

Mawaddah Harahap, M.Kom
Amir Mahmud Husein, M.Kom

Penerapan Efficient-Net Dalam Mengklasifikasi Kanker Kulit



PENERAPAN EFFICIENT-NET DALAM MENGLASIFIKASI
KANJER KULIT

PENULIS

Mawaddah Harahapp, M.Kom

Amir Mahmud Husein, M.Kom

EDITOR

Felix Theдора

PENERBIT

UNPRI PRESS

ANGGOTA IKAPI

Alamat Redaksi

Kampus 2

Jl. Sampul No. 4 Medan



*Hak Cipta dilindungi undang-undang
Dilarang memperbanyak sebagian atau
seluruh isi buku ini dalam bentuk dan cara
apapun tanpa izin tertulis dari penerbit.*

KATA PENGANTAR

Segala puji bagi Tuhan Yang Maha Esa atas rahmat dan karunia-Nya, sehingga penulis dapat menyelesaikan monograf. Kami ucapkan juga rasa terima kasih kami kepada pihak-pihak yang mendukung lancarnya monograf ini mulai dari proses penulisan hingga proses cetak, yaitu orang tua kami, rekan-rekan kami, penerbit, dan masih banyak lagi yang tidak bisa kami sebutkan satu per satu.

Kanker kulit adalah salah satu penyakit mematikan yang paling umum di seluruh dunia. Oleh karena itu, klasifikasi kanker kulit menjadi semakin penting karena pengobatan kanker kulit stadium awal jauh lebih efektif dan efisien. Klasifikasi tiga jenis kanker kulit yang umum, yaitu karsinoma sel basal (BCC), karsinoma sel skuamosa (SCC), dan melanoma menggunakan arsitektur EfficientNet.

Buku monograf yang berjudul ‘Penerapan Efficient-Net Dalam Mengklasifikasikan Kanker Kulit’ diharapkan dapat memberikan pembelajaran bagaimana melakukan klasifikasi dalam menemukan hasil yang akurat sehingga mempermudah para medis memberikan solusi yang tepat. Sehingga masyarakat yang mengalami kanker dapat melakukan antisipasi sejak dini dalam menghindari terjadinya penyakit yang lebih serius.

Kami sadar, masih banyak luput dan kekeliruan yang tentu saja jauh dari sempurna tentang monograf ini. Oleh sebab itu, kami mohon agar pembaca memberi kritik dan saran agar kami dapat terus meningkatkan kualitas monograf.

Medan, 05 Juni 2024

Penulis

DAFTAR ISI

DAFTAR ISI	i
DAFTAR TABEL.....	v
DAFTAR GAMBAR.....	vi
KATA PENGANTAR	viii
BAB 1 PENDAHULUAN.....	1
1.1 Klasifikasi Gambar	1
1.2 Kanker Kulit	7
1.3 Klasifikasi Kanker Kulit.....	9
1.4 Studi Kasus Kanker Kulit	10
BAB 2 EFFICIENTNET	13
2.1 Pengantar	13
2.2 Algoritma EfficientNet	16
2.2.1. EfisienNet-B0	18
2.2.2. EfisienNet-B1	18
2.2.4. EfisienNet-B3	20
2.2.5. EfisienNet-B4	21
2.2.6. EfisienNet-B5	22
2.2.7. EfisienNet-B6	23
2.2.8. EfisienNet-B7	24
BAB 3 AKUSISI DATA.....	26
3.1 Pengantar	26
3.2 Penerapan.....	28
BAB 4 DATA PREPROCESSING	31
4.1 Pra-pemrosesan.....	31
4.2 Augmentasi Data	33

BAB 5 MODELLING.....	36
5.1 CNN Modeling	36
5.2 Pengujian dan Evaluasi Model	39
BAB 6 HASIL PELATIHAN DAN VALIDASI.....	42
6.1 Augmentasi Data	42
6.2 Hasil Pengujian.....	47
DAFTAR PUSTAKA	51

DAFTAR TABEL

Tabel 1 EfficientNet Model.....	17
Tabel 2 Pemisah kumpulan data.....	34
Tabel 3 Performa EfficientNets pada <i>training set</i> dan <i>validation set</i>	48
Tabel 4 Nilai akurasi, presisi, <i>recall</i> , dan skor F1 pada <i>testing set</i>	50

DAFTAR GAMBAR

Gambar 1 Jenis Kanker Kulit.....	10
Gambar 2 Parameter Efficeint-Net.....	15
Gambar 3 Arsitektur EfficientNet.....	17
Gambar 4 EfficientNet-B0	18
Gambar 5 EfficientNet-B1	20
Gambar 6 EfficientNet-B3	21
Gambar 7 EfficientNet-B4	22
Gambar 8 EfficientNet-B5	23
Gambar 9 EfficientNet-B6	24
Gambar 10 EfficientNet-B7	25
Gambar 11 Sampel setiap kelas yang dipilih dari dataset.....	31
Gambar 12 Distribusi frekuensi kelas terpilih (BCC, SCC, MEL).....	33
Gambar 13 Arsitektur Dasar EfficientNet (EfficientNet-B0).....	39
Gambar 14 Training accuracy vs. validation accuracy dan training loss vs. validation loss dari EfficientNet-B0.....	43
Gambar 15 Training accuracy vs. validation accuracy dan training loss vs. validation loss dari EfficientNet-B1	44
Gambar 16 Training accuracy vs. validation accuracy dan training loss vs. validation loss dari EfficientNet-B2.....	45
Gambar 17 Training accuracy vs. validation accuracy dan training..... loss vs. validation loss dari EfficientNet-B3	45
Gambar 18 Training accuracy vs. validation accuracy dan training..... loss vs. validation loss dari EfficientNet-B4	46
Gambar 19 Training accuracy vs. validation accuracy dan training	
loss vs. validation loss dari EfficientNet-B5	46

Gambar 20	Training accuracy vs. validation accuracy dan training loss vs. validation loss dari EfficientNet-B6	47
Gambar 21	Training accuracy vs. validation accuracy dan training loss vs. validation loss dari EfficientNet-B7	47
Gambar 22	Confusion matrix dari semua model EfficientNet..... sebagai hasil klasifikasi kanker kulit (BCC, SCC, MEL) ..	49

KATA PENGANTAR

Segala puji bagi Tuhan Yang Maha Esa atas rahmat dan karunia-Nya, sehingga penulis dapat menyelesaikan monograf. Kami ucapkan juga rasa terima kasih kami kepada pihak-pihak yang mendukung lancarnya monograf ini mulai dari proses penulisan hingga proses cetak, yaitu orang tua kami, rekan-rekan kami, penerbit, dan masih banyak lagi yang tidak bisa kami sebutkan satu per satu.

Kanker kulit adalah salah satu penyakit mematikan yang paling umum di seluruh dunia. Oleh karena itu, klasifikasi kanker kulit menjadi semakin penting karena pengobatan kanker kulit stadium awal jauh lebih efektif dan efisien. Klasifikasi tiga jenis kanker kulit yang umum, yaitu karsinoma sel basal (BCC), karsinoma sel skuamosa (SCC), dan melanoma menggunakan arsitektur EfficientNet.

Buku monograf yang berjudul ‘Penerapan Efficient-Net Dalam Mengklasifikasikan Kanker Kulit’ diharapkan dapat memberikan pembelajaran bagaimana melakukan klasifikasi dalam menemukan hasil yang akurat sehingga mempermudah para medis memberikan solusi yang tepat. Sehingga masyarakat yang mengalami kanker dapat melakukan antisipasi sejak dini dalam menghindari terjadinya penyakit yang lebih serius.

Kami sadar, masih banyak luput dan kekeliruan yang tentu saja jauh dari sempurna tentang monograf ini. Oleh sebab itu, kami mohon agar pembaca memberi kritik dan saran agar kami dapat terus meningkatkan kualitas monograf.

Medan, 05 Juni 2024

Penulis

BAB 1

PENDAHULUAN

1.1 Klasifikasi Gambar

Klasifikasi gambar lebih lazim dalam teknologi modern daripada yang dibayangkan masyarakat. Sementara manusia dapat memahami dan memutuskan sifat suatu objek dalam hitungan detik, kemampuan seperti itu dulunya tidak terbayangkan oleh sistem komputer. Munculnya klasifikasi gambar, ditambah dengan model pembelajaran mesin, membawa perubahan substansial.

Saat ini, sistem klasifikasi gambar memungkinkan berbagai industri, termasuk perawatan kesehatan, e-commerce, dan keamanan, untuk menginterpretasikan data visual secara akurat, membuat keputusan yang tepat, dan meningkatkan proses operasional. Misalnya, para profesional medis menggunakan solusi pencitraan yang didukung pembelajaran mesin untuk memberikan diagnosis yang akurat dalam waktu yang lebih singkat.

Klasifikasi gambar mengacu pada tindakan menentukan label yang paling tepat untuk keseluruhan gambar dari sekumpulan label yang telah ditentukan sebelumnya. Ini merupakan proses penting untuk mengembangkan aplikasi visi komputer.

Misalnya, sistem computer vision diperlukan untuk memasukkan gambar anjing ke dalam kategori anjing, kucing, dan serigala. Melalui perhitungan yang rumit, sistem menyimpulkan bahwa gambar tersebut adalah anjing, bukan kucing atau serigala.

Sistem komputer tidak dapat memahami objek sebagaimana manusia. Bagi komputer, objek adalah data digital yang terdiri dari representasi gambar berpiksel. Dengan sendirinya, sistem tersebut tidak dapat

menyimpulkan spesies, jenis kelamin, atau jenis hewan. Bahkan, sistem tidak mungkin mendeteksi objek apa pun dari data mentah tanpa menggunakan algoritma pembelajaran mesin.

Berikut adalah jenis-jenis teknik klasifikasi gambar

1. Supervised Learning

Supervised Learning melatih model pembelajaran mesin untuk mengidentifikasi pola visual dari sekumpulan dataset gambar berlabel. Selama proses tersebut, model belajar mengaitkan gambar dengan label yang ditetapkan padanya. Misalnya, Anda melatih model untuk mengklasifikasikan wajah dengan memaparkan model ke ribuan gambar berlabel yang memperlihatkan wajah manusia.

Selama pelatihan, teknisi ML memantau keakuratan model saat memprediksi gambar. Kemudian, mereka membuat penyesuaian yang diperlukan untuk memastikan model melakukan lebih sedikit kesalahan dalam iterasi berikutnya. Setelah dilatih, model menggunakan pengetahuan yang tersimpan untuk mengklasifikasikan gambar baru yang belum pernah dilihat sebelumnya.

2. Semi-Supervised Learning

Semi-Supervised Learning menggabungkan metode yang diawasi dan tidak diawasi untuk melatih algoritme klasifikasi gambar. Dalam aplikasi praktis, melatih model dengan kumpulan data beranotasi yang besar menghabiskan sumber daya yang signifikan. Daripada memberi anotasi pada seluruh kumpulan data, tim ML hanya memberi label pada sebagian kecil saja. Kemudian, mereka memasukkan sampel berlabel model ke algoritme yang diawasi,

yang mempelajari dan menetapkan gambar yang tersisa dengan label yang benar. Hasilnya adalah kumpulan besar kumpulan data gambar, di mana model tanpa pengawasan memberi label pada sebagian besarnya. Teknisi data menggunakan seluruh kumpulan data untuk melatih model pengklasifikasi dalam mode pengawasan. Kili Technology mendukung Semi-Supervised Learning, yang memungkinkan organisasi meningkatkan kinerja pelabelan hingga 50%.

3. Deep learning

Deep learning menggunakan jaringan saraf tiruan yang meniru struktur otak manusia. Jaringan saraf tiruan terdiri dari beberapa lapisan tersembunyi yang menampung neuron buatan. Saat menganalisis gambar, model pembelajaran mendalam mengekstraksi fitur dari data mentah dan meneruskannya melalui simpul yang saling terhubung.

Model pembelajaran mendalam dilatih dengan cara yang sama seperti model pembelajaran mesin dasar. Model ini belajar mengaitkan gambar dengan label melalui pelatihan yang diawasi, tidak diawasi, atau semi-diawasi. Yang membedakannya adalah kemampuan model pembelajaran mendalam untuk mengekstrak, menganalisis, dan memahami hubungan dan representasi data gambar yang kompleks dalam skala yang jauh lebih besar.

Meskipun jauh lebih canggih, model pembelajaran mendalam memiliki lebih banyak parameter, kurang dapat ditafsirkan, dan memerlukan waktu pelatihan yang lebih lama. Hal ini menggarisbawahi pentingnya proses anotasi yang efisien, yang memengaruhi waktu pelatihan dan kinerja model.

Data Scientist terus menyempurnakan model pembelajaran mendalam, yang memungkinkan mereka menerapkan berbagai teknik klasifikasi gambar. Berikut ini beberapa model populer yang digunakan untuk klasifikasi gambar.

