

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Berdasarkan studi-studi sebelumnya, berbagai penelitian telah dilakukan untuk memahami topik yang menjadi fokus dalam penelitian ini. Penelitian - penelitian tersebut memberikan kontribusi signifikan dalam mengembangkan dasar teori dan pemahaman yang lebih mendalam terhadap masalah yang diangkat. penelitian terdahulu yang relevan dengan penelitian ini

Tabel 2. 1 Studi Literatur

No	Judul Penelitian	Penulis dan Tahun	Metode	Hasil Akurasi
1	DeepMelaNet: Advancing Melanoma Stage Classification in Skin Cancer Diagnosis	Al Huda, M.S., Tahmid Enam Shrestha, Asmaul Hossain, Nissan Bin Sharif, M Asraf Ali, Timotei Istvan Erdei., 2025	DeepMelaNet dengan CNN dan augmentasi data	hasil akurasi penelitian ini mencapai 93,40%, dengan nilai presisi 98%, recall 94%, dan skor F1 93%.
2	Advanced Deep Learning Models for Melanoma Diagnosis in Computer-Aided Skin Cancer Detection	Kaur, R., Hamid Gholam Hosseini, Maria Linden., 2025	CNN dengan preprocessing dan segmentasi	hasil akurasi penelitian ini mencapai 93,40%, dengan nilai presisi 93,45%, recall 94,51%, dan skor F1 93,98%.
3	Computer Aided Diagnosis of Melanoma Using	Gouabou, A., Jules Colenne, Jiliana Monnier,	CNN dengan game theory	Penelitian ini menggunakan hasil AUROC

	Deep Neural Networks and Game Theory	Jean-Luc Damoiseaux, Abdellatif Moudafi, Djamel Merad., 2022		dengan hasil untuk melanoma mencapai 0,93 dan Benign Keratosis 0,97 dan Nevi 0,96
4	Klasifikasi Kanker Kulit Berbasis CNN dengan Metode Hybrid Preprocessing	Fedryanto Dartiko, Refki Jorgi Pradana, Renti Epana Sari, Wahyu Syahputra, Widhia KZ Oktoeberza, 2024	CNN dengan menggunakan metode hybrid preprocessing yang terdiri CLAHE, morphological closing dan median filter	tahap pengujian sistem berhasil memperoleh hasil yang cukup memuaskan, dengan nilai accuracy sebesar 78,19% dan loss 0.5324.

Pada Tabel 2.1 Penelitian pertama memperkenalkan sebuah model dengan nama DeepMelaNet, sebuah arsitektur deep learning yang dimodifikasi dari EfficientNet untuk tujuan deteksi melanoma pada tahap awal. Dengan mengatasi tantangan deteksi melanoma yang sering terlambat karena ketidakmampuan untuk membedakan dengan jelas antara lesi melanoma yang ganas dan lesi jinak, penelitian ini mengembangkan model yang dapat menangani masalah tersebut dengan lebih efisien. DeepMelaNet berfungsi dengan menggunakan dataset melanoma skin cancer yang berisi lebih dari 10.000 citra lesi kulit, yang mencakup berbagai variasi melanoma, benign keratosis, dan nevus. Dataset ini memberikan keunggulan dalam meningkatkan keandalan dan akurasi model, tetapi juga menunjukkan tantangan dalam hal ketidakseimbangan kelas, di mana jumlah citra benign lebih banyak dibandingkan dengan melanoma. Penelitian ini menunjukkan bahwa penggunaan teknik augmentasi data, seperti rotasi acak dan flipping, dapat membantu mengatasi masalah ketidakseimbangan data dan meningkatkan kemampuan generalisasi model. Hasil dari model ini sangat menggembirakan,

dengan akurasi mencapai 93,40%, precision 98%, recall 94%, dan F1 score 93%, yang menunjukkan bahwa model ini sangat efektif dalam mengidentifikasi melanoma pada tahap awal dengan tingkat keberhasilan yang tinggi. Namun, meskipun hasil yang diperoleh sangat menjanjikan, ada beberapa area yang masih dapat ditingkatkan, seperti optimasi lebih lanjut pada pengaturan hyperparameter dan penanganan dataset yang tidak seimbang. Selain itu, meskipun model ini diuji menggunakan TPU yang memungkinkan pelatihan cepat dan efisien, penelitian ini juga dapat dikembangkan lebih lanjut untuk memastikan model dapat diimplementasikan secara luas di klinik atau rumah sakit dengan kondisi perangkat keras yang bervariasi[6].

