

IMPLEMENTASI DETEKSI JENIS TANAMAN HERBAL DENGAN MODEL KLASIFIKASI GAMBAR MENGGUNAKAN TEACHABLE MACHINE

Amanda Titania Putri^{1*}, Ola Safira¹, Amelia Yulianti¹, Imam Faozi¹, Retno Agus setiawan¹

¹Program Studi Sistem Informasi, Fakultas Sains dan Teknologi, Universitas Harapan Bangsa
Jl, KH. Wahid Hasyim No.274-A, Windusara, Karangklesem, Purwokerto Selatan, Banyumas 53144,
Indonesia

¹amandatitaniaputri@gmail.com*; olasafira20@gmail.com; yulianamelia321@gmail.com; faozi0067@gmail.com;
⁵retnoagussetiawan@uhb.ac.id

ABSTRAK

Tanaman herbal merupakan sumber bahan alami yang banyak dimanfaatkan dalam pengobatan tradisional dan terapi alternatif. Akan tetapi, proses identifikasi jenis tanaman herbal masih sering dilakukan manual sehingga berpotensi menimbulkan kesalahan, terutama bagi masyarakat awam. Tujuan penelitian adalah mengimplementasikan sistem cerdas yang mampu mengklasifikasikan jenis tanaman herbal berdasarkan citra daun, sehingga membantu mengenali tanaman herbal secara mandiri sekaligus memberikan nilai edukasi. Penelitian memanfaatkan dataset citra dari beberapa jenis daun tanaman herbal yang diproses dan dilatih menggunakan Google Teachable Machine. Platform ini menyediakan kemudahan melatih model machine learning melalui pendekatan berbasis gambar tanpa memerlukan pengetahuan pemrograman yang kompleks. Dataset dibagi ke dalam sejumlah kelas sesuai jenis tanaman herbal, dan proses pelatihan dilakukan dengan memvariasikan parameter seperti epoch, batch size, dan learning rate untuk memperoleh konfigurasi paling optimal. Hasil penelitian ini terciptanya aplikasi sistem cerdas berbasis web yang mampu mengklasifikasikan citra tanaman herbal secara efektif, memberikan informasi edukatif kepada pengguna, serta dapat dikembangkan lebih lanjut menjadi alat bantu praktis dalam identifikasi tanaman herbal. Penelitian juga menyoroti beberapa tantangan, seperti kebutuhan dataset cukup besar dan beragam, variasi kondisi pencahayaan dan latar belakang gambar, serta kemampuan model untuk bekerja konsisten pada kondisi nyata di lapangan.

Kata kunci: *Tanaman Herbal, Klasifikasi Citra, Teachable Machine, Pengenalan Daun*

ABSTRACT

Herbal plants are a source of natural ingredients widely used in traditional medicine and alternative therapies. However, the process of identifying herbal plant types is still often done manually, potentially leading to errors, especially for the general public. The aim of this research is to implement an intelligent system capable of classifying herbal plant types based on leaf images, thereby helping to identify herbal plants independently while providing educational value. The research utilizes an image dataset of several types of herbal plant leaves that were processed and trained using Google Teachable Machine. This platform facilitates training machine learning models through an image-based approach without requiring complex programming knowledge. The dataset is divided into several classes according to the type of herbal plant, and the training process is carried out by varying parameters such as epoch, batch size, and learning rate to obtain the most optimal configuration. The results of this research create a web-based intelligent system application that can effectively classify herbal plant images, provide educational information to users, and can be further developed into a practical tool for herbal plant identification. The research also highlights several challenges, such as the need for a sufficiently large and diverse dataset, variations in lighting conditions and image backgrounds, and the model's ability to perform consistently under real-world conditions.

Keywords: *Herbal Plants, Image Classification, Teachable Machine, Leaf Recognition*

PENDAHULUAN

Sejak lama, tanaman herbal telah memainkan peranan krusial dalam kehidupan manusia, hadir sebagai komponen penting dalam pengobatan tradisional, pendukung kesehatan, penambah cita rasa, dan aroma alami. Peningkatan pemahaman ilmiah dan kesadaran terhadap pengobatan alami membuat cara mengelompokkan tanaman herbal semakin esensial. Proses pengelompokan ini membantu mengenali karakteristik dan manfaat suatu tanaman, juga mendukung riset, menjaga kualitas produk, serta melestarikan pengetahuan tradisional yang diturunkan dari generasi ke generasi. Adanya pengelompokan terstruktur dan jelas, penggunaan tanaman herbal dapat dilakukan lebih aman, efektif, dan berkelanjutan (Khalid & Romle, 2023).

Kegiatan mengenali dan mengelompokkan tanaman herbal tidak mudah dilakukan. Keragaman yang tinggi, kemiripan bentuk fisik antar tanaman yang masih satu keluarga, serta pengaruh faktor lingkungan membuat proses pengenalan seringkali membingungkan. Jumlah ahli yang terbatas di bidang taksonomi tanaman semakin memperburuk masalah ini. Kesalahan pengenalan tidak hanya berpotensi menurunkan mutu produk, tetapi juga dapat membahayakan kesehatan masyarakat jika tanaman beracun tertukar dengan tanaman yang aman. Selain itu, di tengah meningkatnya permintaan pasar global terhadap produk herbal, tantangan lain adalah melacak keaslian bahan serta berupaya menjaga kelestarian tanaman di alam bebas (Sucher & Carles, 2008).