1. **EfficientNet** diperkenalkan pada tahun 2019 sebagai jaringan saraf konvolusional yang disempurnakan yang mampu mengekstraksi dan memproses fitur-fitur kompleks sambil menyeimbangkan kecepatan dan akurasi.
2. **ResNet50** mengatasi keterbatasan gradien yang menghilang dalam jaringan konvolusional dengan memungkinkan model untuk melewati lapisan tersembunyi tertentu. Karakteristik ini, yang disebut pemetaan residual, memungkinkan model untuk melatih lapisan yang lebih dalam dengan lebih efisien.
3. **VGG-16** adalah jaringan saraf konvolusional yang sangat akurat dengan sekitar 138 juta parameter yang dapat dilatih. Lapisan konvolusionalnya menggunakan filter 3x3 kecil untuk memproses data gambar spasial dan mencegah overfitting.
4. **ViT** adalah singkatan dari Vision Transformer, model pembelajaran mendalam untuk pemrosesan gambar berdasarkan arsitektur transformer. Mirip dengan transformer untuk aplikasi NLP, ViT membagi gambar menjadi serangkaian patch gambar. Kemudian, ia memprediksi kelas tertentu tempat gambar tersebut berada.
5. **Contrastive Captioner (CoCa)** adalah model encoder-decoder yang dimodifikasi yang dilatih dengan captioning dan contrastive loss untuk memungkinkan pengenalan gambar zero-shot dengan

akurasi tinggi. CoCa menghilangkan cross-attention di paruh pertama lapisan decoder untuk fokus pada pengkodean representasi teks. Kemudian, ia memasukkan hasilnya ke dalam lapisan berikutnya untuk pembelajaran gambar-tekst multimodal.

6. **YOLO** adalah model pembelajaran mendalam yang kuat untuk deteksi objek, tetapi juga mampu digunakan dalam tugas klasifikasi gambar. Algoritme ini sangat populer karena prediksinya yang hanya memerlukan satu lintasan.

Teknologi klasifikasi gambar telah merevolusi berbagai industri. Teknologi ini meningkatkan sumber daya manusia, memungkinkan teknologi canggih, dan membantu organisasi mengurangi biaya. Berikut ini adalah contoh penerapan praktis tugas klasifikasi gambar dalam skenario kehidupan nyata.

1. **Medis dan Kesehatan**

Teknik klasifikasi medis tingkat lanjut terbukti membantu para profesional medis dalam mendiagnosis penyakit tertentu. Misalnya, dokter menggunakan sistem pencitraan berbantuan komputer untuk mendeteksi tumor ganas, patah tulang, dan kondisi kulit. Menurut sebuah penelitian, algoritma pencitraan pembelajaran mendalam sebanding, atau dalam beberapa kasus, mengungguli dokter kulit manusia saat mengklasifikasikan kanker kulit.

2. **Manufaktur**

Solusi klasifikasi gambar memungkinkan produsen untuk meningkatkan kualitas produk dengan mendeteksi cacat secara otomatis. Contoh kasusnya adalah perusahaan manufaktur global yang bermitra dengan Kili Technology untuk melatih model AI

untuk deteksi cacat . Model ini, yang dilatih dengan gambar berlabel akurat, mampu mendeteksi retakan dan goresan tipis yang sering terlewatkan selama pemeriksaan manual. Penerapan sistem deteksi cacat berbasis AI ini menghasilkan penghematan biaya sebesar 25% karena deteksi cacat preventif, menggandakan kecepatan membangun set data pelatihan AI melalui pembelajaran daring, dan membutuhkan 30% lebih sedikit data untuk mencapai akurasi tinggi.

3. Keamanan

Petugas keamanan dan penegak hukum telah beralih ke analisis wajah untuk memberikan identifikasi secara langsung bagi orang yang dicurigai. Dengan model pembelajaran mendalam, mereka dapat secara akurat memprediksi jenis kelamin, usia, dan profil seseorang untuk mengurangi potensi ancaman keamanan. Bila diterapkan di bandara, pengenalan wajah dengan algoritma klasifikasi gambar canggih mengurangi waktu naik pesawat hingga 75% tanpa mengorbankan keamanan.

4. Pertanian

Praktik pertanian juga mendapat dorongan dari sistem pemrosesan gambar. Dengan jaringan saraf konvolusional, sistem tersebut dapat memantau pertumbuhan tanaman, mendeteksi serangan hama, dan mengairi lahan pertanian secara strategis. NatureSweet menganalisis gambar lahan pertanian yang diambil dari udara dengan teknik klasifikasi yang sesuai untuk mengetahui tanda-tanda serangan hama, sehingga meningkatkan hasil panennya sebesar 2% hingga 4% .

5. Kendaraan otonom

Teknologi klasifikasi gambar sangat penting dalam pengembangan mobil tanpa pengemudi. Produsen kendaraan otonom melatih model pembelajaran mendalam untuk mengidentifikasi objek dari jaringan kamera, mengklasifikasikannya secara real time, dan memungkinkan kendaraan menghindari rintangan. Tesla, pemimpin di segmen pasar ini, menghabiskan 70.000 jam GPU untuk melatih kombinasi 48 jaringan saraf.

1.2 Kanker Kulit

Kanker kulit adalah pertumbuhan sel-sel yang rusak dengan kecepatan tidak normal di jaringan kulit. Penyebab utamanya sering kali adalah paparan sinar ultraviolet (UV) yang berlebihan. Kanker kulit tidak diragukan lagi merupakan salah satu jenis kanker paling umum di seluruh dunia. Berdasarkan data dari Organisasi Kesehatan Dunia (WHO), lebih dari 1,5 juta orang terkena dampaknya di seluruh dunia pada tahun 2020. Dari angka tersebut, sekitar 1,2 juta kasus adalah kanker kulit non-melanoma, sementara 325.000 kasus lainnya adalah kanker kulit melanoma.

Selain jumlah kasus yang tinggi, kanker kulit juga memiliki tingkat kematian yang signifikan. Pada tahun 2020, sekitar 64.000 orang meninggal karena kanker kulit non-melanoma, dan 57.000 orang meninggal karena melanoma. Angka-angka ini menunjukkan betapa seriusnya penyakit ini dan pentingnya upaya pencegahan serta pengobatan yang tepat. Meski memiliki tingkat kematian yang cukup tinggi, kanker kulit sebenarnya memiliki peluang penyembuhan yang besar jika didiagnosis dan diobati sejak dini.

Kanker kulit memiliki beberapa ciri khas yang perlu diperhatikan untuk pengenalan dan deteksi dini. Salah satu ciri utama kanker kulit adalah adanya perubahan pada benjolan atau bintik yang sudah ada di kulit, seperti pertumbuhan yang cepat, perubahan warna, ukuran, atau bentuk yang tidak biasa. Selain itu, kanker kulit sering kali ditandai dengan munculnya luka yang tidak sembuh atau bersisik pada kulit, serta adanya benjolan yang terasa gatal atau nyeri. Penting juga untuk memperhatikan adanya perubahan pada tahi lalat, seperti perubahan warna, ukuran, atau bentuk, serta tahi lalat yang berubah menjadi berdarah atau gatal. Mengenali ciri-ciri ini dengan seksama dan segera berkonsultasi dengan profesional kesehatan dapat memungkinkan deteksi dini dan penanganan yang lebih efektif terhadap kanker kulit.

Kanker kulit memiliki dampak yang signifikan pada individu dan masyarakat secara luas. Selain menimbulkan konsekuensi kesehatan yang serius, seperti risiko kematian akibat penyakit ini, kanker kulit juga dapat menyebabkan dampak psikologis yang mengganggu. Individu yang terdiagnosis dengan kanker kulit sering mengalami stres, kecemasan, dan depresi karena kondisi kesehatan mereka. Selain itu, biaya pengobatan kanker kulit yang tinggi juga menjadi beban finansial yang berat bagi banyak individu dan keluarga. Dampak sosial dari kanker kulit juga dapat dirasakan dalam hal penurunan produktivitas dan kualitas hidup yang terpengaruh.

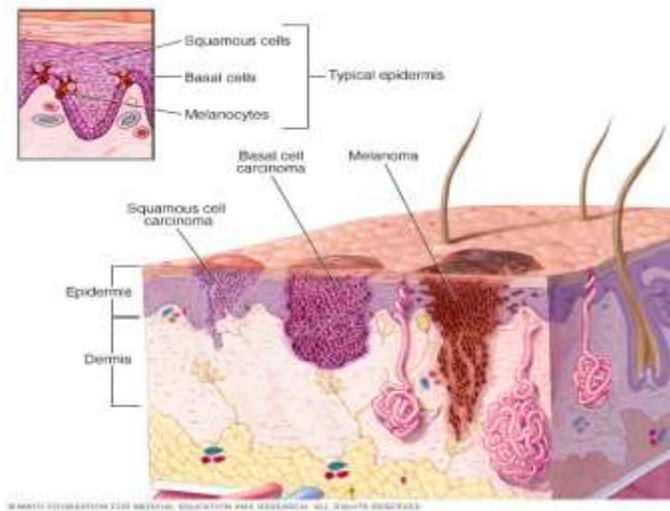
Diagnosis atau deteksi dini sangat penting untuk pengobatan kanker kulit yang efektif dan efisien. Jika kanker kulit dapat diidentifikasi pada tahap awal, semua jenis kanker kulit berpotensi disembuhkan. Namun, tantangan terbesar adalah mendiagnosis kanker kulit pada stadium awal. Metode diagnosis konvensional sering kali bisa sangat menantang dan

rentan terhadap kesalahan. Kesalahan diagnosis ini dapat mengakibatkan penanganan yang terlambat dan penurunan peluang penyembuhan.

Hal ini menunjukkan bahwa pemanfaatan sistem computer vision di bidang diagnosis kanker kulit dapat sangat membantu. Teknologi ini dapat memberikan dukungan signifikan kepada para profesional medis, dan bahkan orang biasa, dalam mengidentifikasi kanker kulit. Dengan bantuan algoritma cerdas dan analisis gambar, sistem computer vision dapat meningkatkan akurasi dan kecepatan diagnosis, mengurangi kesalahan manusia, dan pada akhirnya menyelamatkan lebih banyak nyawa. Integrasi teknologi dalam proses diagnosis medis adalah langkah maju yang penting dalam upaya melawan kanker kulit.

1.3 Klasifikasi Kanker Kulit

Kanker kulit merupakan salah satu jenis kanker yang paling umum di dunia, dan tiga jenis yang paling sering dijumpai adalah karsinoma sel basal (BCC), karsinoma sel skuamosa (SCC), dan melanoma. BCC dan SCC, yang termasuk dalam kategori kanker kulit non-melanoma primer, merupakan bentuk kanker kulit yang paling sering dilaporkan. Meskipun kedua jenis ini lebih umum, melanoma dikenal sebagai jenis kanker kulit yang lebih mematikan karena memiliki angka kematian yang jauh lebih tinggi. Oleh karena itu, pemahaman yang mendalam dan metode deteksi yang akurat untuk semua jenis kanker kulit ini sangat penting dalam upaya penanggulangan penyakit.



Gambar 1 Jenis Kanker Kulit

Pada umumnya, permasalahan sebelumnya lebih banyak berfokus pada klasifikasi melanoma serta beberapa jenis kanker kulit minor lainnya. Hal ini mengakibatkan kurangnya perhatian terhadap klasifikasi BCC dan SCC, meskipun keduanya merupakan jenis kanker kulit yang lebih sering dijumpai. Untuk mengisi celah tersebut dengan memberikan perhatian yang seimbang pada ketiga jenis utama kanker kulit tersebut. Dengan demikian, dapat memberikan kontribusi yang signifikan dalam pengembangan metode deteksi yang lebih komprehensif dan efektif.

1.4 Studi Kasus Kanker Kulit

Terdapat beberapa pembahasan sebelumnya terkait klasifikasi kanker kulit. Ali dkk. mengusulkan model jaringan saraf konvolusional dalam (DCNN) untuk tugas klasifikasi kanker kulit jinak dan ganas. Model tersebut dievaluasi pada dataset HAM10000 dan menghasilkan akurasi sebesar 91,93%. Performa model tersebut lebih baik dibandingkan performa beberapa model pembelajaran transfer pada dataset yang sama.

Patil dan Bellary menggunakan pendekatan CNN untuk membangun sistem klasifikasi stadium kanker kulit melanoma. CNN menggunakan ukuran kesamaan untuk pemrosesan teks (SMTP) sebagai fungsi kerugian. Metode ini berhasil mencapai akurasi 96% dalam mengklasifikasikan melanoma stadium 1, stadium 2, dan stadium 3. Model CNN yang dirancang mencapai akurasi 92,64%.

Sujainidkk. membandingkan model regresi linier dan model pembelajaran mendalam dalam deteksi melanoma. Hasilnya membuktikan bahwa model deep learning CNN lebih baik dibandingkan model regresi linier dengan akurasi lebih tinggi dan tingkat negatif palsu lebih rendah dalam mendeteksi melanoma. Gururajdkk. juga menggunakan CNN untuk klasifikasi kanker kulit. Kumpulan data MNIST: HAM10000 difilter dan diproses sebelumnya dengan teknik seperti pengambilan sampel, segmentasi menggunakan autoencoder dan decoder, dan pisau cukur tumpul. Setelah prapemrosesan, model DenseNet169 dan model Resnet50 dilatih. Hasil pengujian menunjukkan bahwa DenseNet169 dengan teknik under sampling menghasilkan akurasi 91,2% dan F1-score 91,7%, sedangkan Resnet50 dengan teknik oversampling menghasilkan akurasi 83% dan F1-score 84%. Xiao dan Wu merancang model Global-DNN dan Global-Lokal untuk mengklasifikasikan kanker kulit menjadi melanoma dan keratosis seboroik. Mereka mengintegrasikan fitur pola biner lokal (LBP) dengan fitur konvolusional yang mendalam dan memanfaatkan deteksi arti-penting visual agar dapat melakukan klasifikasi secara efektif dan menghilangkan gangguan latar belakang. Model yang diusulkan diuji pada dataset kanker kulit ISIC-2017. Model Global-DNN mencapai akurasi 85,8% dalam mengenali melanoma dan akurasi 91,7% dalam mengenali keratosis seboroik. Model Global-Lokal mencapai akurasi

84,8% dalam mengenali melanoma dan akurasi 91,3% dalam mengenali keratosis seboroik.

