

PENERAPAN MACHINE LEARNING MENGGUNAKAN TEACHABLE MACHINE UNTUK MENDETEKSI JENIS TANAH BERBASIS CITRA DIGITAL

Muhammad Abdul Syawal Laan, Edwin A. U. Malahina
Teknik Informatika Sekolah Tinggi Manajemen Informatika
Komputer Uyelindo Kupang
Jl. Perintis Kemerdekaan I, Kayu Putih, Kec. Oebobo, Kota
Kupang, Nusa Tenggara Tim. 85228
syawallaan07@gmail.com

ABSTRAK

Tanah memiliki peran penting dalam sektor pertanian dan pengelolaan lahan. Namun, metode konvensional dalam identifikasi tanah masih menghadapi tantangan dalam hal efisiensi waktu, biaya, serta ketergantungan pada tenaga ahli. Untuk mengatasi masalah ini, penelitian ini mengembangkan sistem berbasis web dalam mendeteksi jenis tanah menggunakan teknologi *Machine Learning* melalui *Teachable Machine*. Sistem ini dirancang untuk mengidentifikasi tujuh jenis tanah, yaitu aluvial, andosol, entisol, inceptisol, humus, kapur, dan pasir, berdasarkan citra digital yang dikumpulkan dari berbagai lokasi di Kupang dan internet. Metode yang digunakan melibatkan pelatihan model *Machine Learning* menggunakan *Teachable Machine*, yang kemudian diintegrasikan ke dalam platform berbasis web. Pengujian dilakukan untuk mengevaluasi tingkat akurasi sistem dalam mengklasifikasikan jenis tanah serta memberikan rekomendasi tanaman yang sesuai. Hasil penelitian menunjukkan bahwa sistem mencapai tingkat akurasi 90%, dengan variasi akurasi untuk masing-masing jenis tanah. Dengan adanya sistem ini, diharapkan pengelolaan lahan menjadi lebih efektif dan berkelanjutan di wilayah Kupang.

Kata Kunci : Citra Digital, Klasifikasi Tanah, Machine Learning, Pengolahan Citra, Teachable Machine.

1. PENDAHULUAN

Tanah memiliki peran penting dalam berbagai sektor, termasuk pertanian dan infrastruktur. Keberagaman jenis tanah di Kupang memerlukan proses identifikasi yang akurat untuk mendukung pemanfaatan lahan secara optimal[1].

Namun, metode konvensional dalam identifikasi tanah masih menghadapi tantangan dalam hal efisiensi waktu, biaya, serta ketergantungan pada tenaga ahli. Pendekatan tradisional ini membutuhkan analisis laboratorium yang memakan waktu lama dan sulit diterapkan secara luas oleh petani atau pihak lain yang membutuhkan informasi cepat mengenai kondisi tanah

Perkembangan teknologi, khususnya dalam pengolahan citra digital dan *Machine Learning*, telah membuka peluang baru dalam proses identifikasi tanah. Penelitian sebelumnya menunjukkan bahwa metode *Machine Learning* berbasis citra mampu mencapai akurasi tinggi dalam pengenalan objek berbasis gambar[2].

Potensi ini dapat dimanfaatkan untuk mendeteksi jenis tanah dengan biaya yang lebih rendah dan proses analisis yang lebih cepat dibandingkan metode konvensional. Penelitian ini mengembangkan sistem berbasis website yang mengintegrasikan *Machine Learning* untuk mengklasifikasikan jenis tanah serta memberikan rekomendasi tanaman yang sesuai. Sistem ini dirancang untuk membantu petani di Kupang dalam mengambil keputusan berbasis data guna mengoptimalkan pemanfaatan lahan. Dengan memanfaatkan dataset gambar tanah yang diproses menggunakan algoritma klasifikasi, sistem ini dapat meningkatkan efisiensi identifikasi tanah dan dapat diakses dengan lebih mudah oleh masyarakat luas[3].

Selain itu, penelitian oleh[4] menyatakan bahwa pengaturan *epoch* dan *learning rate* dalam *Teachable Machine* dapat mengoptimalkan akurasi model klasifikasi. Oleh karena itu, penelitian ini tidak hanya berfokus pada penerapan teknologi *Machine Learning* untuk identifikasi tanah, tetapi juga mengkaji optimalisasi parameter model guna meningkatkan akurasi deteksi tanah secara signifikan.

2. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Penelitian ini didasari oleh beberapa penelitian terdahulu yang menunjukkan efektivitas *Machine Learning* dalam pengenalan dan klasifikasi objek berbasis citra digital. menggunakan *Convolutional Neural Network* (CNN) untuk klasifikasi tanaman pada citra resolusi tinggi,[5].

