

KLASIFIKASI POSE TIDUR MENGGUNAKAN ALGORITMA RESNET

Muhammad Akmal Nafis; Gunawan Ariyanto
Program Studi Teknik Informatika, Fakultas Komunikasi dan
Informatika, Universitas Muhammadiyah Surakarta

Abstrak

Arsitektur deep learning yang semakin berkembang, kini merevolusi kerja pada pengenalan gambar. *ResNet (Residual Neural Network)* adalah salah satu arsitektur deep learning yang sudah berkembang dan memiliki banyak variasi. Penelitian ini bertujuan untuk mengevaluasi klasifikasi posisi tidur menggunakan *ResNet*, arsitektur deep learning yang terkenal akan efektivitasnya dalam tugas pengenalan citra. Dengan memanfaatkan dataset gambar tidur yang ditangkap melalui kamera, melakukan training dan testing model *ResNet* untuk memperoleh model terbaik dalam kerja klasifikasi gambar, metode ini memungkinkan tercapainya performa dari model *ResNet*. Melalui eksperimen ekstensif, menunjukkan efektivitas berbagai varian *ResNet* dalam mengklasifikasikan posisi tidur dengan akurat, termasuk posisi menghadap ke kiri, kanan, telentang, dan negatif dengan membandingkan kinerja *ResNet18*, *ResNet34*, *ResNet50*, *ResNet101*, dan *ResNet152*, memberikan wawasan tentang efektivitas dalam klasifikasi posisi tidur. Pengujian menunjukkan bahwa varian-varian model *ResNet* yang dipilih tidak terlalu menunjukkan perbedaan yang signifikan. Akan tetapi pengujian performa komputasi menunjukkan beberapa varian *ResNet* yang unggul pada aspek tertentu, sehingga pemilihan model dapat dilakukan dengan melihat performa komputasi dibanding performa klasifikasi yang tidak terlalu signifikan sehingga menghasilkan kesimpulan bahwa variasi, kuantitas, dan proporsi dataset sangat mempengaruhi kemampuan model untuk melakukan generalisasi pada pose tidur yang berbeda.

Kata Kunci: *Deep learning*, klasifikasi pose tidur, perbandingan model, pengenalan citra, *ResNet*

Abstract

Deep learning architectures are increasingly evolving, now revolutionizing work on image recognition. ResNet (Residual Neural Network) is a deep learning architecture that has been developed and has many variations. This study aims to evaluate sleep position classification using ResNet, a deep learning architecture known for its effectiveness in image recognition tasks. By utilizing a dataset of sleeping images captured via camera, training and testing the ResNet model to obtain the best model for image classification work, this method makes it possible to achieve the performance of the ResNet model. By leveraging a dataset of sleep images captured through various sensors or cameras, the method allows for non-intrusive monitoring of sleep poses. Through extensive experiments, this study demonstrates the efficacy of different ResNet variants in accurately classifying sleep poses, including left, right, supine, and negative by comparing the performance of ResNet18, ResNet34, ResNet50, ResNet101, and ResNet152, providing insights into their effectiveness in sleep pose classification. Testing shows that the selected ResNet model variants do not show significant differences. However, computational performance testing shows that several ResNet variants are superior in certain aspects, so model selection can be done by looking at computational performance rather than classification performance which is not very significant. Models trained with proportionally varied datasets show increased accuracy. This research concludes that the variety, quantity and proportion of the dataset greatly influence the model's ability to generalize to different sleeping poses.

Keywords: *ResNet, sleep pose classification, image recognition, deep learning, model comparison*

1. PENDAHULUAN

Kemajuan teknologi dalam arsitektur deep learning, seperti *ResNet* (*Residual Neural Network*), telah banyak merevolusi pengenalan gambar. *ResNet*, yang diperkenalkan oleh Kaiming He dkk. pada tahun 2015, menangani tantangan dalam melatih jaringan syaraf yang sangat dalam dengan memperkenalkan koneksi lintas yang memungkinkan propagasi gradien yang efektif (He dkk., 2015). Terobosan ini telah secara signifikan meningkatkan kinerja berbagai tugas *computer vision*, termasuk tugas klasifikasi gambar dan deteksi objek sehingga dapat mencapai hasil yang maksimal pada klasifikasi yang diantaranya pada studi kasus lain adalah pengenalan wajah (Santoso & Ariyanto, 2018) dan pengenalan sidik jari (Nurfita & Ariyanto, 2018). Tujuan dari penelitian ini adalah membandingkan model deep learning *ResNet* dan klasifikasi posisi tidur yang kuat dengan memanfaatkan *ResNet*. Fokus utama dari penelitian ini adalah pada pelatihan, pengujian dan evaluasi model deep learning untuk klasifikasi posisi tidur. Metode tradisional dalam pemantauan tidur yang sudah ada seringkali melibatkan perangkat yang mengganggu sehingga membuat tidak nyaman, yang bisa menjadi tantangan bagi individu dengan kondisi kesehatan tertentu. Oleh karena itu, kebutuhan akan teknik pemantauan tidur yang tidak mengganggu dan akurat, terutama dalam konteks pemantauan posisi tidur, sangat diperlukan. Perbandingan lima varian *ResNet*, yaitu *ResNet18*, *ResNet34*, *ResNet50*, *ResNet101*, dan *ResNet152*, akan dilakukan di dalam penelitian ini untuk menentukan model mana yang paling efektif dalam mengklasifikasikan berbagai posisi tidur, termasuk posisi terlentang, tengkurap, dan lateral pada kondisi lingkungan tertentu menggunakan suatu mesin komputasi. Evaluasi akan mencakup akurasi dan keandalan sistem deteksi, dengan mempertimbangkan faktor-faktor seperti lingkungan tidur yang berbeda dan kemungkinan gangguan. Selain itu, studi ini akan mengeksplorasi kelayakan integrasi sistem yang diusulkan ke dalam kerangka kerja perawatan kesehatan yang sudah ada.