Daghrirdkk. mengusulkan pendekatan hibrid menggunakan teknik Deep Learning dan Machine Learning untuk deteksi melanoma. Setiap gambar kanker kulit diproses terlebih dahulu dengan menghilangkan garis rambut, mensegmentasi area lesi, dan mengekstraksi fitur lesi. Penelitian ini menggabungkan hasil prediksi KNN, SVM, dan CNN dengan menggunakan suara mayoritas untuk mengidentifikasi kanker kulit melanoma. Hasil akhir pemungutan suara terbanyak menunjukkan keakuratan sebesar 88,4%.

Thurnhofer-Hemsi dan Domínguez menyajikan kerangka machine learning untuk klasifikasi kanker kulit menggunakan lima model CNN canggih, yaitu GoogLeNet, InceptionV3, DenseNet201, Inception-ResNetV2, dan MobileNetV2. Untuk setiap model, pengklasifikasi biasa dan pengklasifikasi hierarki diterapkan. Pengklasifikasi biasa digunakan untuk secara langsung mengklasifikasikan masukan dalam salah satu dari 7 kelas kanker kulit, sedangkan pengklasifikasi hierarki digunakan untuk membedakan kelas nevi dari yang lain dan kemudian mengklasifikasikan 6 kelas lainnya. Eksperimen menunjukkan bahwa model DenseNet201 dengan pengklasifikasi biasa lebih baik dibandingkan model lainnya dalam mengklasifikasikan kanker kulit.

BAB 2

EFFICIENTNET

2.1 Pengantar

Jaringan saraf konvolusional (CNN) pertama kali diperkenalkan pada tahun 1980-an. Salah satu contoh pertama CNN yang diketahui adalah *Time Delay Neural Network* (TDNN) yang dikembangkan pada tahun 1987 oleh Alex Waibel dan tim penelitiannya. TDNN difokuskan pada pengenalan ucapan, termasuk pengenalan fonem yang tidak bergantung pada pergeseran. Pekerjaan pertama pada jaringan saraf konvolusional (CNN) modern terjadi pada tahun 1990-an ketika sebuah makalah oleh Yann LeCun dkk. berjudul “Pembelajaran Berbasis Gradien yang Diterapkan pada Pengenalan Dokumen” telah diterbitkan. Kemudian, arsitekturnya diadaptasi untuk deteksi deepfake.

Ketika jaringan saraf konvolusional dikembangkan, hal tersebut dilakukan dengan biaya sumber daya yang tetap. Jaringan ini kemudian ditingkatkan skalanya untuk mencapai akurasi yang lebih baik ketika lebih banyak sumber daya tersedia. Model ResNet 18 dapat ditingkatkan ke model ResNet 200 dengan menambahkan lebih banyak lapisan ke model asli. Dalam sebagian besar situasi, teknik penskalaan ini telah membantu memberikan akurasi yang lebih baik pada sebagian besar kumpulan data perbandingan. Namun teknik penskalaan model konvensional sangatlah acak. Beberapa model diskalakan berdasarkan kedalaman, dan beberapa model diskalakan secara lebar. Beberapa model hanya mengambil gambar dengan resolusi lebih besar untuk mendapatkan hasil yang lebih baik. Teknik penskalaan model secara acak ini memerlukan penyetulan manual dan banyak jam kerja, sering kali menghasilkan sedikit atau tidak ada

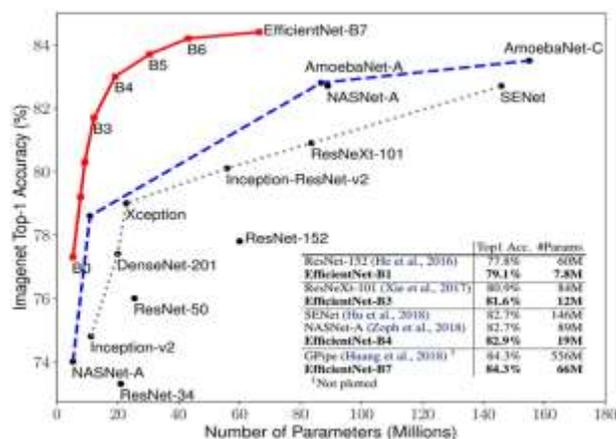
peningkatan kinerja. Penulis EfficientNet mengusulkan peningkatan model CNN untuk mendapatkan akurasi dan efisiensi yang lebih baik dengan cara yang lebih bermoral.

Diperkenalkan pada tahun 2019 oleh tim peneliti di Google AI, EfficientNet menjadi arsitektur yang dapat digunakan untuk banyak tugas yang menantang, termasuk pengenalan objek, segmentasi gambar, dan bahkan pemrosesan bahasa. Keberhasilannya berasal dari kemampuannya untuk menyeimbangkan dua faktor penting dalam pembelajaran mendalam: efisiensi komputasi dan kinerja model. Model pembelajaran mendalam tradisional sering kali memiliki trade-off antara akurasi dan konsumsi sumber daya. EfficientNet mengatasi tantangan ini dengan memperkenalkan pendekatan baru yang disebut "penskalaan gabungan". Dengan menskalakan dimensi model (lebar, kedalaman, dan resolusi) secara sistematis dengan cara yang berprinsip, EfficientNet mencapai tingkat efisiensi yang belum pernah terjadi sebelumnya tanpa mengorbankan akurasi. Metode ini memungkinkan model mencapai keseimbangan yang optimal, sehingga dapat beradaptasi dengan berbagai anggaran komputasi dan kemampuan perangkat keras.

EfficientNet adalah arsitektur jaringan neural konvolusional dan metode penskalaan yang menskalakan semua dimensi kedalaman/lebar/resolusi secara seragam menggunakan *koefisien gabungan*. Tidak seperti praktik konvensional yang menskalakan faktor-faktor ini secara sewenang-wenang, metode penskalaan EfficientNet menskalakan lebar, kedalaman, dan resolusi jaringan secara seragam dengan serangkaian koefisien penskalaan tetap. EfficientNet menggunakan teknik yang disebut koefisien gabungan untuk meningkatkan skala model dengan cara yang sederhana namun efektif.

Daripada menskalakan lebar, kedalaman, atau resolusi secara acak, penskalaan gabungan menskalakan setiap dimensi secara seragam dengan serangkaian koefisien penskalaan tetap tertentu. Dengan menggunakan metode penskalaan dan AutoML, penulis efisien mengembangkan tujuh model dari berbagai dimensi, yang melampaui akurasi paling mutakhir dari sebagian besar jaringan saraf konvolusional, dan dengan efisiensi yang jauh lebih baik.

EfficientNet didasarkan pada jaringan dasar yang dikembangkan oleh penelusuran arsitektur neural menggunakan kerangka kerja AutoML MNAS. Jaringan ini disetel dengan baik untuk memperoleh akurasi maksimum tetapi juga dikenai penalti jika jaringan tersebut sangat membutuhkan komputasi yang berat. Jaringan ini juga dikenai penalti untuk waktu inferensi yang lambat ketika jaringan tersebut membutuhkan banyak waktu untuk membuat prediksi. Arsitektur ini menggunakan konvolusi hambatan terbalik seluler yang mirip dengan MobileNet V2 tetapi jauh lebih besar karena peningkatan FLOPS. Model dasar ini ditingkatkan untuk memperoleh keluarga EfficientNet.



Gambar 2 Parameter Efficent-Net

EfficientNet family terdiri dari 8 model, mulai dari EfficientNet-B0 hingga EfficientNet-B7.

Tabel 1. EfficientNet Model

FEATURES	TOP-1 ACC	TOP-5 ACC	PARAMS	FLOPS
EfficientNet-B0	77.1%	93.5%	5.5M	0.59B
EfficientNet-B1	79.1%	94.4%	7.8M	0.70B
EfficientNet-B2	80.1%	94.9%	9.2M	1.0B
EfficientNet-B3	81.6%	95.7%	12M	1.8B
EfficientNet-B4	82.9%	96.4%	19M	4.2B
EfficientNet-B5	83.6%	96.7%	30M	9.9B
EfficientNet-B6	84.0%	96.8%	43M	19B
EfficientNet-B7	84.3%	97.0%	66M	37B

EfficientNet-B0 adalah fondasi yang menjadi dasar dibangunnya seluruh keluarga EfficientNet. Ini adalah model terkecil dan paling efisien dalam varian EfficientNet.

2.2 Algoritma EfficientNet

EfficientNet menggunakan lapisan Mobile Inverted Bottleneck (MBConv), yang merupakan kombinasi konvolusi yang dapat dipisahkan berdasarkan kedalaman dan blok sisa terbalik. Selain itu, arsitektur model menggunakan optimasi Squeeze-and-Excitation (SE) untuk lebih meningkatkan performa model. Lapisan MBConv merupakan blok penyusun fundamental arsitektur EfficientNet. Ia terinspirasi oleh blok residual terbalik dari MobileNetV2 tetapi dengan beberapa modifikasi.

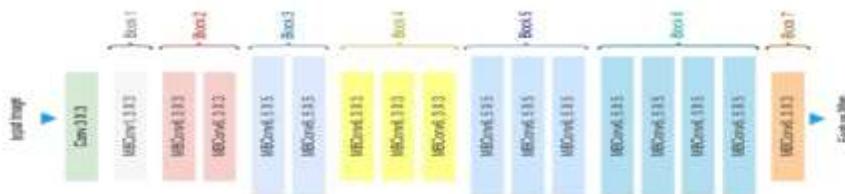
Lapisan MBConv dimulai dengan konvolusi berdasarkan kedalaman, diikuti oleh konvolusi berdasarkan titik (konvolusi 1x1) yang memperluas jumlah saluran, dan terakhir, konvolusi 1x1 lainnya yang mengurangi

jumlah saluran kembali ke jumlah semula. Desain hambatan ini memungkinkan model untuk belajar secara efisien sambil mempertahankan tingkat daya representasi yang tinggi.

Selain lapisan MBConv, EfficientNet menggabungkan blok SE, yang membantu model belajar untuk fokus pada fitur-fitur penting dan menyembunyikan fitur-fitur yang kurang relevan. Blok SE menggunakan pengumpulan rata-rata global untuk mengurangi dimensi spasial peta fitur menjadi satu saluran, diikuti oleh dua lapisan yang terhubung sepenuhnya.

Lapisan ini memungkinkan model mempelajari ketergantungan fitur berdasarkan saluran dan membuat bobot perhatian yang dikalikan dengan peta fitur asli, sehingga menekankan informasi penting.

EfficientNet hadir dalam berbagai varian, seperti EfficientNet-B0, EfficientNet-B1, dan seterusnya, dengan koefisien skala yang bervariasi. Setiap varian mewakili trade-off yang berbeda antara ukuran model dan akurasi, yang memungkinkan pengguna untuk memilih varian model yang sesuai berdasarkan persyaratan spesifik mereka.



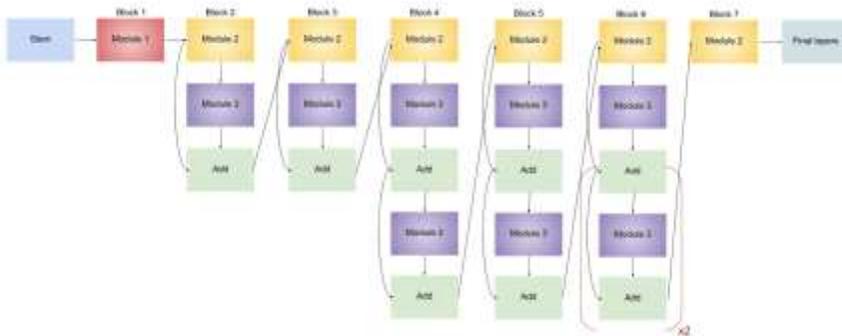
Gambar 3 *Arsitektur EfficientNet*

EfficientNet memperkenalkan konsep penskalaan efisien yang mengoptimalkan ketiga dimensi utama (depth, width, resolution) secara bersamaan menggunakan faktor penskalaan yang ditentukan oleh eksperimen. Ini berbeda dengan metode penskalaan tradisional yang biasanya hanya memperbesar salah satu dimensi.

Secara keseluruhan, keluarga EfficientNet menawarkan berbagai pilihan model yang dapat disesuaikan dengan kebutuhan spesifik, mulai dari model yang ringan dan efisien hingga model yang sangat kuat namun memerlukan lebih banyak sumber daya.

2.2.1. EfisienNet-B0

EfficientNet-B0 adalah jaringan saraf konvolusional yang dilatih pada lebih dari satu juta gambar dari database ImageNet. Jaringan dapat mengklasifikasikan gambar ke dalam 1000 kategori objek, seperti keyboard, mouse, pensil, dan banyak binatang. Hasilnya, jaringan telah mempelajari representasi fitur yang kaya untuk berbagai macam gambar. Jaringan memiliki ukuran input gambar 224-kali-224.



