serta ROI yang berbeda.

Metode terbaru untuk mendeteksi keaslian uang juga telah dilakukan oleh para peneliti di negara lain, yaitu *Chemometrics Fuzzy Autocatalytic Set*. Pada penelitian tersebut, metode *Advanced Fuzzy Graph Chemometrics* digunakan untuk membedakan uang kertas lima puluh Ringgit Malaysia (RM50) asli dan palsu (Hassan et al., 2022). Metode baru ini lebih cepat dari PCA dalam analisis keaslian uang kertas palsu. Namun, metode tersebut memiliki dua kelemahan, yaitu: permintaan komputasi yang tinggi dan implementasi yang rumit. Berdasarkan permasalahan dan penelitian yang telah dilakukan, dibangun sebuah sistem untuk mendeteksi keaslian uang menggunakan metode pemrosesan citra yang lebih akurat, yaitu metode *Convolutional Neural Network* (CNN).

Metode CNN adalah prosedur penyelesaian jaringan saraf dalam yang paling umum diterapkan untuk menganalisis gambar visual. CNN adalah *multilayer perceptron* dengan setiap neuron terhubung ke semua neuron di lapisan berikutnya (Andika et al., 2023; Yamashita et al., 2018). Selain itu, ada keunggulan metode CNN yaitu dapat secara otomatis mengekstraksi fitur penting dari setiap gambar tanpa bantuan manusia (Chen et al., 2021; Haider et al., 2023). Metode CNN juga lebih efisien dibandingkan metode jaringan saraf lainnya, terutama dalam hal memori dan kompleksitas (Alzubaidi et al., 2021; Irfansyah et al., 2021). Metode CNN juga berhasil mendeteksi keaslian uang dengan akurasi di atas 90% dibandingkan

dengan metode lainnya. Penelitian ini menggunakan dua arsitektur CNN pra-terlatih yang terkenal dan arsitektur model yang dimodifikasi, yaitu GoogLeNet, AlexNet, dan model yang dimodifikasi. GoogLeNet memiliki modul *inception*, yang melakukan berbagai ukuran konvolusi dan menggabungkan filter untuk lapisan selanjutnya, sedangkan AlexNet memiliki input lapisan yang disediakan oleh satu lapisan sebelumnya, bukan serangkaian filter (Firat et al., 2023; Singh et al., 2022). Kedua arsitektur ini memiliki sejumlah lapisan dan parameter yang kompleks, oleh karena itu dibuatlah model yang dimodifikasi untuk membandingkan hasil keduanya, dengan mengurangi lapisan dan menyesuaikan parameter dengan data yang ada.

Beberapa penelitian sebelumnya menyatakan bahwa identifikasi dengan metode CNN dapat dilakukan secara otomatis dan cepat, memungkinkan pengguna untuk segera menentukan apakah uang yang diterima adalah asli atau palsu (Andika et al., 2023; Pratama, A & Cobantoro, A, 2023). Penelitian lainnya menyatakan bahwa metode CNN dapat diintegrasikan dengan teknologi lain, seperti sistem pemindai otomatis dan aplikasi mobile (Han et al., 2018; Soeharto et al., 2024). Berdasarkan temuan tersebut dapat dikatakan metode ini memberikan dampak yang positif. Sehingga dilakukan penelitian ini yang bertujuan untuk membangun algoritma CNN pada sistem pendeteksi keaslian uang dengan berbasis citra. Sistem dalam bentuk aplikasi *Website* dengan menggunakan *Visual Studio Code*. Hasil pengukuran sistem dengan metode CNN dapat menentukan keaslian uang dengan tingkat akurasi diatas.

2. METODE

Penelitian ini dilakukan di lingkungan terkontrol, seperti laboratorium komputer dan melibatkan tahapan pengembangan, yaitu merancang, membangun, dan menguji sistem pendeteksi keaslian uang berbasis metode CNN. *Convolutional Neural Network* (CNN) adalah bagian dari beberapa jenis jaringan saraf atau jaringan saraf tiruan yang biasa digunakan untuk memproses dan mengolah data gambar. CNN juga merupakan pengembangan dari metode *Multi Layer Perceptron* (MLP) (Taye, 2023). Dibandingkan dengan MLP, CNN memiliki jumlah dimensi yang lebih besar. CNN memiliki beberapa lapisan yang digunakan untuk menyaring setiap proses, yaitu lapisan *convolution*, lapisan *pooling*, dan lapisan *fully connected* (Adi et al., 2024). Lapisan *convolution* adalah lapisan pertama yang mengekstraksi fitur dari gambar input. Pada lapisan ini, "encoding" gambar akan menjadi peta fitur. Dalam contoh aplikasi, lapisan *pooling* yang biasa digunakan adalah *pooling* maksimum dan *pooling* rata-rata. Proses *pooling* maksimum adalah lapisan yang berfungsi untuk mengurangi ukuran spasial guna mengurangi jumlah parameter dan perhitungan ketika ukuran gambar terlalu besar (Zafar et al., 2022). Peta fitur yang dihasilkan oleh tahap sebelumnya, yaitu lapisan *pooling*, akan membentuk *array multidimensional*, sehingga sebelum melanjutkan ke tahap lapisan *fully connected*, peta fitur yang telah dihasilkan akan melalui proses *flatten* atau *reshape* terlebih dahulu. Proses *flatten* akan mengubahnya menjadi vektor yang nantinya dapat digunakan sebagai input dari lapisan *fully connected* (Jeczmiónek & Kowalski, P, 2021). Adapun tahapan metode CNN dalam mendeteksi keaslian uang adalah sebagai berikut:

Akuisisi Data

Tahap pertama dari metode CNN adalah proses akuisisi data dengan mengambil data uang asli menggunakan proses pengambilan gambar sehingga diperoleh data digital. Selanjutnya, gambar uang asli diedit menggunakan *Adobe Photoshop* untuk menghapus beberapa elemen penting pada uang seperti benang pengaman dan watermark sehingga berbeda dari uang asli, yang kemudian disimpan sebagai dataset uang palsu (Ibrahim et al., 2023; Saputra, R et al., 2022).

Seleksi Data

Seleksi adalah proses memilih atau mengumpulkan data yang dianggap relevan untuk analisis (Ferreira & Mendonca, M, Dinic, P, S, 2021). Data yang digunakan adalah gambar digital uang asli dalam berbagai denominasi. (2) Gambar yang digunakan adalah gambar uang kertas rupiah yang diterbitkan pada tahun 2016 dengan denominasi IDR 1.000,00, IDR 2.000,00, IDR 5.000,00, IDR 10.000,00, IDR 20.000,00, IDR 50.000,00, dan IDR 100.000,00. Gambar uang kertas rupiah tahun 2010-2014 dengan denominasi IDR 10.000,00, IDR 20.000,00, IDR 50.000,00, dan IDR 100.000,00. Gambar uang kertas rupiah tahun 2009 dengan denominasi Rp 2.000,00 dan gambar uang kertas rupiah tahun 2005 dengan denominasi Rp 50.000,00 dan Rp 10.000,00. Pada tahap seleksi, gambar digital uang asli dan uang palsu akan dipisahkan ke dalam dua folder. Proses seleksi yang dilakukan oleh *Python* dilakukan dengan *looping* data dalam direktori dan memberikan label untuk setiap *loop*. Data yang digunakan adalah gambar digital uang asli dan uang palsu dalam berbagai denominasi. Total data yang digunakan berjumlah 2.141 gambar digital.

Prapemrosesan Data

Tahap berikutnya adalah prapemrosesan. Pada tahap ini, proses mengubah ukuran gambar digital uang asli dan uang palsu akan dilakukan (Aprillia et al., 2024; Dimas, 2021). Gambar-gambar akan diproses untuk diubah ukurannya menjadi 224x224 piksel untuk model *GoogLeNet*, 256x256 untuk model *AlexNet*, dan 200x200 untuk model yang dimodifikasi yang sebelumnya berukuran 670 x 1530, sehingga ukuran file gambar lebih kecil dan mempercepat proses pelatihan. Ukuran perubahan ini dibedakan berdasarkan ukuran optimal yang disediakan oleh masing-masing model. Selain itu, gambar digital akan ditingkatkan seperti *crop*, *flip*, dan *mirror* sehingga data yang dihasilkan menjadi lebih beragam

Transformasi

Transformasi adalah proses mengubah data ke dalam bentuk lain sehingga menghasilkan penyajian yang sesuai dengan tugas yang akan dilakukan dalam proses data *mining*. Transformasi umumnya melibatkan banyak metode mulai dari *smoothing*, agregasi, diskretisasi, konstruksi atribut, generalisasi. Transformasi data yang dilakukan adalah membagi data menjadi 70% data pelatihan dan 30% data pengujian, dengan jumlah ini menghasilkan hasil terbaik berdasarkan pengujian yang telah dilakukan. Proses berikutnya adalah mengubah tipe data awal, yaitu unit8 menjadi float32, karena tipe data float32 adalah angka pecahan dengan presisi lebih tinggi daripada angka bulat. Selain itu, proses penskalaan data juga dilakukan, yaitu dengan membagi konstanta dengan 255, karena intensitas cahaya RGB berada dalam kisaran 0 – 255. Dalam proses ini, gambar digital akan diubah menjadi *array multidimensional*.

Pemodelan

Proses pemodelan adalah proses menentukan jumlah lapisan pada arsitektur CNN yang digunakan. Pada proses pemodelan terdapat 3 tahapan yaitu: tahap *convolution*, *pooling*, dan *flatten* (Alwanda et al, 2020). Input dari proses ini berupa gambar dan akan menghasilkan output berupa data vektor yang akan menjadi input pada proses pengujian.

lapisan *convolution* adalah lapisan pertama yang mengekstraksi ciri dari citra yang dimasukkan. Pada penelitian ini misalnya, dataset uang asli Rp. 20.000 di resize menjadi 224 x 224 dan kemudian ditentukan kedalamannya menjadi 224 x 224 x 3. Angka 3 merupakan notasi jumlah layer yaitu *red*, *green*, dan *blue*. Dari contoh data citra tersebut, diambil sebagian *pixel* yang berukuran 5x5 yang nantinya akan dikalikan dengan matriks kernel 3x3 dengan nilai antara -1 sampai 1. Contoh perkalian citra 5x5 dengan kernel 3x3 sebagaimana pada Gambar 1.