Perkembangan teknologi dapat membantu mengatasi hambatan yang dirasakan. Penerapan *machine learning* dan *computer vision* terbukti dapat meningkatkan ketepatan pengenalan dan pengelompokan gambar tanaman. Teknologi ini memungkinkan sistem mengenali pola visual secara otomatis dari data gambar, sehingga mampu membedakan jenis tanaman dengan tingkat akurasi tinggi. Inovasi ini tidak hanya penting bagi dunia penelitian, tetapi juga krusial di industri kesehatan, farmasi, dan perdagangan herbal. Salah satu platform yang mendukung implementasi teknologi ini adalah *Teachable Machine*, sebuah alat daring yang dikembangkan oleh Google. Platform ini dirancang agar mudah digunakan oleh siapa saja, termasuk mereka yang tidak memiliki latar belakang pemrograman. Dengan mengunggah kumpulan data gambar, pengguna dapat melatih model pengelompokan gambar secara praktis dan menguji hasilnya dalam berbagai situasi nyata. *Teachable Machine* tidak hanya menjadi sarana edukatif untuk memperkenalkan konsep *machine learning*, tetapi

juga dapat dimanfaatkan sebagai solusi awal dalam mengembangkan sistem pengenalan tanaman herbal yang lebih akurat.

Gabungan pengetahuan tradisional tanaman herbal dan dukungan teknologi modern *machine learning*, diharapkan kendala pengenalan dapat diminimalkan. Hal ini akan memperkuat upaya penggunaan tanaman herbal secara aman dan efektif, sekaligus mendukung pengembangan penelitian ilmiah dan pelestarian sumber daya alam yang berharga bagi kesehatan serta kesejahteraan masyarakat global.

BAHAN DAN METODE PENELITIAN

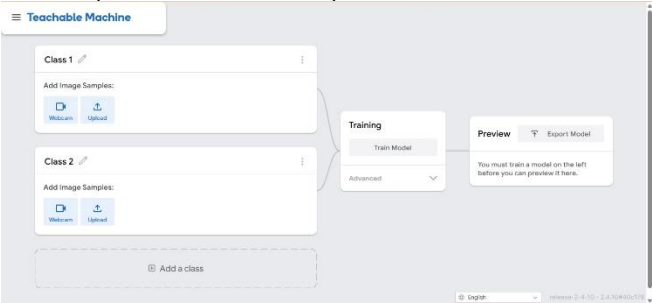
Teachable Machine

Teachable Machine dari Google adalah alat daring yang memudahkan pembuatan model kecerdasan buatan dasar, bahkan bagi mereka yang tidak memiliki pengetahuan pemrograman yang luas. Awalnya diluncurkan pada tahun 2017, alat ini kemudian ditingkatkan ke versi 2.0, yang mendukung berbagai fungsi pembelajaran mesin seperti mengenali gambar, suara, dan posisi tubuh. Dalam penelitian ini, *Teachable Machine* dipergunakan untuk membuat model yang dapat mengidentifikasi tanaman herbal melalui sistem klasifikasi gambar (Asaad & Abdulazeez, 2024).

Tata letak utama *Teachable Machine* terdiri dari tiga bagian kunci: memasukkan data, melatih model, dan melihat hasil klasifikasi. Tampilan antar muka *teachable machine* dapat dilihat pada **Error! Reference source not found..** Data pelatihan dan pengujian dapat diperoleh dengan mengunggah gambar atau merekamnya melalui webcam. Klasifikasi dapat dilakukan dalam dua mode yaitu biner (untuk dua kategori) atau multi-kelas (dengan memasukkan berbagai jenis tanaman herbal untuk identifikasi), seperti jahe, kunyit, dan temulawak. Dalam pengaturan pelatihan lanjutan, penyempurnaan pada tiga pengaturan penting *epoch*, *batch size*, dan *learning rate* dapat meningkatkan ketepatan model. Penyesuaian yang tepat pada parameter-parameter ini sangat penting agar model dapat lebih efektif memahami ciri visual dari setiap jenis tanaman herbal, khususnya jika kualitas gambar berbeda pada aspek seperti pencahayaan, sudut kamera, atau ketajaman. Setelah pelatihan, hasil klasifikasi dapat dievaluasi pada pengaturan preview, di mana gambar baru dari tanaman herbal diuji dan dikategorikan berdasarkan model yang telah dilatih (Kmail, 2024).

Akurasi diagnosa dilakukan dengan proses pencocokkan prediksi model dengan label pada data uji yang telah ditetapkan. Model yang dilatih dapat diekspor melalui fungsi ekspor. *Teachable Machine* menawarkan berbagai pilihan ekspor,

termasuk *TensorFlow.js* memungkinkan integrasi instan ke dalam aplikasi berbasis web, *TensorFlow/Keras* mendukung pengembangan lebih lanjut dalam lingkungan Python, *TensorFlow Lite* dirancang untuk penggunaan pada perangkat seluler yang berjalan di sistem Android. Hasil dari metode ini memperlihatkan bahwa penelitian telah berhasil menciptakan sistem awal yang dirancang untuk mengenali jenis tanaman herbal menggunakan model klasifikasi berbasis machine learning. Pemanfaatan dari *Teachable Machine* memperlihatkan kecerdasan buatan berpotensi diintegrasikan secara efektif dibidang kesehatan tradisional dan pertanian, khususnya untuk proses identifikasi tanaman hermal secara cepat dan akurat (Manoharan, 2021)



Gambar 1. Antarmuka pengguna grafis dari Google Teachable Machine

Data Set

Penelitian ini mengevaluasi kemampuan dari Teachable Machine untuk proses mengidentifikasi berbagai jenis tanaman herbal. Dataset gambar tanaman herbal dari Kaggle digunakan sebagai studi kasus untuk tugas klasifikasi multi-kelas. Kaggle, didirikan tahun 2010 merupakan platform populer untuk kompetisi, melibatkan pemodelan prediktif dan analisis data, sering digunakan untuk mempelajari proyek ilmu data dan pembelajaran mesin (Naeem et al., 2021).