Membuktikan kemampuan CNN dalam mengenali objek dengan akurasi tinggi. Penelitian ini relevan karena CNN merupakan bagian dari arsitektur yang digunakan oleh *Teachable Machine*, yang juga membutuhkan pengenalan pola berbasis gambar untuk klasifikasi tanah

[6]Mengembangkan aplikasi *Deep Learning* berbasis Android untuk mendeteksi penyakit daun singkong menggunakan TensorFlow[7].

Studi ini menunjukkan potensi *Machine Learning* dalam aplikasi mobile untuk bidang pertanian. Selain itu, penelitian tentang *Teachable Machine* menyarankan bahwa pengaturan parameter seperti *epoch* dan *learning rate* dapat memengaruhi akurasi model klasifikasi[8]

Penelitian tentang mengaplikasikan metode *Support Vector Machine* (SVM) untuk pengenalan

dalam pola tanda tangan menggunakan data hiperspektral [9], menunjukkan bahwa metode ini dapat mencapai akurasi tinggi dalam identifikasi.

Penelitian tentang mengembangkan model CNN untuk klasifikasi geologi berbasis citra, yang mencapai tingkat akurasi tinggi dalam mendeteksi karakteristik tanah dari citra udara.[10]

[11] Penelitian ini menerapkan algoritma *Random Forest* untuk klasifikasi kualitas air dan prediksi kelayakan air minum. Penggunaan teknik data mining, khususnya *Random Forest*, diharapkan dapat mengidentifikasi pola kompleks dalam data dan faktor-faktor yang mempengaruhi kualitas air, menggunakan dataset *Water*.

2.2. Machine Learning Dalam Klasifikasi Citra

Machine Learning telah digunakan secara luas dalam pengolahan citra digital, terutama dalam bidang pertanian dan geologi. CNN dan SVM menjadi teknik yang sering digunakan dalam mengklasifikasikan citra tanah dengan akurasi yang tinggi [12].

Penggunaan *Teachable Machine* dalam penelitian ini didasarkan pada kemampuannya dalam mempermudah proses pelatihan model klasifikasi tanpa memerlukan keahlian teknis mendalam.[13]

2.3. Teoretis Teachable Machine

Teachable Machine merupakan platform berbasis web yang dikembangkan oleh Google untuk memungkinkan pengguna melatih model *Machine Learning* dengan mudah. Platform ini mendukung klasifikasi berbasis citra, suara, dan pose tubuh. Penelitian sebelumnya menyebutkan bahwa optimalisasi parameter seperti jumlah *epoch* dan *learning rate* berpengaruh signifikan terhadap akurasi model yang dihasilkan[14].

2.4. Pengolahan Citra Digital Dalam Identifikasi Tanah

Pengolahan citra digital mencakup proses pra-pemrosesan, ekstraksi fitur, dan klasifikasi. Dalam penelitian ini, teknik normalisasi warna dan peningkatan kontras digunakan untuk meningkatkan kualitas citra tanah sebelum diklasifikasikan menggunakan model *Teachable Machine*.

2.5. Jenis Tanah Dan Karakteristiknya


Jenis tanah yang digunakan dalam penelitian ini terdiri dari aluvial, andosol, entisol, inceptisol, humus, kapur, dan pasir. Setiap jenis tanah memiliki karakteristik unik yang mempengaruhi kesesuaian tanaman yang dapat tumbuh di atasnya. Dengan bantuan *Machine Learning*, proses identifikasi tanah dapat dilakukan dengan lebih cepat dan akurat dibandingkan metode konvensional.

3. METODE PENELITIAN

3.1. Metode Penelitian

Penelitian ini terbagi menjadi tiga tahapan utama yaitu perancangan sistem, uji coba, dan penerapan


Tahapan penelitian dapat dilihat pada gambar 1. Penelitian ini diawali dengan pengamatan langsung untuk mengidentifikasi masalah melalui studi literatur yang melibatkan bahan bacaan dari berbagai sumber. Setelah itu, dilakukan analisis data untuk menentukan dataset yang akan digunakan sebagai bahan pelatihan, yang meliputi pengumpulan gambar jenis tanah. Sistem yang dikembangkan kemudian diuji menggunakan *Teachable Machine* untuk mengevaluasi kinerjanya, dengan tujuan utama menguji akurasi sistem. Hasil prediksi sistem ini selanjutnya diekspor ke TensorFlow.js, sebagai langkah awal pengembangan web. Proses pengembangan web ini melibatkan bahasa pemrograman seperti JavaScript, PHP, MYSQL, dan HTML, yang mencakup perancangan, implementasi, integrasi, pengujian, dan pemeliharaan, guna menilai kemampuan web yang dikembangkan.