ResNet18 telah memperoleh banyak pengakuan untuk penggunaannya pada banyak penerapan pada bidang medis, salah satunya adalah segmentasi organ dan jaringan untuk meningkatkan diagnosis dan perencanaan pengobatan. (Odusami dkk., 2021) *ResNet34* juga telah diterapkan secara efektif dalam analisis dan pelestarian lukisan fresco Tionghoa perantaraan, menunjukkan kemampuan generalisasi yang kuat dan mengungguli model-model tradisional seperti AlexNet, GoogLeNet, dan VGGNet dalam akurasi dan tingkat *recall*. (Gao dkk., 2023) Dalam suatu penelitian juga disebutkan bahwa para penulis mengembangkan model berbasis deep learning *ResNet50* yang bertujuan untuk mengidentifikasi secara akurat individu yang mengenakan masker wajah, mengatasi tantangan yang dihadapi oleh sistem pengenalan wajah yang biasanya dilatih dengan wajah tanpa masker namun kini harus beradaptasi dengan kondisi pandemi. (Mandal dkk., 2021) Studi yang mengusulkan model *ResNet101* baru berbasis konvolusi dilated padat berhasil melakukan klasifikasi tumor hati medis, mengatasi masalah yang ada pada metode jaringan saraf konvolusional saat ini terkait akurasi klasifikasi gambar, ekspresi fitur, dan kemampuan ekstraksi sehingga membuktikan keefektifitasan model *ResNet101* dalam melakukan klasifikasi. (Zhang, 2021) Model terakhir yang akan digunakan dalam penelitian ini adalah *ResNet152* yang dalam suatu studi diperlihatkan bahwa arsitektur *ResNet-152* menunjukkan kinerja unggul dalam mengkategorikan penyakit paru-paru dari gambar X-ray, dengan mencapai skor F1 tinggi sebesar 94%, sehingga direkomendasikan untuk digunakan dibandingkan dengan arsitektur *ResNet50* dan *ResNet101* untuk tujuan ini. (Hasanah dkk., 2023)


Studi yang meneliti tentang arsitektur yang berfokus pada model kecil dengan proses *training* yang cepat menjelaskan bahwa model *ResNet* yang asli telah mengalami berbagai

peningkatan, salah satunya adalah EfficientNetV2. Model ini dirancang untuk lebih kecil dan lebih cepat dalam pelatihan dibandingkan dengan model-model sebelumnya. Dalam penelitian ini, penulis menggunakan model *ResNet* asli untuk klasifikasi posisi tidur. Meskipun ada model-model yang lebih baru dan lebih efisien seperti EfficientNetV2, *ResNet* tetap menjadi pilihan yang relevan karena stabilitas dan kinerjanya yang telah terbukti dalam berbagai tugas pengenalan gambar. (Tan & Le, 2021) Penelitian deteksi pose tidur menggunakan kamera *infrared* yang dilatih dengan *transfer learning* menunjukkan alasan kuat untuk menggunakan transfer learning, terutama ketika dataset yang digunakan relatif kecil. (Mohammadi dkk., 2021) Dalam konteks penelitian ini, transfer learning memungkinkan pemanfaatan pengetahuan yang telah diperoleh dari model yang dilatih pada dataset besar untuk meningkatkan performa pada dataset yang lebih kecil. Hal ini sangat relevan dengan penelitian kami, di mana dataset yang digunakan juga terbatas, sehingga transfer learning menjadi strategi yang efektif untuk meningkatkan akurasi klasifikasi posisi tidur. F. Fistranda, F. Austin, dan M. Sadrawi dalam studi yang melakukan analisis komparatif terhadap beberapa model deep learning, termasuk *ResNet*, untuk tugas klasifikasi menunjukkan keunggulan dan kelemahan masing-masing model dalam konteks aplikasi medis. Studi ini memberikan dasar bagi penelitian penulis untuk memilih *ResNet* sebagai model utama, sekaligus menyadari adanya alternatif lain seperti YOLO dan *EfficientNet* yang mungkin memiliki keunggulan tertentu dalam situasi yang berbeda. (Fistranda dkk., 2023) Studi referensi yang teridentifikasi dalam hasil pencarian menunjukkan pendekatan yang berbeda untuk klasifikasi pose tidur menggunakan berbagai model dan teknik deep learning. Sebagai contoh, ada suatu penelitian yang menggunakan jaringan multi-task learning yang mendalam untuk mengklasifikasikan pose kepala dan tubuh bagian atas selama tidur dengan akurasi rata-rata 92,5%. Sistem ini bergantung pada kamera keamanan rumah untuk pengumpulan data. (Li dkk., 2022)