Dataset berisi 300 gambar tanaman herbal terbagi 3 kelompok yaitu 100 gambar daun kunyit, 100 gambar lidah buaya, dan 100 gambar daun teh. Sebanyak 80% gambar digunakan untuk melatih model, sementara 20% sisanya dipakai untuk pengujian akurasi. Karena Teachable Machine tidak menyediakan validasi terpisah, evaluasi dilakukan dengan menggunakan dataset pengujian untuk menilai kemampuan klasifikasi tanaman herbal (Hu et al., 2021).

Tabel 1. Konfigurasi Data (n=300)

Training Data	Daun Teh Hijau	80
	Daun Kunyit	80
	Lidah Buaya	80
Test Data	Daun Teh Hijau	20
	Daun Kunyit	20
	Lidah Buaya	20

Hyper-Parameter Tuning

Setiap kumpulan gambar, termasuk yang menggambarkan tanaman herbal, memiliki

karakteristik unik yang terbentuk oleh lingkungan tempat gambar diambil, tujuan penggunaan, dan kamera atau perangkat yang digunakan untuk pengambilan gambar. Oleh karena itu, agar pembelajaran mesin dapat secara efektif mengidentifikasi dan memanfaatkan atribut unik yang terdapat dalam setiap gambar, sangat penting untuk mengatur pengaturan pelatihan pada tingkat yang paling efektif. Penyesuaian pengaturan ini melibatkan penyesuaian variabel-variabel tersebut berdasarkan apa yang membuat setiap kumpulan gambar unik, dan dikenal sebagai penyesuaian hiperparameter. Hal ini memastikan model belajar sebaik mungkin (Villalobos-Arias, et al., 2020).

Teachable Machine menyediakan tiga pengaturan utama yang dapat Anda sesuaikan yaitu jumlah siklus pembelajaran (*epoch*), jumlah gambar yang diproses secara bersamaan (*batch size*), dan kecepatan pembelajaran (*learning rate*). Jumlah epoch menunjukkan berapa kali koleksi gambar lengkap dijalankan melalui proses pembelajaran. Biasanya, meningkatkan jumlah epoch membuat model lebih akurat; namun, menaikkan angka ini terlalu tinggi dapat membuat model terlalu fokus pada gambar pelatihan. Ketika model terlalu fokus, model menjadi sangat akurat dengan gambar yang digunakan untuk pelatihan, tetapi kesulitan dengan gambar baru (Ladds et al., 2017).

Besarnya laju pembelajaran menentukan tingkat penyesuaian model. Laju terlalu tinggi dapat membuat model gagal mencapai solusi terbaik, laju terlalu rendah memperlambat proses belajar dan berisiko membuat model berhenti pada solusi yang kurang optimal. Ukuran batch adalah jumlah contoh pelatihan yang dilihat model sebelum memperbarui dirinya. Saat jumlah gambar yang diproses dalam setiap batch lebih sedikit, penyesuaian dapat lebih akurat, tetapi proses pelatihan model menjadi lebih lama. Sebaliknya, menggunakan batch yang lebih besar mempercepat proses tetapi mungkin membuat model kurang adaptif (Youssef, & Ismail, 2024).

Penelitian ini melibatkan pelatihan model untuk mengklasifikasikan gambar tanaman herbal. Penyesuaian epoch, ukuran batch, dan laju pembelajaran dilakukan karena faktor-faktor ini memengaruhi kinerja model. Setelah pelatihan, model diuji dengan gambar baru untuk mengevaluasi akurasi, yang dihitung sebagai jumlah kasus uji yang diklasifikasikan benar ('n') dari total data uji ('N') dengan label sebenarnya diketahui. Kasus klasifikasi yang salah, dihitung mempergunakan rumus (N - n) (Ankalaki, et al., 2024)

Receiver Operating Characteristic (ROC)

Kurva ROC merupakan teknik yang digunakan untuk menilai performa model pembelajaran mesin, khususnya dalam melakukan klasifikasi objek ke dalam kategori tertentu. Metode ini membantu menganalisis seberapa akurat model dalam membedakan satu jenis tanaman dari jenis lainnya dalam kelompok tanaman herbal. Hasil klasifikasi dibagi menjadi empat jenis *true-positive* (TP), *true-negative* (TN), *false-positive* (FP), dan *false-negative* (FN). Menggunakan hasil ini, dua ukuran penting dihitung sensitivitas, juga disebut *true positive rate* (TPR), dan spesifisitas, juga dikenal sebagai *false positive rate* (FPR). Sensitivitas (TPR) menunjukkan seberapa baik sistem mengidentifikasi gambar tanaman herbal dengan benar ketika gambar tersebut sebenarnya positif. Spesifisitas FPR menunjukkan seberapa sering sistem salah mengidentifikasi gambar non-tanaman sebagai tanaman. Setelah melatih model *Teachable Machine* dengan kondisi hiperparameter optimal, data uji gambar tanaman herbal dimasukkan untuk mengevaluasi kinerja klasifikasi. Analisis ROC kemudian diterapkan untuk menghitung akurasi, TPR, dan FPR. Evaluasi memberikan pemahaman komprehensif tentang kemampuan diagnostik model dalam mengidentifikasi jenis tanaman herbal yang berbeda dengan benar sambil meminimalkan kesalahan klasifikasi (Lin, et al., 2021).