Gambar 1. Tahapan Penelitian

3.2. Teachable Machine

Pada gambar 2. Menampilkan ruang kerja *Teachable Machine*. Menurut situs resmi *Teachable Machine* (*Teachable Machine*, 2017) menjelaskan bahwa *Teachable Machine* adalah sebuah website yang dibuat oleh Google yang dapat membantu dalam membuat model ML dengan cepat, mudah dan dapat diakses oleh semua orang. *Teachable Machine* menawarkan fitur untuk melakukan evaluasi dan penyesuaian model lebih lanjut selama proses pelatihan, dimana pengguna bisa mengatur parameter seperti jumlah *epoch*, *batch size*, dan *learning rate*. Pengguna juga memiliki hak akses untuk menilai model yang telah dilatih dengan menggunakan *confusion matrix* dan melihat grafik selama setiap *epoch*.




Gambar 2. Tampilan website Teachable Machine

3.3. Convolutional Neural Network

Pada gambar 3. Menampilkan arsitektur CNN yang merupakan pengembangan dari ANN konvensional. *Artificial Neural Network* (ANN) merupakan metode *Machine Learning* yang memiliki 3-4 layer yang dinamakan multilayer perceptron. CNN memiliki arsitektur *network* yang terdiri dari puluhan hingga ratusan layer. CNN memproses citra melalui *network layer* dan menghasilkan *output* pada kelas tertentu. Setiap layer melakukan pembelajaran, *Output* dari setiap layer digunakan sebagai *input* untuk layer selanjutnya. Pada awal *network*, layer menghasilkan fitur-fitur sederhana seperti warna, kecerahan dan tepi. Kemudian, jaringan tersebut berkembang untuk mengenali fitur yang lebih kompleks[15].

Jaringan Saraf Konvolusional merupakan struktur yang terdiri dari tiga tingkatan utama, yakni tingkatan masukan (*input layer*), tingkatan keluaran (*output layer*), dan sejumlah tingkatan tersembunyi (*hidden layers*). Tingkatan tersembunyi umumnya mengandung berbagai jenis lapisan, termasuk lapisan konvolusional, lapisan pooling, lapisan normalisasi, lapisan ReLU, *fully connected layer*, dan *loss layer*.



Gambar 3. Arsitektur CNN

3.4. Jenis Tanah

Tanah memiliki karakteristik unik seperti tekstur, warna, dan kandungan mineral. Karakteristik tersebut berperan penting dalam menentukan tingkat kesuburan tanah dan jenis tanaman yang cocok untuk ditanam. Setiap jenis tanah memiliki komposisi dan sifat fisik yang berbeda, yang memengaruhi kapasitas tanah dalam mendukung pertumbuhan tanaman. Penelitian ini akan menganalisis 7 jenis tanah, yaitu tanah aluvial, andosol, entisol, inceptisol, humus,


kapur, pasir. Pada Tabel 1. Menampilkan data tanah yang akan dijadikan dataset.

Tabel 1. Data Tanah

No	Nama Tanah	Jumlah Data	Gambar
1	Aluvial	100 Sampel	
2	Andosol	100 Sampel	
3	Entisol	100 Sampel	
4	Hmus	100 Sampel	
5	Inceptisol	100 Sampel	
6	Kapur	100 Sampel	
7	Pasir	100 Sampel	

3.5. Usecase Diagram


Pada gambar 4. Menampilkan *Usecase diagram* menggambarkan sebuah interaksi antar satu atau lebih aktor dengan fitur-fitur sistem dan menunjukkan fungsionalitas yang diharapkan dari sebuah sistem untuk pengguna (*user*). Aktor yang dapat mengakses Sistem ini meliputi admin dan user. kedua aktor tersebut memiliki hak akses yang berbeda.



Gambar 4. Usecase Diagram


3.6. Class Diagram

Pada gambar 5. Menampilkan *Class Diagram* yang merupakan kumpulan metode atau alat yang digunakan untuk menggambarkan data atau objek yang diciptakan, yang berakar dan bersumber dari realitas nyata yang dikenal sebagai entitas, beserta relasi antar entitas tersebut, menggunakan beragam notasi.



Gambar 5. *Class Diagram*

3.7. Activity Diagram



Gambar 6. *Activity Diagram*

Pada Gambar 6, ditampilkan *Activity Diagram* yang menggambarkan alur kerja sistem dari awal hingga akhir. Diagram ini menunjukkan tahapan proses utama, mulai dari pengguna mengunggah gambar tanah, sistem melakukan pemrosesan citra, hingga hasil klasifikasi dan rekomendasi tanaman ditampilkan kepada pengguna. Diagram ini digunakan untuk memvisualisasikan bagaimana proses berjalan dalam sistem secara berurutan.

