

GOOGLE TEACHABLE MACHINE: PEMANFAATAN MACHINE LEARNING BERBASIS CNN UNTUK IDENTIFIKASI CEPAT BATUAN MINERAL KALSIT, KUARSA, DAN MAGNETIT

Albert Zicko Johannes^{1*}, Minsyahril Bukit², Agustinus D. Betan³, dan Jonshon Tarigan⁴

^{1,2,4}Program Studi Fisika, Fakultas Sains dan Teknik, Universitas Nusa Cendana Kupang

³Jurusan Teknik Mesin, Politeknik Negeri Kupang

¹E-mail*: zickojohannes@staf.undana.ac.id

²E-mail: m.bukit@staf.undana.ac.id

³E-mail: agustinusbetan@gmail.com

⁴E-mail: jon76tarigan@staf.undana.ac.id

ABSTRAK

Google Teachable Machine adalah aplikasi berbasis website yang dapat dimanfaatkan penggunanya untuk membuat suatu model *machine learning* tanpa perlu menulis kode. Aplikasi ini memanfaatkan Jaringan Saraf Konvolisional (CNN) dalam prosesnya. Pada penelitian ini dilakukan pemanfaatan Teachable Machine untuk membuat model *machine learning* yang dapat mengidentifikasi batuan mineral khususnya magnetit, kalsit, dan kuarsa. Prosedur penelitian dilakukan melalui beberapa tahapan yaitu: Pengumpulan Sampel, Klasifikasi Sampel (*Dataset*), Pelatihan Model (*Training*), dan Proses Evaluasi. Pengumpulan data sampel berupa gambar batuan mineral diperoleh dan diunduh dari Google. Data tersebut kemudian dibagi menjadi tiga kelas mineral yaitu magnetit, kalsit, dan kuarsa yang digunakan sebagai input pada aplikasi Teachable Machine. Pelatihan model pada Teachable Machine menggunakan *input epochs* 100, *batch size* 64, dan *learning rate* 0.0001. Hasil pemodelan Teachable Machine kemudian dievaluasi dan menunjukkan bahwa model yang diperoleh dapat mengenali mineral magnetit, kalsit, dan kuarsa dengan akurasi, presisi, recall, spesifitas, dan nilai F1 rata-rata sebesar 91.11% (86.67%), 87.30%, 86.67%, 93.33%, dan 86.50%. Penelitian ini menunjukkan bahwa pemanfaatan Teachable Machine membantu melakukan identifikasi cepat, akurat dan mudah sehingga dapat memberikan kontribusi dalam mempercepat proses analisis batuan mineral, pengambilan keputusan, dan pengembangan strategi eksplorasi. Selain itu hasil ini menunjukkan aplikasi ini memiliki potensi pengembangan yang lebih luas dalam bidang-bidang ilmu yang beragam.

Kata Kunci: Teachable Machine, Machine Learning, CNN, Magnetit, Kuarsa dan Kalsit

ABSTRACT

Google Teachable Machine is a web-based application that allows users to create a machine learning model without the need for coding. The application utilizes Convolutional Neural Networks (CNN) in its process. In this study, Teachable Machine was utilized to create a machine learning model capable of identifying specific mineral rocks, particularly magnetite, calcite, and quartz. The research procedure was conducted through several stages: Sample Collection, Sample Classification (*Dataset*), Model Training, and Evaluation Process. Sample data in the form of mineral rock images were obtained and downloaded from Google. The data was then divided into three mineral classes: magnetite, calcite, and quartz, which were used as inputs in the Teachable Machine. Model training in Teachable Machine used input epochs of 100, batch size of 64, and learning rate of 0.0001. The results of the Teachable Machine modeling were then evaluated, showing that the obtained model could recognize magnetite, calcite, and quartz minerals with an average accuracy, precision, recall, specificity, and F1-score of 91.11% (86.67%), 87.30%, 86.67%, 93.33%, and 86.50% respectively. This research indicates that the utilization of Teachable Machine assists in quick, accurate, and easy identification, thereby contributing to speeding up the process of mineral rock analysis, decision-making, and exploration strategy development. Additionally, these results demonstrate the potential for broader development of this application in various fields of study.