HASIL DAN PEMBAHASAN

Optimization of hyper-parameters tuning in Teachable Machine

Optimasi hiperparameter di *Teachable Machine* adalah tentang mengubah beberapa pengaturan untuk membuat model bekerja lebih baik. Biasanya, ini termasuk mengubah seberapa cepat model belajar, ukuran grup data yang diproses, dan berapa lama model dilatih untuk mendapatkan hasil terbaik. Lakukan eksperimen dengan hati-hati dan perbaiki berulang kali sangat penting untuk menemukan keseimbangan yang pas antara ketepatan model dan efisiensi penggunaan komputer (DeCastro-García, et al., 2019)

1. Epoch


Dalam pembelajaran mesin, jumlah epoch merupakan parameter penting yang secara signifikan memengaruhi kemampuan model untuk belajar dari dataset pelatihan. Sebuah epoch merujuk pada satu putaran lengkap melalui seluruh dataset, dan mengubah nilai ini dapat secara signifikan memengaruhi apakah model menjadi terlalu sederhana atau terlalu kompleks. Jumlah epoch yang tidak cukup dapat mencegah model untuk belajar dengan baik dari data. Sebaliknya, jika jumlah epoch berlebihan, model

mungkin hanya menghafal data pelatihan daripada belajar untuk mengidentifikasi contoh baru. Sehingga, penting menentukan jumlah epoch yang tepat untuk memastikan model akurat dan dapat generalisasi secara efektif (Ladds et al., 2017).

Error! Reference source not found. memperlihatkan bagaimana jumlah epoch memengaruhi akurasi model dalam mengidentifikasi tiga jenis tanaman herbal (Teh Hijau, Daun Kunyit, dan Lidah Buaya). Jumlah epoch bervariasi dari 20 hingga 150, dan mereka memeriksa akurasi pada setiap langkah menggunakan data uji. Setelah 20 epoch, ketiga jenis tanaman tersebut mencapai akurasi 100%, artinya model mampu mempelajari fitur data dengan sangat baik hanya dalam beberapa kali iterasi. Hal ini menunjukkan bahwa bahkan pada tahap awal, proses pembelajaran sudah cukup baik untuk klasifikasi yang akurat. Akan tetapi, pencapaian akurasi sempurna ini perlu diteliti lebih mendalam karena bisa menjadi indikasi terjadinya overfitting. Kemungkinan ini disebabkan oleh ukuran dataset yang terbatas (hanya 300 gambar) dan kesamaan antar kelas data yang memungkinkan model terlalu cepat mengenali pola tertentu tanpa benar-benar mempelajari generalisasi.

Kemampuan model untuk memperoleh akurasi tinggi sejak tahap awal pelatihan juga dapat diuraikan oleh fitur *Teachable Machine* yang memanfaatkan model dasar (*pre-trained model*) dengan bobot awal yang telah terlatih pada gambar umum. Hal ini memungkinkan sistem dengan cepat mengenali karakteristik dasar daun seperti bentuk dan tekstur, sehingga terlihat seolah model berhasil melakukan generalisasi. Pengujian menggunakan dataset eksternal masih penting untuk menjamin kinerja model dalam situasi sebenarnya dan menghindari bias pada hasil pelatihan.

Pada 50–100 epoch, akurasi tetap tinggi, rata-rata sekitar 98%. Meski akurasi Teh Hijau sedikit turun menjadi 93%, tanaman lain tetap hampir sempurna, sehingga pelatihan ini dianggap seimbang, cukup lama untuk belajar tanpa membuat model terlalu kompleks. Namun, pada 150 epoch, akurasi keseluruhan jatuh drastis menjadi 47%, menunjukkan model kesulitan menggeneralisasi meski telah dilatih intensif, sehingga kemampuan diagnostiknya menurun.




Gambar 2. Ketepatan Diagnostik Teh Hijau, Daun Kunyit dan Lidah Buaya Berdasarkan Jumlah Epoch

2. Learning Rate

Learning rate (laju pembelajaran) merupakan hiperparameter kunci menentukan kecepatan penyesuaian model terhadap data pelatihan, menentukan besarnya langkah yang diambil selama fase penyesuaian bobot dalam algoritma *gradient descent*. Jika laju pembelajaran terlalu tinggi, model mungkin kesulitan mencapai konvergensi dan berfluktuasi di sekitar solusi yang kurang optimal. Sebaliknya, jika laju pembelajaran diatur terlalu rendah, pelatihan dapat menjadi terlalu lambat atau menyebabkan *underfitting*, model kesulitan mengidentifikasi pola yang signifikan. Oleh karena itu, penyesuaian laju pembelajaran yang tepat sangat penting untuk menyeimbangkan kecepatan konvergensi dan ketepatan prediksi (Li & Yang, 2020).