4. HASIL DAN PEMBAHASAN

4.1. Hasil Pengujian Sistem


Implementasi teknologi *Machine Learning* berbasis website dirancang untuk menghasilkan sistem yang dapat membantu pengguna dalam mengidentifikasi jenis tanah serta kesesuaiannya dengan tanaman tertentu. Secara umum, sistem ini dapat diakses oleh dua jenis pengguna, yaitu admin dan user. Sistem ini dibangun menggunakan bahasa pemrograman PHP dan MySQL sebagai database server-nya.

Pada gambar 6. Menampilkan halaman login khusus untuk admin. Admin harus memasukkan username dan password yang terdaftar. Jika salah, sistem menampilkan error; jika benar, admin diarahkan ke beranda.



Gambar 6. Halaman Login admin


Pada gambar 7. Menampilkan halaman beranda setelah admin login. Admin dapat mengakses tiga menu utama: data admin, data class, dan data identifikasi. Tersedia juga tombol logout di pojok kanan bawah untuk keluar dari sistem.



Gambar 7. Halaman beranda admin


Pada gambar 8. Menampilkan halaman khusus untuk admin dengan fitur menambah, mengubah, dan

menghapus data. Halaman ini menampilkan informasi pengguna yang memiliki akses ke sistem, termasuk nama, alamat, telepon, email, dan password.

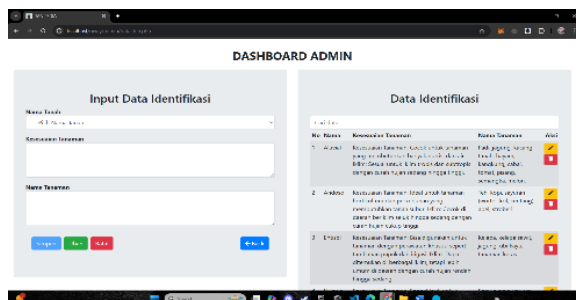


Gambar 8. Halaman Data admin

Pada gambar 9. Menampilkan halaman yang dirancang untuk admin dalam mengelola data jenis tanah, termasuk menambah, mengubah, dan menghapus informasi. Di sisi kanan, data tanah seperti nama dan deskripsi ditampilkan dengan rapi. Sementara itu, di sisi kiri terdapat formulir untuk mempermudah proses pengeditan dan penambahan data. Selain itu, tombol "Back" disediakan untuk memudahkan navigasi kembali ke halaman beranda



Gambar 9. Halaman Data class



Gambar 10. Halaman Data identifikasi

Pada gambar 10. Menampilkan Halaman ini memungkinkan admin mengelola data identifikasi jenis tanah, termasuk nama, kesesuaian iklim, dan daftar tanaman. Formulir pengeditan ada di kiri, sementara data ditampilkan di kanan. Tombol "Back" disediakan untuk kembali ke beranda.


Pada gambar 11. Menampilkan halaman antarmuka utama dari sistem deteksi jenis tanah di TaniPedia, menawarkan dua metode utama untuk melakukan identifikasi. Pengguna dapat memilih untuk mendeteksi jenis tanah secara *real-time*

menggunakan kamera atau dengan mengunggah gambar tanah dalam format gambar untuk dianalisis secara manual




Gambar 11. Halaman Utama user

Pada gambar 12. Menampilkan Halaman yang memungkinkan pengguna untuk mengenali jenis tanah dengan cara mengunggah gambar. Cukup pilih foto tanah yang ingin dianalisis, lalu tekan tombol "Unggah dan Prediksi". Sistem akan memproses gambar dan menampilkan hasil deteksi, termasuk nama jenis tanah beserta tingkat akurasi. Jika ingin mengetahui lebih banyak informasi tentang tanah yang terdeteksi, pengguna dapat menekan tombol "Cek Tanah".




Gambar 12. Halaman Deteksi tanah upload gambar

Pada gambar 13. Menampilkan halaman yang berfungsi untuk mendeteksi jenis tanah melalui pemindaian *real time*. Pengguna dapat mengambil gambar tanah secara *real time* dengan menekan tombol kamera. Setelah itu, sistem akan menganalisis dan menampilkan hasil deteksi, termasuk nama tanah serta tingkat akurasi. Selanjutnya, pengguna dapat mengklik tombol "Cek Tanah" untuk mendapatkan informasi detail tentang yang terdeteksi.