Penelitian ini juga melibatkan pengumpulan dan pembuatan dataset yang ekstensif oleh tim kami. Dataset ini akan digunakan untuk melatih dan menguji model, memastikan bahwa hasil yang diperoleh relevan dan dapat diandalkan. Dengan memanfaatkan kemampuan berbagai varian *ResNet*, penelitian ini bertujuan untuk memberikan solusi non-invasif untuk memantau posisi tidur, yang berpotensi memberikan dampak positif bagi individu dengan kondisi kesehatan tertentu. Pembuatan dataset sangat krusial dalam mempengaruhi kinerja enam model *machine learning*. Seperti pada penelitian yang menganalisis delapan belas dataset medis kecil dan menerapkan teknik pengurangan ukuran pada dua dataset yang lebih besar, penelitian ini menilai kinerja model melalui akurasi, presisi, *recall*, f-score, spesifisitas, dan area di bawah kurva ROC (AUC). Temuan menunjukkan bahwa kinerja model lebih tergantung pada representasi dataset daripada ukurannya. *AdaBoost* dan *Naïve Bayes* muncul sebagai model yang paling tangguh untuk data medis terbatas, diikuti oleh SVM, dengan *Random Forest* dan *Neural Networks* menunjukkan tingkat ketangguhan yang bervariasi. Studi ini menekankan interaksi kompleks antara ukuran dataset dan kinerja model dalam konteks medis, dengan implikasi untuk meningkatkan teknologi kesehatan. (Althnani dkk., 2021) Pada penelitian lain, diketahui bahwa pentingnya pembuatan dan evaluasi dataset dalam pelatihan model deep learning. *ImageNet* telah menjadi benchmark dalam penelitian pengenalan gambar, menunjukkan bagaimana dataset yang besar dan beragam dapat meningkatkan kinerja model secara signifikan. Dalam penelitian ini, penulis mengumpulkan dan menciptakan dataset sendiri, dengan belajar dari pendekatan *ImageNet* untuk memastikan dataset yang dibuat cukup representatif dan memungkinkan pelatihan model yang efektif. (Russakovsky dkk., 2015)

2. METODE


Metodologi untuk deteksi pose tidur menggunakan *ResNet* melibatkan beberapa langkah kunci yang ditampilkan pada Gambar 1. Pertama, pengumpulan dan persiapan data melibatkan pengambilan gambar tidur dan melakukan pra-pemrosesan gambar tersebut dengan cara mengubah ukuran, normalisasi, dan augmentasi data. Pelatihan dan evaluasi model berfokus pada pemanfaatan arsitektur *ResNet*, model pembelajaran mendalam yang dikenal karena efektivitasnya dalam tugas pengenalan gambar, untuk mengklasifikasikan pose tidur dengan akurasi. Model dilatih dan divalidasi menggunakan *dataset* berlabel, dan kinerjanya dinilai berdasarkan metrik seperti akurasi dan presisi. Selama pengujian model, model yang telah dilatih dievaluasi pada set uji terpisah untuk menentukan kemampuannya dalam generalisasi pose tidur yang berbeda. Hasilnya kemudian dianalisis, dengan mempertimbangkan kinerja model dibawah berbagai kondisi, dan visualisasi seperti confusion matrix dan grafik digunakan untuk menyajikan temuan secara jelas.




Gambar 1. Tahapan Pengembangan Machine Learning

A. Pemilihan Model *ResNet*

Bagian ini menjelaskan bagaimana alur input dan pemrosesan salah satu model deteksi pose tidur yang berbasis arsitektur *ResNet*, yaitu *ResNet50*. Gambar 2 menjelaskan bagaimana gambar diproses sebelumnya, dan bagaimana lapisan model memproses tensor gambar input.



Gambar 2. Arsitektur Model *ResNet50*




Gambar 3. Skip Connection ResNet

Tensor gambar input melewati beberapa tahap, yang masing-masing berkontribusi pada aspek-aspek yang berbeda dari tugas klasifikasi seperti yang tercantum pada Gambar 2. Gambar 3 menunjukkan pada awalnya, tensor input diproses di Tahap 1, yang mencakup lapisan convolutional diikuti oleh batch normalization, fungsi aktivasi *ReLU*, dan max pooling untuk mengecilkan dimensi spasial input. Tahap-tahap berikutnya (2-5) terdiri dari Conv dan Identity blocks yang menerapkan lapisan convolutional, batch normalization, dan fungsi aktivasi *ReLU*, dengan skip connections untuk menjaga informasi dan meningkatkan stabilitas pelatihan. Selanjutnya, pemrosesan model melibatkan global average pooling, yang mengurangi setiap peta fitur menjadi satu nilai. Ini diikuti dengan flattening output dan melewatinya melalui fully connected layers. Akhirnya, model menghasilkan probabilitas output untuk setiap kelas menggunakan dense layer dengan softmax activation.