$$\begin{array}{|c|c|c|c|c|} \hline a_{11} & a_{12} & a_{13} & a_{14} & a_{15} \\ \hline a_{21} & a_{22} & a_{23} & a_{24} & a_{25} \\ \hline a_{31} & a_{32} & a_{33} & a_{34} & a_{35} \\ \hline a_{41} & a_{42} & a_{43} & a_{44} & a_{45} \\ \hline a_{51} & a_{52} & a_{53} & a_{54} & a_{55} \\ \hline \end{array} \times \begin{array}{|c|c|c|} \hline b_{11} & b_{12} & b_{13} \\ \hline b_{21} & b_{22} & b_{23} \\ \hline b_{31} & b_{32} & b_{33} \\ \hline \end{array} = \begin{array}{|c|c|c|} \hline c_{11} & c_{12} & c_{13} \\ \hline c_{21} & c_{22} & c_{23} \\ \hline c_{31} & c_{32} & c_{33} \\ \hline \end{array}$$

Gambar 1. Hasil dari Proses *Convolution* berupa *Feature Map*

Contoh perhitungan untuk mendapatkan hasil pada posisi 1 seperti berikut:

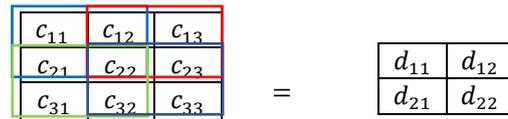
$$c_{11} = a_{11} \times b_{11} + a_{12} \times b_{12} + a_{13} \times b_{13} + a_{21} \times b_{21} + a_{22} \times b_{22} + a_{23} \times b_{23} + a_{31} \times b_{31} + a_{32} \times b_{32} + a_{33} \times b_{33}$$

Untuk mendapatkan hasil pada posisi yang lain adalah menggunakan cara yang sama. Hasil output (*O*) dari proses lapisan konvolusi menggunakan rumus (1) (Zhao et al, 2024):

$$O = \frac{W-F+2P}{S} + 1 \tag{1}$$

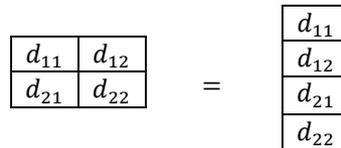
W adalah ukuran gambar, *F* adalah ukuran filter atau kernel, *P* adalah *padding*, dan *S* adalah *stride*. Hasil konvolusi matriks gambar dengan filter (kernel) disebut peta fitur atau peta aktivasi. Pada penelitian ini, *padding* mengambil nilai 0.

Pada tahapan *max pooling*, *stride* yang digunakan adalah 1 dengan kernel 2x2. Pada diketahui nilai *W* = 5 x 5 dan *F* = 2 x 2. Dengan menggunakan perumusan (1), didapatkan hasil output dengan ukuran yang lebih kecil, yaitu 2. Untuk mendapatkan matriks *max pooling*, diambil nilai maksimum matriks 2 x 2 dari matriks hasil konvolusi



Gambar 2. Proses Pembentukan *Max Pooling*

Tahap selanjutnya adalah *flatten*, yaitu transformasi hasil matriks pada tahapan *max pooling* kedalam bentuk vektor. Contoh pembentukan vektor dari matriks ditunjukkan pada [Gambar 3](#).



Gambar 3. Hasil Proses *Flatten* berupa Vektor

Pengujian Model

Setelah ketiga model telah dibentuk, maka akan dilakukan proses pengujian dengan 9 kali percobaan agar melihat perbedaan hasil yang didapatkan. Parameter yang akan dipakai pada penelitian ini antara lain *epoch* bernilai 10, 25, dan 50, dan ukuran *pixel* berukuran 200x200, dan 244x244, 256x256.

Evaluasi

Proses evaluasi atau interpretasi adalah visualisasi hasil dari pengujian dataset yang dilakukan. Visualisasi ditampilkan bisa dalam bentuk grafik dengan sumbu X menunjukkan jumlah perulangan atau *epoch* yang dipakai, sedangkan untuk sumbu Y menunjukkan nilai dari hasil pengujian yang memiliki rentang dari 0 – 1 atau dikalikan 100, sehingga hasil pengujian dalam bentuk persentase. Analisis data dilakukan dengan cara membandingkan hasil perhitungan nilai *training loss*, *validation loss*, akurasi pelatihan, dan akurasi validasi pada variasi nilai *epoch*, *pixel*, dan *learning rate*.

3. HASIL DAN PEMBAHASAN

Hasil

Pembentukan model CNN pada penelitian ini adalah menggunakan model *AlexNet* (Irfansyah et al, 2021) dan model *GoogleNet*. Pada model *AlexNet*, terdiri atas 5 buah *convolution layer*, 3 *max pooling layer*, 1 *flatten layer* dan 3 *dense layer*. Sedangkan pada model *GoogleNet*, terdiri atas 32 buah *convolution layer*, 7 buah *max pooling layer*, 1 buah *dropout layer*, 1 buah *flatten layer*, dan 3 buah *dense layer*.