Penelitian kedua melakukan pengembangan model deep learning yang dapat mendeteksi melanoma secara otomatis pada tahap awal, dengan memanfaatkan serangkaian teknik canggih dalam computer-aided diagnosis (CAD). Model yang digunakan mengintegrasikan beberapa tahap, dimulai dengan preprocessing citra untuk menghilangkan gangguan seperti rambut dan meningkatkan kontras citra dermatoskopi yang sering kali memiliki kualitas rendah. Penggunaan operasi morfologis dan agregasi kontekstual dalam jaringan neural deep learning menjadi inti dari proses ini. Untuk segmentasi, model ini menerapkan deep learning untuk mengekstrak area lesi dengan lebih akurat, sementara tahap klasifikasi dilakukan menggunakan deep neural networks untuk membedakan melanoma dari lesi jinak. Meskipun penelitian ini menggunakan dataset ISIC 2020 yang cukup besar dan beragam, ada beberapa kekurangan yang perlu diperhatikan, terutama dalam hal variasi kondisi kulit yang tidak tercakup secara penuh dalam dataset tersebut, seperti kulit yang lebih gelap atau kondisi pencahayaan yang buruk. Hal ini berisiko menyebabkan model memiliki kesulitan dalam menggeneralisasi pada populasi yang lebih luas. Meskipun demikian, model ini menunjukkan akurasi yang sangat baik sebesar 93,40%, yang menunjukkan bahwa preprocessing dan segmentasi yang tepat sangat membantu dalam meningkatkan hasil klasifikasi[8].

Penelitian ketiga melakukan pendekatan baru dalam sistem diagnosis melanoma dengan menggabungkan teknologi deep learning berbasis Convolutional Neural Networks (CNN) dan teori permainan (game theory). Salah satu tantangan utama dalam penerapan deep learning untuk diagnosis medis adalah transparansi dan pemahaman proses pengambilan keputusan yang dilakukan oleh model, yang sering kali dianggap sebagai “black box” oleh banyak profesional medis. Untuk mengatasi tantangan ini, penelitian ini mengintegrasikan game theory untuk meningkatkan pemahaman tentang bagaimana model membuat keputusan dan mengurangi ketidakpastian yang dapat muncul saat model memberikan prediksi. Dengan menggunakan dataset ISIC yang terdiri dari ribuan citra lesi kulit, model ini melakukan klasifikasi dengan mengelompokkan lesi berdasarkan tingkat kepercayaan prediksi, yaitu tingkat keyakinan apakah lesi tersebut melanoma, nevus, atau benign keratosis. Salah satu kekurangan utama dalam penelitian ini adalah meskipun model menggunakan game theory untuk meningkatkan transparansi, pemahaman yang lebih dalam mengenai bagaimana game theory mempengaruhi keputusan akhir model masih perlu dijelaskan lebih lanjut kepada praktisi medis agar mereka dapat lebih mudah mengadopsi teknologi ini. Selain itu, meskipun model ini menunjukkan performa yang sangat baik dengan AUROC 0,93 untuk melanoma, 0,96 untuk nevus, dan 0,97 untuk benign keratosis, tantangan lainnya adalah memastikan bahwa sistem ini dapat bekerja secara konsisten di berbagai skenario medis dunia nyata. Penelitian ini menunjukkan bahwa menggabungkan metode game theory dengan deep learning tidak hanya dapat meningkatkan akurasi model, tetapi juga memberikan lebih banyak transparansi, yang penting bagi para dokter dan profesional medis dalam mengambil keputusan berbasis model.[13]

Pada penelitian yang dilakukan Dartiko[14], fokus utama terletak pada pengembangan sistem klasifikasi kanker kulit berbasis deep learning untuk membedakan antara melanoma benign (jinak) dan malignant (ganas) secara otomatis. Konsep utama penelitian ini adalah klasifikasi berbasis Convolutional Neural Network (CNN) yang dipadukan dengan rangkaian pra-

pemrosesan data secara hybrid, yakni penggunaan CLAHE, morphological closing, dan median filter. Tahapan pra-pemrosesan ini terutama ditujukan untuk mengatasi masalah utama pada citra kulit, seperti rendahnya kontras dan adanya noise berupa rambut-rambut halus di area epidermis.