Gambar 13. Halaman Deteksi tanah secara real time

Pada gambar 14. Jika objek tanah yang diunggah atau dipindai tidak terdeteksi dengan baik, sistem akan menampilkan pesan "Nama tanah tidak ditemukan di database". Selain itu, tombol "Cek Tanah" akan dinonaktifkan dan tidak dapat diklik.



Gambar 14. Halaman Deteksi tanah akurasi rendah

Pada gambar 15. Menampilkan ketika sistem berhasil mendeteksi jenis tanah. Informasi yang ditampilkan mencakup nama tanah, deskripsi, manfaat, kesesuaian tanaman, serta jenis tanaman yang cocok. Jika tanah yang terdeteksi memiliki kandungan unsur hara yang baik, maka sistem akan merekomendasikan tanaman yang sesuai. Pengguna dapat kembali ke halaman sebelumnya dengan menekan tombol "Kembali".



Gambar 15. Halaman hasil Deteksi tanah

4.2. Pengujian nilai *hyperparameter* dan analisis data

Penelitian ini dilakukan berdasarkan data yang diperoleh melalui telaah literatur dan pengamatan lapangan. Sebanyak 100 sampel citra per jenis tanah telah berhasil dikumpulkan dalam dataset, mencakup tanah aluvial, andosol, entisol, humus, inceptisol, kapur, dan pasir. Penelitian ini bertujuan untuk mengeksplorasi pengaruh nilai *hyperparameter*, yaitu *epoch*, *learning rate*, dan *batch size*, terhadap akurasi klasifikasi citra tanah menggunakan metode eksperimental. Data citra tanah yang diperoleh dari internet dikategorikan berdasarkan jenisnya, kemudian dibersihkan dan dimodifikasi dengan teknik seperti perubahan posisi dan rotasi untuk meningkatkan variasi data. Proses klasifikasi dilakukan menggunakan *Teachable Machine* dengan model *Convolutional Neural Network* (CNN), di mana nilai *epoch*, *learning rate*, dan *batch size* dijadikan variabel yang diuji untuk menentukan kombinasi parameter terbaik dalam meningkatkan akurasi sistem.

Tabel 2 parameter pengujian dengan nilai *epoch*, *learning rate* dan *batch size*

No	Nilai epoch	Nilai Learning rate	Nilai Batch Size
1.	10	0.00001	16
2	50	0.0001	32
3	100	0.001	64
4	250	0.01	128

Berdasarkan Tabel 2, maka didapatkan sejumlah 64 kali pengujian untuk menilai berbagai tingkat akurasi dalam pengenalan citra melalui persentase. Dalam pengujian ini, data citra dibagi menjadi dua kategori: data untuk pelatihan dan data untuk pengujian. Hal ini bertujuan untuk menentukan persentase akurasi terbaik berdasarkan sampel data yang dilatih menggunakan layanan *Teachable Machine*. Hasil pengujian dan proses penentuan nilai optimasi tersebut dapat dilihat pada Tabel 3.

Tabel 3. Pengujian variasi nilai *epoch*, *batch size* dan *learning rate*

No	Sampel	Epoch	Batch Size	Learning rate	Loss per epoch		Accuracy per epoch		Original test	Outside test
					loss	Test loss	acc	Tes acc		
1	100	10	16	0.00001	1.58	1.59	0.59	0.53	18-23%	18-25%
2	100	10	16	0.0001	0.35	0.49	0.95	0.90	29-66%	22-51%
3	100	10	16	0.001	0.01	0.11	1	0.95	64-100%	43-93%
4	100	10	16	0.01	1.57	1.59	0.64	0.58	21-37%	65-100%
5	100	10	32	0.00001	1.57	1.59	0.64	0.58	17-25%	19-34%
6	100	10	32	0.0001	0.53	0.54	0.91	0.89	29-96%	32-51%
7	100	10	32	0.001	0.25	0.10	1	0.98	49-100%	54-94%
8	100	10	32	0.01	0.00	0.56	1	0.98	68-100%	58-100%
9	100	10	64	0.00001	1.76	1.78	0.42	0.35	17-23%	19-25%
10	100	10	64	0.0001	0.75	0.92	0.88	0.76	24-92%	21-28%
11	100	10	64	0.001	0.04	0.14	1	0.95	54-100%	27-65%
12	100	10	64	0.01	0.00	0.66	1	0.99	56-100%	74-97%
13	100	10	128	0.00001	1.81	1.81	0.26	0.27	17-33%	18-25%
14	100	10	128	0.0001	1.11	1.11	0.79	0.79	27-54%	19-30%
15	100	10	128	0.001	0.10	0.27	0.98	0.92	51-100%	40-86%
16	100	10	128	0.01	0.10	0.27	0.98	0.92	38-100%	25-66%

