G-Tech
Jurnal Teknologi Terapan

F.SAINTEK Unira Malang | Vol. 6 | No. 1
April, 2022
P-ISSN 2580-8737, E-ISSN 2623-064X

Implementasi *Convolutional Neural Network* untuk Klasifikasi Citra Soil Nikel dan Non Nikel

SUDALTO
Akademi Teknologi AUB Surakarta
*email : sudalto@at-aub.ac.id

ABSTRAK

Soil merupakan suatu hasil proses residual dari suatu batuan. Keberadaan soil tertentu memiliki kandungan unsur yang bermanfaat bagi kehidupan manusia, salah satunya yakni unsur Ni atau Nikel. Umumnya kandungan unsur pada soil, tercermin dari sifat fisik biasanya dapat di bedakan dengan bantuan panca indera. Maksud penelitian untuk mengembangkan model machine learning dari data tipe soil nikel dan non nikel. Tujuan dalam penelitian ini untuk klasifikasi soil nikel dan non nikel menggunakan *machine learning* dan mengetahui akurasi model. Metode penelitian terdiri dari 2 yakni kualitatif dan kuantitatif, serta diolah menggunakan *Convolution Neural Network* (CNN). Citra digital atau image merupakan bahan baku dalam proses pengembangan model berupa citra soil nikel dan non nikel. Data citra digital diambil sebanyak 580 dibagi menjadi 2 kelas (*binary*) dengan skenario pembagian data latih dan validasi sebesar 80 : 20 %. Semua data image diolah menggunakan arsitektur CNN dengan perpaduan 3 layer konvolusi sebagai fitur ektrasi dan 1 *fully connected* layer sebagai output klasifikasi dari model yang dikembangkan. Berdasarkan hasil dari proses pelatihan data menjadi suatu model didapatkan akurasi sebesar 96 % dengan waktu total selama 20 menit 25 detik.

Kata kunci: *CNN, soil, nikel, non nikel*

ABSTRACT

Soil is a result of the residual process of a rock. The existence of certain soils contains elements that are beneficial to human life, one of which is the element Ni or Nickel. Generally, the elemental content in soil, reflected in its physical properties, can usually be distinguished with the help of the five senses. The purpose of this research is to develop a machine learning model from nickel and non-nickel soil type data. The purpose of this research is to classify nickel and non-nickel soil using machine learning and determine the accuracy of the model. The research method consists of two, namely qualitative and quantitative, and processed using the Convolution Neural Network (CNN). Digital images or images are the raw material in the model development process in the form of nickel and non-nickel soil images. 580 digital image data were taken and divided into 2 classes (binary) with scenarios of sharing training and validation data of 80: 20%. All image data is processed using CNN architecture with a combination of 3 convolution layers as the extraction feature and 1 fully connected layer as the classification output of the developed model. Based on the results of the data training process into a model, an accuracy of 96% was obtained with a total time of 20 minutes 25 seconds.

Keywords: *CNN, soil, nickel, non nickel*

PENDAHULUAN

Soil nikel merupakan suatu endapan residual bernilai ekonomis tersebar luas di daerah bagian timur Indonesia khususnya daerah Sulawesi. Endapan ini terbentuk oleh pelapukan intensif pada batuan yang mengandung unsur Ni, utamanya batuan ultramafik (Kusuma dkk., 2019). Keberadaannya menjadikan negara Indonesia sebagai penghasil nikel terbesar di dunia. Julukan negara Indonesia sebagai harta karun sektor komoditas tambang utamanya nikel sangatlah sesuai. Dilansir dari berita CNBC, (2021) indonesia menempati urutan peringkat pertama atau sekitar 23,7% dari total sumber daya nikel di seluruh dunia.