Ilustrasi **Error! Reference source not found.** menunjukkan ketepatan diagnostik model yang dilatih pada berbagai laju pembelajaran, mulai dari 10^{-5} hingga 10^{-2} . Laju pembelajaran menentukan besarnya perubahan bobot selama fase pelatihan, dan memilih nilai yang tepat sangat penting untuk menemukan keseimbangan ideal kecepatan konvergensi dan akurasi klasifikasi. Dengan laju pembelajaran 10^{-2} (0,01), model mencapai akurasi sempurna (100%) setelah dilatih selama 20 epoch dengan ukuran batch 16. Hal ini menunjukkan bahwa model dengan cepat mencapai solusi optimal tanpa osilasi atau divergensi, yang berarti konfigurasi ini memungkinkan pembelajaran yang paling efektif.

Ketika laju pembelajaran dikurangi menjadi 10^{-3} (0.001) dan 10^{-4} (0.0001), model secara konsisten mencapai akurasi tinggi, dengan rata-rata sekitar 98% secara keseluruhan, melalui pelatihan selama 50 hingga 100 epoch dan ukuran batch 32–64. Meskipun sedikit di bawah kinerja maksimum pada 0,01, temuan ini menunjukkan konsistensi yang lebih besar di berbagai kelas, menunjukkan generalisasi yang kuat dengan variasi akurasi yang minimal.



Gambar 3. Ketepatan Diagnostik Teh Hijau, Daun Kunyit dan Lidah Buaya Berdasarkan Jumlah Laju Pembelajaran

3. Batch Size


Dalam *machine learning*, data pelatihan dibagi menjadi beberapa bagian kecil yang masing-masing berisi sejumlah item tertentu, disebut *batch size*. Metode yang menggunakan batch kecil ini untuk memperbarui pengaturan model disebut *mini-batch gradient descent*. Mini-batch memungkinkan perhitungan lebih cepat, pembaruan model lebih stabil, dan sering menghasilkan performa yang lebih baik (Osawa et al., 2022).

Ilustrasi grafik pada **Error! Reference source not found.** ini menunjukkan ketepatan diagnostik data uji yang dievaluasi oleh model yang dilatih saat ukuran batch meningkat dari 16 hingga 256. Dengan ukuran batch 16 (20 epoch), model mencapai akurasi sempurna (100%) di setiap kelas. Hal ini menunjukkan bahwa ukuran batch yang kecil memungkinkan model untuk menyesuaikan bobot lebih sering, sehingga dapat mengidentifikasi karakteristik esensial dataset dengan efisien.

Ketika ukuran batch ditingkatkan menjadi 32–64 (50–100 epoch), model mempertahankan akurasi tinggi (sekitar 98% secara keseluruhan), dengan variasi statistik yang lebih kecil dibandingkan dengan ukuran batch yang jauh lebih kecil. Hal ini menunjukkan bahwa ukuran batch sedang mencapai keseimbangan yang menguntungkan antara efisiensi komputasi dan dinamika pembelajaran yang konsisten. Namun, dengan ukuran batch yang lebih besar, kinerja mulai menurun. Secara khusus, dengan ukuran batch 256 (150 epoch), akurasi total menurun secara signifikan menjadi sekitar 47%. Penurunan ini disebabkan oleh *underfitting*, karena ukuran batch yang terlalu besar mengurangi laju pembaruan bobot, menyebabkan konvergensi

yang tidak efektif dan generalisasi yang buruk pada data uji yang tidak dikenal.

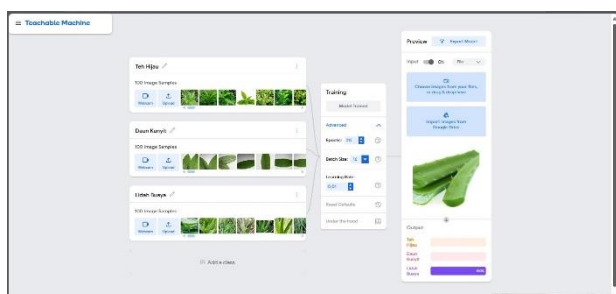
Berdasarkan temuan ini, ukuran batch ideal tampaknya adalah 16, yang menghasilkan akurasi tertinggi (100%), atau 64, yang mencapai kinerja stabil dan andal (98%) dengan variasi yang lebih rendah dan konsistensi yang lebih baik di berbagai kelas. Oleh karena itu, memilih ukuran batch yang sesuai sangat penting untuk mencapai keseimbangan antara akurasi, stabilitas, dan pelatihan yang efisien dalam tugas klasifikasi.



Gambar 4. Ketepatan Diagnostik Teh Hijau, Daun Kunyit dan Lidah Buaya pada Berbagai Ukuran Batch di Teachable Machine

Optimization Result of Hyper-Parameters in Teachable Machine

Hasil dari memperbaiki pengaturan penting di Teachable Machine menunjukkan bahwa ada peningkatan besar dalam cara model bekerja. Peningkatan ini membuat prediksi lebih tepat dan waktu pelatihannya menjadi lebih cepat untuk berbagai jenis tugas. Penelitian selanjutnya bisa melihat bagaimana penggunaan pengaturan yang sudah diperbaiki ini bisa diterapkan di platform pembelajaran mesin lainnya dan bagaimana pengaruhnya di kehidupan nyata.