Pada tahap pengujian dilakukan modifikasi dari arsitektur yang berbeda yaitu *AlexNet* dan *GoogleNet*. Modifikasi dilakukan pada proses pengujian dengan ukuran 224x224 *pixel* untuk model *GoogleNet*, 256x256 untuk model *AlexNet* dan 200x200 untuk model modifikasi dan epoch sebesar 10. [Tabel 1](#). menunjukkan bahwa hasil dari proses training model dengan menggunakan perulangan atau epoch sebesar 10 mendapatkan hasil akhir berupa *training loss* sebesar 40%, *validation loss* = 50%, *training accuracy* = 80% dan *validation accuracy* = 78%.

Tabel 1. Evaluasi Hasil Pengujian Model

<i>Epoch</i>	<i>Training Loss</i>	<i>Validation Loss</i>	<i>Training Accuracy</i>	<i>Validation Accuracy</i>
1	0,90	0,65	0,64	0,65
2	0,63	0,60	0,65	0,76
3	0,60	0,57	0,70	0,72
....
....
10	0,40	0,50	0,80	0,78

Selanjutnya dilakukan proses *Confusion Matrix* untuk melihat hasil prediksi dari hasil ujinya apakah data yang di uji sesuai dengan prediksi dari masing masing model yang telah dibangun. Hasil dari pengujian *confusion matrix* terdapat pada [Tabel 2](#).

Tabel 2. Tabel Perbandingan Hasil *Confusion Matrix*

Model	Uang Asli Benar	Uang Asli Salah	Uang Palsu Benar	Uang Palsu Salah
AlexNet	221	93	239	88
GoogleNet	92	224	264	62
Modifikasi	196	107	466	76

Pengujian berikutnya adalah melihat perbedaan hasil jika masing- masing model di uji dengan ukuran *pixel* dan *epoch* yang berbeda beda. Hasil pengujian dari ketiga model dapat dilihat pada [Tabel 2](#). 224x224 *pixel* untuk model *GoogleNet*, 256x256 untuk model *AlexNet* dan 200x200 untuk model modifikasi, sebagaimana pada [Tabel 3](#)

Tabel 3. Tabel Hasil Pengujian dengan Ukuran yang Berbeda

Model	EEpoch	Pixel	Training		Validation		t (Hour)
			Accuracy	Loss	Accuracy	Loss	
AlexNet	10	200 x 200	61,0%	30,9%	60,9%	45,0%	2,50
	25	200 x 200	59,8%	40,0%	58,4%	70,2%	5,40
	50	200 x 200	55,2%	35,2%	63,2%	29,5%	7,00
	10	244 x 244	64,4%	65,0%	64,4%	70,0%	3,20
	25	244 x 244	67,7%	35,0%	68,1%	31,7%	5,92
	50	244 x 244	61,2%	62,6%	62,4%	40,0%	7,67
	10	256 x 256	64,2%	65,0%	64,4%	70,0%	3,50
	25	256 x 256	63,6%	52,2%	61,2%	50,0%	6,17
	50	256 x 256	65,5%	49,0%	66,3%	43,9%	7,83
Google Net	10	200 x 200	61,3%	37,1%	59,9%	45,2%	4,00
	25	200 x 200	68,2%	29,4%	66,2%	40,2%	7,83
	50	200 x 200	63,6%	41,5%	62,2%	54,5%	12,13
	10	244 x 244	61,0%	30,9%	60,9%	45,0%	4,50
	25	244 x 244	65,0%	65,8%	64,0%	65,2%	8,00
	50	244 x 244	60,2%	35,2%	63,2%	29,5%	13,0
	10	256 x 256	63,0%	65,8%	64,0%	65,2%	4,67
	25	256 x 256	61,2%	42,6%	65,2%	61,0%	8,20
	50	256 x 256	65,5%	53,0%	67,3%	42,3%	13,13
Modifikasi	10	200 x 200	95,6%	13,0%	82,2%	46,0%	0,28
	25	200 x 200	96,4%	9,00%	80,0%	54,0%	0,58
	50	200 x 200	97,7%	5,00%	80,0%	83,0%	0,83
	10	244 x 244	81,4%	40,5%	78,3%	45,9%	0,33
	25	244 x 244	97,0%	7,00%	79,7%	66,0%	0,75
	50	244 x 244	97,8%	4,00%	82,6%	69,9%	1,50
	10	256 x 256	87,0%	28,0%	77,0%	50,0%	0,67
	25	256 x 256	95,6%	10,0%	82,0%	53,0%	1,40
	50	256 x 256	96,7%	6,00%	82,8%	52,0%	1,83

Berdasarkan hasil [Tabel 3](#), hasil terbaik dari masing masing model disimpan dalam format .h5 dan dilakukan uji coba model kedalam *website* dengan menggunakan Bahasa *python*. Ketiga model yaitu *Alexnet*, *Googlenet* dan modifikasi akan dipakai bersamaan agar bisa terlihat hasil prediksi dari tiap-tiap model. File *python* dijalankan melalui terminal dan akan menghasilkan tampilan *website* seperti [Gambar 4](#), yang didapatkan hasil bahwa model *Alexnet* memprediksi uang tersebut palsu, model *Googlenet* memprediksi uang tersebut asli, dan untuk model modifikasi memprediksi uang tersebut asli.