No	Sampel	Epoch	Batch Size	Learning rate	Loss per epoch		Accuracy per epoch		Original test	Outside test
					loss	Test loss	acc	Tes acc		
17	100	50	16	0.00001	0.64	0.68	0.89	0.93	25-88%	25-46%
18	100	50	16	0.0001	0.02	0.08	1	0.99	52-100%	45-88%
19	100	50	16	0.001	0.00	0.09	1	0.96	67-100%	33-92%
20	100	50	16	0.01	0.00	0.13	1	0.98	95-100%	64-100%
21	100	50	32	0.00001	0.85	1.02	0.87	0.76	19-74%	22-35%
22	100	50	32	0.0001	0.05	0.21	1	0.95	45-100%	42-72%
23	100	50	32	0.001	0.00	0.00	1	1	99-100%	50-99%
24	100	50	32	0.01	0.00	0.05	1	0.97	62-100%	53-99%
25	100	50	64	0.00001	1.14	1.26	0.79	0.68	30-54%	18-31%
26	100	50	64	0.0001	0.13	0.24	0.98	0.93	42-99%	45-74%
27	100	50	64	0.001	0.00	0.15	1	0.94	76-100%	30-84%
28	100	50	64	0.01	0.00	0.23	1	0.95	65-100%	81-100%
29	100	50	128	0.00001	1.46	1.44	0.68	0.69	19-33%	16-26%
30	100	50	128	0.0001	0.22	0.30	0.97	0.95	35-97%	35-84%
31	100	50	128	0.001	0.00	0.13	1	0.95	51-100%	48-94%
32	100	50	128	0.01	0.00	0.18	1	0.94	52-100%	82-100%
33	100	100	16	0.00001	0.28	0.46	0.96	0.90	43-94%	35-57%
34	100	100	16	0.0001	0.00	0.08	1	0.96	50-100%	29-78%
35	100	100	16	0.001	0.00	0.02	1	0.98	62-100%	50-100%
36	100	100	16	0.01	0.00	0.02	1	0.98	94-100%	50-97%
37	100	100	32	0.00001	0.50	0.61	0.93	0.86	33-90%	23-44%
38	100	100	32	0.0001	0.01	0.15	1	0.96	75-100%	63-97%
39	100	100	32	0.001	0.00	0.17	1	0.94	61-100%	36-98%
40	100	100	32	0.01	0.00	0.32	1	0.95	91-100%	84-100%
41	100	100	64	0.00001	0.71	0.82	0.90	0.81	24-94%	20-30%
42	100	100	64	0.0001	0.03	0.23	1	0.90	46-100%	63-96%
43	100	100	64	0.001	0.00	0.29	1	0.94	58-100%	77-100%
44	100	100	64	0.01	0.00	0.07	1	0.96	51-100%	50-99%
45	100	100	128	0.00001	1.06	1.16	0.84	0.76	19-70%	20-30%
46	100	100	128	0.0001	0.07	0.21	0.99	0.94	61-100%	45-78%
47	100	100	128	0.001	0.00	0.10	1	0.98	69-100%	39-94%
48	100	100	128	0.01	0.00	0.10	1	0.97	87-100%	50-98%
49	100	250	16	0.00001	0.05	0.24	0.99	0.91	51-100%	52-83%
50	100	250	16	0.0001	0.00	0.07	1	0.98	90-100%	68-99%
51	100	250	16	0.001	0.00	0.22	1	0.97	60-100%	39-95%
52	100	250	16	0.01	0.00	0.08	1	0.98	63-100%	51-94%
53	100	250	32	0.00001	0.15	0.21	0.98	0.95	40-100%	43-72%
54	100	250	32	0.0001	0.00	0.10	1	0.97	66-100%	39-87%
55	100	250	32	0.001	0.00	0.07	1	0.98	86-100%	39-99%
56	100	250	32	0.01	0.00	0.33	1	0.92	86-100%	94-100%
57	100	250	64	0.00001	0.29	0.47	0.96	0.89	46-82%	24-48%
58	100	250	64	0.0001	0.29	0.47	0.96	0.89	53-91%	33-46%
59	100	250	64	0.001	0.00	0.22	1	0.96	54-100%	91-100%
60	100	250	64	0.01	0.00	0.00	1	1	52-100%	58-100%
61	100	250	128	0.00001	0.51	0.57	0.91	0.90	32-92%	28-51%
62	100	250	128	0.0001	0.01	0.15	1	0.93	51-100%	48-89%
63	100	250	128	0.001	0.00	0.21	1	0.95	61-100%	72-100%
64	100	250	128	0.01	0.00	0.14	1	0.98	77-100%	93-100%