Gambar 5. Model Pembelajaran Mesin Setelah Penyesuaian Hiperparameter

Tanaman herbal merupakan sumber daya alam yang berharga yang sering digunakan dalam pengobatan tradisional dan metode penyembuhan

alternatif. Perkembangan pesat teknologi seperti machine learning dan computer vision membuka cara baru untuk membantu mengidentifikasi tanaman herbal ini, yang sebelumnya bergantung pada tenaga manusia dan keahlian mereka. Dalam penelitian ini, *Google Teachable Machine* digunakan untuk membuat model yang dapat mengklasifikasikan gambar tanaman herbal, dengan fokus pada Teh Hijau, Daun Kunyit, dan Lidah Buaya. Studi ini menganalisis berbagai pengaturan seperti jumlah putaran pelatihan, kecepatan pembelajaran, dan ukuran *batch data* untuk meningkatkan akurasi model dalam mengklasifikasikan tanaman, serta mengevaluasi kinerja sistem secara keseluruhan (Pratondo, Elfahmi, & Novianty, 2022).

Melihat proses pelatihan, atau epoch, menunjukkan bahwa jumlah kali model dilatih sangat penting untuk seberapa baik kinerjanya. Pada 20 epoch, model berhasil mengenali semua jenis tanaman akurasi 100%, menunjukkan bahwa model belajar cepat dan hanya membutuhkan sedikit pelatihan. Pada 50 hingga 100 epoch, akurasi tetap sangat tinggi sekitar 98%, dengan penurunan ringan untuk Teh Hijau (93%), artinya model mampu generalisasi dengan baik. Namun, ketika pelatihan diperpanjang hingga 150 epoch, akurasi turun tajam menjadi 47%, menunjukkan bahwa model mungkin telah belajar terlalu banyak dari data pelatihan atau tidak cukup. Hal ini menunjukkan bahwa meskipun waktu pelatihan yang lebih singkat dapat menghasilkan hasil yang baik, waktu pelatihan yang lebih lama dapat membuat hasil dan keandalan model menjadi lebih buruk. Waktu pelatihan terbaik ditemukan sekitar 75 epoch, di mana model menjadi stabil dan akurat (Hussein & Shareef, 2024).

Kecepatan pembelajaran juga memiliki dampak besar terhadap kinerja. Ketika laju pembelajaran diatur cukup tinggi pada 0.01, model mencapai akurasi sempurna (100%) dalam 20 *epoch*, menggunakan ukuran batch 16. Ketika laju pembelajaran lebih rendah pada 0.001 atau 0.0001, akurasi tetap tinggi secara keseluruhan pada 98%, dan lebih stabil di berbagai kelas, menunjukkan kemampuan generalisasi yang kuat dengan variasi minimal. Namun, pada laju pembelajaran terendah 0.000001, sistem tidak dapat belajar dengan baik, dan akurasi turun menjadi 47%. Kinerja buruk ini disebabkan model tidak cukup menyesuaikan diri dengan data karena langkah pembelajaran terlalu kecil untuk perubahan yang efektif. Oleh karena itu, laju pembelajaran terbaik adalah 0.01 untuk akurasi

tertinggi atau 0.0001 untuk stabilitas yang lebih baik.

Ukuran batch data juga memengaruhi cara model belajar dan tingkat akurasi. Batch kecil ukuran 16 memiliki akurasi sempurna (100%), model dapat memperbarui bobotnya secara sering dan mempelajari fitur penting dengan baik. Ukuran batch sedang (32-64) mempertahankan kinerja tinggi sebesar 98% sambil mengurangi perbedaan akurasi, memberikan kombinasi yang baik antara stabilitas dan efisiensi. Namun, penggunaan batch besar (256) menyebabkan akurasi turun secara signifikan menjadi 47% karena model tidak cocok dengan data dan menjadi kurang adaptif. Oleh karena itu, ukuran batch terbaik ditemukan pada 16 untuk kinerja optimal atau 64 untuk akurasi yang stabil.

Pengoptimalan hiperparameter menunjukkan bahwa penggunaan *Teachable Machine* mampu mengidentifikasi gambar tanaman herbal dengan akurat. Pengaturan optimal ditemukan pada 75 *epoch*, *learning rate* 0,0001, dan *batch size* 64, menghasilkan performa yang stabil dan dapat diandalkan. Dibandingkan studi sebelumnya pada klasifikasi gambar medis yang menggunakan AI untuk pengelompokan gambar medis, hasil ini membuktikan potensi *Teachable Machine* sebagai alat bantu dalam penelitian, pendidikan, dan identifikasi tanaman herbal (Khalid & Romle, 2023).

Namun, studi ini memiliki kelemahan. Dataset yang digunakan cukup kecil, dengan hanya 300 gambar dan tiga jenis tanaman herbal. Perubahan pencahayaan, latar belakang, dan kualitas gambar mungkin memengaruhi seberapa baik model dilatih, dan tidak ada dataset eksternal untuk memverifikasi hasil. Untuk penggunaan yang lebih luas, diperlukan dataset yang lebih besar dan beragam agar model menjadi lebih andal (Roopashree & Anitha, 2021).