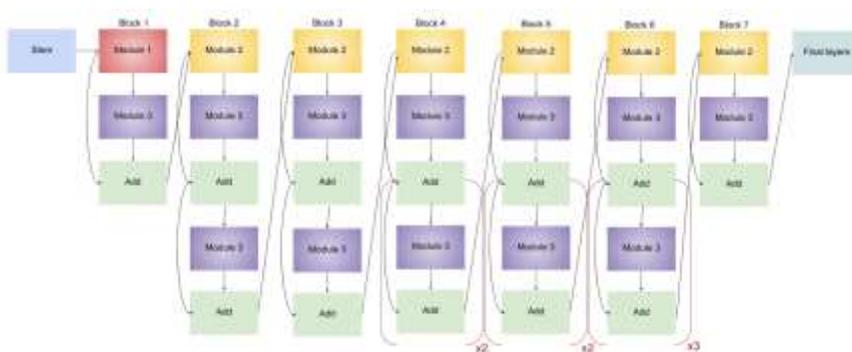
Gambar 4 *EfficientNet-B0*

2.2.2. EfisienNet-B1

EfficientNet-B1 adalah varian yang dihasilkan dari penskalaan model dasar EfficientNet-B0 menggunakan teknik compound scaling. Teknik ini memperhitungkan faktor penskalaan yang mengoptimalkan kedalaman (depth), lebar (width), dan resolusi (resolution) secara bersamaan untuk meningkatkan kinerja. Pada EfficientNet-B1, kedalaman jaringan

meningkat, jumlah saluran (channels) pada setiap lapisan bertambah, dan resolusi gambar input diperbesar. Peningkatan ini memungkinkan model untuk menangkap lebih banyak fitur dari data input, sehingga meningkatkan akurasi prediksi.

Namun, dengan peningkatan kinerja ini, penggunaan sumber daya komputasi juga meningkat. EfficientNet-B1 memerlukan lebih banyak memori dan waktu komputasi dibandingkan dengan B0, membuatnya lebih sesuai untuk aplikasi yang memiliki sumber daya komputasi yang memadai. Model ini cocok digunakan untuk tugas-tugas yang memerlukan akurasi tinggi dalam pengenalan gambar, seperti klasifikasi objek atau deteksi anomali, dimana trade-off antara kinerja dan penggunaan sumber daya dapat diterima.



Gambar 5 *EfficientNet-B1*

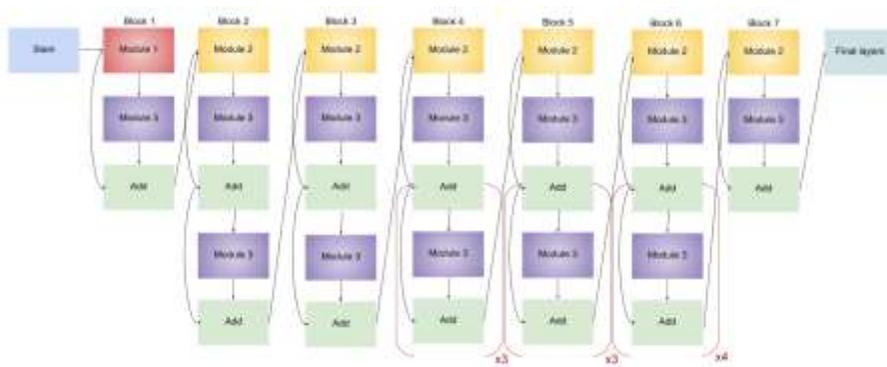
2.2.3. EfficientNet-B2

Arsitekturanya sama dengan model di atas, satu-satunya perbedaan di antara keduanya adalah jumlah peta fitur (saluran) yang bervariasi sehingga meningkatkan jumlah parameter. EfficientNet-B2 adalah hasil dari penskalaan lebih lanjut dari EfficientNet-B1. Model ini mempertahankan prinsip compound scaling dengan meningkatkan

kedalaman, lebar, dan resolusi lebih jauh lagi. Dengan kedalaman yang lebih besar, model ini mampu mempelajari representasi fitur yang lebih kompleks dan mendalam dari data input. Lebar jaringan yang lebih besar memungkinkan lebih banyak unit komputasi paralel pada setiap lapisan, meningkatkan kapasitas model untuk menangkap variasi data yang lebih luas.

Peningkatan resolusi gambar input juga membantu model untuk menangkap detail yang lebih halus, yang sangat penting dalam tugas-tugas pengenalan gambar dengan banyak objek atau fitur kecil. Namun, peningkatan ini juga berarti kebutuhan sumber daya komputasi yang lebih besar. Model ini memerlukan lebih banyak memori dan waktu komputasi dibandingkan dengan B1, tetapi memberikan peningkatan akurasi yang signifikan, menjadikannya pilihan yang baik untuk aplikasi dengan kebutuhan akurasi tinggi dan ketersediaan sumber daya yang cukup.

2.2.4. EfisienNet-B3



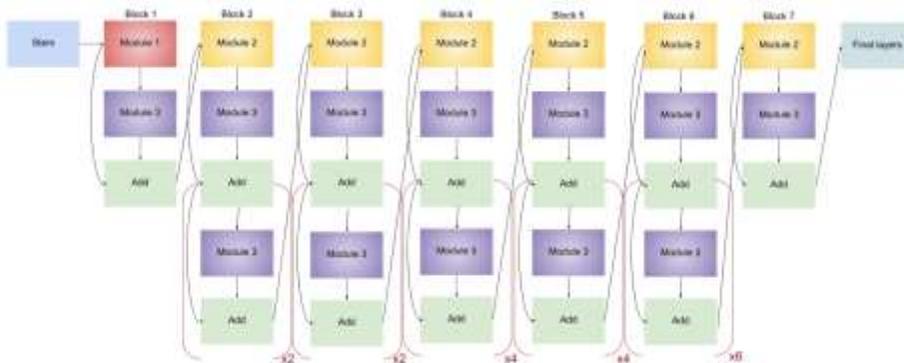
Gambar 6 *EfficientNet-B3*

EfficientNet-B3 melanjutkan tren penskalaan dengan meningkatkan semua tiga dimensi utama: kedalaman, lebar, dan resolusi gambar. Dengan

peningkatan kedalaman, jaringan dapat menangkap lebih banyak pola dan hubungan kompleks dalam data. Lebar jaringan yang lebih besar meningkatkan kapasitas model, memungkinkan lebih banyak informasi diproses secara paralel pada setiap lapisan. Resolusi gambar yang lebih tinggi memungkinkan model untuk mengenali detail yang lebih halus, meningkatkan kemampuan deteksi dan klasifikasi.

Model ini memberikan peningkatan kinerja yang signifikan dalam tugas-tugas pengenalan gambar dibandingkan dengan varian sebelumnya. Namun, penggunaan sumber daya juga meningkat seiring dengan peningkatan kinerja. EfficientNet-B3 memerlukan lebih banyak memori dan waktu komputasi, menjadikannya pilihan yang tepat untuk aplikasi yang dapat menangani beban komputasi yang lebih besar dan memerlukan akurasi tinggi, seperti pengenalan wajah, deteksi objek, dan klasifikasi citra medis.

2.2.5. EfisienNet-B4



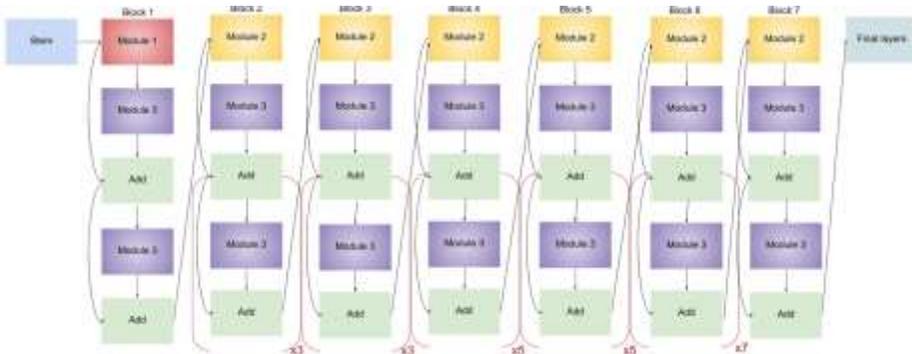
Gambar 7 *EfficientNet-B4*

EfficientNet-B4 adalah model yang lebih besar dibandingkan B3, dengan peningkatan lebih lanjut dalam kedalaman, lebar, dan resolusi.

Model ini dirancang untuk menangkap lebih banyak detail dan pola kompleks dalam data, meningkatkan akurasi prediksi. Penskalaan yang lebih besar memungkinkan model untuk memproses gambar dengan resolusi lebih tinggi, sehingga cocok untuk tugas-tugas yang memerlukan analisis gambar yang mendalam dan detail.

Peningkatan ini juga berarti bahwa EfficientNet-B4 memerlukan lebih banyak sumber daya komputasi. Model ini membutuhkan lebih banyak memori dan waktu komputasi dibandingkan dengan B3, membuatnya lebih cocok untuk aplikasi dengan ketersediaan sumber daya yang cukup besar. Aplikasi seperti analisis citra medis, pengenalan objek dalam gambar berkualitas tinggi, dan tugas-tugas yang memerlukan akurasi tinggi dalam kondisi variabilitas data yang tinggi akan sangat diuntungkan dengan penggunaan model ini.

2.2.6. EfisienNet-B5



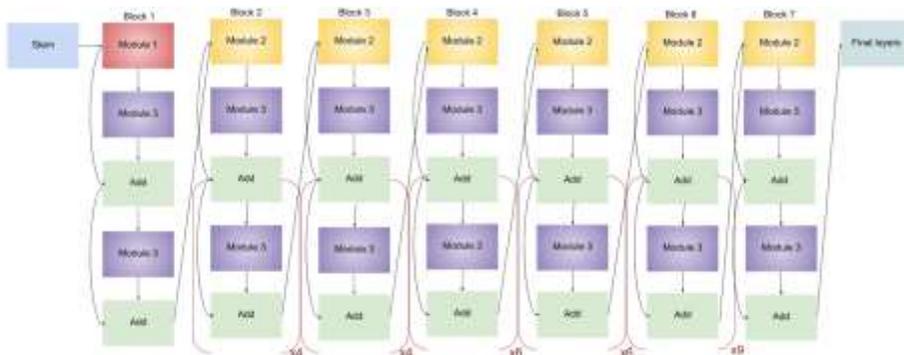
Gambar 8 *EfficientNet-B5*

EfficientNet-B5 melanjutkan penskalaan dari B4 dengan peningkatan lebih lanjut dalam kedalaman, lebar, dan resolusi gambar. Model ini dirancang untuk memberikan kinerja yang lebih tinggi dengan kapasitas yang lebih besar untuk menangkap fitur dan pola dalam data. Penskalaan

ini memungkinkan model untuk menangani tugas-tugas yang lebih kompleks dan detail dengan akurasi yang lebih baik.

Namun, peningkatan kinerja ini juga memerlukan sumber daya komputasi yang lebih signifikan. EfficientNet-B5 membutuhkan lebih banyak memori dan waktu komputasi dibandingkan dengan B4, menjadikannya pilihan yang cocok untuk aplikasi dengan kebutuhan komputasi tinggi dan yang memerlukan akurasi sangat tinggi. Contohnya termasuk aplikasi dalam bidang kesehatan untuk analisis citra medis, sistem pengawasan dengan deteksi objek yang kompleks, dan aplikasi industri yang memerlukan analisis data gambar yang detail dan akurat.

2.2.7. EfisienNet-B6

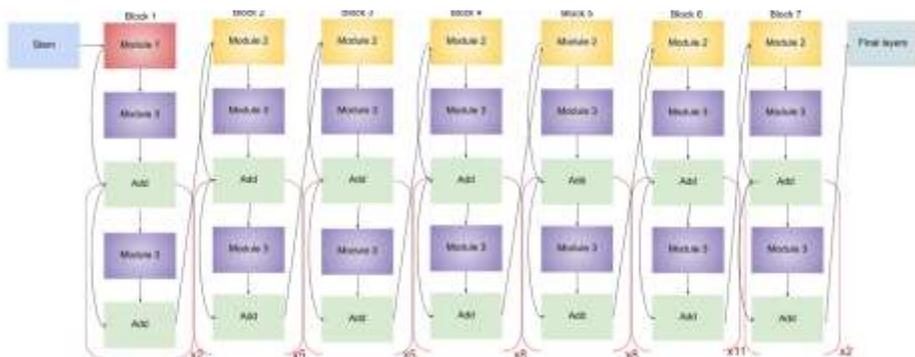


Gambar 9 *EfficientNet-B6*

EfficientNet-B6 lebih besar dari B5 dan mencakup peningkatan dalam kedalaman, lebar, dan resolusi gambar. Model ini dirancang untuk memberikan akurasi yang lebih tinggi dengan memanfaatkan peningkatan kapasitas komputasi. Dengan lebih banyak lapisan dan unit komputasi pada setiap lapisan, EfficientNet-B6 dapat menangkap pola yang lebih kompleks dan detail dalam data gambar.

Namun, dengan peningkatan ini, kebutuhan sumber daya komputasi juga meningkat secara signifikan. EfficientNet-B6 memerlukan lebih banyak memori dan waktu komputasi, membuatnya lebih cocok untuk aplikasi yang memiliki sumber daya komputasi yang cukup besar. Aplikasi seperti pengenalan objek dalam video berkualitas tinggi, analisis citra medis dengan detail tinggi, dan sistem pengawasan yang memerlukan deteksi objek yang sangat akurat akan sangat diuntungkan dengan model ini.

2.2.8. EfisienNet-B7



Gambar 10 EfficientNet-B7

EfficientNet-B7 adalah varian terbesar dalam keluarga EfficientNet. Model ini memiliki kedalaman, lebar, dan resolusi tertinggi di antara semua varian, yang menghasilkan akurasi terbaik. Dengan penskalaan yang lebih besar, model ini mampu menangkap detail dan pola yang sangat kompleks dalam data gambar, memberikan kinerja yang superior dalam tugas-tugas pengenalan gambar.