Keywords: Teachable Machine , Machine Learning, CNN, Magnetite, Quartz and Calcite

1. PENDAHULUAN

Teachable Machine adalah sebuah aplikasi web yang memungkinkan pengguna untuk membuat model *machine learning* tanpa perlu menulis kode [1]. Alat ini dapat digunakan untuk mengenali gambar, suara, dan pose tubuh. *Teachable Machine* menggunakan Tensorflow, sebuah perpustakaan untuk *machine*

* Penulis Korespondensi

Dikirim : 4 Maret 2024

Diterima : 1 April 2024

Publikasi Online : 31 Oktober 2024

ISSN: 2337-7631 (Printed)

ISSN: 2654-4091 (Online)

learning dalam bahasa *JavaScript*, untuk melatih dan menjalankan hasil pelatihan dalam model di peramban web, yang dapat membuat pembangunan model *machine learning* menjadi cepat, mudah, dan dapat diakses oleh siapa saja.

Dalam proses pelatihan, sistem *Teachable Machine* menggunakan Jaringan Saraf Konvolusional (CNN) [2]. CNN adalah jenis jaringan saraf tiruan yang memiliki kemampuan khusus dalam mengenali pola dan fitur dalam suatu data visual, seperti gambar dan video [3]. Sebelum CNN, pengenalan gambar dan visual lainnya seringkali memerlukan fitur-fitur manual yang harus diekstraksi dari gambar, seperti tepi, warna, dan tekstur. CNN mengubah paradigma ini dengan memungkinkan sistem secara otomatis mengekstraksi fitur-fitur penting, yang membuatnya lebih efisien dan efektif. Penggunaan CNN telah terbukti akurat meliputi berbagai bidang seperti penggunaan CNN untuk pengenalan wajah seperti penelitian yang dilakukan oleh [4], [5], dan [6], klasifikasi objek dalam gambar yang diteliti oleh [7], [8], dan [9], dan banyak lagi.

Teachable Machine dapat dimanfaatkan oleh semua orang tanpa keahlian teknis khusus mengenai *machine learning*. Pengenalan objek menggunakan *Teachable Machine* telah banyak diteliti dalam berbagai bidang studi, beberapa diantaranya dilakukan oleh [10], [11], [12], [13], [14], dan [15]. Penelitian-penelitian tersebut menunjukkan bahwa penggunaan *Teachable Machine* dapat memudahkan identifikasi dan klasifikasi secara signifikan. Khusus dalam konteks mineralogi, pemanfaatan *Teachable Machine* dalam memudahkan identifikasi dan klasifikasi memiliki potensi besar terutama untuk mengidentifikasi berbagai jenis kelas batuan mineral. Kemampuan ini tidak hanya bermanfaat dalam pengambilan keputusan di lapangan dan eksplorasi sumber daya alam, tetapi juga meningkatkan pemahaman kita tentang formasi geologi secara keseluruhan.

Meskipun banyak penelitian telah dilakukan dalam bidang identifikasi mineral dengan pendekatan dan keunikan tersendiri [16][17][18][19], namun, pendekatan identifikasi mineral yang diusulkan dalam penelitian ini menawarkan terobosan baru dengan memanfaatkan kemajuan dalam bidang *machine learning*, terutama dengan menggunakan CNN melalui *Teachable Machine*. Pendekatan ini memberikan keuntungan signifikan dalam kecepatan, akurasi dan kemudahan penggunaan. Dengan demikian, penelitian ini mengisi celah dalam literatur dengan menyajikan solusi yang inovatif dan efisien untuk identifikasi mineral yang cepat, akurat dan mudah. Oleh karena itu, tujuan penelitian ini adalah untuk menguji efektivitas *Teachable Machine* melalui parameter-parameter uji peforma dalam membantu identifikasi dan klasifikasi secara cepat dan mudah terutama untuk batuan mineral magnetit, kalsit dan kuarsa. Dengan dilakukannya penelitian ini, diharapkan dapat memberikan kontribusi sebagai berikut:

- a. Pengembangan metode identifikasi cepat, akurat dan mudah. Penelitian ini memberikan kontribusi dalam pengembangan metode identifikasi cepat batuan mineral menggunakan teknologi *machine learning* berbasis CNN. Dengan memanfaatkan *Teachable Machine*, penelitian ini menyediakan pendekatan yang mudah dipelajari dan dipahami tanpa banyak keahlian khusus untuk mengidentifikasi mineral-mineral tertentu.
- b. Kontribusi terhadap pengembangan teknologi berbasis *machine learning*. Penelitian ini juga berkontribusi pada pengembangan teknologi *machine learning* dalam konteks pengenalan objek dan identifikasi visual. Dengan memanfaatkan *Teachable Machine*, penelitian ini menunjukkan potensi aplikasi ini yang lebih luas dalam bidang-bidang ilmu yang beragam, serta memperluas pemahaman tentang penggunaan aplikasi *open-source* untuk pengembangan solusi praktis.
- c. Penerapan praktis dalam berbagai konteks. Hasil penelitian ini dapat diterapkan dalam berbagai konteks praktis, termasuk dalam industri eksplorasi mineral, pertambangan, serta penelitian geologi dan lingkungan. Teknologi identifikasi cepat dapat memberikan manfaat signifikan dalam mempercepat proses analisis batuan mineral, pengambilan keputusan, dan pengembangan strategi eksplorasi.