Gambar 4. User Interface Website

Pembahasan

Pada penelitian ini model yang akan dilatih dengan 3 arsitektur yang berbeda yaitu *AlexNet*, *GoogleNet* dan Modifikasi model. Ketiga arsitektur tersebut di latih dengan ukuran 224×224 pixel untuk model *GoogleNet*, 256×256 untuk model *AlexNet*, dan 200×200 untuk model modifikasi dengan *epoch* sebesar 10. Pada model dengan arsitektur *AlexNet* didapatkan bahwa nilai *training loss* sebesar 65%, *validation loss* = 70%, *training accuracy* = 64% dan *validation accuracy* = 64%. Model selanjutnya adalah model dengan arsitektur *GoogleNet* didapatkan hasil bahwa nilai *training loss* sebesar 65,8%, *validation loss* = 65,2%, *training accuracy* = 63% dan *validation accuracy* = 64%. Dan model terakhir adalah model dengan arsitektur modifikasi didapatkan hasil bahwa nilai *training loss* sebesar 40.5%, *validation loss* = 45.9%, *training accuracy* = 81.4% dan *validation accuracy* = 78.3%. Berdasarkan data pada Tabel 1 didapatkan nilai penurunan untuk *training loss* dan *validation loss*, sedangkan untuk *training accuracy* dan *validation accuracy* mengalami peningkatan nilai. Hasil ini sesuai dengan teori dan hasil penelitian sebelumnya (Sadewa & Yamasari, 2024).

Tabel 2 menunjukkan sebanyak 196 data diklasifikasikan benar sesuai target yaitu uang asli dan 107 data diklasifikasikan tidak sesuai target yaitu uang palsu. Kemudian sebanyak 466 data diklasifikasikan benar sesuai target yaitu uang palsu dan 76 data diklasifikasikan tidak sesuai target yaitu uang asli. Dari hasil perhitungan akurasi, dapat disimpulkan bahwa metode CNN dapat melakukan klasifikasi keaslian uang kertas rupiah dengan cukup baik. Kesalahan-kesalahan CNN dalam mengklasifikasi citra uang kertas disebabkan oleh adanya perbedaan citra yang dideteksi, yaitu terdapat uang lusuh yang *invisible ink*-nya tidak begitu tampak. Oleh karena itu, diperlukan penambahan data training yang lebih banyak dan bervariasi khususnya citra uang lusuh, sehingga uang tersebut dapat terdeteksi dengan baik. Selain itu, juga dapat ditambahkan fitur hasil ekstraksi sehingga masing-masing kelas dapat memiliki lebih banyak parameter yang beragam untuk memudahkan metode CNN dalam mengenali pola serta mengidentifikasi keaslian uang kertas dengan lebih spesifik.

Berdasarkan Tabel 3, Pada model *AlexNet*, hasil terbaik diperoleh pada percobaan ke 9 yang menggunakan *epoch* 50 dan *pixel* 256×256 dengan *training loss* sebesar 49%, *validation loss* = 43.9%, *training accuracy* = 65.5% dan *validation accuracy* = 66.3%. Pada model *GoogleNet*, hasil terbaik diperoleh pada percobaan ke 2 yang menggunakan *epoch* 25 dan *pixel* 200×200 dengan *training loss* sebesar 29.4%, *validation loss* = 40.2%, *training accuracy* = 68.2% dan *validation accuracy* = 66.2%. dan pada model modifikasi, hasil terbaik diperoleh pada percobaan ke 3 yang menggunakan *epoch* 50 dan *pixel* 244×244 dengan *training loss* sebesar 4%, *validation loss* = 69.9%, *training accuracy* = 97.8% dan *validation accuracy* = 82.65%. Untuk proses waktu pengujian, peningkatan *pixel* menyebabkan waktu pengujian semakin lama, contohnya *AlexNet* pada *pixel* 200×200 membutuhkan waktu 2.5 jam, sedangkan pada *pixel* 256×256 membutuhkan waktu 7.83 jam. Hal ini bisa dijelaskan bahwa, jika ukuran gambar meningkat, jumlah operasi konvolusi yang harus dilakukan juga meningkat secara proporsional. Contohnya Sebagai contoh, jika gambar awal berukuran 64×64 pixel dan meningkat menjadi 128×128 pixel, jumlah total operasi konvolusi meningkat dari $64 \times 64 = 4096$ operasi menjadi $128 \times 128 = 16384$ operasi untuk setiap filter. Untuk model *AlexNet*, membutuhkan waktu proses lebih singkat dibandingkan dengan *GoogleNet* disebabkan *AlexNet* memiliki 8 lapisan (5 lapisan konvolusi dan 3 lapisan fully connected). Arsitektur ini relatif sederhana dan memiliki lebih sedikit parameter dibandingkan dengan *GoogLeNet* memiliki 22 lapisan yang jauh lebih dalam dan lebih kompleks dibandingkan dengan *AlexNet*. Untuk model modifikasi, waktu proses lebih singkat lagi karena ada pengurangan lapisan. Hasil dari ketiga