Tabel 4. Tingkat Pengujian Terbaik

No	Sample	Epoch	Learning Rate	Batch Size	Loss Per Epoch		Accuracy Per Epoch		Original	Outside
					loss	test loss	acc	test acc		
1	100	100	0.0001	16	0.00	0.08	1	0.96	50-100%	29-78%
2	100	250	0.0001	32	0.00	0.10	1	0.97	66-100%	39-87%
3	100	100	0.001	128	0.00	0.10	1	0.98	69-100%	39-94%
4	100	250	0.001	16	0.00	0.22	1	0.97	60-100%	39-95%
5	100	250	0.0001	32	0.00	0.10	1	0.97	66-100%	39-87%
6	100	50	0.001	128	0.00	0.13	1	0.95	51-100%	48-94%
7	100	100	0.001	128	0.00	0.10	1	0.98	69-100%	39-94%
8	100	50	0.001	16	0.00	0.09	1	0.96	67-100%	33-92%
9	100	50	0.1	32	0.00	0.05	1	0.97	62-100%	53-99%
10	100	50	0.001	64	0.00	0.15	1	0.94	76-100%	30-84%

Berdasarkan data tabulasi yang disajikan, pencarian nilai *epoch*, *learning rate*, dan *batch size* yang optimal telah dilakukan dengan menggunakan *Teachable Machine* dengan menggunakan 100 sampel gambar per kelas untuk total 7 kelas. Analisis ini menghasilkan kesimpulan bahwa terdapat tingkatan efektivitas pengenalan objek yang sangat baik, yang dapat dilihat melalui tabel 3. Yang menunjukkan nilai persentase terendah dari "*Outside Test Class*", yang mengindikasikan penurunan dalam pengenalan gambar objek asing yang tidak termasuk dalam kategori yang diuji. Meskipun begitu, kesimpulan ini juga terpengaruh oleh akurasi dari data uji awal untuk jenis tanah yang diuji, yang disebut dengan "*Original Test Class*". Kualitas hasil akan semakin meningkat seiring dengan bertambahnya persentase pada kategori "*Original Test Class*". Inilah 10 hasil pengujian teratas yang telah dipilih dan dianalisis berdasarkan tingkat akurasi, yang dapat dilihat pada Tabel 4.

5. KESIMPULAN DAN SARAN

Berdasarkan penelitian yang telah dilakukan, sistem deteksi jenis tanah dapat dilakukan melalui dua metode, yaitu pemindaian real-time atau dengan mengunggah gambar objek tanah. Optimalisasi klasifikasi citra menggunakan *Teachable Machine* diperoleh melalui pengujian berbagai kombinasi parameter, seperti epoch (50, 100, 250), batch size (16, 32, 64, 128), serta learning rate (0.0001, 0.001, 0.1), dengan total 700 sampel data latih yang terdiri dari 100 sampel per kelas untuk 7 kelas tanah. Hasil pengujian menunjukkan bahwa kombinasi *epoch* 100, *learning rate* 0.001, dan *batch size* 128 memberikan performa terbaik dengan akurasi 69-100% untuk data asli dan 39-94% untuk data luar. Sistem yang dikembangkan telah terbukti mampu mengklasifikasikan jenis tanah secara optimal sesuai dengan fungsinya, sebagaimana dibuktikan melalui pengujian langsung di lapangan yang menunjukkan bahwa seluruh fitur bekerja dengan baik. Selain sebagai alat klasifikasi, sistem ini juga memiliki nilai edukatif dengan memberikan informasi mengenai berbagai jenis tanah, karakteristiknya, serta kesesuaiannya dengan jenis tanaman tertentu, sehingga dapat membantu dalam pengambilan keputusan terkait pemanfaatan lahan. Untuk pengembangan lebih lanjut, beberapa saran yang dapat diterapkan agar sistem ini lebih optimal dan akurat antara lain: menambahkan lebih banyak jenis tanah agar mampu mengenali variasi tanah yang lebih luas, meningkatkan jumlah dan kualitas dataset untuk memperoleh akurasi yang lebih tinggi, serta mengembangkan sistem ke dalam bentuk aplikasi mobile agar lebih praktis digunakan oleh petani, peneliti, dan pihak terkait. Selain itu, penggunaan model klasifikasi citra lain seperti EfficientNet, MobileNet, DenseNet, Vision Transformer (ViT), atau YOLO dapat dipertimbangkan untuk meningkatkan akurasi dan efisiensi dalam mendeteksi jenis tanah. Karena hasil klasifikasi sangat bergantung pada

kualitas dan jumlah citra yang digunakan, maka diperlukan pengujian lebih lanjut untuk memastikan kinerja sistem yang lebih baik di berbagai kondisi lingkungan.