SIMPULAN

Penelitian ini memperlihatkan, dimungkinkan untuk membuat model klasifikasi tanaman menggunakan *Google Teachable Machine* dengan hasil yang baik, dengan mengubah faktor seperti *epoch*, *learning rate*, dan *batch size*, model tersebut berhasil membedakan antara Teh Hijau, Daun Kunyit, dan Lidah Buaya dengan sangat baik. Studi ini menemukan bahwa epoch sekitar 75, *learning rate* 0.0001, dan *batch size* 64 memberikan hasil terbaik dan paling konsisten, dengan akurasi total 98%. Dalam beberapa kasus, terutama saat menggunakan pengaturan epoch

dan batch yang lebih kecil, akurasi bahkan mencapai 100%, namun hasil ini kemungkinan bias karena jumlah dataset yang terbatas.

Hasil menunjukkan bahwa *Teachable Machine* adalah alat yang berguna dan mudah digunakan untuk membuat model klasifikasi gambar, dan Anda tidak perlu memiliki pengetahuan mendalam tentang pemrograman untuk menggunakannya. Alat ini tidak hanya berguna untuk penelitian tetapi juga untuk pengajaran dan membantu komunitas dalam mengidentifikasi tanaman. Namun, studi ini menyoroti beberapa masalah penting, seperti jumlah data yang sedikit, jenis tanaman yang tidak cukup, dan tidak memeriksa model dengan sumber eksternal. Permasalahan ini membatasi seberapa baik model dapat diterapkan dalam situasi yang berbeda dan menunjukkan bahwa masih diperlukan pekerjaan lebih lanjut untuk memperbaikinya.

Teachable Machine signifikan meningkatkan keberhasilan dan keandalan model, alat yang berguna untuk mempelajari tanaman herbal, mendidik masyarakat, dan mungkin membantu bidang obat herbal (Ottoni, et al., 2023)

SARAN

Studi di masa depan sebaiknya bertujuan untuk mengumpulkan lebih banyak gambar dari berbagai jenis tanaman herbal. Gambar-gambar ini perlu diambil dalam kondisi pencahayaan yang berbeda, dari sudut pandang yang beragam, dan dalam berbagai lingkungan agar model dapat berfungsi dengan baik dalam situasi yang berbeda-beda. Dengan memiliki variasi data yang lebih luas, sistem klasifikasi tanaman akan menjadi lebih andal dan fleksibel saat digunakan dalam kehidupan sehari-hari (Patil, et al., 2024).

Langkah kunci lainnya adalah menggunakan metode untuk memeriksa akurasi model, seperti validasi silang atau menggunakan dataset terpisah untuk pengujian. Metode ini memberikan gambaran yang lebih baik tentang seberapa baik model berfungsi dan membantu mencegah *overfitting*, yaitu ketika model bekerja dengan baik pada data pelatihan tetapi kesulitan dengan informasi baru yang belum pernah dilihat sebelumnya. Validasi yang kuat memastikan bahwa model yang dilatih tetap andal dan konsisten.

Saat menggunakan model, model tersebut dapat ditambahkan ke aplikasi seluler atau situs web. Hal ini memudahkan lebih banyak orang untuk mengidentifikasi tanaman herbal, menjadikannya berguna dalam situasi sehari-hari.

Selain itu, penelitian lebih lanjut harus melihat bagaimana Teachable Machine dibandingkan dengan sistem AI lain seperti TensorFlow atau jaringan saraf konvolusional khusus. Perbandingan ini akan menunjukkan seberapa akurat, efisien, dan skalabel setiap metode, membantu menemukan cara terbaik untuk mengenali tanaman herbal (Ferrag, et al., 2019). Selain penelitian dan pengembangan, Teachable Machine memiliki potensi besar dalam bidang pendidikan. Alat ini dapat digunakan di sekolah dan universitas untuk membantu mengajar siswa dalam mata pelajaran seperti ilmu komputer, biologi, dan ilmu kesehatan. Hal ini tidak hanya memperkenalkan siswa pada apa itu kecerdasan buatan, tetapi juga menunjukkan bagaimana kecerdasan buatan dapat menyelesaikan masalah nyata dalam kehidupan sehari-hari. Akhirnya, untuk memastikan sistem berfungsi dengan baik dalam situasi nyata, pengujian harus dilakukan di kebun herbal, pasar, atau pertanian. Pengujian ini akan membantu memahami seberapa andal dan berguna model tersebut dalam lingkungan nyata (Carney et al., 2020).