Keberadaan endapan nikel laterit umumnya dicirikan dengan kehadiran warna tanah merah

kekuningan gelap hingga agak hitam. Arifin dkk (2015) menyatakan bahwa warna soil laterit nikel coklat kemerahan, teksture butiran *softsand* pada daerah Kabupaten Morowali. Warna soil endapan nikel laterit daerah Kabaena, Bombana umumnya berwarna coklat tua – merah kekuningan (Jafar, 2017). Warna soil endapan nikel laterit kecamatan Pomala umumnya berwarna coklat kemerahan (Kusuma, 2019).

Perkembangan teknologi dari masa ke masa memberikan peluang dan musibah bagi generasi millennial, terutama ketika mereka tidak siap dengan perubahan itu (Azis, 2019). Perkembangan ini juga menyebabkan data berhamburan dan mudah didapatkan. Image atau citra digital merupakan salah satu bukti nyata dari kelimpahan data di berbagai media social. Kelahiran dari *computer vision* salah satunya dipicu oleh kehadiran *image*. Hingga saat ini, banyak sekali metode yang digunakan dalam mengolah data image atau citra digital.

Artificial intelligence (AI) menjadi topik menarik yang sering dibicarakan akhir-akhir ini. Kehadiran AI sendiri hampir menyentuh semua sektor kehidupan tak terkecuali untuk sektor industry. AI merupakan suatu bidang keilmuan yang membuat komputer menirukan kecerdasan dan kebiasaan manusia. *Machine learning* bekerja menggunakan algoritma yang dibuat berdasarkan pada hukum matematik yang bekerja layaknya otak manusia (Maulama & Rochmawati, 2020). Teknik dalam mengembangkan *Machine learning* terdapat 4 jenis yaitu *supervised learning, unsupervised learning, semi unsupervised learning*, dan *reinforcement learning* (Astuti, 2021). Algoritma *Convolution Neural Network* (CNN) merupakan suatu teknik sekaligus metode yang umumnya digunakan dalam mengolah citra digital atau gambar. Salah satu pemanfaatan dari *machine learning* adalah image processing atau pengolahan citra digital.

Identifikasi tipe soil dilakukan dengan panca indera penglihatan manusia dengan mengamati 2 parameter utama yaitu warna dan bentuk. Seperti halnya komputer melihat dan mempelajari data citra digital melalui warna dan bentuk yang direpresentasikan dalam angka (matrik). Proses komputer dalam melihat citra digital dilakukan menggunakan dengan metode CNN. Oleh karena itu, maksud penelitian untuk mengembangkan model *machine learning* dari data soil nikel dan non nikel. Tujuan dalam penelitian ini untuk klasifikasi soil nikel dan non nikel menggunakan *machine learning* dan mengetahui akurasi model. Hasil dari pengembangan model machine learning ini, tentu diharapkan dapat memberikan manfaat positif dan edukatif kepada seluruh kalangan masyarakat terutama untuk membantu identifikasi soil dan penerapannya dalam optimalisasi penggunaan lahan.

METODE PENELITIAN

Metode yang digunakan pada penelitian ini dalah metode penelitian kualitatif dan kuantitatif. Metode kualitatif meliputi dimulai dari penemuan masalah kemudian mengkaji studi literatur untuk menyelesaikan masalah. Metode kuantitatif terletak pada pengambilan data dan mengolah data dengan menggunakan *Convolutional Neural Network*. Kedua metode itu di implementasi menjadi beberapa tahapan meliputi pengumpulan data, pengolahan data awal, perancangan arsitektur CNN, pelatihan data citra digital menjadi model *machine learning*, dan evaluasi model hasil *training*.

Alat dan bahan yang diperlukan dalam penelitian ini meliputi *Google Colaboratory*, *GPU Tesla K80*, HP kamera resolusi 16 MP, dan bahasa pemrograman python. Adapun library dalam mengolah yakni Tensorflow.