CLAHE digunakan sebagai teknik inti dalam proses pra-pemrosesan guna meningkatkan kontras lokal dan mempertegas detail tekstur serta tepi lesi pada citra dermatoskopi. Setelah citra melewati rangkaian pra-pemrosesan ini, CNN langsung menerima data hasil transformasi tersebut untuk proses klasifikasi ke dalam dua kategori utama: benign dan malignant. Tidak diperlukan tahapan ekstraksi fitur manual, karena CNN mampu mengekstraksi fitur penting secara otomatis dari citra yang telah diperbaiki secara visual dengan preprocessing.

Sistem klasifikasi yang diusulkan menghasilkan akurasi 78,19% pada pengujian, dengan nilai loss sebesar 0.5324. Nilai ini menunjukkan peningkatan performa dibandingkan beberapa penelitian terdahulu yang menggunakan dataset lebih kecil atau pipeline sederhana tanpa preprocessing hybrid. Penelitian ini menyimpulkan bahwa sistem berbasis kombinasi preprocessing (CLAHE, morphological closing, median filter) dan CNN menunjukkan potensi tinggi untuk mendukung diagnosis kanker kulit dini secara otomatis, meski diakui bahwa eksplorasi lebih lanjut terhadap arsitektur dan pendekatan lain masih terbuka lebar

2.2 Kanker Kulit Melanoma

Kanker kulit adalah penyakit yang disebabkan oleh pembentukan sel-sel abnormal, tergantung pada sifat dan intensitasnya, dapat menyusup atau menyebar ke berbagai area tubuh[2]. Salah satunya adalah melanoma, melanoma adalah jenis kanker kulit yang sangat berbahaya dan berasal dari degenerasi melanosit, yaitu sel penghasil pigmen melanin di kulit. Melanin berfungsi melindungi kulit dari kerusakan akibat paparan sinar ultraviolet (UV), yang merupakan salah satu faktor risiko utama terjadinya melanoma. Meski insidennya lebih rendah dibandingkan kanker kulit non-melanoma, melanoma menyumbang sekitar 75% kematian akibat kanker kulit karena

potensi invasi dan metastasisnya yang tinggi[15], [16]. Kanker kulit dibagi menjadi 2 yaitu Malignant Melanoma dan Non Melanoma. Malignant melanoma berasal dari sel melanosit pada kulit maupun mukosa, malignant melanoma dipisah dari kanker kulit lainnya karena memiliki *behaviour* yang berbeda. Non melanoma berasal dari sel keratin dan dapat dibedakan menjadi empat jenis yaitu Basal Cell Carcinoma, Squamous cell Carcinoma, Skin Adnexal Tumor[17]. Menurut Skin Cancer Foundation kanker kulit adalah kanker paling umum yang ada di Amerika Serikat dan di seluruh dunia, diperkirakan di tahun 2025 sebanyak 212,200 kasus terdiagnosis di Amerika Serikat, dari jumlah tersebut sebanyak 107,240 kasus akan bersifat in situ (noninvasif), terbatas pada epidermis (lapisan atas kulit), dan 104,960 kasus akan bersifat invasif, menembus epidermis ke lapisan kedua kulit (dermis). Dari kasus invasif, 60,550 kasus akan dialami oleh pria dan 44,410 kasus akan dialami oleh wanita[5].

2.3 Augmentasi Data

Augmentasi data adalah teknik memperkaya dataset dengan cara memodifikasi data yang sudah ada, seperti rotasi, flipping, translasi, penskalaan, dan perubahan pencahayaan. Teknik ini sangat penting dalam pengembangan model deep learning, khususnya di bidang medis, karena data citra yang berkualitas dan terlabel seringkali terbatas[18]. Augmentasi data bertujuan meningkatkan keragaman data, mengurangi overfitting, dan meningkatkan akurasi model. Studi terbaru menunjukkan bahwa augmentasi seperti flipping, rotasi, dan translasi dapat meningkatkan akurasi model[18]. Dengan augmentasi, model deep learning menjadi lebih robust terhadap variasi data nyata di lapangan.