model yang telah dilatih dan dicoba berbeda-beda dikarenakan beberapa faktor, salah satunya adalah jumlah layer atau kompleksitas layer perlu sesuai dengan jumlah data dan kompleksitas data, CNN dapat digunakan untuk memodelkan hubungan yang kompleks antara input dan output untuk menemukan pola-pola pada data sehingga layer yang kompleks dapat mengurangi kemampuan model untuk mempelajari pola-pola yang relevan pada data input. Layer model yang kompleks tidak selalu meningkatkan kinerja model secara signifikan, pengoptimalan parameter dapat lebih membantu kinerja model secara keseluruhan. Pada model modifikasi, memiliki hasil yang jauh lebih baik dibandingkan dengan 2 model sebelumnya, dengan nilai persentase *accuracy* yang tinggi, nilai *loss* yang rendah dan waktu yang dibutuhkan lebih singkat. Hal tersebut dikarenakan salah satu faktor nya adalah jumlah dataset, kompleksitas layer dan pengoptimalan parameter cocok dengan jenis model ketiga yaitu model modifikasi sehingga proses pelatihan menghasilkan hasil yang lebih baik.

Pada Gambar 4, sistem *interface* yang dibangun telah menunjukkan hasil deteksi keaslian uang kertas dengan cukup baik, dengan tampilan desain yang sederhana dan mudah difahami, navigasi yang mudah, interaktif dan user-friendly, fungsionalitas yang konsisten. Kesalahan penentuan uang asli pada model Alexnet disebabkan karena ketidaktepatan mengolah data citra melalui pembacaan tanda *watermark* pada uang asli.

Hasil penelitian ini, dapat dibandingkan dengan penelitian lain dari nilai *accuracy training* dan *accuracy testing* sebagaimana pada Tabel 4. Metode ANN ternyata memiliki *accuracy training* dan *accuracy testing* yang lebih besar dibandingkan metode CNN dengan nilai epoch dan pixel yang lebih besar.

Tabel 4. Tabel Perbandingan Hasil Penelitian dengan Penelitian Lain

Model	EEpoch	Pixel	Accuracy		Referensi
			Training	Testing	
CNN	15	224 x 224	94,26%	92,86%	(Sadewa et al, 2024).
KNN	34	400 x 800	94,00%	88,00%	(Tamara et al, 2022).
ANN	206	400 x 400	99,91%	99,78%	(Kaya et al, 2016)
CNN	50	244 x 244	97,80%	82,65%	(Prihastuti Harsani).

Secara keseluruhan, hasil penelitian ini dapat memberikan kontribusi signifikan dalam meningkatkan keakuratan, efisiensi, dan keamanan dalam proses deteksi keaslian uang, serta mendorong inovasi dan pengembangan sistem serupa. Selain itu, hasil penelitian juga dapat memberikan dampak positif pada industri keuangan, penegakan hukum, efisiensi operasional, edukasi masyarakat, serta pengembangan teknologi di masa depan. Temuan ini sejalan dengan hasil penelitian sebelumnya yang menyatakan bahwa identifikasi dengan metode CNN dapat dilakukan secara otomatis dan cepat, memungkinkan pengguna untuk segera menentukan apakah uang yang diterima adalah asli atau palsu (Andika et al., 2023; Pratama, A & Cobantoro, A, 2023). Penelitian lainnya menyatakan bahwa metode CNN dapat diintegrasikan dengan teknologi lain, seperti sistem pemindai otomatis dan aplikasi mobile (Han et al., 2018; Soeharto et al., 2024). Namun, tentunya penelitian ini masih memiliki kekurangan, meliputi perlunya eksperimen lebih lanjut untuk meningkatkan *training accuracy* dan *validation accuracy*. Saran untuk penelitian selanjutnya adalah melakukan uji coba yang lebih luas dan mendalam dengan cara menambah jumlah layer dan menggunakan komputer dengan spesifikasi yang lebih tinggi agar pemrosesan menjadi lebih singkat.

4. SIMPULAN

Perancangan sistem identifikasi uang palsu berbasis citra telah dilakukan menggunakan metode CNN. Dalam penelitian ini digunakan dataset sebanyak 2.141 uang kertas yang terdiri atas 1015 uang asli dan 1126 uang palsu. Sebelum dilakukan proses pembuatan model data, perlu dilakukan *resize* menjadi 224x224 pixel untuk model *GoogleNet*, 256x256 untuk model *AlexNet* dan 200x200 untuk model modifikasi. Data yang telah diubah ukurannya kemudian dilakukan proses transformasi. Pada tahap ini data dibagi menjadi 70% data latih dan 30% data uji. Proses selanjutnya adalah tahap konversi tipe data dari unit8 ke float32 dan penskalaan data sebesar 255. Hasil terbaik diperoleh dengan parameter yang digunakan pada tahap pengujian yaitu nilai *epoch* 50 dan *pixel* 244x244, *learning rate* 0.001. Berdasarkan pada parameter yang digunakan, hasil yang diperoleh adalah *training loss* sebesar 4%, *validation loss* = 69.9%, *training accuracy* = 97.8% dan akurasi *validation accuracy* = 82.65%. Penambahan jumlah leyer dapat mrnyebabkan waktu pemrosesan menjadi lebih lama.