Pengumpulan data difokuskan pada pengambilan gambar atau citra digital soil nikel dan non nikel, pengumpulan data soil non nikel dilakukan menggunakan kamera 16 MP sedangkan soil nikel dengan *crawling image* dari google. Hasil dari pengumpulan data dari 2 sumber tersebut didapatkan jumlah total 580 image.

Pengolahan data awal dilakukan dengan pembagian data sesuai dengan jumlah kelas yang akan diselesaikan. Dalam penelitian ini, jumlah kelas ada 2 yakni soil nikel dan non nikel. Kemudian jumlah total data dibagi dengan scenario data latih dan data validasi yakni 80 : 20 %. Selain itu, dilakukan berbagai teknik pre-processing gambar meliputi *rescale*, *rotation*, *zoom range*, *sheare range*, *horizontal flip* dan *vertical flip*. Semua teknik itu dilakukan untuk meningkatkan jumlah gambar atau augmentasi terhadap image yang akan diolah agar lebih variatif dan meminimalisir terjadinya *overfitting*.

Perancangan arsitektur CNN memiliki tujuan untuk mengambil atau ekstraksi fitur yang akan dipelajari ketika proses pelatihan model. Fitur yang akan dipelajari meliputi bentuk (garis, lingkaran bahkan sudut) dan warna. Perancangan arsitektur CNN dalam penelitian dibagi menjadi 2 yaitu fitur ekstraksi terdiri dari 3 layer konvolusi dan lapisan klasifikasi terdiri dari 1 *fully connected layer*. Dipadukan dengan konfigurasi *kernel* ukuran 3 x 3, *filter* layer pertama, kedua, dan ketiga berturut-turt adalah

16, 32, & 64, maxpooling 2 x 2, serta padding 0. Konfigurasi itu untuk melakukan proses pelatihan data menjadi model *machine learning*. *Fully connected layer* penelitian ini menggunakan aktivasi *Relu, hidden layer* dengan *neuron* 32, dan fungsi aktivasi klasifikasi berupa *sigmoid*.

Tabel 1. *Feature Extraction* yang dipelajari CNN

Label	*Feature Extraction*	Distribusi warna	Klasifikasi
	Warna: Coklat kehitaman, abu – abu kehitaman Tekstur: Halus bentuk dominan sama	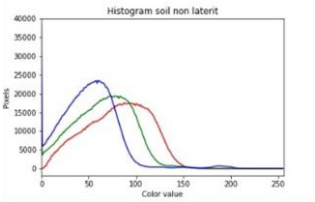	Non-Nikel
	Warna: hitam kemerahan, merah gelap kekuningan Tekstur: Kasar dan terkadang mempunyai bentuk	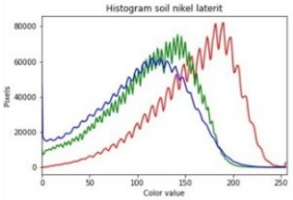	Soil Nikel

Pelatihan model dilakukan menggunakan beberapa pengaturan *backpropagation* meliputi *hyperparameter* Adam (*Adaptive Movementen Estimator*), *learning rate* 0.00005 dan *loss* function berupa *Binary Crossentropy*. Tahap ini berfungsi untuk memperoleh dan memperbarui *weight* dan *bias* sehingga bisa mendapatkan suatu hasil model *machine learning* dengan akurasi yang tinggi.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

$$Precision = \frac{TP}{TP + FP}$$

$$Recall = \frac{TP}{TP + FN}$$

$$F1\text{-}score = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

Gambar 1. Perhitungan evaluasi model

Evaluasi dari model hasil *training* berguna untuk melihat tingkat kebinggungan dari model dalam mengklasifikasikan data image input. Model akan dievaluasi untuk mengetahui tingkat keakurasian model dengan *confusion matrix* yang menampilkan *report* berupa *recall, precision, F1-Score* dan *Accuracy* (gambar 1). Ke empat dari hasil report didapatkan melalui perhitungan matematis dari *True Positive* (TP), *True Negative* (TN), *False Positive* (FP) dan *False Negative* (FN).*True positif* akan dibagi dengan semua kelas output (*true positive* dan *true negative*) untuk mendapatkan hasil evaluasi pada model yang telah dibuat (Park & Lee., 2017).