2.4 Penghapusan Garis Rambut

Penghapusan garis rambut dan peningkatan kontras citra merupakan langkah penting dalam preprocessing citra dermoskopi untuk deteksi melanoma, karena kehadiran rambut pada citra kulit dapat mengaburkan area lesi dan menurunkan akurasi segmentasi serta klasifikasi oleh model deep

learning. Dalam penelitian oleh Kaur et al.[8], melakukan pembersihan terhadap garis rambut yang ada pada dataset citra pada ISIC 2020. Dengan merubah warna dari citra dataset yang awalnya menggunakan ruang warna RGB (Red Green Blue) dirubah menjadi skala abu-abu, dilanjutkan dengan mendeteksi melalui operasi penutupan dan pengurangan morfologi.

Dalam metode yang disulkan oleh Kaur et al. Operasi penutupan dilakukan antara citra asli I dan elemen penataan SE dengan menerapkan dilasi (\oplus), diikuti dengan operasi erosi (\ominus), seperti yang diberikan dalam Rumus 2.1.

$$\text{Close}_{img} = (I(x,y) \oplus SE) \ominus SE \quad (2.1)$$

Operasi penutupan citra menghilangkan bagian yang tidak relevan dari sebuah citra. Selain itu, operasi ini juga menghilangkan lubang-lubang kecil, mengisi celah di antara garis batas, dan menghaluskan kontur dari luar. Untuk mendeteksi perbedaan antara dua citra dan bagian yang tidak rata, pengurangan dilakukan antara citra yang diperoleh setelah penutupan Close_{img} dan citra asli I , seperti yang disajikan dalam Rumus 2.2.

$$\text{Diff}_{img} = \text{Close}_{img} - I \quad (2.2)$$

Setelah pengurangan, citra yang dihasilkan berisi piksel yang berbeda di antara keduanya. Proses binarisasi menggunakan $T = 25$ sebagai ambang batas digunakan untuk menghasilkan *hair mask* dan memperhalus piksel rambut. Selama perbandingan ini, piksel latar belakang ditetapkan ke '0', dan piksel latar depan, termasuk yang terkait dengan rambut, ditetapkan ke '1'. Untuk memperbaiki batas-batas dan menjembatani kesenjangan dalam citra yang dihasilkan, operasi dilatasi diterapkan.

$$\text{Dilation}_{img} = \text{Diff}_{img} > T \quad (2.3)$$

$$\text{Dilation}_{img} = \text{Dilation}_{img} \oplus SE \quad (2.4)$$

$$\text{New}_{img} = \begin{cases} I, & \text{if } \text{Dilation}_{img} == 0 \\ I_{\text{new}}, & \text{with new remmapping} \end{cases} \quad (2.5)$$

Piksel dalam citra dilatasi disalin ke dalam citra baru berdasarkan perbandingan: jika nilai piksel adalah '0', maka piksel tersebut dianggap sebagai latar belakang citra baru. Piksel yang memiliki nilai bukan nol dibandingkan dengan ambang batas untuk memeriksa apakah piksel tersebut adalah piksel berbulu, dan, jika terdeteksi, piksel tersebut diganti dengan intensitas piksel tetangganya[8].

2.5 Peningkatan Kontras Citra

Penigkatan kontras citra sangat diperlukan dalam peningkatan visibilitas, akurasi, dan kualitas citra secara keseluruhan. Dengan proses sebelumnya, hasil citra mengalami rekontruksi ulang dengan menyalin citra baru ke dalam citra lama sehingga berdampak terhadap contrast dan resolusi dari citra yang digunakan.

Teknik peningkatan kontras, seperti Contrast Limited Adaptive Histogram Equalization (CLAHE), memainkan peran penting dalam pencitraan medis, khususnya dalam meningkatkan kualitas diagnostik citra. Teknik-teknik ini didesain untuk meningkatkan visibilitas fitur-fitur penting dalam citra, sehingga memudahkan algoritme dan profesional medis untuk mengidentifikasi kelainan dan membuat diagnosis yang akurat[19].