Namun, peningkatan kinerja ini datang dengan biaya komputasi yang tinggi. EfficientNet-B7 memerlukan lebih banyak memori dan waktu komputasi dibandingkan dengan semua varian sebelumnya, membuatnya

cocok untuk aplikasi yang memerlukan akurasi tertinggi dan memiliki sumber daya komputasi yang memadai. Aplikasi seperti analisis citra medis berkualitas tinggi, sistem pengawasan canggih, dan proyek penelitian yang memerlukan analisis data gambar yang sangat detail dan akurat akan sangat diuntungkan dengan penggunaan model ini.

Delapan varian EfficientNet, mulai dari EfficientNet-B0 hingga EfficientNet-B7, dirancang dan dilatih menggunakan kumpulan data kanker kulit yang telah diproses sebelumnya. Setiap model diuji dengan gambar uji yang sama untuk mengklasifikasikan jenis kanker kulit menjadi BCC, SCC, atau melanoma (MEL). Hasil klasifikasi dari setiap model kemudian dibandingkan menggunakan metrik kinerja tertentu.

Dengan fokus pada perbandingan kinerja kedelapan jenis arsitektur EfficientNet, bertujuan untuk mengidentifikasi model yang paling efektif untuk tugas klasifikasi kanker kulit. Melalui analisis mendalam terhadap kinerja masing-masing model, dapat menemukan model EfficientNet yang paling sesuai dan akurat untuk digunakan dalam mendeteksi dan mengklasifikasikan BCC, SCC, dan melanoma.

BAB 3

AKUISISI DATA

3.1 Pengantar

Akuisisi data adalah proses pengumpulan, pengukuran, dan pengolahan data dari berbagai sumber untuk dianalisis lebih lanjut. Proses ini sangat penting dalam berbagai bidang, termasuk sains, teknik, dan industri, karena memungkinkan pengambilan keputusan yang lebih baik berdasarkan data yang akurat. Proses akuisisi data biasanya dimulai dengan penggunaan sensor yang dirancang untuk mengukur kondisi fisik tertentu seperti suhu, tekanan, suara, atau listrik. Sensor-sensor ini memainkan peran kunci dalam mendeteksi perubahan lingkungan atau parameter yang sedang dipantau, kemudian mengubah fenomena fisik tersebut menjadi sinyal listrik.

Setelah sensor mengumpulkan data dalam bentuk sinyal listrik, langkah berikutnya adalah mengonversi sinyal tersebut menjadi format digital. Proses ini dilakukan menggunakan konverter analog-ke-digital (ADC), yang mengubah sinyal analog menjadi sinyal digital yang dapat diproses oleh komputer. Konversi ini sangat penting karena data digital lebih mudah untuk dianalisis dan disimpan dibandingkan data analog. Dengan menggunakan ADC, kita dapat memastikan bahwa data yang dihasilkan akurat dan siap untuk diproses lebih lanjut.

Setelah data dikonversi menjadi bentuk digital, tahap berikutnya adalah pengolahan sinyal. Pengolahan sinyal ini bisa melibatkan berbagai teknik seperti penyaringan, penguatan, atau transformasi sinyal. Tujuan dari pengolahan ini adalah untuk menghilangkan noise yang dapat mengganggu kualitas data dan meningkatkan keakuratan serta keandalan

data yang telah dikumpulkan. Penyaringan data dapat membantu menghapus gangguan atau fluktuasi yang tidak diinginkan, sementara penguatan sinyal dapat meningkatkan level sinyal agar lebih mudah dianalisis.

Setelah melalui tahap pengolahan, data yang telah diproses kemudian disimpan dalam format yang sesuai untuk dianalisis lebih lanjut. Penyimpanan data ini harus dilakukan dengan cara yang efisien untuk memastikan bahwa data tetap utuh dan dapat diakses dengan mudah ketika dibutuhkan. Format penyimpanan yang digunakan biasanya disesuaikan dengan jenis analisis yang akan dilakukan, dan bisa mencakup format data seperti CSV, database, atau format lainnya yang kompatibel dengan perangkat lunak analisis yang akan digunakan.

Analisis data yang diperoleh melalui proses akuisisi ini bisa dilakukan untuk berbagai tujuan, mulai dari pemantauan kondisi lingkungan, kontrol proses industri, hingga penelitian ilmiah. Dalam konteks pemantauan lingkungan, data dapat digunakan untuk memantau perubahan iklim atau kualitas udara. Dalam industri, data tersebut dapat membantu mengoptimalkan proses produksi dan memastikan kualitas produk. Dalam penelitian ilmiah, data akurat sangat penting untuk menguji hipotesis dan mendapatkan pemahaman yang lebih dalam tentang fenomena alam.

Sistem akuisisi data terdiri dari beberapa komponen utama, termasuk sensor, unit pemrosesan sinyal, perangkat keras akuisisi data, dan komputer. Setiap komponen ini bekerja bersama untuk memastikan bahwa data dapat dikumpulkan, diolah, dan dianalisis dengan efisien. Penyaluran data dalam sistem akuisisi data dapat dilakukan secara seri maupun paralel dari instrumen ke komputer, tergantung pada kebutuhan dan efisiensi yang diinginkan. Dengan sistem yang terintegrasi dengan baik, akuisisi data

dapat dilakukan secara real-time, memungkinkan respons yang cepat terhadap perubahan yang terdeteksi, dan memastikan bahwa analisis data dilakukan dengan data yang paling mutakhir dan akurat.

3.2 Penerapan

Dataset bersumber dari Kaggle dan disediakan oleh Maharana. Dataset asli sebenarnya disiapkan untuk tantangan ISIC 2019, yang merupakan salah satu kompetisi terkenal dalam bidang deteksi dan klasifikasi kanker kulit. Larxel, yang menyediakan dataset asli di Kaggle, telah melakukan pekerjaan awal yang penting. Namun, Maharana mengambil langkah lebih jauh dengan memodifikasi dan mengubah kumpulan data tersebut agar lebih mudah digunakan.

Dataset terdiri dari 25.331 gambar yang diklasifikasikan kedalam 8 kelas yang berbeda untuk masalah klasifikasi multikelas. Meskipun dataset asli mencakup berbagai jenis lesi kulit, permasalahan hanya berfokus pada tiga kelas utama yaitu karsinoma sel basal (BCC), karsinoma sel skuamosa (SCC), dan melanoma (MEL). Pemilihan tiga jenis utama kanker kulit ini didasarkan pada prevalensi dan tingkat keparahan masing-masing jenis, dengan melanoma dikenal sebagai jenis yang paling mematikan. Fokus pada ketiga kelas ini memungkinkan untuk mendalami karakteristik spesifik dan tantangan dalam mendeteksi dan mengklasifikasikan jenis kanker kulit yang paling umum dan berbahaya.

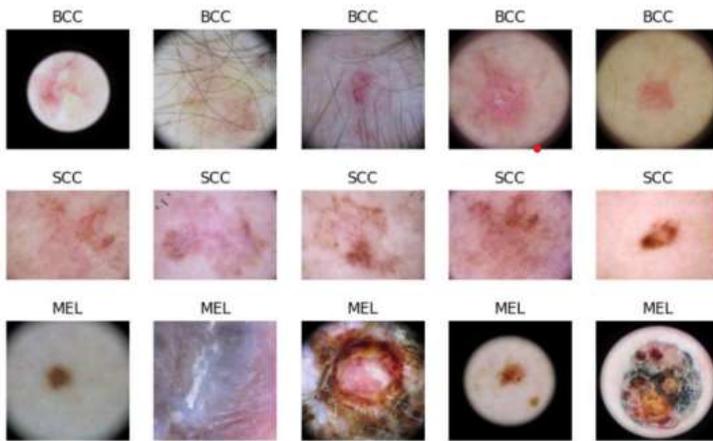
Sampel dari masing-masing kelas yang dipilih ditunjukkan pada Gambar 11. BCC sering kali tampak sebagai benjolan atau bintil kecil yang tembus cahaya pada kulit, dengan tekstur yang mungkin seperti mutiara atau lilin. BCC cenderung berkembang di area yang sering terpapar sinar matahari seperti wajah, telinga, dan leher. Karakteristik ini menjadikan BCC sebagai salah satu jenis kanker kulit yang lebih mudah

dikenali, meskipun deteksi dini tetap penting untuk mencegah penyebaran lebih lanjut.

Di sisi lain, SCC sering muncul sebagai bercak merah bersisik, luka terbuka, atau pertumbuhan berlebih dengan depresi sentral. SCC memiliki potensi untuk menjadi lebih agresif dibandingkan BCC jika tidak ditangani dengan cepat. Penyakit ini juga cenderung berkembang di area tubuh yang sering terpapar sinar matahari, tetapi dapat muncul di mana saja pada tubuh. Penampilan SCC yang bervariasi membuatnya lebih menantang untuk dideteksi secara visual, sehingga klasifikasi otomatis menggunakan model deep learning menjadi sangat penting.

Melanoma (MEL) adalah jenis kanker kulit yang paling berbahaya dan mematikan. Melanoma sering kali muncul sebagai tahi lalat yang bentuknya tidak beraturan atau bintik hitam dengan warna yang tidak merata. Keberagaman penampilan melanoma membuatnya sangat sulit dideteksi tanpa alat bantu diagnostik yang canggih. Kemampuan untuk membedakan melanoma dari lesi jinak dan jenis kanker kulit lainnya sangat penting karena deteksi dini melanoma dapat secara signifikan meningkatkan prognosis dan tingkat kelangsungan hidup pasien.

Dengan menggunakan dataset yang telah disederhanakan, bertujuan untuk mengembangkan dan menguji berbagai arsitektur EfficientNet dalam mengklasifikasikan gambar kanker kulit. Melalui proses pelatihan dan pengujian yang ketat, model-model ini diharapkan dapat memberikan tingkat akurasi yang tinggi dalam mendeteksi dan mengklasifikasikan BCC, SCC, dan MEL. Pada pengembangan teknologi diagnostik yang lebih baik, menunjukkan potensi penggunaan deep learning dalam aplikasi medis yang kritis.



Gambar 11 Sampel setiap kelas yang dipilih dari dataset

BAB 4

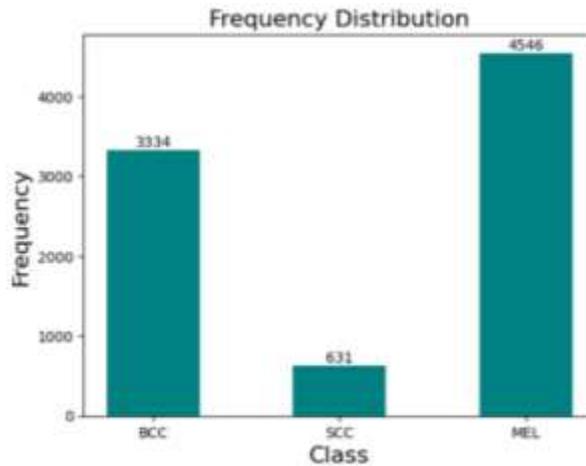
DATA PREPROCESSING

4.1 Pra-pemrosesan

Sebelum dataset digunakan pada tahap pelatihan model, dataset harus melalui tahap pra-pemrosesan data terlebih dahulu. Pra-pemrosesan data bertujuan untuk mengatur, memodifikasi, dan membersihkan data agar data tersebut layak dan mudah digunakan pada tahap selanjutnya. Langkah-langkah dalam pra-pemrosesan data meliputi pengumpulan data dari berbagai sumber yang relevan, pembersihan data untuk menghapus data yang tidak lengkap, duplikat, dan tidak relevan, serta transformasi data seperti normalisasi, standardisasi, dan encoding untuk memastikan bahwa data berada dalam format yang sesuai untuk pelatihan model. Selain itu, dilakukan seleksi fitur untuk memilih fitur-fitur yang relevan dan menghapus fitur-fitur yang tidak relevan atau berlebihan, serta pembagian dataset menjadi data pelatihan, validasi, dan pengujian untuk memastikan model dapat diuji dan divalidasi dengan baik.

Dalam hal ini, dari 8 kelas yang ada pada dataset, hanya diambil gambar yang termasuk dalam kelas BCC (Basal Cell Carcinoma), SCC (Squamous Cell Carcinoma), dan MEL (Melanoma). Pemilihan ini dilakukan untuk memfokuskan analisis dan pelatihan model pada jenis-jenis kanker kulit yang paling relevan. Distribusi frekuensi ketiga kelas terpilih ini dapat dilihat pada Gambar 11. Informasi distribusi ini penting untuk memahami keseimbangan data dalam dataset, yang dapat mempengaruhi kinerja model. Jika terdapat ketidakseimbangan kelas yang signifikan, mungkin diperlukan teknik penyeimbangan data seperti oversampling, undersampling, atau penggunaan metode data augmentation

untuk memastikan model tidak bias terhadap kelas tertentu. Dengan melakukan pra-pemrosesan data yang baik, diharapkan dataset yang digunakan untuk pelatihan model akan lebih berkualitas dan menghasilkan model yang lebih akurat dan handal.



Gambar 12 Distribusi frekuensi kelas terpilih (BCC, SCC, MEL)

Gambar 12 menunjukkan distribusi sampel yang tidak merata, yang dapat menyebabkan model memprioritaskan kelas mayoritas dan mengabaikan kelas minoritas dalam klasifikasi. Ketidakseimbangan ini merupakan masalah umum dalam banyak dataset dan dapat berdampak negatif pada performa model pembelajaran mesin, karena model cenderung lebih akurat dalam memprediksi kelas mayoritas tetapi kurang mampu dalam mengenali kelas minoritas. Untuk mengatasi masalah dataset yang tidak seimbang, kami melakukan undersampling pada dataset dengan mengambil 631 sampel dari setiap kelas. Dataset ini memiliki sebanyak 1.893 gambar kanker kulit, yang terdiri dari 631 gambar BCC (Basal Cell Carcinoma), 631 gambar SCC (Squamous Cell Carcinoma),

dan 631 gambar MEL (Melanoma). Langkah undersampling ini membantu untuk menciptakan keseimbangan antara kelas-kelas yang ada sehingga model dapat belajar secara efektif dari ketiga kelas tersebut tanpa bias yang berlebihan terhadap kelas mayoritas.