HASIL DAN PEMBAHASAN

Dataset

Pengambilan data dilakukan menggunakan kamera handpone beresolusi 16 MP, format *Red Green Blue* (RGB), ekstensi .jpeg. Pengetahuan dasar dalam membedakan atau mengklasifikasikan antara soil nikel laterit dan non laterit sangatlah diperlukan. Karena hal itu, sangatlah penting dalam pengolahan data terutama saat proses konvolusi layer yang memiliki tujuan untuk melakukan ekstraksi fitur (Tabel 1). Tabel 1 akan menjelaskan mengenai *feature extraction* pada citra digital soil yang diteliti termasuk warna dan tekstur dari masing-masing percontohan.

Arsitektur *Convolution Neural Network*

Desain dari arsitektur CNN yang dibuat pada penelitian ini ditunjukkan pada (Gambar 2). Arsitektur terbagi dalam 2 tahapan, yakni *feature learning* atau fitur ekstraksi dan *classification*. Prose feature learning dimulai dari layer (Conv2D, Relu, Maxpooling) sedangkan proses klasifikasi dimulai dari *flatten* hingga *sigmoid*. Desain arsitektur CNN dibangun menggunakan input data citra digital

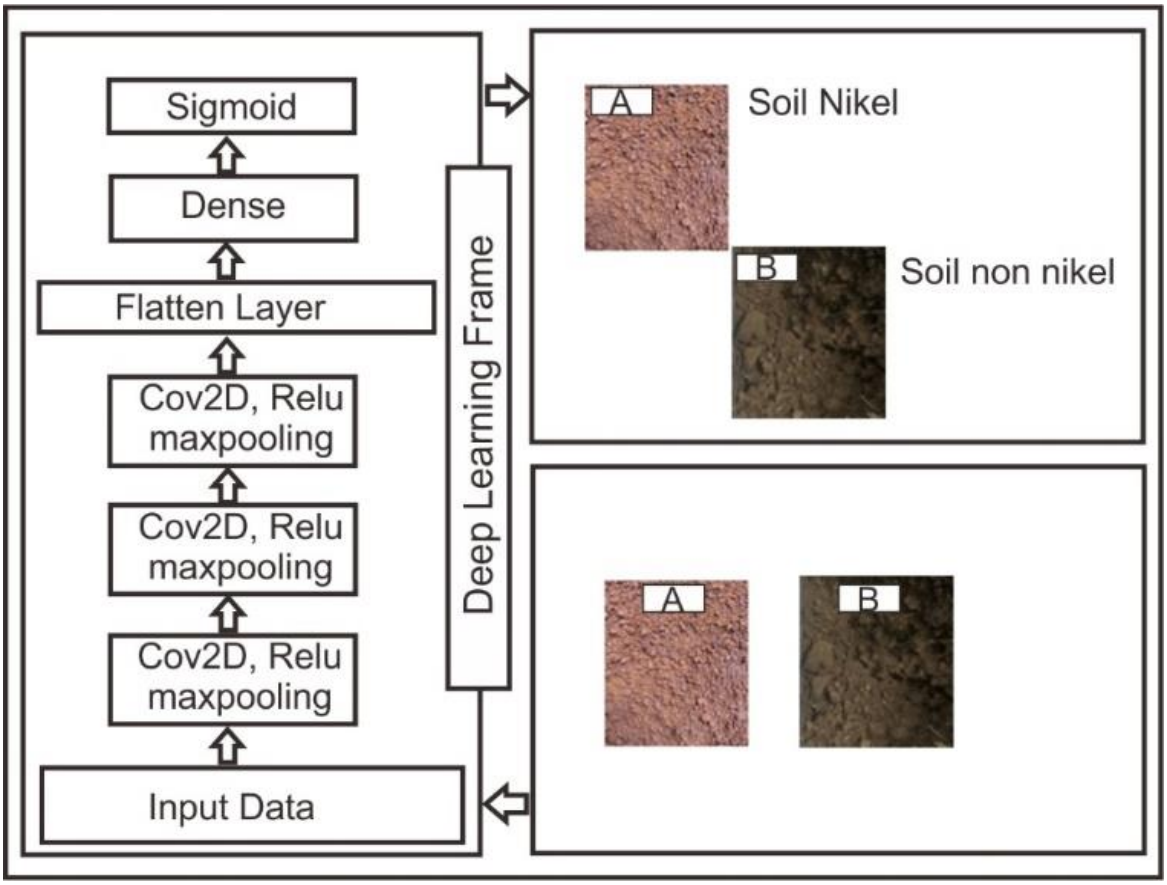

Gambar 2. Rancangan Arsitektur CNN

ukuran 227 x 227 dengan format RGB. Tiap input image atau citra digital akan dilakukan proses konvolusi pada layer yang dimiliki oleh arsitektur CNN. Konvolusi adalah proses operasi untuk menghasilkan *feature map* dengan menggunakan kernel secara berulang (Wicaksono dkk., 2020). Sedangkan hasil dari proses konvolusi akan diteruskan kedalam *fully connected layer* untuk dilakukan proses klasifikasi.

Hasil Pelatihan

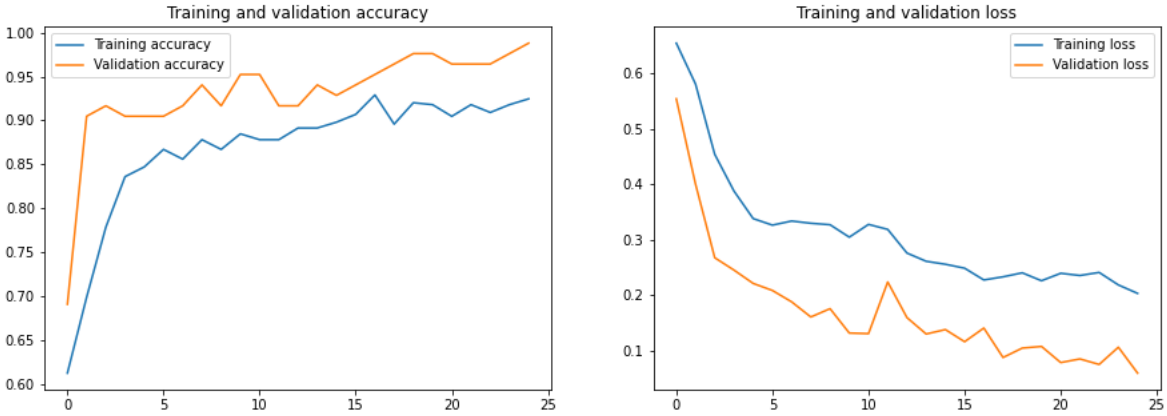

Gambar 3. Hasil *training* kiri (akurasi) dan kanan *loss* atau kegagalan

Proses pelatihan menggunakan jumlah 25 *epoch*, *batch size* 16, nilai *learning rate* 0.00005. *Accuracy* dari *training* model mencapai berkisar 97 %. Proses *training* disini menggunakan *hyperparameter* dari *Adaptive Movement Estimation* (Adam). Dalam waktu pelatihan model dilakukan dengan total waktu 20 menit 25 detik. Berikut grafik hasil *training*