Arsitektur *ResNet-50*, dikenal karena efektivitasnya dalam tugas pengenalan gambar, cocok untuk deteksi pose tidur karena dapat menangani kompleksitas jaringan dalam yang efektif melalui koneksi residualnya. Ini juga memungkinkan model untuk dilatih secara mendalam sambil mengurangi masalah gradient yang menghilang. Arsitektur ini diimplementasikan menggunakan PyTorch, dilatih dengan dataset yang akan dijelaskan pada sub bab selanjutnya. Library PyTorch digunakan oleh penulis dalam penelitian ini karena PyTorch menyediakan fleksibilitas dan kemampuan debugging yang lebih baik dibandingkan dengan library lain, serta didukung oleh komunitas yang luas dan dokumentasi yang komprehensif, yang memudahkan pengembangan dan penerapan model machine learning. Sehingga penulis bisa berfokus dalam evaluasi dan komparasi varian-varian model *ResNet* yang akan dilakukan.

B. Data Collection dan Data Preparation

Pengumpulan dataset dilakukan melalui rekaman video yang melibatkan penulis dan dua teman penulis dengan empat kelas pose tidur (kiri, kanan, terlentang, negatif. Negatif berarti tempat tidur kosong atau pose yang tidak dikenali seperti duduk, berdiri, dll.). Setiap orang memiliki 3 video rekaman untuk setiap kelas kecuali kelas negatif. Video yang direkam memiliki durasi 90 detik untuk semua kelas. Video yang direkam diambil setiap 3 frame per detik. Jadi setiap kelas memiliki sekitar 270 gambar (bisa lebih atau kurang). Kemudian gambar dari setiap kelas digabungkan menjadi satu dataset yang totalnya sekitar 270 gambar x 3 orang = sekitar 810 gambar. Kelas negatif memiliki total 270 gambar. Jadi, totalnya akan menjadi sekitar 810+810+810+270 gambar (bisa lebih).



Gambar 4. Dataset A1

Dataset yang penulis kumpulkan pada penelitian kali ini adalah dataset yang diberi nama A1 dengan contoh gambar yang bisa dilihat pada Gambar 4 di atas. Dataset ini diambil di kos lama penulis dengan pencahayaan dari jendela di samping kiri dan pencahayaan lampu dari atas. Variasi pada dataset ini terletak pada pencahayaan, warna sprei pink, warna bantal hitam dan pakaian object manusia oranye, putih dan ungu tua lalu warna pakaian hijau dan putih pada kelas negative.

Selain dataset A1, ada beberapa dataset lainnya yang dibuat oleh teman penulis, yaitu dataset A2 dan A3 yang dapat dilihat pada Tabel 1. Dataset A2 dan A3 dibuat dengan mempertimbangkan variasi yang berbeda dengan dataset A1, sehingga model *ResNet* dapat mengenali berbagai kondisi lingkungan pada subject pose tidur secara lebih luas dan mencakup banyak situasi. Dataset ini dapat dikembangkan dengan variasi latar belakang ruangan, pencahayaan, warna sprei, warna bantal, warna pakaian orang dan penambahan objek lain seperti selimut, bantal guling dan lain-lain jika menginginkan keberagaman dataset dan memiliki sumber daya komputasi yang cukup untuk memasukkan semua dataset itu pada proses *training*.

Dataset A1A2A3 akan digabungkan sehingga berjumlah total 10011 gambar. Selain dataset A1A2A3, adapula dataset B1B2 yang diambil dari *IEEE VIP CUP 2021 Dataset "Privacy-Preserving In-Bed Human Pose Estimation"* yang memiliki dua variasi, yaitu *covered* dan *uncovered*. (Liu dkk., 2022) B1 adalah dataset *uncovered* atau dataset dengan subjek orang tidur yang tidak memakai selimut. Sedangkan dataset B2 adalah dataset *covered*, yang berarti dataset ini memiliki subjek orang yang tidak memakai selimut. Dengan pengumpulan data yang bervariasi dalam hal pencahayaan, lokasi, dan pakaian, penulis bertujuan untuk memastikan bahwa model yang dikembangkan dapat mengenali pose tidur dalam berbagai kondisi. Data gabungan B1 dan B2 digabungkan menjadi dataset B1B2

dengan total jumlah gambar adalah 3577. Data ini kemudian akan diproses dan digunakan untuk melatih model *ResNet* yang berbeda untuk mengevaluasi kinerja dalam klasifikasi posisi tidur.

Tabel 1. Variasi dataset A1, A2, dan A3

Dataset	Tempat	Pencahayaan	Warna Sprei	Warna Bantal	Pakaian Orang 1	Pakaian Orang 2	Pakaian Orang 3
A1	Kamar kos penulis	Samping dari jendela dan satu lampu kamar	Pink	Hitam	Kaos kuning dan celana hitam	Kaos putih dan celana hitam	Kaos ungu dan celana hitam
A2	Kamar kos penulis	Samping dari jendela dan satu lampu kamar	Biru	Pink	Kaos biru dan celana hitam	Kaos hijau dan celana hitam	Kaos merah dan celana putih
A3	Kamar teman penulis	Lampu kamar dan cahaya lingkungan dari kiri	Hijau	Hijau	Kaos hitam dan celana hitam	Kaos hijau tua dan celana hitam	Kaos hijau dan kain sarung coklat

C. Model Training and Evaluation

Proses pelatihan model *ResNet* melibatkan persiapan dataset pose tidur dan pelatihan model untuk mengenali dan mengklasifikasikan berbagai pose tidur. Selama pelatihan, dataset dibagi menjadi batch, dan model mengulangi setiap batch untuk belajar dari data. Model dilatih menggunakan loss function untuk mengevaluasi prediksi terhadap label yang sebenarnya, dan optimizer digunakan untuk menyesuaikan parameter model berdasarkan loss tersebut. Matriks kinerja seperti training loss dan akurasi dipantau sepanjang proses pelatihan untuk menilai kemajuan pembelajaran model.