2. MATERI DAN METODE

Prosedur Penelitian

Berikut ini akan dijelaskan prosedur penelitian yang dilakukan melalui alur tahapan sistem identifikasi sampel dengan memanfaatkan *Teachable Machine* seperti yang ditunjukkan pada Gambar 1, meliputi tahap [14] :

- a. Pengumpulan Sampel: Tahap awal pengumpulan beragam data sampel, terutama dalam bentuk gambar batuan mineral.
- b. Klasifikasi Sampel (*Dataset*): Setelah tahap pengumpulan, sampel-sampel tersebut diklasifikasikan dan diorganisir secara sistematis ke dalam dataset terstruktur. Proses klasifikasi ini melibatkan pelabelan setiap sampel sesuai dengan jenis mineralnya, yaitu magnetit, kalsit, atau kuarsa.

- c. Pelatihan Model (*Training*): Selanjutnya, dataset terstruktur menjalani proses pelatihan model dalam penelitian ini menggunakan *Teachable Machine*. Parameter seperti *epochs*, *batch size*, dan *learning rate* dikonfigurasi secara cermat untuk mengoptimalkan proses pelatihan.
- d. Proses Evaluasi: Setelah selesai tahap pelatihan, efektivitas model yang telah dilatih dievaluasi. Proses evaluasi ini melibatkan penilaian terhadap metrik-metrik kinerja model seperti akurasi, presisi, recall, spesifisitas, dan nilai F1. Metrik-metrik ini memberikan informasi tentang kemampuan model untuk mengidentifikasi batuan mineral dengan akurat.
- e. Eksport Model (js, *TensorFlow*, dan *TensorFlow Lite*): Terakhir, model yang telah dilatih diekspor ke berbagai format file termasuk *JavaScript* (js), *TensorFlow*, dan *TensorFlow Lite*. Proses ekspor ini memfasilitasi integrasi model yang telah dilatih ke dalam berbagai aplikasi dan platform.



Gambar 1. Tahapan alur sistem identifikasi sampel dengan *Teachable Machine* [14].

Berdasarkan Gambar 1, langkah awal adalah melakukan tahap Pengumpulan Sampel. Pengumpulan sampel disini berupa gambar sampel batuan dari ketiga jenis mineral. Pengumpulan gambar ini dilakukan dengan memanfaatkan *package Python* dari PyPI yaitu *Google-image-downloader* [20]. Pengaplikasian *script* dapat dilihat pada Gambar 2. *Script* ini membantu mengunduh data secara massal dari *Google* dan merubah ukuran sampel data menjadi ukuran *pixel* yang diinginkan.

```
In [7]: pip install google-images-downloader
...
In [3]: from google_images_downloader import GoogleImagesDownloader
downloader = GoogleImagesDownloader(browser="chrome", show=False, debug=False, quiet=False, disable_safeui=False) # Construct downloader
# Download 50 images in ./downloads folder
#downloader.download("magnetite", destination="D:\download\Gambar", limit=100, resize=(224, 224), file_format="JPEG")
#downloader.download("cat", destination="C:\download\destination") # Download at specified destination
#downloader.download("bird", limit=200) # Download 100 images
#downloader.download("dog", resize=(256, 256)) # Download with images resizing
#downloader.download("fish", file_format="JPEG") # Download with images re-formatting (JPEG or PNG)
downloader.close() # Do not forget to close the driver
<
Scrolling...
Downloading...
100% [██████████] 100/100 [15:40<00:00,  9.40s/it]
```