DAFTAR PUSTAKA

- [1] D. Fiantis, *Morfologi Dan Klasifikasi Tanah*. Lembaga Pengembangan Teknologi Informasi Dan Komunikasi (Lptik) Universitas Andalas, 2017. Doi: 10.25077/Car.4.2.
- [2] D. Immanuel Salintohe, I. Alwiah Musdar, T. Informatika, And S. Kharisma Makassar, "Implementasi *Machine Learning* Untuk Mengidentifikasi Tanaman Hias Pada Aplikasi Tierra," *Jtriste*, Vol. 9, No. 1, Pp. 1–15, 2022.
- [3] R. K. Endrayanto And A. Muttaqin, "Penerapan *Machine Learning* Berbasis Data Geospasial Untuk Optimalisasi Lahan Pertanian Pada Masa Pandemi Dan Pasca Pandemi," *Seminar Nasional Geomatika*, P. 161, Apr. 2021, Doi: 10.24895/Sng.2020.0-0.1131.
- [4] M. Wasil, H. Harianto, And F. Fathurrahman, "Pengaruh Epoch Pada Akurasi Menggunakan Convolutional Neural Network Untuk Klasifikasi Fashion Dan Furniture," *Infotek: Jurnal Informatika Dan Teknologi*, Vol. 5, No. 1, Pp. 53–61, Jan. 2022, Doi: 10.29408/Jit.V5i1.4393.
- [5] E. N. Arrofiqoh And H. Harintaka, "Implementasi Metode Convolutional Neural Network Untuk Klasifikasi Tanaman Pada Citra Resolusi Tinggi," *Geomatika*, Vol. 24, No. 2, P. 61, Nov. 2018, Doi: 10.24895/Jig.2018.24-2.810.
- [6] M. Faturrachman And I. Yustiana, "Disease Detection System In Cassava Leaves Using Android-Based Deep Learning And Tensorflow."
- [7] "Klasifikasi Tutupan Lahan Menggunakan Supervised *Machine Learning* Pada Citra Satelit Menggunakan Google Earth Engine."
- [8] D. D. Daniswara, I. A. Taufik, And P. A. Riyantoko, "Optimasi Pengolahan Data Facemask Di *Teachable Machine* Melalui Analisis Nilai Epoch Dan Learning Rate," *Prosiding Seminar Nasional Sains Data*, Vol. 3, No. 1, Pp. 178–183, Nov. 2023, Doi: 10.33005/Senada.V3i1.110.
- [9] "Analisis Perbandingan Arsitektur Convolutional Neural Network Pada Klasifikasi Jenis Penyakit Daun Padi".
- [10] Y. Zhang, Y. Liu, P. Sun, H. Yan, X. Zhao, And L. Zhang, "Ifcnn: A General Image Fusion Framework Based On Convolutional Neural Network," *Information Fusion*, Vol. 54, Pp. 99–118, Feb. 2020, Doi: 10.1016/J.Inffus.2019.07.011.
- [11] K. Abdi, A. Warjaya, I. Muthmainnah, And P. H. Pahutar, "Penerapan Algoritma Random Forest Dalam Prediksi Kelayakan Air Minum," *Jurnal Ilmu Komputer Dan Informatika*, Vol. 3, No. 2, Pp. 81–88, Jan. 2024, Doi: 10.54082/Jiki.81.

- [12] M. Carney *Et Al.*, “*Teachable Machine*: Approachable Web-Based Tool For Exploring *Machine Learning* Classification,” In *Extended Abstracts Of The 2020 Chi Conference On Human Factors In Computing Systems*, New York, Ny, Usa: Acm, Apr. 2020, Pp. 1–8. Doi: 10.1145/3334480.3382839.
- [13] A. Wijoyo, A. Y. Saputra, S. Ristanti, R. Sya’ban, M. Amalia, And R. Febriansyah, “*Pembelajaran Machine Learning*”.
- [14] T. L. Kurz, S. Jayasuriya, K. Swisher, J. Mativo, R. Pidaparti, And D. T. Robinson, “The Impact Of *Teachable Machine* On Middle School Teachers’ Perceptions Of Science Lessons After Professional Development,” *Educ Sci (Basel)*, Vol. 14, No. 4, Apr. 2024, Doi: 10.3390/Educsci14040417.
- [15] M. D. Zeiler And R. Fergus, “Visualizing And Understanding Convolutional Networks,” *Lecture Notes In Computer Science*, 2014, Pp. 818–833. Doi: 10.1007/978-3-319-10590-1_53