Contrast Limited Adaptive Histogram Equalization (CLAHE) secara signifikan meningkatkan kualitas citra medis, khususnya dalam pencitraan medis. Dengan meningkatkan kontras lokal, CLAHE membuat detail penting, seperti pembuluh darah dan batas lesi, menjadi lebih terlihat. Hal ini sangat penting untuk diagnosis yang akurat dan ekstraksi fitur yang efektif dalam model *deep learning*

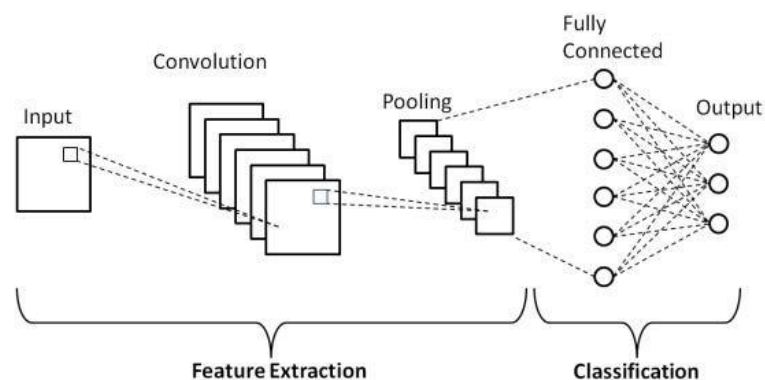
2.6 Convolutional Neural Network (CNN)

Convolutional Neural Networks (CNN) telah merevolusi bidang pembelajaran mendalam, khususnya dalam pemrosesan citra dan visi komputer. Arsitektur CNN dirancang secara cerdas untuk meniru cara manusia memahami informasi visual. Convolutional Neural Network (CNN)

merupakan salah satu arsitektur deep learning yang dirancang khusus untuk pemrosesan data berbentuk grid, seperti citra digital. CNN terdiri dari beberapa lapisan utama, yaitu Input layer, convolutional layer, pooling layer, dan fully connected layer.

Input layer berfungsi untuk menerima data pixel mentah dari sebuah citra. Setiap citra biasanya direpresentasikan sebagai array tiga dimensi yang biasa dikenal sebagai tensor, dimana dimensinya sesuai dengan tinggi, lebar dan saluran warna (RGB). Lapisan konvolusi berkerja sebagai sebuah jantung dari CNN, dimana lapisan ini menerapkan serangkaian filter (atau kernel) pada citra input, setiap filter dirancang untuk mendeteksi fitur tertentu seperti tepi, tekstur, atau bentuk dalam citra, langkah ini secara signifikan mengurangi dimensi spasial dari input sekaligus mempertahankan informasi penting. Masuk kedalam Pooling layer, Pooling layer berfungsi untuk mengurangi beban komputasi, mengurangi overfitting, dan mempertahankan fitur penting serta membuang informasi kurang penting, metode paling umum yang sering digunakan ialah Max pooling dan Average pooling[20].

Secara kesimpulan lapisan konvolusi berfungsi mengekstraksi fitur spasial dari citra, sedangkan pooling mengurangi dimensi data dan meningkatkan efisiensi komputasi. Lapisan fully connected berperan dalam proses klasifikasi akhir[7].



Gambar 2.1 Arsitektur CNN

2.7 DeepMelaNet

DeepMelaNet adalah model deep learning yang dirancang khusus untuk klasifikasi kanker kulit melanoma sebagai malignan (berbahaya) atau benign (tidak berbahaya). Model ini dikembangkan dari arsitektur EfficientNet dengan modifikasi signifikan untuk meningkatkan akurasi dan efisiensi dalam tugas diagnostik klinis[6]. EfficientNet merupakan arsitektur CNN yang kuat dan telah dilatih sebelumnya pada dataset citra berskala besar (ImageNet). Dengan memodifikasi model yang telah dilatih sebelumnya, DeepMelaNet dapat memanfaatkan fitur-fitur penting yang dipelajari dari citra dalam dataset. Fitur-fitur ini kemudian disesuaikan secara khusus untuk tugas klasifikasi kanker kulit

DeepMelaNet menggunakan arsitektur EfficientNet sebagai basis karena kemampuan compound scaling-nya yang memungkinkan penyeimbangan antara kompleksitas komputasi dan performa. Modifikasi utama meliputi:

1. Blok MBConv Termodifikasi:
 - a. Pengurangan rasio ekspansi (expansion ratio) untuk mengurangi biaya akses memori.
 - b. Penggunaan kernel 3×3 dengan lapisan 1×1 untuk meningkatkan efisiensi komputasi.
2. Integrasi SE Blocks:

Blok Squeeze-and-Excitation dimaksudkan untuk modulasi saluran (channel-wise) fitur ekstraksi, meningkatkan fokus pada pola klinis yang relevan.
3. Lapisan Klasifikasi Binari:

Penggantian lapisan akhir dengan neuron sigmoid tunggal untuk tugas klasifikasi biner (0 = benign, 1 = malignan)

Dengan menggunakan teknik preprocessing seperti augmentasi data untuk Menambahahkan Variasi dalam dataset yang digunakan. Pada pengujian menggunakan dataset besar.