Dataset validasi digunakan untuk memantau kinerja model pada data yang belum pernah dilihat, membantu memastikan model tidak mengalami overfitting pada data pelatihan. Ini melibatkan evaluasi loss dan akurasi model pada set validasi setelah setiap epoch pelatihan. Jika model menunjukkan peningkatan kinerja pada set validasi, parameternya dapat disimpan untuk mempertahankan versi model yang berkinerja terbaik. Proses ini memastikan bahwa model terlatih dengan baik dan dapat digeneralisasi dengan baik ke data baru. Sebelum dimulainya proses *training*, penulis mengatur *hyperparameter*

yang dapat dilihat pada Tabel 2 yang nantinya akan diterapkan pada saat proses *training* dimulai. Sehingga, proses *training* dapat dijalankan dengan kondisi yang diinginkan selama proses penelitian.

Tabel 2. Hyperparameter Training

Hyperparameter	Value
Learning Rate	0.001
Batch Size	32
Optimizer	Adam
Loss Function	Categorical Cross Entropy
Epoch	25
Input Image Size	224x224
Number of Classes	4

D. Model Testing and Result Visualization

Tahap pengujian model *ResNet* menilai kinerjanya pada *dataset* pengujian terpisah dengan data yang belum pernah dilihat sebelumnya, mengevaluasi sejauh mana model ini mampu melakukan generalisasi dan mengklasifikasikan berbagai posisi tidur. Metrik yang dihasilkan dalam pengujian suatu model akan dibandingkan dengan metrik yang dihasilkan oleh model lain. Sehingga, model yang memiliki performa klasifikasi pose tidur yang paling efektif pada dataset dan mesin komputasi yang sudah dibuat akan terlihat. Pengujian semua varian ResNet pada mesin satu komputasi juga akan dilakukan untuk menemukan model mana yang paling efektif dalam menggunakan sumber daya komputasi. Pengujian sumber daya komputasi akan dilakukan dengan membandingkan penggunaan *CPU*, *GPU RAM*, *memory RAM*, dan kecepatan proses klasifikasi.


Hasilnya divisualisasikan dengan tabel untuk memperjelas detail pasti hasil penelitian dan grafik dan diagram, yang menggambarkan kinerja model dalam membedakan berbagai posisi tidur agar mudah dibaca dalam bentuk visual. Tantangan selama pengujian, seperti perbedaan variasi dataset, perbedaan proporsi dataset campuran pada dataset A1A2A3B1B2 dan potensi perbaikan untuk iterasi model di masa depan diidentifikasi untuk memandu pengembangan berkelanjutan.

3. HASIL DAN PEMBAHASAN

A. Performa *Training*

A.1 Performa *training* dataset A1A2A3.

Loss pada validasi juga mencapai kurang dari 3% pada awal *epoch* dan hampir mencapai 0% pada akhir *epoch* yang dapat dilihat pada Gambar 5. Akurasi *training* pada model-model yang dilatih dengan dataset A1A2A3 yang dapat dilihat pada Gambar 6 mencapai lebih dari 97% pada awal *epoch* dan berangsur-angsur naik hingga mendekati 100%. Sedangkan loss berawal dari sekitar 10% pada semua model dan berangsur-angsur turun hingga mendekati 0%. Validasi model-model tersebut juga mencapai akurasi *training* sebesar 99% pada awal *epoch* dan mencapai akurasi yang mendekati 100% pada akhir epoch. Akan tetapi, model *ResNet152* mengalami penurunan akurasi dan kenaikan loss dengan lonjakan tinggi pada epoch ke-7 dengan akurasi 98,6% dan loss sebesar 7%.




Gambar 5. Grafik performa *loss* pada *training* model dengan dataset A1A2A3




Gambar 6. Grafik performa akurasi pada *training* model dengan dataset A1A2A3.

A.2 Performa *training* dataset B1B2.

Gambar 8 menunjukkan bahwa *learning rate* pada percobaan *training* model dengan dataset B1B2 memperoleh hasil akurasi dan *loss* yang cukup baik seperti pada Gambar 7. Sebaliknya, *training* dan *loss* pada validasi menunjukkan hasil yang tidak konsisten. Akan tetapi akurasi yang diperoleh masih ada pada angka yang cukup tinggi, yaitu lebih dari 98% akurasi dan *loss* kurang dari 7% pada akhir *epoch*. Ini menunjukkan bahwa proses *training* memperoleh hasil yang cukup baik karena memiliki *loss* yang sedikit dan akurasi yang tinggi pada akhir *epoch* atau pengulangan.



Gambar 7. Grafik performa *loss* pada *training* model dengan dataset B1B2.