seperti pada (Gambar 3). Grafik dibawah pada bagian kiri atau akurasi dapat dilihat bahwa ketika proses pelatihan atau penambahan *epoch* menyebabkan tingkat akurasi model semakin baik. *Epoch* ke 25 pada grafik kiri menunjukkan tingkat akurasi data *training* dan *validation* paling tinggi dengan nilai keduanya yakni 0,97 dan 0,92. Grafik kanan dapat dilihat bahwa semakin besar jumlah *epoch* atau lama tahap proses pelatihan tingkat *training* dan *validation loss* semakin kecil. Dari 2 grafik dibawah dapat dilihat semakin besar jumlah *epoch* memberikan dampak positif terhadap model hasil pelatihan. Grafik dibawah masih dapat diprediksi bahwa ketika jumlah *epoch* ditambah sangat memungkinkan penurunan loss atau kegagalan dan peningkatan akurasi model.

Uji Performa Model

Uji performa model dilakukan dengan menggunakan data test sebanyak 28 image untuk soil nikel dan 17 non nikel. Uji performa model ini dilakukan secara otomatis dengan metode *confusion matrix* yang menghasilkan beberapa parameter meliputi *Precission, Recall, F1-Score, Support* atau jumlah data dan akurasi (Tabel 2). Pada tabel tersebut dapat dilihat bahwa *precision, recall, f1-score* mendekati nilai 1,00 maka dapat di interprestasikan bahwa proses pelatihan data menjadi model semakin baik dan sebaliknya.

Tabel 2. Hasil Uji Performa Model

Klasifikasi	*Report Confusion matrix*			
	Precision	***Recall***	***F1-score***	***Support***
Soil nikel	0.97	1,00	0.98	28
Non Nikel	1,00	0.94	0.97	17
Akurasi model soil nikel dan non nikel			0.96	

Kemudian hasil akurasi dari pelatihan model memiliki nilai 0.96 atau 96%. Hasil akurasi yang didapatkan dari *report confusion matrix* terhadap data test inilah yang dijadikan sebagai acuan dalam menentukan hasil akurasi. Hal demikian dipilih karena pada dasarnya data input yakni data test merupakan data asli yang tidak di ikut sertakan sewaktu proses pelatihan data menjadi model *machine learning*.

Confusion matrix digunakan untuk melihat hasil kekeliruan model dalam memprediksi atau mengklasifikasikan terhadap citra digital input. Matrix ini pada dasarnya memiliki 2 hasil yakni visualisasi tanpa normalisasi dan disertai normalisasi. Pada visualisasi matrix dibawah merupakan hasil visualisasi setelah dilakukan proses normalisasi (Gambar 4). Matrix dibawah menunjukkan bahwa semua citra digital atau image kategori soil nikel dapat diklasifikasikan dengan benar semua atau nilai 1.00, namun

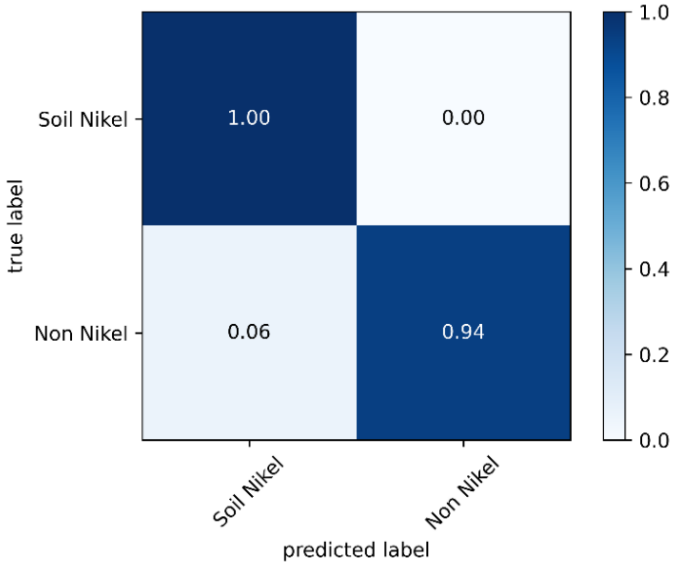

Gambar 4. Confusion *matrix* terhadap hasil model

pada citra digital soil non nikel hanya dapat diklasifikasikan benar dengan nilai 0.94 dan sisanya 0.06 dibaca sebagai soil nikel.