DAFTAR PUSTAKA

- Abraham, A., Jose, R., Ahmad, J., Joshi, J., Jacob, T., Khalid, A., ... Toma, M. (2023). Comparative Analysis of Machine Learning Models for Image Detection of Colonic Polyps vs. Resected Polyps. *Journal of Imaging*, 9(10), 215. doi:10.3390/jimaging9100215
- Alhussainan, N. F., Ben Youssef, B., & Ben Ismail, M. M. (2024). A Deep Learning Approach for Brain Tumor Firmness Detection Based on Five Different YOLO Versions: YOLOv3–YOLOv7. *Computation*, 12(3), 44. doi:10.3390/computation12030044
- Ankalaki, S., G Biradar, V., Naik P, K. K., & S. Hukkeri, G. (2024). A Deep Learning Approach for Malnutrition Detection. *International Journal of Online and Biomedical Engineering (IJOE)*, 20(06), 116–138. doi:10.3991/ijoe.v20i06.46919
- Carney, M., Webster, B., Alvarado, I., Phillips, K., Howell, N., Griffith, J., ... Chen, A. (2020). 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* (pp. 1–8). New York, NY, USA: ACM. doi:10.1145/3334480.3382839
- DeCastro-García, N., Muñoz Castañeda, Á. L., Escudero García, D., & Carriegos, M. V. (2019). Effect of the Sampling of a Dataset in the Hyperparameter Optimization Phase over the Efficiency of a Machine Learning Algorithm. *Complexity*, 2019(1). doi:10.1155/2019/6278908
- Fatimah Khalid, & Amirul Azuani Romle. (2023). Herbal Plant Image Classification using Transfer Learning and Fine-Tuning Deep Learning Model. *Journal of Advanced Research in Applied Sciences and Engineering Technology*, 35(1), 16–25. doi:10.37934/araset.34.3.1625
- Ferrag, M. A., Maglaras, L., Janicke, H., & Smith, R. (2019). Deep Learning Techniques for Cyber Security Intrusion Detection: A Detailed Analysis. doi:10.14236/ewic/icscsr19.16
- Hu, Y., Xu, L., Huang, P., Luo, X., Wang, P., & Kang, Z. (2021). Reliable Identification of Oolong Tea Species: Nondestructive Testing Classification Based on Fluorescence Hyperspectral Technology and Machine Learning. *Agriculture*, 11(11), 1106. doi:10.3390/agriculture11111106
- Hussein, B. M., & Shareef, S. M. (2024). An Empirical Study on the Correlation between Early Stopping Patience and Epochs in Deep Learning. *ITM Web of Conferences*, 64, 01003. doi:10.1051/itmconf/20246401003
- Kmail, A. (2024). Mitigating digestive disorders: Action mechanisms of Mediterranean herbal active compounds. *Open Life Sciences*, 19(1). doi:10.1515/biol-2022-0857
- Ladds, M. A., Thompson, A. P., Kadar, J.-P., J Slip, D., P Hocking, D., & G Harcourt, R. (2017). Super machine learning: improving accuracy and reducing variance of behaviour classification from accelerometry. *Animal Biotelemetry*, 5(1), 8. doi:10.1186/s40317-017-0123-1

- Li, J., & Yang, X. (2020). A Cyclical Learning Rate Method in Deep Learning Training. In 2020 International Conference on Computer, Information and Telecommunication Systems (CITS) (pp. 1–5). IEEE. doi:10.1109/CITS49457.2020.9232482
- Lin, N., Chen, Y., Liu, H., & Liu, H. (2021). A Comparative Study of Machine Learning Models with Hyperparameter Optimization Algorithm for Mapping Mineral Prospectivity. *Minerals*, 11(2), 159. doi:10.3390/min11020159
- Manoharan J, S. (2021). Flawless Detection of Herbal Plant Leaf by Machine Learning Classifier Through Two Stage Authentication Procedure. *Journal of Artificial Intelligence and Capsule Networks*, 3(2), 125–139. doi:10.36548/jaicn.2021.2.005
- Naeem, S., Ali, A., Chesneau, C., Tahir, M. H., Jamal, F., Sherwani, R. A. K., & Ul Hassan, M. (2021). The Classification of Medicinal Plant Leaves Based on Multispectral and Texture Feature Using Machine Learning Approach. *Agronomy*, 11(2), 263. doi:10.3390/agronomy11020263
- Osawa, K., Tsuji, Y., Ueno, Y., Naruse, A., Foo, C.-S., & Yokota, R. (2022). Scalable and Practical Natural Gradient for Large-Scale Deep Learning. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(1), 404–415. doi:10.1109/TPAMI.2020.3004354
- Otoni, A. L. C., de Amorim, R. M., Novo, M. S., & Costa, D. B. (2023). Tuning of data augmentation hyperparameters in deep learning to building construction image classification with small datasets. *International Journal of Machine Learning and Cybernetics*, 14(1), 171–186. doi:10.1007/s13042-022-01555-1
- Patil, K., Suryawanshi, Y., Dhoka, A., & Chumchu, P. (2024). Plumbago Zeylanica (Chitrak) leaf image dataset: A comprehensive collection for botanical studies, herbal medicine research, and environmental analyses. *Data in Brief*, 52, 109929. doi:10.1016/j.dib.2023.109929
- Pratondo, A., Elfahmi, E., & Novianty, A. (2022). Classification of *Curcuma longa* and *Curcuma zanthorrhiza* using transfer learning. *PeerJ Computer Science*, 8, e1168. doi:10.7717/peerj-cs.1168
- Renas Rajab Asaad, & M. Abdulazeez, A. (2024). Comprehensive Classification of Iris Flower Species: A Machine Learning Approach. *Indonesian Journal of Computer Science*, 13(1). doi:10.33022/ijcs.v13i1.3717
- Roopashree, S., & Anitha, J. (2021). DeepHerb: A Vision Based System for Medicinal Plants Using Xception Features. *IEEE Access*, 9, 135927–135941. doi:10.1109/ACCESS.2021.3116207
- Sucher, N., & Carles, M. (2008). Genome-Based Approaches to the Authentication of Medicinal Plants. *Planta Medica*, 74(6), 603–623. doi:10.1055/s-2008-1074517
- Villalobos-Arias, L., Quesada-López, C., Guevara-Coto, J., Martínez, A., & Jenkins, M. (2020). Evaluating hyper-parameter tuning using random search in support vector machines for software effort estimation. In *Proceedings of the 16th ACM International Conference on Predictive Models and Data Analytics in Software Engineering* (pp. 31–40). New York, NY, USA: ACM. doi:10.1145/3416508.3417121