4.2 Augmentasi Data

Setelah proses undersampling, dataset dibagi menjadi tiga bagian yang berbeda, yaitu set pelatihan, set validasi, dan set pengujian. Pembagian ini dilakukan untuk memastikan bahwa model dapat dilatih, divalidasi, dan diuji dengan dataset yang representatif dan tidak terpengaruh oleh data yang telah dilihat sebelumnya. Set pelatihan mencakup 70% dari total dataset, yang digunakan untuk melatih model. Set validasi mencakup 20%, digunakan untuk mengukur kinerja model selama pelatihan dan untuk menghindari overfitting. Terakhir, set pengujian mencakup 10%, digunakan untuk mengukur kinerja model setelah selesai dilatih. Dalam hal ini, dataset yang terdiri dari 1.893 gambar dibagi menjadi 1.325 gambar untuk set pelatihan, 379 gambar untuk set validasi, dan 189 gambar untuk set pengujian. Distribusi ini ditunjukkan dalam Tabel 2.

Tabel 2. Pemisah kumpulan data

	Perengkapan latihan	Set validasi	Perangkat pengujian	Total
SMK	441	126	64	631
SCC	441	126	64	631
MEL	441	126	64	631
Total	1323	378	192	1893

Selain pembagian dataset, ada langkah penting lainnya yang dilakukan untuk mempersiapkan data sebelum digunakan dalam pelatihan model

pembelajaran mesin, khususnya jaringan saraf konvolusional (Convolutional Neural Network atau CNN). Semua gambar dalam dataset harus diubah ukurannya menjadi 256×256 piksel. Perubahan ukuran ini dilakukan untuk memastikan bahwa semua gambar memiliki dimensi yang konsisten, yang sangat penting untuk pemrosesan gambar melalui model pembelajaran mesin. Dimensi gambar yang seragam membantu dalam mengurangi kompleksitas komputasi, karena model tidak perlu menyesuaikan ukuran gambar yang berbeda-beda selama proses pelatihan. Ini juga memastikan bahwa model dapat mempelajari fitur dari gambar secara lebih efisien.

Ukuran gambar yang dipilih, yaitu 256×256 piksel, dipilih dengan pertimbangan yang matang. Ukuran ini cukup kecil untuk memastikan efisiensi komputasi, namun tetap cukup besar untuk mempertahankan fitur-fitur penting dari gambar asli. Menggunakan gambar dengan ukuran yang terlalu besar dapat menyebabkan peningkatan waktu dan sumber daya komputasi yang diperlukan, sedangkan gambar yang terlalu kecil mungkin tidak memberikan informasi yang cukup bagi model untuk mempelajari fitur yang relevan. Oleh karena itu, ukuran 256×256 piksel dianggap sebagai ukuran yang optimal untuk menjaga keseimbangan antara efisiensi dan informasi yang dapat diambil dari gambar.

Selain itu, augmentasi gambar juga dilakukan sebagai bagian dari proses persiapan data. Augmentasi gambar adalah teknik yang digunakan untuk meningkatkan keragaman dan ukuran set pelatihan dengan menerapkan transformasi acak pada gambar. Dalam hal ini, augmentasi gambar dilakukan dengan menerapkan pembalikan acak dan rotasi acak pada gambar. Teknik augmentasi ini membantu model untuk belajar dari variasi gambar yang lebih luas, yang dapat meningkatkan akurasi model

dan mengurangi efek overfitting. Dengan memiliki dataset yang lebih beragam, model dapat lebih baik dalam menangani variasi yang ada dalam data dunia nyata.

Augmentasi data juga memiliki manfaat lain dalam meningkatkan kinerja model pembelajaran mesin. Dengan menggunakan gambar yang bervariasi, model dapat menjadi lebih robust terhadap perubahan kecil dalam data input. Misalnya, rotasi acak pada gambar dapat membantu model untuk lebih baik dalam mengenali objek dari berbagai sudut pandang. Pembalikan acak juga dapat membantu model untuk memahami bahwa orientasi objek tidak selalu konsisten. Dengan demikian, augmentasi data tidak hanya membantu dalam meningkatkan ukuran set pelatihan, tetapi juga dalam meningkatkan generalisasi model terhadap data yang tidak terlihat sebelumnya.

Dalam keseluruhan proses, langkah-langkah seperti pembagian dataset, perubahan ukuran gambar, dan augmentasi data semuanya bertujuan untuk mempersiapkan dataset yang optimal untuk pelatihan model pembelajaran mesin. Dengan dataset yang terorganisir dan diproses dengan baik, model CNN dapat dilatih dengan lebih efisien dan akurat. Ini memastikan bahwa model dapat mempelajari fitur-fitur penting dari data dengan baik dan dapat diterapkan secara efektif pada tugas-tugas pengenalan gambar di dunia nyata.

BAB 5

MODELLING

5.1 CNN Modeling

Modeling adalah suatu proses atau teknik yang digunakan untuk menciptakan representasi dari sistem atau fenomena dunia nyata. Representasi ini dapat berupa fisik, matematika, atau simulasi komputer, yang bertujuan untuk membantu memahami, menganalisis, atau memprediksi perilaku sistem tersebut. Dalam berbagai disiplin ilmu seperti sains, teknik, ekonomi, dan manajemen, modeling memainkan peran penting dalam mendukung pengambilan keputusan dan pengembangan solusi yang efektif.

Pada dasarnya, modeling dimulai dengan identifikasi dan pemahaman elemen-elemen kunci dari sistem yang akan dimodelkan. Elemen-elemen ini kemudian disederhanakan dan diwakili dalam bentuk model. Proses penyederhanaan ini sangat penting karena dunia nyata seringkali terlalu kompleks untuk diwakili secara lengkap. Dengan menyederhanakan dan memfokuskan pada aspek-aspek yang paling relevan, model dapat memberikan wawasan yang berguna tanpa dibebani oleh detail yang berlebihan.

Ada berbagai jenis model yang dapat digunakan, tergantung pada tujuan dan konteksnya. Model fisik adalah representasi nyata yang bisa disentuh dan dilihat, seperti maket arsitektur atau model pesawat terbang. Model matematika menggunakan persamaan dan algoritma untuk menggambarkan hubungan antara variabel-variabel dalam sistem. Sedangkan model simulasi komputer memungkinkan pengguna untuk menjalankan eksperimen virtual yang mensimulasikan dinamika sistem

yang kompleks, sering digunakan dalam bidang seperti meteorologi, epidemiologi, dan rekayasa sistem.

Keberhasilan suatu model sangat bergantung pada validitas dan reliabilitasnya. Validitas merujuk pada seberapa baik model tersebut mencerminkan kenyataan yang sebenarnya, sedangkan reliabilitas merujuk pada konsistensi hasil yang diberikan oleh model tersebut. Proses validasi dan verifikasi model sering kali melibatkan perbandingan output model dengan data nyata atau hasil eksperimen untuk memastikan bahwa model tersebut dapat diandalkan.

Modeling juga memiliki keterbatasan yang harus diakui. Sebuah model adalah penyederhanaan dari dunia nyata dan oleh karena itu tidak bisa menangkap semua detail dan variabel yang ada. Asumsi-asumsi yang dibuat selama proses modeling dapat mempengaruhi akurasi dan aplikasi dari model tersebut. Oleh karena itu, penting untuk selalu mengkaji ulang dan memperbaharui model seiring dengan perkembangan pengetahuan dan data baru.

Dalam dunia yang semakin kompleks dan data-driven, modeling menjadi alat yang semakin penting. Dengan kemampuan untuk mengintegrasikan data dari berbagai sumber dan mensimulasikan berbagai skenario, modeling membantu dalam perencanaan strategis, manajemen risiko, dan pengembangan inovasi. Melalui pendekatan ini, individu dan organisasi dapat membuat keputusan yang lebih informasional dan responsif terhadap perubahan lingkungan.

Model CNN mampu mengekstraksi dan mempelajari fitur-fitur atau ciri-ciri dari citra yang akan diklasifikasikan. Model CNN yang digunakan untuk klasifikasi kanker kulit didasarkan pada arsitektur EfficientNet. Scaling pada model CNN biasanya dilakukan dengan meningkatkan

neuron-neuron pada suatu layer untuk mencegah overfitting. Karena permasalahan yang dihadapi adalah multiclass classification, softmax digunakan sebagai fungsi aktivasi pada layer output dan categorical cross-entropy digunakan sebagai fungsi loss. Untuk optimizer, digunakan Adam karena secara umum mampu untuk memberikan peningkatan performa model dengan lebih signifikan dibandingkan dengan optimizer lainnya. Learning rate diatur menjadi 0,001.

Perlu diketahui bahwa proses pelatihan model yang berkepanjangan biasanya mengakibatkan overfitting yang diindikasikan oleh nilai validation loss yang terus meningkat. Untuk menangani masalah ini, teknik early stopping dapat dimanfaatkan. Early stopping pada dasarnya berarti menghentikan proses pelatihan model ketika model telah overfitting atau telah memenuhi kondisi tertentu. Early stopping berusaha untuk menghilangkan pengaruh berlebih dari noisy label sehingga model dapat generalize dengan lebih baik. Patience dari early stopping diatur menjadi 10 epochs sehingga membuat proses pelatihan model berhenti setelah melalui 10 epochs tanpa adanya pengembangan pada nilai validation loss.

Untuk setiap model EfficientNet, proses pelatihan model akan dijalankan dalam 150 epochs. Ukuran batch sebesar 32 citra digunakan untuk setiap iterasi pada pelatihan.

5.2 Pengujian dan Evaluasi Model

Setelah melakukan modeling, semua model EfficientNet tersebut dilatih dengan training set yang diikuti proses validasi dengan validation set untuk memastikan generalization. Pada tahapan ini, dilakukan pengujian dengan testing set pada semua model EfficientNet yang telah dilatih. Pada

pengujian tersebut, metrik yang digunakan adalah akurasi, presisi, recall, dan F1-score. Rumus keempat metrik tersebut adalah sebagai berikut:

$$\text{accuracy} = \frac{\text{number of correctly classified images}}{\text{total number of images}}$$

$$\text{precision} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Positive}}$$

$$\text{recall} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Negative}}$$

$$\text{F1 - score} = 2 \times \frac{\text{precision} \times \text{recall}}{\text{precision} + \text{recall}}$$

Akurasi digunakan untuk mengukur persentase klasifikasi yang tepat yang dihasilkan oleh model. Akan tetapi, akurasi tidak dapat digunakan untuk menentukan performa model terhadap suatu kelas tertentu. Oleh karena itu, juga digunakan metrik presisi dan recall. Sebagai contoh, dalam konteks kelas BCC, presisi digunakan untuk menghitung jumlah gambar yang diklasifikasikan oleh model sebagai BCC yang memang merupakan gambar BCC, sedangkan recall menghitung jumlah gambar BCC yang berhasil diklasifikasikan dengan tepat oleh model. Presisi dan recall memberikan informasi apakah model yang diuji mengabaikan kelas-kelas tertentu atau tidak. Selain itu, pengujian juga akan memanfaatkan metrik F1-score yang merupakan perhitungan performa model secara keseluruhan dengan menggabungkan presisi dan recall.

Sementara itu, hasil pengujian ditampilkan dalam bentuk confusion matrix agar dapat lebih mudah memahami seberapa baik setiap model EfficientNet dalam mengklasifikasikan masing-masing kelas kanker kulit. Dengan dijalankannya pengujian, dapat dilakukan evaluasi terhadap performa model dalam klasifikasi kanker kulit. Hasil evaluasi dapat dijadikan indikator untuk perbaikan atau perbandingan model.

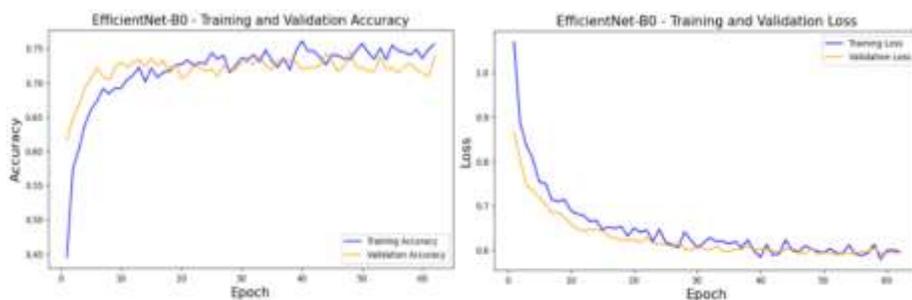
BAB 6

HASIL PELATIHAN DAN VALIDASI

6.1 Augmentasi Data

Karena penerapan penghentian dini, proses pelatihan dan validasi mungkin tidak mencapai 150 epoch. Proses pelatihan dan validasi akan berhenti ketika tidak ada lagi peningkatan nilai kerugian yang signifikan. Setiap model EfficientNet dengan nilai kerugian validasi terendah nantinya akan digunakan untuk mengevaluasi performanya pada tahap pengujian.