KESIMPULAN DAN SARAN

Kesimpulan

Pengembangan model *machine learning* dibangun dengan jumlah data soil nikel dan non nikel 580 citra digital dengan arsitektur CNN menggunakan 3-layer konvolusi dan 1-layer klasifikasi serta konfigurasi nilai *learning rate* 0.00005, waktu pelatihan model 20 menit 25 detik menghasilkan akurasi sebesar 96 %. Model *machine learning* yang telah dikembangkan dapat dilakukan dengan implementasi kedalam beberapa perangkat keras salah satunya handphone, dengan mengkonversi model (.h5) menjadi (. *tflite*).

Saran

Penelitian ini dapat dikembangkan lanjut melalui penambahan kelas kategori dari jenis soil lain, misalnya soil yang terdapat pada sekitar gunungapi ataupun soil yang berada di daerah Gunungkidul. Selain itu penelitian ini dapat dilakukan modifikasi lanjut arsitektur CNN dengan penambahan kedalaman layer serta pengaturan konfigurasi dari *backpropagation*. Penggunaan metoda transfer learning ataupun *deep convolutional neural network* juga dapat dijadikan alternative lain dalam menyelesaikan permasalahan klasifikasi untuk penelitian ini.

UCAPAN TERIMAKASIH

Terima kasih kepada Unggul Prabowo dan Rekan – rekan ahli geologi lainnya yang telah membantu identifikasi dan validasi semua data citra digital dalam penelitian ini. Selain itu, terima kasih kepada pihak institusi yang telah memberi bantuan dalam pelaksanaan penelitian ini.

REFERENSI

Arifin M, Widodo S, Anshariah, (2015). Karakteristik Endapan Nikel Laterit Pada Blok X Pt. Bintang delapan Mineral Kecamatan Bahodopi Kabupaten Morowali Provinsi Sulawesi Tengah, Jurnal Geomine, vol 01 hal 37-45.

Astuti, F. A. (2021). Pemanfaatan Teknologi Artificial Intelligence untuk Penguatan Kesehatan dan Pemulihan Ekonomi Nasional. *Jurnal Sistem Cerdas*, *4*(1), 25-34.

Azis, T. N. (2019, December). Strategi pembelajaran era digital. In *The Annual Conference on Islamic Education and Social Science* (Vol. 1, No. 2, pp. 308-318).

Jafar, N. (2017). Identifikasi Sebaran Nikel Laterit Berdasarkan Hasil Test Pit Kecamatan Kabaena Kabupaten Bombana Provinsi Sulawesi Tenggara. Jurnal Geomine, 5(2).

K. Park and J. Lee (2017).Classification of apple leaf conditions in hyper-spectral images for diagnosis of Marssonina blotch using mRMR and deep neural network, Comput. Electron. Agric., vol. 148, pp. 179–187, 201

Kusuma R A I, Kamaruddin H, Rosana M F, dan Yuningsih E T, (2019), Geokimia Endapan Nikel Laterit di Tambang Utara, Kecamatan Pomalaa, Kabupaten Kolaka, Provinsi Sulawesi Tengara. Jurnal Geologi dan Sumberdaya Mineral, 20(2), hal 85–92.

Maulama F dan Rochmawati N, (2020), Klasifikasi Citra Buah Menggunakan Convolutional Neural Network.JINACS (Journal of Informatics and Computer Science).1(II). hal : 104-108.

Wicaksono G, Andryana S, Benrahman, (2020). Aplikasi Pendeteksi Penyakit Pada Daun Tanaman Apel Dengan Metode Convolutional Neural Network. JOINTECS (Journal of Information Technology and Computer Science). 5(1), hal : 09 – 16.