Gambar 8. Grafik performa akurasi pada *training* model dengan dataset B1B2.


A.4 Performa *training* dataset gabungan A1B1B2.

Akurasi dan *loss* pada *training* model dengan dataset A1B1B2 menunjukkan *learning rate* yang cukup bagus dapat dilihat pada Gambar 9 dan Gambar 10. Sedangkan

akurasi dan *loss* pada validasi menunjukkan learning rate yang tidak konsisten pada sekitar *epoch* ke-2 hingga ke-10. Dataset tipe A untuk training ini adalah dataset A1 yang berjumlah 2544 dan dataset tipe B berjumlah 3577.




Gambar 9. Grafik performa *loss* pada *training* model dengan dataset A1B1B2.




Gambar 10. Grafik performa akurasi pada *training* model dengan dataset A1B1B2.

A.5 Performa *training* dataset gabungan A1A2A3B1B2.

Dataset ini memiliki proporsi dataset tipe A yaitu A1A2A3 dengan jumlah 7822 dan dataset tipe B yaitu B1B2 yang berjumlah 3577. Dataset A1A2A3B1B2 yang digunakan untuk proses training kali ini tidak memiliki jumlah yang proporsional dengan jumlah dataset tipe A lebih banyak jika dibandingkan data tipe B. Performa training pada model ini yang dapat dilihat pada Gambar 11 dan Gambar 12 menunjukkan hasil yang cukup stabil. Sedangkan learning rate dan loss ketika validasi menunjukkan ketidakstabilan, akan tetapi masih menunjukkan hasil akhir yang cukup baik karena hampir mencapai loss sebesar 0% dan akurasi yang juga hampir mencapai 100%.




Gambar 11. Grafik performa *loss* pada *training* model dengan dataset A1A2A3B1B2.




Gambar 12. Grafik performa akurasi pada *training* model dengan dataset A1A2A3B1B2.

A.6 Performa *training* dataset gabungan A1A2A3B1B2 proporsional.

Dataset ini memiliki proporsi dataset tipe A dengan jumlah 4089 dan dataset tipe B yang berjumlah 3577. Proporsi jumlah dataset tipe A dan tipe B yang dipakai pada proses *training* kali ini sudah disesuaikan untuk diuji performanya dalam melakukan klasifikasi gambar pose tidur dengan dataset tipe A dan tipe B. Model yang sudah dilatih dengan dataset yang proporsional pada umumnya akan dapat mengenali semua pola pada macam-macam tipe dataset yang sudah dilatih pada model tersebut. Performa training pada model ini yang dapat dilihat pada Gambar 13 dan Gambar 14 menunjukkan hasil yang cukup stabil. Sedangkan learning rate dan loss ketika validasi menunjukkan ketidakstabilan, akan tetapi masih menunjukkan hasil akhir yang cukup baik. Model ini selanjutnya akan dilakukan proses *testing* menggunakan dataset tipe A dan tipe B untuk menguji apakah proporsi dataset dapat mempengaruhi performa klasifikasi.



Gambar 13. Grafik performa *loss* model dengan dataset A1A2A3B1B2 proporsional.




Gambar 14. Grafik performa akurasi model dengan dataset A1A2A3B1B2 proporsional.

B. Performa *Testing*

1. Model yang di-*training* dengan dataset A1A2A3 di-*testing* dengan dataset A1A2A3

Tabel 3. Metrik Performa Model A1A2A3_A1A2A3

	<i>ResNet18</i>	<i>ResNet34</i>	<i>ResNet50</i>	<i>ResNet101</i>	<i>ResNet152</i>
Accuracy	0.999	0.999	0.998	0.988	0.997
Precision	0.999	0.999	0.998	0.988	0.997
Recall	0.999	0.999	0.998	0.988	0.997
F1 Score	0.999	0.999	0.998	0.988	0.997




Gambar 15. Performa *testing* model A1A2A3 pada dataset A1A2A3

Hasil *testing* yang dapat dilihat pada Tabel 3, menunjukkan bahwa jika model dilakukan *training* menggunakan dataset A1A2A3 dan dilakukan *testing* menggunakan dataset yang sama, maka akan menghasilkan performa yang baik. Performa *testing* pada dataset ini menunjukkan bahwa performa *ResNet101* dan *ResNet152* lebih rendah dari model-model yang lain walaupun tidak begitu signifikan. Gambar 15 adalah visualisasi dari Tabel 3, yang menunjukkan bahwa tidak ada perbedaan performa klasifikasi yang signifikan antara varian *ResNet* yang satu dengan yang lainnya.

2. Model yang di-*training* dengan dataset A1A2A3 di-*testing* dengan dataset B1B2

Tabel 4. Metrik Performa Model A1A2A3_B1B2

	<i>ResNet18</i>	<i>ResNet34</i>	<i>ResNet50</i>	<i>ResNet101</i>	<i>ResNet152</i>
<i>Accuracy</i>	0.331	0.343	0.343	0.253	0.151
<i>Precision</i>	0.110	0.234	0.260	0.217	0.297
<i>Recall</i>	0.331	0.343	0.343	0.253	0.151
<i>F1 Score</i>	0.165	0.256	0.280	0.170	0.196




Gambar 16. Performa *testing* model A1A2A3 pada dataset B1B2

Tabel 4 menunjukkan hasil *testing* pada dataset B1B2 menggunakan model yang ditrain dengan dataset A1A2A3 menunjukkan penurunan performa secara drastis dengan akurasi 11% hingga 34% saja. Hal ini disebabkan oleh perbedaan yang sangat besar di antara dataset A1A2A3 dengan dataset B1B2 dari segi tempat tidur, tata ruangan, pencahayaan, dan perbedaan warna pada banyak objek. Visualisasi yang dapat dilihat pada Gambar 16, menunjukkan bahwa model ResNet unggul dari varian model yang lain dengan mendapatkan akurasi, presisi, *recall*, dan *F1 Score* tertinggi.