5. DAFTAR PUSTAKA

- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of Deep Learning: Concepts, CNN Architectures, Challenges, Applications, Future Directions. , 8(53): 1-74. <https://doi.org/10.1186/s40537-021-00444-8>.
- Andika, A. J., Kristian, Y., & Setiawan, E. I. (2023). Deteksi Komentar Cyberbullying Pada YouTube Dengan Metode Convolutional Neural Network - Long Short-Term Memory Network (CNN-LSTM). *TEKNIKA: Jurnal Teknologi Informasi Dan Komunikasi*, 12(3). <https://doi.org/10.34148/teknika.v12i3.677>.
- Aprillia, D., Rohana, T., Mudzakir, T. Al, & Wahiddin, D. (2024). Deteksi Nominal Mata Uang Rupiah Menggunakan Metode Convolutional Neural Network dan Feedforward Neural Network. *KLIK: Kajian Ilmiah Informatika Dan Komputer*, 4(4). <https://doi.org/10.30865/klik.v4i4.1711>.
- Atmojo, I. R. W. (2020). Implementasi Pembelajaran Berbasis Science, Technology, Engenering, Art And Mathematich (STEAM) Untuk Meningkatkan Kompetensi Paedagogik dan Professional Guru SD Melalui Metode Lesson Study. *Jurnal Pendidikan Dasar*, 8(2). <https://doi.org/10.20961/jpd.v8i2.44214>.
- Balakrishnan, V., Zing, H. L., & Laporte, E. (2023). Covid-19 Infodemic–Understanding Content Features in Detecting Fake News using a Machine Learning Approach. *Malaysian Journal of Computer Science*, 36(1), 1–13. <https://doi.org/10.22452/mjcs.vol36no1.1>.
- Chen, X., Zhang, B., & Gao, D. (2021). Bearing Fault Diagnosis Base on Multi-Scale CNN and LSTM Model. *Journal of Intelligent Manufacturing*, 32, 971-987. <https://doi.org/10.1007/s10845-020-01600-2>.
- Dimas, H. S. (2021). Sosialisasi CIKUR (Ciri-Ciri Keaslian Rupiah) Tahun Emisi 2016 untuk Menghambat Peredaran Uang Palsu dalam Penerimaan Dana Sumbangan di Masjid Al Irsyad Kertonegoro Kecamatan Jenggawah Kabupaten Jember. *MUJTAMA: Jurnal Pengabdian Masyarakat*, 1(1). <https://doi.org/10.32528/mujtama.v1i1.5132>.
- Ferreira, J., & Mendonca, M, Dinic, P, S, R. (2021). Data Selection in Neural Networks. *EEE Open Journal of Signal Processing*, 1(2), 533–534. <https://doi.org/10.1109/OJSP.2021.3106197>.
- Firat, H., Asker, M. E., Bayindir, M. I., & Hanbay, D. (2023). MHybrid 3D/2D Complete Inception Module and Convolutional Neural Network for Hyperspectral Remote Sensing Image Classification. *Neural Processing Letters*, 55. <https://doi.org/10.1007/s11063-022-10929-z>.
- Haider, I., Yang, H. J., Lee, G. S., & Kim, S. H. (2023). Robust Human Face Emotion Classification using Triplet-Loss-Based Deep CNN Features and SVM. *Sensors*, 23(10), 1–19. <https://doi.org/10.3390/s23104770>.
- Hamidah, W., Hasbullah, N, A, P., Irawan, T, S, B., & Kaswar, A, B. (2022). Deteksi Nominal Uang Kertas Menggunakan OCR (Optical Character Recognition). *Jurnal Ilmu Komputer Dan Teknologi Informasi*, 7(2), 72–76. <https://doi.org/10.36805/technoexplore.v7i2.2123>.
- Han, D., Liu, Q., & Fan, W. (2018). A new image classification method using CNN transfer learning and web data augmentation. *Expert Systems with Applications*, 95, 43–56. <https://doi.org/10.1016/j.eswa.2017.11.028>.
- Hassan, N., Ahmad, T., Mahat, N. A., Maarof, H., & K., H. F. (2022). Counterfeit Fifty Ringgit Malaysian Banknotes Authentication using Novel Graph-Based Chemometrics Method. , *Scientific Report*, 5(4826), 1–14. <https://doi.org/10.1038/s41598-022-08821-w>.
- Horst, F. V. D., Snell, J., & Theeuwes, J. (2021). Enhancing Banknote Authentication by Guiding Attention to Security Features and Manipulating Prevalence Expectancy. *Cognitive Research: Principles and Implications*, 6(73), 1–10. <https://doi.org/10.1186/s41235-021-00341-x>.
- Ibrahim, M. M., Rahmadewi, R., & Nurpulaela, L. (2023). Pendeteksian Nominal Uang Pada Gambar Menggunakan Convolutional Neural Network: Integrasi Metode Pra-Pemrosesan Citra Dan Klasifikasi Berbasis CNN. *Jurnal Teknik Informatika*, 7(2). <https://doi.org/10.36040/jati.v7i2.6863>.
- Irfansyah, D., Mustikasari, M., & Suroso, A. (2021). Arsitektur Convolutional Neural Network (CNN) Alexnet untuk Klasifikasi Hama pada Citra Daun Tanaman Kopi. *Jurnal Informatika: Jurnal Pengembangan IT*, 6(2), 87-92. <https://doi.org/10.30591/jpit.v6i2.2802>.
- Jeczmionek, E., & Kowalski, P, A. (2021). Flattening Layer Pruning in Convolutional Neural Networks. *Symmetry*, 13(7), 1–13. <https://doi.org/10.3390/sym13071147>.
- Kaya, E., Yasar, A., & Saritas, I. (2016). Banknote Classification using Artificial Neural Network Approach. *International Journal of Intelligent Systems and Applications in Engineering*, 4(1), 16-19. <https://ijisae.org/index.php/IJISAE/article/view/421>.
- Makundan, A., Tsao, Y, M., Cheng, W, M., Lin, F, C., & Wang, H, C. (2023). Automatic Counterfeit Currency Detection using a Novel Snapshot Hyperspectral Imaging Algorithm. *Sensors*, 23(4), 1–14. <https://doi.org/10.3390/s23042026>.
- Miladiah., Umar, R., & Riadi, I. (2019). Implementasi Local Binary Pattern untuk Deteksi Keaslian Mata Uang