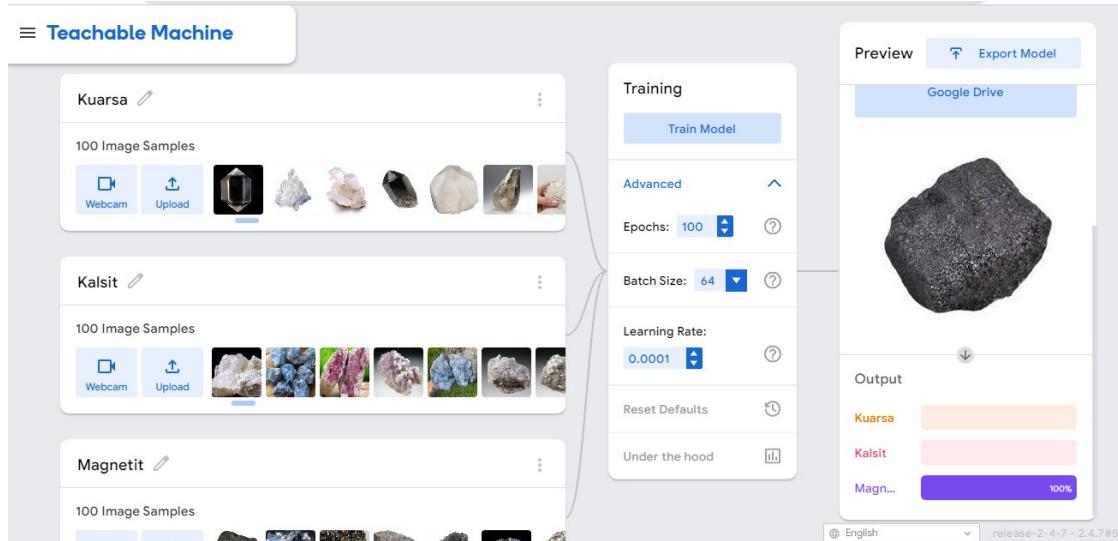
Gambar 2. Aplikasi *script* *Google-images-downloader*.

Pada proses ini juga dilakukan langkah kedua yaitu Klasifikasi Sampel. Sampel gambar yang diunduh pada penelitian ini terdiri dari 300 gambar yang telah diklasifikasikan menjadi tiga kelas yaitu 100 gambar mineral kuarsa, 100 gambar mineral kalsit dan 100 gambar mineral magnetit.

Dalam melatih model digunakan *Teachable Machine* seperti yang ditunjukkan pada Gambar 3. Terdiri dari tiga bagian yang merupakan bagian *input* (bagian kiri), proses *Training* (bagian tengah), dan *output* (bagian kanan). Pada bagian kiri Gambar 3 dilakukan pembagian tiga kelas dan pengunggahan gambar sampel mineral ke tiap kelas. Pada bagian tengah Gambar 3 adalah bagian pelatihan model (*training*). Ketika tombol “*Advance*” ditekan maka akan terlihat *Teachable Machine* memakai tiga jenis *input* yaitu *epochs*, *batch size* dan *learning rate*. *Epochs* adalah jumlah hitungan ketika setiap dan semua sampel telah dipakai *training* minimal satu kali. *Batch size* adalah ukuran set sampel yang dipakai pada satu kali *training*. Misal sampel ada 80, *batch size* adalah 16 maka data akan dibagi menjadi 5 *batch*. Setelah 5 *batch* di-*training* maka telah dilakukan 1 *epoch*. Pada *Teachable Machine* sampel yang dipakai untuk *training* dan pengujian langsung dibagi masing-masing sebanyak 85% dan 15%. Sehingga dari 300 gambar sampel yang disediakan maka akan diambil sebanyak 45 gambar khusus sebagai pengujian. Pada penelitian ini tiga *input* yang digunakan untuk *epochs*, *batch size*, dan *learning rate* adalah 100, 64, dan 0.0001.

Bagian *output* yang lebih lengkap dari *training* dapat dilihat dengan menekan tombol “*under the hood*”. *Output Teachable Machine* terdiri dari 4 hal yang merupakan hasil proses evaluasi yaitu *accuracy per class*, *confusion matrix*, *accuracy per epoch*, dan *loss per epoch*. *Accuracy per class* menyatakan nilai akurasi model *machine learning* setelah dilakukan pengujian dengan sampel tes untuk setiap sampel. *Confusion matrix* adalah cara menilai performa dari *output* suatu model dengan membandingkan antara nilai aktual dan nilai prediksi. *Accuracy per epoch* merupakan kurva plot nilai akurasi untuk setiap *epoch*. *Loss per epoch* merupakan kurva plot nilai *loss* untuk setiap *epoch*, dimana *loss* adalah ukuran yang

mengukur sejauh mana model mendekati atau menjauhi hasil yang diharapkan.



Gambar 3. Tampilan antarmuka Teachable Machine.