2.8 Evaluasi Metrik Hasil Akurasi

Dalam mengevaluasi kinerja model klasifikasi biner seperti DeepMelaNet, hasil prediksi dipetakan ke dalam sebuah matriks konfusi (Confusion Matrix). Pemetaan ini membandingkan label prediksi model dengan label sebenarnya (Ground Truth). Dalam penelitian ini, kelas Malignant (Ganas) dikategorikan sebagai kelas Positif, sedangkan kelas Benign (Jinak) dikategorikan sebagai kelas Negatif. Berdasarkan kategori tersebut, komponen evaluasi didefinisikan sebagai berikut:

- True Positive (TP): Merupakan jumlah data citra yang sebenarnya memiliki label Malignant dan berhasil diprediksi dengan tepat oleh model sebagai Malignant. Nilai TP yang tinggi mengindikasikan kemampuan model dalam mendeteksi kanker dengan benar.
- True Negative (TN): Merupakan jumlah data citra yang sebenarnya memiliki label Benign dan berhasil diprediksi dengan tepat oleh model sebagai Benign. Nilai TN mencerminkan kemampuan model dalam mengenali kondisi normal atau tidak berbahaya.
- False Positive (FP): Dikenal sebagai Type I Error (Alarm Palsu), yaitu jumlah data citra yang sebenarnya Benign namun salah diprediksi oleh model sebagai Malignant.
- False Negative (FN): Dikenal sebagai Type II Error, yaitu jumlah data citra yang sebenarnya Malignant namun salah diprediksi oleh model sebagai Benign.

metrik akurasi menunjukkan proporsi prediksi yang benar dibandingkan dengan total prediksi yang dilakukan. Akurasi dihitung dengan rumus:

$$Akurasi = \frac{Jumlah\ Prediksi\ Benar}{Total\ Jumlah\ Prediksi} \quad (2.6)$$

Namun, meskipun akurasi sering digunakan, ia tidak selalu mencerminkan performa model dengan tepat, terutama dalam kasus kelas yang tidak seimbang. Dalam hal ini, metrik lain, seperti Precision, Recall, dan F1-score, lebih relevan.

Precision mengukur seberapa banyak prediksi positif yang benar di antara semua prediksi positif yang dihasilkan oleh model. Hal ini penting dalam aplikasi di mana biaya kesalahan positif sangat tinggi, seperti dalam deteksi penipuan atau diagnosis medis. Precision dihitung dengan rumus:

$$Precision = \frac{True\ Positive}{True\ Positive + False\ Positive} \quad (2.7)$$

Recall mengukur seberapa banyak prediksi positif yang benar dibandingkan dengan seluruh data positif yang ada. Ini memberikan gambaran tentang kemampuan model untuk mendeteksi semua kasus positif yang ada. Recall sangat penting dalam aplikasi di mana kehilangan data positif dapat berakibat fatal, seperti dalam deteksi penyakit. Recall dihitung dengan rumus:

$$Recall = \frac{True\ Positive}{True\ Positive + False\ Negative} \quad (2.8)$$

F1-score adalah rata-rata harmonis antara Precision dan Recall. F1-score memberikan keseimbangan antara Precision dan Recall, sehingga sangat berguna ketika kedua metrik tersebut penting. F1-score dihitung dengan rumus:

$$F1Score = \frac{Precision \times Recall}{Precision + Recall} \quad (2.9)$$

Selain itu, dalam situasi di mana model digunakan untuk klasifikasi multikelas, Confusion Matrix juga sering digunakan untuk memberikan gambaran yang lebih jelas mengenai kinerja model. Matriks ini menunjukkan distribusi prediksi untuk setiap kelas, yang membantu dalam mengidentifikasi kesalahan klasifikasi dan area yang perlu diperbaiki.