3. Model yang di-training dengan dataset A1A2A3B1B2 di-testing dengan dataset A1A2A3

Tabel 5. Metrik Performa Model A1A2A3B1B2_A1A2A3

	<i>ResNet18</i>	<i>ResNet34</i>	<i>ResNet50</i>	<i>ResNet101</i>	<i>ResNet152</i>
<i>Accuracy</i>	1	0.995	0.995	0.999	0.999
<i>Precision</i>	1	0.995	0.995	0.999	0.999
<i>Recall</i>	1	0.995	0.995	0.999	0.999
<i>F1 Score</i>	1	0.995	0.995	0.999	0.999



Gambar 17. Performa *testing* model A1A2A3B1B2 pada dataset A1A2A3


Tabel 5 menunjukkan penggabungan dataset A1A2A3 dan B1B2 untuk training bertujuan untuk memperkaya variasi pada dataset, sehingga model dapat mengklasifikasi dataset A1A2A3 dan B1B2 secara akurat. Pengujian testing model A1A2A3B1B2 pada dataset A1A2A3 menghasilkan performa yang cukup bagus dan tidak ada perbedaan performa pada tiap model. Gambar 17 menunjukkan bahwa tidak ada perbedaan yang signifikan pada performa klasifikasi semua model.

4. Model yang di-training dengan dataset A1A2A3B1B2 di-testing dengan dataset B1B2.

Tabel 6. Metrik Performa Model A1A2A3B1B2_B1B2

	<i>ResNet18</i>	<i>ResNet34</i>	<i>ResNet50</i>	<i>ResNet101</i>	<i>ResNet152</i>
<i>Accuracy</i>	0.332	0.331	0.330	0.335	0.337

Precision	0.170	0.157	0.182	0.199	0.194
Recall	0.332	0.331	0.330	0.335	0.337
F1 Score	0.224	0.212	0.235	0.248	0.245




Gambar 18. Performa *testing* model A1A2A3B1B2 pada dataset B1B2

Model A1A2A3B1B2 pada Tabel 6 menunjukkan performa yang sangat rendah pada pengujian menggunakan dataset B1B2. Pengujian ini menunjukkan bahwa model A1A2A3B1B2 yang memiliki variasi dataset B1B2 tidak mengalami peningkatan performa pada *testing* menggunakan dataset B1B2. Hal ini disebabkan oleh jumlah proporsi dari dataset A dan dataset B pada dataset A1A2A3B1B2 tidak seimbang. Jumlah gambar pada dataset A di sini memiliki jumlah 7822 dan dataset B berjumlah 3577. Perbedaan jumlah dataset gambar pada dataset A dan B menyebabkan model yang dilatih tidak dapat mengenali salah satu tipe gambar yang memiliki porsi sedikit, yaitu dataset tipe B karena model gagal untuk melakukan generalisasi pola gambar pada dataset yang memiliki proporsi sedikit. Sehingga, pada penelitian ini akan dilakukan pengujian pada dataset tipe B menggunakan model yang sudah dilatih dengan dataset A1A2A3B1B2 dengan proporsi yang seimbang untuk mengetahui jawaban dari permasalahan proporsi. Pada gambar 18 juga terlihat bahwa hasil pengujian menghasilkan akurasi performa klasifikasi pose tidur yang tidak terlalu berbeda antara satu varian model dengan model yang lain.

5. Model yang di-*training* dengan dataset A1A2A3B1B2 di-*testing* dengan dataset A1A2A3B1B2.

Tabel 7. Metrik Performa Model A1A2A3B1B2_A1A2A3B1B2

	ResNet18	ResNet34	ResNet50	ResNet101	ResNet152
Accuracy	0.899	0.879	0.913	0.924	0.919
Precision	0.922	0.908	0.929	0.937	0.934
Recall	0.899	0.879	0.913	0.924	0.919
F1 Score	0.901	0.882	0.914	0.925	0.920




Gambar 19. Performa *testing* model A1A2A3B1B2 pada dataset A1A2A3B1B2

Pengujian model A1A2A3B1B2 menggunakan dataset A1A2A3B1B2 juga mencapai performa yang tidak maksimal dengan akurasi, presisi, recall dan F1 score di sekitar 80% seperti pada Tabel 14. Penyebab kurangnya performa pada pengujian ini adalah walaupun model A1A2A3B1B2 berhasil melakukan klasifikasi dataset A1A2A3, tetapi model ini tidak berhasil mengklasifikasi dataset B1B2 dengan akurat. Sedangkan pada Gambar 19 terlihat bahwa hasil performa klasifikasi pada semua matriks tidak memiliki perbedaan yang signifikan antara varian-varian model yang diuji.