Evaluasi lebih lanjut dapat dilakukan dengan mengolah data *Confusion Matrix* pada Tabel 1. *True Positive* (TP) merupakan prediksi positif dan hasil benar, *True Negative* (TN) merupakan prediksi negatif dan hasil salah, *False Positive* (FP) merupakan prediksi positif dan hasil salah, dan *False Negative* (FN) merupakan prediksi negatif dan hasil benar. Pengolahan data ini berupa perhitungan parameter yaitu akurasi, presisi, *recall* (sensitivitas), spesifisitas, dan nilai F1 [15]. Akurasi (A) yaitu gambaran seberapa akurat model dalam memprediksi dengan benar. Presisi (P) menggambarkan ukuran ketepatan antara prediksi positif dengan hasil benar. *Recall* (R) atau Sensitivitas menggambarkan seberapa sering model dalam memberikan hasil benar pada prediksi positif. Spesifisitas (S) menggambarkan seberapa sering model dalam memberikan hasil benar pada prediksi negatif. Nilai F1 menggambarkan penggabungan antara presisi dan *recall* yang berguna untuk mengukur keseimbangan antara keduanya. Akurasi dapat digunakan sebagai ukuran performa jika dataset memiliki jumlah data FN dan FP yang mendekati. Namun jika tidak, maka nilai F1 digunakan sebagai ukuran performa [21].

Tabel 1. Tabel *Confusion matrix*.

		Prediksi	
		Positif	Negatif
Aktual	Benar	TP	FN
	Salah	FP	TN

Kelima nilai parameter dapat dihitung dengan Persamaan (1) hingga Persamaan (5) berikut [21], [22] :

$$A = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (1)$$

$$P = \frac{TP}{(TP + FN)} \quad (2)$$

$$R = \frac{TP}{(TP + FN)} \quad (3)$$

$$S = \frac{TN}{(TN + FP)} \quad (4)$$

$$F1 = \frac{2(R \times P)}{(R + P)} \quad (5)$$

Setelah melatih model, langkah berikutnya adalah mengevaluasi model tersebut. Pada tahap ini, dilakukan uji coba menggunakan gambar sampel atau melalui *webcam*, dan sistem *Teachable Machine* akan menampilkan hasilnya dalam bentuk akurasi dalam bentuk persentase (Gambar 3). Selain itu, model ini dapat diekspor untuk pengembangan lebih lanjut dalam bentuk berkas js, *TensorFlow*, dan *TensorFlow Lite* yang dapat dikembangkan menjadi berbagai aplikasi.

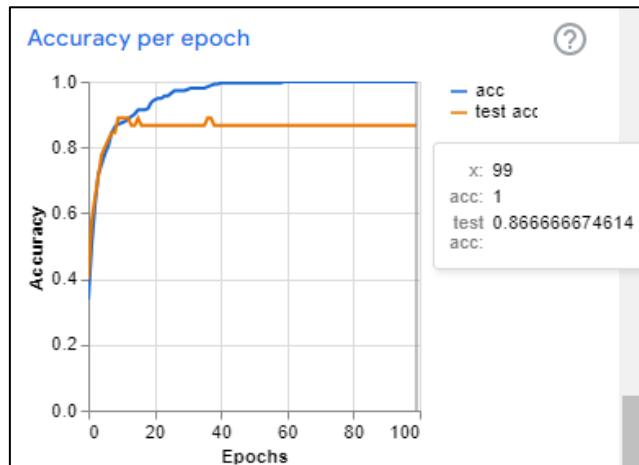
3. HASIL DAN PEMBAHASAN

Hasil *Teachable Machine* menunjukkan bahwa model yang diperoleh dapat mengenali mineral magnetit, kalsit, dan kuarsa dengan akurasi per kelas (jumlah sampel uji sebanyak 15% data sampel tiap kelas) masing-masing sebesar 100%, 73%, 87% (Gambar 4). Akurasi model setiap epoch yang diperoleh dapat dilihat pada Gambar 5, warna biru merupakan perkembangan akurasi model setiap *epoch*, sedangkan warna merah merupakan akurasi data uji dari model setiap *epoch* (R). Hasil menunjukkan terjadi peningkatan akurasi model sampai dengan 100% dan R sebesar 86.67%.