- Rupiah. *Jurnal Edukasi Dan Penelitian Informatika*, 5(2), 197-201. <https://doi.org/10.26418/jp.v5i2.32721>.
- Pratama, A. R., & Cobantoro, A. F. (2023). Klasifikasi Citra Pneumonia Menggunakan Arsitektur Convolutional Neural Network (CNN). *Jurnal Ilmiah NERO*, 8(2), 133-144. <https://doi.org/10.21107/nero.v8i2.18992>.
- Pratama, A. R., Mustajib, M., & Nugroho, A. (2020). Deteksi Citra Uang Kertas dengan Fitur RGB Menggunakan K-Nearest Neighbor. *Jurnal Eksplora Informatika*, 9(2), 163-172. <https://doi.org/10.30864/eksplora.v9i2.336>.
- Sadewa, B. A., & Yamasari, Y. (2024). Implementasi Deep Transfer Learning untuk Klasifikasi Nominal Uang Kertas Rupiah. *JINACS (Journal of Informatics and Computer Science)*, 5(4), 543-551. <https://doi.org/10.26740/jinacs.v5n04.p543-551>.
- Saputra, R. A., Nangi, J., Ningrum, I. P., Almaliki, M. F., & Pratama, L. R. A. (2022). Deteksi Uang Palsu Rupiah dengan Menggunakan Metode Deteksi Tepi Laplacian of Gaussian (LoG) dan Algoritma K-Means Clustering. *Jurnal Buana Informatika*, 13(2), 85-92. <https://doi.org/10.24002/jbi.v13i02.5448>.
- Singh, I., Goyal, G., & Chandel, A. (2022). AlexNet Architecture Based Convolutional Neural Network for Toxic Comments Classification. *J. of King Saud Univ. Comp. and Inf. Sci*, 34(9), 7547-7558. <https://doi.org/10.1016/j.jksuci.2022.06.007>.
- Siregar, A. S., & Ishaq. (2023). Analisis Hukum Positif dan Hukum Pidana Islam terhadap Tindak Pidana dalam Membelanjakan Uang. *JRTI (Jurnal Riset Tindakan Manusia)*, 8(3). <https://doi.org/10.29210/30033377000>.
- Soeharto, M., Hasan, M. J., Susanto, A. R., & Fahrezi, D. A. (2024). Mengklasifikasi Mata Uang Lima Ribu Rupiah dan Dua Ribu Rupiah dengan Menggunakan Algoritma CNN. *Jurnal Teknik Informatika, Sains Dan Ilmu Komunikasi*, 2(3). <https://doi.org/10.59841/saber.v2i3.1407>.
- Taye, M. M. (2023). Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions. *Computation*, 11(3), 1-23. <https://doi.org/10.3390/computation11030052>.
- Wardani, K. D. K. A., Jayanti, K. I. D., Gorda, A. A., & Supriyadinata, N. E. (2024). Upaya Penanggulangan Peredaran Upal Di Kota Denpasar Melalui Edukasi Cikur (Ciri - Ciri Keaslian Uang Rupiah). *Diseminasi: Jurnal Pengabdian Kepada Masyarakat*, 6(2). <https://doi.org/10.33830/diseminasiabdimas.v6i2.6286>.
- Wong, Y. J. (2020). Comparative study of artificial neural network (ANN), adaptive neuro-fuzzy inference system (ANFIS) and multiple linear regression (MLR) for modeling of Cu (II) adsorption from aqueous solution using biochar derived from rambutan (*Nephelium lappaceum*) pee. *Environmental Monitoring and Assessment*, 192(7). <https://doi.org/10.1007/s10661-020-08268-4>.
- Yamashita, R., M., N., G., D. R. K., & Togashi, K. (2018). Convolutional Neural Networks: An Overview and Application in Radiology. *Insights into Imaging*, 9, 611-629. <https://doi.org/10.1007/s13244-018-0639-9>.
- Zafar, A., Aamir, M., Nawi, N. M., Arshad, A., Riaz, S., Alruban, A., Dutta, A. K., & Almotairi, S. (2022). P A Comparison of Pooling Methods for Convolutional Neural Networks. *Applied Sciences*, 12(17), 1-21. <https://doi.org/10.3390/app12178643>.