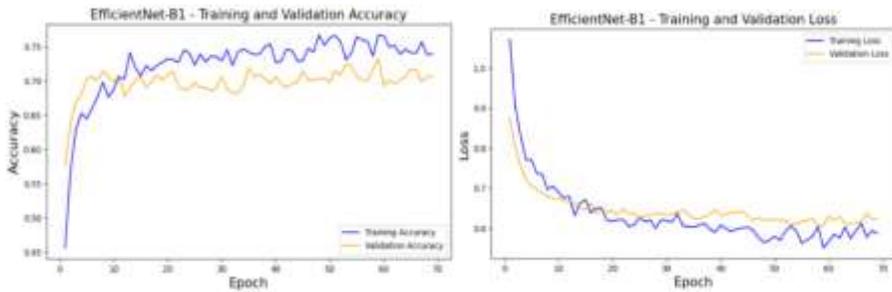
Model EfficientNet-B0 untuk klasifikasi kanker kulit hanya melewati 62 periode pelatihan dan validasi. Model EfficientNet-B0 pada epoch ke-52 ditandai sebagai nilai kerugian validasi terendah yang diperoleh. Pada epoch tersebut akurasi pelatihan sebesar 73,47%, akurasi validasi sebesar 71,69%, dan kerugian validasi sebesar 0,5882. Grafik akurasi pelatihan vs akurasi validasi dan kerugian pelatihan vs kerugian validasi selama jumlah epoch ditunjukkan pada Gambar 14.



Gambar 14 Training accuracy vs. validation accuracy dan training loss vs. validation loss dari EfficientNet-B0

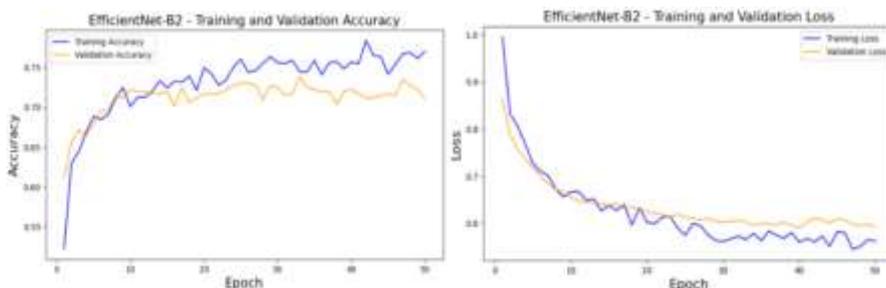
Model EfficientNet-B1 untuk klasifikasi kanker kulit melewati 69 epochs pelatihan dan validasi. Nilai *validation loss* terbaik yang dicapai oleh EfficientNet-B1 adalah 0,6057 yang diperoleh pada epoch ke-59.

Pada *epoch* tersebut, *training accuracy* sebesar 76,72% dan *validation accuracy* sebesar 73,28%. Grafik *training accuracy vs. validation accuracy* dan *training loss vs. validation loss* dapat dilihat pada Gambar 15.



Gambar 15 *Training accuracy vs. validation accuracy dan training loss vs. validation loss dari EfficientNet-B1*

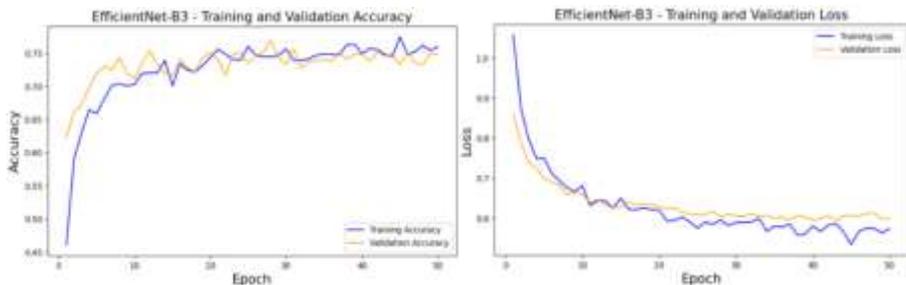
Sedangkan untuk model EfficientNet-B2, proses pelatihan dan validasi mencapai 50 *epochs*. EfficientNet-B2 mencapai 0,5903 sebagai *validation loss* terbaik pada *epoch* ke-40. Pada *epoch* tersebut, *training accuracy* sebesar 75,66% dan *validation accuracy* sebesar 72,22%. Gambar 16 menunjukkan grafik *training accuracy vs. validation accuracy* dan *training loss vs. validation loss* sepanjang *epoch*.



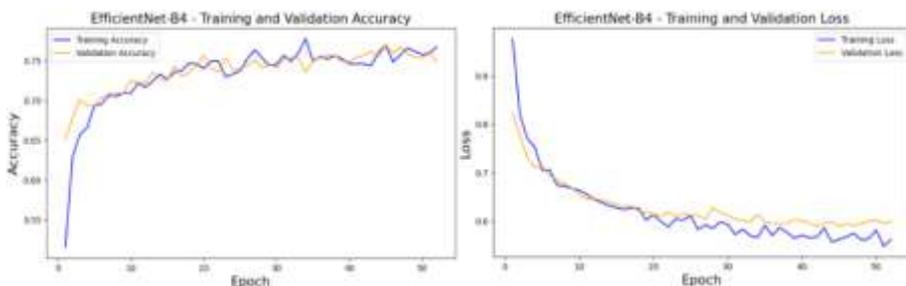
Gambar 16 *Training accuracy vs. validation accuracy dan training loss vs. validation loss dari EfficientNet-B2*

Untuk tugas klasifikasi kanker kulit, model EfficientNet-B3 menjalani 50 *epochs* pelatihan dan validasi. EfficientNet-B3 mencapai *validation loss* terbaik pada *epoch* ke-40 yaitu 0,5945. *Training accuracy* adalah 74,91% dan *validation accuracy* adalah 74,87% pada *epoch* tersebut. Gambar 15 menunjukkan *training accuracy* vs. *validation accuracy* dan *training loss* vs. *validation loss* model sepanjang *epoch*.

Model EfficientNet-B4 yang kami rancang mencapai 52 *epochs* pelatihan dan validasi. Pada *epoch* ke-42, EfficientNet-B4 mencapai *validation loss* terbaik, yaitu 0,5885. *Training accuracy* adalah 74,60% dan *validation accuracy* adalah 75,66% pada *epoch* ke-42. Gambar 17 menunjukkan *training accuracy* vs. *validation accuracy* dan *training loss* vs. *validation loss* dari model sepanjang *epoch*.



Gambar 17 Training accuracy vs. validation accuracy dan training loss vs. validation loss dari EfficientNet-B3

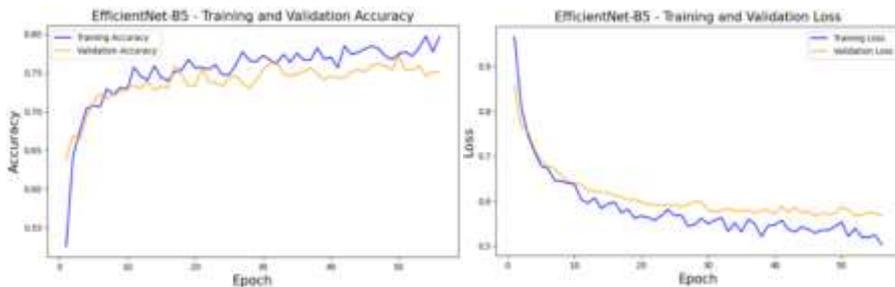


Gambar 18 Training accuracy vs. validation accuracy dan training loss vs. validation loss dari EfficientNet-B4

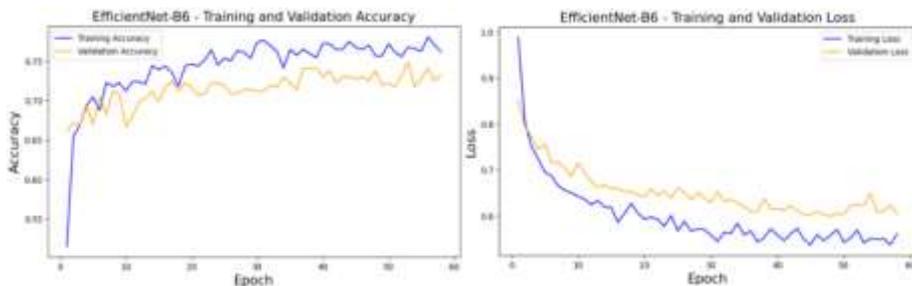
Model EfficientNet-B5 yang dibangun menjalani proses pelatihan dan validasi dalam 56 *epochs*. EfficientNet-B5 berhasil mencapai 0,5665 pada

epoch ke-46 sebagai *validation loss* terbaik. *Training accuracy* pada *epoch* tersebut adalah 78,46%, sedangkan *validation accuracy* sebesar 75,93%. Gambar 18 menunjukkan *training accuracy vs. validation accuracy* dan *training loss vs. validation loss* dari model sepanjang *epoch*.

Model EfficientNet-B6 yang dirancang menjalani 58 *epochs* pelatihan dan validasi. Model terbaik EfficientNet-B6 diperoleh pada *epoch* ke-48. *Validation loss* terbaik adalah 0,5983 dengan akurasi 75,66% pada *training set* dan akurasi 73,81% pada *validation set*. Grafik *training accuracy vs. validation accuracy* dan *training loss vs. validation loss* ditunjukkan pada Gambar 19.



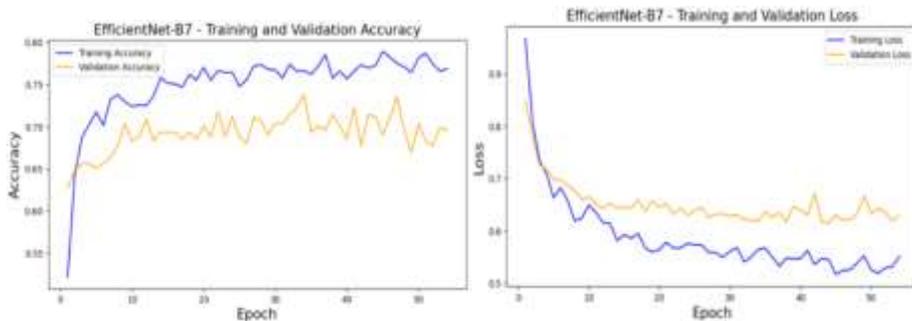
Gambar 19 *Training accuracy vs. validation accuracy dan training loss vs. validation loss dari EfficientNet-B5*



Gambar 20 *Training accuracy vs. validation accuracy dan training loss vs. validation loss dari EfficientNet-B6*

Model EfficientNet-B7 untuk klasifikasi kanker kulit mengalami 54 *epochs* pelatihan dan validasi. Model terbaik EfficientNet-B7 diperoleh pada *epoch* ke-44. *Validation loss* terbaik adalah 0,6148 dengan akurasi

77,25% pada *training set* dan akurasi 71,16% pada *validation set*. Grafik *training accuracy vs. validation accuracy* dan *training loss vs. validation loss* ditampilkan pada Gambar 21.



Gambar 21 *Training accuracy vs. validation accuracy dan training loss vs. validation loss dari EfficientNet-B7*

Performa dan kinerja semua model EfficientNet tersebut pada *training set* dan *validation set* dapat dirangkum seperti yang terlihat pada Tabel 3. Akurasi tertinggi pada *training set* adalah 78,46% yang dicapai oleh EfficientNet-B5. Selain itu, EfficientNet-B5 juga mencapai akurasi tertinggi pada *validation set*, yaitu sebesar 75,93%. Secara umum, semua model EfficientNet yang kami rancang dapat bekerja dengan baik dalam mengklasifikasikan kanker kulit pada *training set* dan *validation set*.

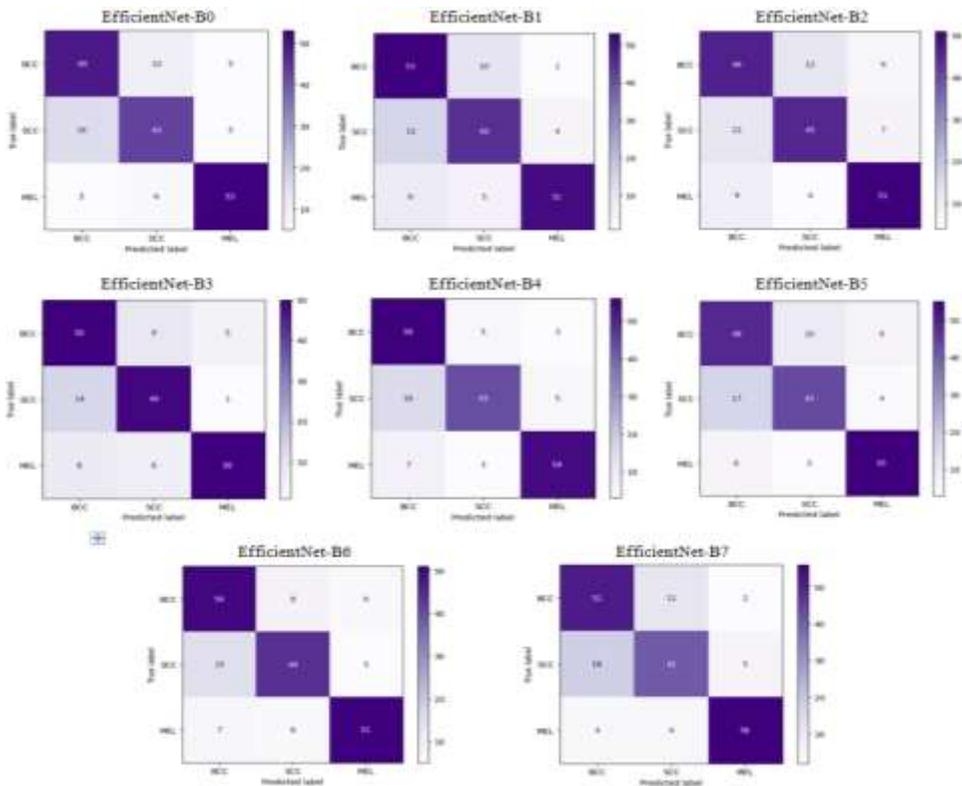
Tabel 3. Performa EfficientNets pada *training set* dan *validation set*

Model	Training set		Validation set	
	Accuracy (%)	Loss	Accuracy (%)	Loss
EfficientNet-B0	73.47	0.5944	71.69	0.5882
EfficientNet-B1	76.72	0.5502	73.28	0.6057
EfficientNet-B2	75.66	0.5600	72.22	0.5903
EfficientNet-B3	74.91	0.5808	74.87	0.5945

EfficientNet-B4	74.60	0.5660	75.66	0.5885
EfficientNet-B5	78.46	0.5286	75.93	0.5665
EfficientNet-B6	75.66	0.5576	73.81	0.5983
EfficientNet-B7	77.25	0.5451	71.16	0.6148

6.2 Hasil Pengujian

Nilai *weight* terbaik yang diperoleh dari tahap pelatihan digunakan dalam model EfficientNet. Kemudian, dilakukan pengujian semua model EfficientNet pada *testing set*. *Testing set* yang digunakan ini berisi 192 citra kanker kulit yang telah diubah ukurannya menjadi 256×256 piksel. Hasil klasifikasi kanker kulit pada *testing set* disajikan sebagai *confusion matrix*.