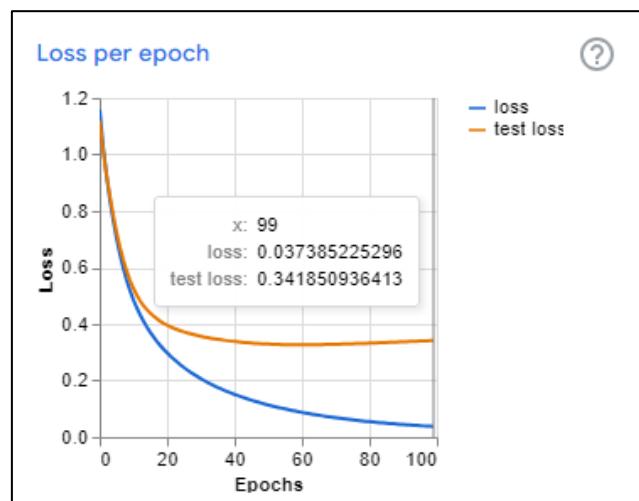
Kurva *loss per epoch* dapat dilihat pada Gambar 6, warna biru menyatakan perkembangan *loss* model setiap epoch, sedangkan warna merah adalah *test loss* data uji setiap epoch. *Loss* setiap *epoch* menunjukkan nilai 0.037 dan untuk *test loss* sebesar 0.34.

Accuracy per class		
CLASS	ACCURACY	# SAMPLES
Kuarsa	0.87	15
Kalsit	0.73	15
Magnetit	1.00	15

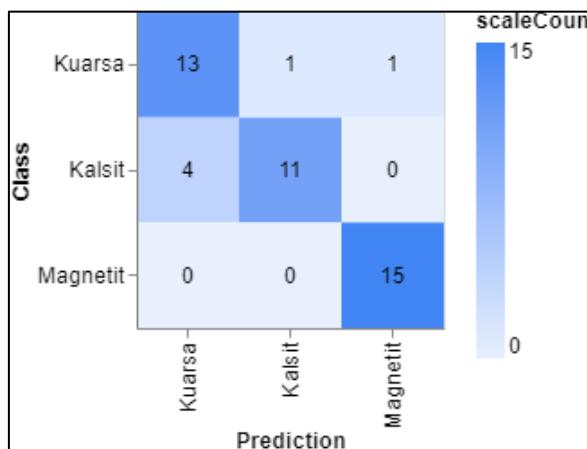
Gambar 4. *Output Teachable Machine* untuk nilai akurasi tiap kelas.



Gambar 5. *Output Teachable Machine* kurva akurasi terhadap *epoch*.



Gambar 6. *Output Teachable Machine* kurva *loss* setiap *epoch*.



Gambar 7. Confusion matrix Teachable Machine Class terhadap Prediksi.

Tabel 2. Tabel Confusion matrix biner per kelas.

		Prediksi	
		Positif	Negatif
Aktual	Benar	15	0
	Salah	1	29
Kuarsa		Prediksi	
		Positif	Negatif
Aktual	Benar	13	2
	Salah	4	26
Kalsit		Prediksi	
		Positif	Negatif
Aktual	Benar	11	4
	Salah	1	29

Selain itu untuk menilai performa model dilakukan pengolahan *confusion matrix* pada Gambar 7 yang telah dikonversi ke bentuk biner tiap kelas seperti yang ditunjukkan pada Tabel 2 [22] dengan menggunakan parameter dari Persamaan (1) – (5). Nilai setiap parameter dari tiap kelas mineral dapat dilihat pada Tabel 3. Dari hasil ini diperoleh nilai parameter yang tertinggi untuk magnetit yang menunjukkan model sudah dapat mengidentifikasi magnetit dengan cukup sempurna. Model masih memiliki kelemahan belum bisa membedakan kuarsa dan kalsit terlihat dari nilai presisi dan *recall* yang rendah. Selain itu dilihat secara keseluruhan yaitu nilai F1 yang dihasilkan adalah 86.5 %, maka bisa dikatakan model sudah bagus dimana berdasarkan standar nilai F1 diatas 70% sudah dianggap bagus [23]. Hasil lain yang terlihat adalah adanya perbedaan nilai akurasi antara menggunakan Persamaan (1) dan hasil dari *Teachable Machine*. Pada *Teachable Machine* perhitungan akurasinya langsung dengan menggunakan jumlah prediksi benar dibagi jumlah sampel tiap kelas, persamaan ini menjadi mirip dengan *recall* dimana nilai TP+FN sebanding jumlah sampel tiap kelas.

Tabel 3. Nilai parameter akurasi, presisi, *recall*, spesifisitas, dan nilai F1.

Kelas Mineral	A (%)	P (%)	R (%)	S (%)	F1 (%)
Magnetit	97.78	93.75	100.00	96.67	96.77
Kuarsa	86.67	76.47	86.67	86.67	81.25
Kalsit	88.89	92	73.33	96.67	81.46
Model	91.11	87.30	86.67	93.33	86.50

Penelitian ini menunjukkan bahwa *Teachable Machine* merupakan alat bantu yang efektif dan mudah digunakan untuk membuat model identifikasi cepat batuan mineral berdasarkan foto atau gambar. Tetapi model yang diperoleh masih perlu ditingkatkan dengan memperbanyak jumlah sampel, *epochs*, serta penentuan ukuran *batch* dan *learning rates* yang optimal.

4. KESIMPULAN

Berdasarkan hasil yang diperoleh dapat disimpulkan *Teachable Machine* sebagai aplikasi berbasis website dapat dimanfaatkan dengan efektif dan mudah dalam pembuatan model identifikasi mineral magnetit, kuarsa dan kalsit. *Training* menggunakan input epochs 100, batch size 64 dan learning rate 0.0001 berhasil memperoleh model yang cukup bagus dengan akurasi, presisi, recal, spesifitas dan nilai F1 rata-rata sebesar 91.11 %, 87.30%, 86.67%, 93.33% dan 86.50%. Dimana model tersebut mampu megidentifikasi lebih baik mineral magnetit dibandingkan dengan dua mineral lainnya.

DAFTAR PUSTAKA

- [1] Google Creative Lab, “Teachable Machine.” [Online]. Available: <https://experiments.withgoogle.com/teachable-machine>. [Accessed 24 October 2023].
- [2] N. Siddiqui, “Creating Deep Convolutional Neural Networks for Image Classification.” [Online]. Available: <https://programminghistorian.org/en/lessons/image-classification-neural-networks>. [Accessed 24 October 2023].
- [3] Datagen, “Convolutional Neural Network: Benefits, Types, and Applications.” [Online]. Available: <https://datagen.tech/guides/computer-vision/cnn-convolutional-neural-network/>. [Accessed 24 October 2023].
- [4] N. Dewi and F. Ismawan, “Implementasi Deep Learning Menggunakan CNN Untuk Sistem Pengenalan Wajah,” *Faktor Exacta*, vol. 14, no. 1, pp. 34, Mar 2021, doi: [10.30998/faktorexacta.v14i1.8989](https://doi.org/10.30998/faktorexacta.v14i1.8989).
- [5] J. Wang dan Z. Li, “Research on Face Recognition Based on CNN,” in *IOP Conference Series: Earth and Environmental Science*, Institute of Physics Publishing, Jul 2018. doi: [10.1088/1753-1315/170/3/032110](https://doi.org/10.1088/1753-1315/170/3/032110).
- [6] M. Arsal, B. A. Wardijono, dan D. Anggraini, “Face Recognition Untuk Akses Pegawai Bank Menggunakan Deep Learning Dengan Metode CNN,” *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 6, no. 1, pp. 55–63, Jun 2020, doi: [10.25077/TEKNOSI.V6I1.2020.55-63](https://doi.org/10.25077/TEKNOSI.V6I1.2020.55-63).
- [7] A. Anton, N. F. Nissa, A. Janiati, N. Cahya, dan P. Astuti, “Application of Deep Learning Using Convolutional Neural Network (CNN) Method For Women’s Skin Classification,” *Scientific Journal of Informatics*, vol. 8, no. 1, pp. 144–153, Mei 2021, doi: [10.15294/sji.v8i1.26888](https://doi.org/10.15294/sji.v8i1.26888).
- [8] N. Sharma, V. Jain, dan A. Mishra, “An Analysis Of Convolutional Neural Networks For Image Classification,” *Procedia Comput Sci*, vol. 132, pp. 377–384, Jan 2018, doi: [10.1016/J.PROCS.2018.05.198](https://doi.org/10.1016/J.PROCS.2018.05.198).
- [9] J. K. Leonard, “Image Classification and Object Detection Algorithm Based on Convolutional Neural Network,” *Science Insights*, vol. 31, no. 1, pp. 85–100, Nov 2019, doi: [10.15354/si.19.re117](https://doi.org/10.15354/si.19.re117).
- [10] Y. H. Natbais dan A. B. S. Umbu, “Aplikasi Deteksi Penyakit pada Daun Tomat Berbasis Android Menggunakan Model Terlatih Tensorflow Lite,” *TEKNOTAN*, vol. 17, no. 2, pp. 83, Agu 2023, doi: [10.24198/jt.vol17n2.1](https://doi.org/10.24198/jt.vol17n2.1).
- [11] C. Chazar dan M. H. Rafsanjani, “Penerapan Teachable Machine Pada Klasifikasi Machine Learning Untuk Identifikasi Bibit Tanaman,” dalam *Seminar Nasional : Inovasi & Adopsi Teknologi* , 2022, doi: [10.35969/inotek.v2i1.207](https://doi.org/10.35969/inotek.v2i1.207).
- [12] N. Tri, S. Saptadi, P. Chyan, dan V. M. Widjaja, “Desain Model Klasifikasi Sampah Organik Menjadi Bahan Baku Briket Biomassa Menggunakan Metode Deep Learning,” *Jurnal Informatika dan Komputer*, vol. 6, no. 2, pp. 160–168, 2022, doi: [10.26798/jiko.v6i2.559](https://doi.org/10.26798/jiko.v6i2.559).
- [13] M. Bagus Baihaqi, Y. Litanianda, dan A. Triyanto, “Implementasi Tensor Flow Lite Pada Teachable Untuk Identifikasi Tanaman Aglonema Berbasis Android,” *KOMPUTEK : Jurnal Teknik*, vol. 6, no. 1, 2022, [Online]. Available: <http://studentjournal.umpo.ac.id/index.php/komputek>. [Accessed 24 October 2023].
- [14] E. A. U. Malahina, R. P. Hadjon, dan F. Y. Bisilisin, “Teachable Machine: Real-Time Attendance of Students Based on Open Source System,” *The IJICS (International Journal of Informatics and Computer Science)*, vol. 6, no. 3, pp. 140, Nov 2022, doi: [10.30865/ijics.v6i3.4928](https://doi.org/10.30865/ijics.v6i3.4928).
- [15] A. Azzam Ajhari, K. Jonathan Sitorus, D. Putri Nur Lyrawati, E. Felix Satria Sridana, R. Lestari, dan W. Vivi Farida, “Noaa Image Classification Using Google’s Teachable Machine,” dalam *Seminar Nasional Riset dan Inovasi Teknologi (SEMNAS RISTEK) 2023*, 2023, doi: [10.30998/semnasristek.v7i1.6244](https://doi.org/10.30998/semnasristek.v7i1.6244).
- [16] N. A. Baykan dan N. Yilmaz, “Mineral identification using color spaces and artificial neural networks,” *Comput Geosci*, vol. 36, no. 1, pp. 91–97, Jan 2010, doi: [10.1016/J.CAGEO.2009.04.009](https://doi.org/10.1016/J.CAGEO.2009.04.009).
- [17] L. D. Whittig, “X-Ray Diffraction Techniques for Mineral Identification and Mineralogical Composition,” *Methods of Soil Analysis, Part 1: Physical and Mineralogical Properties, Including*