Gambar 21 Confusion matrix dari semua model EfficientNet sebagai hasil klasifikasi kanker kulit (BCC, SCC, MEL)

Nilai akurasi, presisi, *recall*, dan skor F1 pada *testing set* untuk semua model EfficientNet yang dirancang ditunjukkan pada Tabel 4. EfficientNet-B4 memiliki akurasi tertinggi yaitu 79,69%. Akurasi tertinggi kedua adalah 77,60% dicapai oleh EfficientNet-B1 dan EfficientNet-B3. Presisi tertinggi adalah 85,98% yang diperoleh dengan menggunakan EfficientNet-B3. Selain itu, EfficientNet-B0, EfficientNet-B4, dan EfficientNet-B7 juga berhasil mencapai presisi lebih dari 80%. EfficientNet-B4 juga mencapai *recall* terbaik, yaitu sebesar 76,56%. Sedangkan untuk skor F1, EfficientNet-B3 memiliki nilai tertinggi, yaitu 79,21%. Mengikuti nilai tersebut, EfficientNet-B4 memiliki skor F1

tertinggi kedua, yaitu sebesar 79,03%. Berdasarkan hasil pengujian, EfficientNet-B4 yang kami rancang dapat dianggap sebagai model terbaik untuk klasifikasi kanker kulit di antara model EfficientNet lainnya.

Tabel 4. Nilai akurasi, presisi, *recall*, dan skor F1 pada *testing set*

Model	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
EfficientNet-B0	75.52	80.24	69.79	74.65
EfficientNet-B1	77.60	79.53	70.83	74.93
EfficientNet-B2	73.96	78.29	71.35	74.66
EfficientNet-B3	77.60	85.98	73.44	79.21
EfficientNet-B4	79.69	81.67	76.56	79.03
EfficientNet-B5	76.04	78.57	74.48	76.47
EfficientNet-B6	75.52	77.22	72.40	74.73
EfficientNet-B7	77.08	82.53	71.35	76.54

Secara keseluruhan, semua model EfficientNet yang dirancang berhasil mencapai akurasi, presisi, *recall*, dan skor F1 yang tinggi. Dengan kata lain, model EfficientNet memiliki performa dan kualitas yang baik dalam mengklasifikasikan kanker kulit BCC, SCC, dan melanoma. Namun, model yang dirancang masih bisa salah mengklasifikasikan kanker kulit. Hal ini kemungkinan besar disebabkan oleh beberapa kemiripan antara BCC, SCC, dan melanoma. Kemiripan tersebut dapat terjadi karena aspek genetik yang mengubah pola kanker kulit dan menciptakan lebih banyak varian. Selain itu, kinerja klasifikasi model berkemungkinan dapat ditingkatkan dengan memanfaatkan teknik segmentasi citra.

DAFTAR PUSTAKA

- [1] M. Arnold, M. Laversanne, D. Singh, J. Vignat, S. Vaccarella, and F. Meheus, “Melanoma awareness month 2022,” International Agency for Research on Cancer, 2022. <https://www.iarc.who.int/news-events/melanoma-awareness-month-2022/>.
- [2] World Health Organization (WHO), “Ultraviolet radiation,” World Health Forum, 1995. .
- [3] L. Zeng et al., “Advancements in nanoparticle-based treatment approaches for skin cancer therapy,” *Molecular Cancer*, vol. 22, no. 1, pp. 1–50, 2023, doi: 10.1186/s12943-022-01708-4.
- [4] M. Zambrano-Román, J. R. Padilla-Gutiérrez, Y. Valle, J. F. Muñoz-Valle, and E. Valdés-Alvarado, “Non-melanoma skin cancer: a genetic update and future perspectives,” *Cancers*, vol. 14, no. 10, 2022, doi: 10.3390/cancers14102371.
- [5] N. Melarkode, K. Srinivasan, S. M. Qaisar, and P. Plawiak, “AI-powered diagnosis of skin cancer: a contemporary review, open challenges and future research directions,” *Cancers*, vol. 15, no. 4, 2023, doi: 10.3390/cancers15041183.
- [6] H. Sujaini, E. Y. Ramadhan, and H. Novriando, “Comparing the performance of linear regression versus deep learning on detecting melanoma skin cancer using apple core ml,” *Bulletin of Electrical Engineering and Informatics*, vol. 10, no. 6, pp. 3110–3120, 2021, doi: 10.11591/eei.v10i6.3178.
- [7] “Skin cancer,” International Agency for Research on cancer, 2020. <https://www.iarc.who.int/cancer-type/skin-cancer/> (accessed Feb. 03, 2023).

- [8] W. Hu, L. Fang, R. Ni, H. Zhang, and G. Pan, "Changing trends in the disease burden of non-melanoma skin cancer globally from 1990 to 2019 and its predicted level in 25 years," *BMC Cancer*, vol. 22, no. 1, pp. 1–11, 2022, doi: 10.1186/s12885-022-09940-3.
- [9] P. Fontanillas et al., "Disease risk scores for skin cancers," *Nature Communications*, vol. 12, no. 1, pp. 1–13, 2021, doi: 10.1038/s41467-020-20246-5.
- [10] J. Daghrrir, L. Tlig, M. Bouchouicha, and M. Sayadi, "Melanoma skin cancer detection using deep learning and classical machine learning techniques: A hybrid approach," 2020, doi: 10.1109/ATSIP49331.2020.9231544.
- [11] H. L. Gururaj, N. Manju, A. Nagarjun, V. N. M. Aradhya, and F. Flammini, "DeepSkin: A deep learning approach for skin cancer classification," *IEEE Access*, vol. 11, pp. 50205–50214, 2023, doi: 10.1109/ACCESS.2023.3274848.
- [12] K. Miller, "A sharper eye: how advanced imaging technologies and artificial intelligence are transforming melanoma diagnosis," *The Melanoma Letter*, vol. 38, no. 1, 2020.
- [13] D. Mohammad, I. Aljarrah, and M. Jarrah, "Searching surveillance video contents using convolutional neural network," *International Journal of Electrical and Computer Engineering*, vol. 11, no. 2, pp. 1656–1665, Apr. 2021, doi:10.11591/ijece.v11i2.pp1656-1665.
- [14] M. A. Uthaib and M. S. Croock, "Multiclassification of license plate based on deep convolution neural networks," *International Journal of Electrical and Computer Engineering*, vol. 11, no. 6,

- pp. 5266–5276, Dec. 2021, doi: 10.11591/ijece.v11i6.pp5266-5276.
- [15] A. Berroukham, K. Housni, M. Lahraichi, and I. Boulfri, “Deep learning-based methods for anomaly detection in video surveillance: a review,” *Bulletin of Electrical Engineering and Informatics*, vol. 12, no. 1, pp. 314–327, 2023, doi:10.11591/eei.v12i1.3944.
- [16] M. Tan and Q. V. Le, “EfficientNet: Rethinking model scaling for convolutional neural networks,” in *36th International Conference on Machine Learning, ICML 2019, May 2019*, pp. 10691–10700.
- [17] T. Selim, I. Elkabani, and M. A. Abdou, “Students engagement level detection in online e-learning using hybrid EfficientNetB7 together with TCN, LSTM, and Bi-LSTM,” *IEEE Access*, vol. 10, pp. 99573–99583, 2022, doi: 10.1109/ACCESS.2022.3206779.
- [18] M. Moghaddam, M. Charmi, and H. Hassanpoor, “Jointly human semantic parsing and attribute recognition with feature pyramid structure in EfficientNets,” *IET Image Processing*, vol. 15, no. 10, pp. 2281–2291, 2021, doi: 10.1049/ipr2.12195.
- [19] M. S. Ali, M. S. Miah, J. Haque, M. M. Rahman, and M. K. Islam, “An enhanced technique of skin cancer classification using deep convolutional neural network with transfer learning models,” *Machine Learning with Applications*, vol. 5, 2021, doi:10.1016/j.mlwa.2021.100036.
- [20] R. Patil and S. Bellary, “Machine learning approach in melanoma cancer stage detection,” *Journal of King Saud University-*

- Computer and Information Sciences, vol. 34, no. 6, pp. 3285–3293, 2022, doi: 10.1016/j.jksuci.2020.09.002.
- [21] F. Xiao and Q. Wu, “Visual saliency based global-local feature representation for skin cancer classification,” *IET Image Processing*, vol. 14, no. 10, pp. 2140–2148, 2020, doi: 10.1049/iet-ipr.2019.1018.
- [22] K. Thurnhofer-Hemsi and E. Domínguez, “A convolutional neural network framework for accurate skin cancer detection,” *Neural Processing Letters*, vol. 53, no. 5, pp. 3073–3093, 2021, doi: 10.1007/s11063-020-10364-y.
- [23] P. Maharana, “ISIC 2019 skin lesion images for classification,” 2022. <https://www.kaggle.com/datasets/salviohexia/isic-2019-skin-lesion-images-for-classification> (accessed Feb. 11, 2023).
- [24] E. Rendón, R. Alejo, C. Castorena, F. J. Isidro-Ortega, and E. E. Granda-Gutiérrez, “Data sampling methods to deal with the big data multi-class imbalance problem,” *Applied Sciences (Switzerland)*, vol. 10, no. 4, 2020, doi: 10.3390/app10041276.
- [25] D. Yarats, R. Fergus, and I. Kostrikov, “Image augmentation is all you need: regularizing deep reinforcement learning from pixels,” *International Conference on Learning Representations*, Vienna, Austria, 2021, pp. 1-21.
- [26] K. Okokpujie, S. John, C. Ndujiuba, J. A. Badejo, and E. Noma-Osaghae, “An improved age invariant face recognition using data augmentation,” *Bulletin of Electrical Engineering and Informatics*, vol. 10, no. 1, pp. 179–191, 2021, doi: 10.11591/eei.v10i1.2356.

- [27] J. C. Setyono and A. Zahra, “Data augmentation and enhancement for multimodal speech emotion recognition,” *Bulletin of Electrical Engineering and Informatics*, vol. 12, no. 5, pp. 3008–3015, 2023, doi: 10.11591/eei.v12i5.5031.
- [28] S. Bozinovski, “Reminder of the first paper on transfer learning in neural networks, 1976,” *Informatica (Slovenia)*, vol. 44, no. 3, pp. 291–302, 2020, doi: 10.31449/INF.V44I3.2828.
- [29] T. Yu and H. Zhu, “Hyper-parameter optimization: a review of algorithms and applications,” *arXiv*, pp. 1–56, 2020, doi: 10.48550/arXiv.2003.05689.
- [30] L. Rice, E. Wong, and J. Z. Kolter, “Overfitting in adversarially robust deep learning,” in *37th International Conference on Machine Learning, ICML 2020*, 2020, pp. 8049–8074.
- [31] X. Xia et al., “Robust early-learning: hindering the memorization of noisy labels,” in *ICLR 2021-9th International Conference on Learning Representations*, 2021, pp. 1–15.

Kanker kulit adalah salah satu penyakit mematikan yang paling umum di seluruh dunia. Oleh karena itu, klasifikasi kanker kulit menjadi semakin penting karena pengobatan kanker kulit stadium awal jauh lebih efektif dan efisien. Klasifikasi tiga jenis kanker kulit yang umum, yaitu karsinoma sel basal (BCC), karsinoma sel skuamosa (SCC), dan melanoma menggunakan arsitektur EfficientNet. Kumpulan data telah diproses sebelumnya dan setiap gambar dalam kumpulan data diubah ukurannya menjadi 256×256 piksel sebelum digabungkan pada tahap selanjutnya. Training dataset semua jenis EfficientNet mulai dari EfficientNet-B0 hingga EfficientNet-B7 dan membandingkan performanya. Berdasarkan hasil pengujian, seluruh model EfficientNet yang dilatih mampu menghasilkan akurasi, presisi, recall, dan skor F1 yang baik dalam klasifikasi kanker kulit. Khususnya, model EfficientNet-B4 yang kami rancang mencapai akurasi 79,69%, presisi 81,67%, perolehan 76,56%, dan skor F1 79,03% sebagai yang tertinggi di antara model lainnya.