- Statistics of Measurement and Sampling, pp. 671–698, Okt 2015, doi: [10.2134/AGRONMONGR9.1.C49](https://doi.org/10.2134/AGRONMONGR9.1.C49).
- [18] J. L. Baldwin, R. M. Bateman, dan C. L. Wheatley, “Application Of A Neural Network To The Problem Of Mineral Identification From Well Logs,” *Petrophysics*, vol. 31, no. 5, 1990. [Online]. Available: <https://onepetro.org/petrophysics/article-abstract/170779/Application-Of-A-Neural-Network-To-The-Problem-Of?redirectedFrom=fulltext>. [Accessed 24 Oktober 2023].
- [19] S. Aligholi, G. R. Lashkaripour, R. Khajavi, dan M. Razmara, “Automatic mineral identification using color tracking,” *Pattern Recognit*, vol. 65, pp. 164–174, Mei 2017, doi: [10.1016/J.PATCOG.2016.12.012](https://doi.org/10.1016/J.PATCOG.2016.12.012).
- [20] Harkame, “google-images-downloader · PyPI.” [Online]. Available: <https://pypi.org/project/google-images-downloader/>. [Accessed 25 October 2023].
- [21] S. Ghoneim, “Accuracy, Recall, Precision, F-Score & Specificity, which to optimize on?”. [Online]. Available: <https://towardsdatascience.com/accuracy-recall-precision-f-score-specificity-which-to-optimize-on-867d3f11124>. [Accessed 24 Oktober 2023]
- [22] Bharathi, “Latest Guide on Confusion Matrix for Multi-Class Classification.”. [Online]. Available: <https://www.analyticsvidhya.com/blog/2021/06/confusion-matrix-for-multi-class-classification/>. [Accessed 24 October 2023]
- [23] I. Logunova, “A Guide to F1-score,” serokell. [Online]. Available: <https://serokell.io/blog/a-guide-to-f1-score>. [Accessed 26 October 2023]