6. Model yang di-*training* dengan dataset A1B1B2 di-*testing* dengan dataset B1B2

Tabel 8. Metrik Performa Model A1B1B2_B1B2

	<i>ResNet18</i>	<i>ResNet34</i>	<i>ResNet50</i>	<i>ResNet101</i>	<i>ResNet152</i>
<i>Accuracy</i>	0.548	0.510	0.563	0.525	0.586
<i>Precision</i>	0.785	0.773	0.579	0.708	0.637
<i>Recall</i>	0.548	0.510	0.563	0.525	0.586
<i>F1 Score</i>	0.533	0.512	0.565	0.520	0.590




Gambar 20. Performa *testing* model A1B1B2 pada dataset B1B2

Pengujian yang ditampilkan pada Tabel 8 menggunakan model yang di-*training* menggunakan dataset A1 dan B1B2, lalu di-*testing* menggunakan dataset B1B2. Performa yang dihasilkan menunjukkan peningkatan pada testing menggunakan dataset B1B2 hingga mencapai akurasi 51% sampai 78%. Pada Gambar 20 juga terlihat bahwa performa akurasi, *recall* dan *F1 score* varian model ResNet50 dan ResNet152 adalah yang terbaik, tetapi kedua varian itu memiliki presisi yang terburuk pada presisi.

7. Model yang di-*training* dengan dataset B1B2 di-*testing* dengan dataset B1B2

Tabel 9. Metrik Performa Model B1B2_B1B2

	<i>ResNet18</i>	<i>ResNet34</i>	<i>ResNet50</i>	<i>ResNet101</i>	<i>ResNet152</i>
<i>Accuracy</i>	0.969	0.977	0.979	0.97	0.97
<i>Precision</i>	0.969	0.977	0.979	0.97	0.97
<i>Recall</i>	0.969	0.977	0.979	0.97	0.97
<i>F1 Score</i>	0.969	0.977	0.979	0.97	0.97



Gambar 21. Performa *testing* model B1B2 pada dataset B1B2


Hasil pengujian B1B2 yang menghasilkan performa yang baik hingga mencapai hampir 100% pada akurasi, presisi, *recall* dan *F1 Score*. Jika dilihat pada Gambar 21, maka memang tidak ada performa akurasi, presisi, *recall* dan *F1 score* yang memiliki perbedaan yang signifikan antara varian model ResNet yang diuji. Tetapi jika dilihat pada Tabel 9, maka diketahui bahwa ResNet50 memiliki performa klasifikasi tertinggi pada semua metrik dengan skor 97,9%.

8. Model yang di-*training* dengan dataset B1B2 di-*testing* dengan dataset A1A2A3

Tabel 10. Metrik Performa Model B1B2_A1A2A3

	<i>ResNet18</i>	<i>ResNet34</i>	<i>ResNet50</i>	<i>ResNet101</i>	<i>ResNet152</i>
<i>Accuracy</i>	0.177	0.296	0.277	0.328	0.146
<i>Precision</i>	0.163	0.088	0.206	0.245	0.152

<i>Recall</i>	0.177	0.296	0.277	0.328	0.146
<i>F1 Score</i>	0.121	0.136	0.232	0.268	0.127




Gambar 22. Performa *testing* model B1B2 pada dataset A1A2A3

Hasil pengujian pada model B1B2 yang di-*testing* menggunakan dataset A1A2A3 pada Tabel 10 menghasilkan performa yang sangat rendah dengan angka 10% hingga sekitar 30% pada metrik akurasi, presisi, *recall* dan *F1 score*. Jika dilihat pada Gambar 22, terlihat jelas bahwa varian ResNet101 memiliki performa klasifikasi terbaik pada pengujian ini.

9. Model yang di-*training* dengan dataset A1A2A3B1B2 proporsional di-*testing* dengan dataset B1B2

Tabel 11. Metrik Performa Model A1A2A3B1B2_proporsional_B1B2


	<i>ResNet18</i>	<i>ResNet34</i>	<i>ResNet50</i>	<i>ResNet101</i>	<i>ResNet152</i>
<i>Accuracy</i>	0.9778	0.9875	0.9764	0.9847	0.9764
<i>Precision</i>	0.9778	0.9875	0.9766	0.9847	0.9764
<i>Recall</i>	0.9778	0.9875	0.9764	0.9847	0.9764
<i>F1 Score</i>	0.9778	0.9875	0.9764	0.9847	0.9764



Gambar 23. Performa *testing* model A1A2A3B1B2 proporsional pada dataset B1B2

Hasil pengujian terakhir pada Tabel 11, dapat dilihat bahwa model A1A2A3B1B2 yang sudah di-*training* menggunakan dataset yang proporsional di-*testing* menggunakan dataset B1B2 menghasilkan performa yang jauh meningkat hingga sekitar 97% untuk model *ResNet18*, *ResNet50*, *ResNet152* dan sekitar 98% untuk model *ResNet34* dan *ResNet101* pada metrik akurasi, presisi, *recall* dan *F1 score*. Hal ini membuktikan bahwa dataset yang proporsional dapat meningkatkan akurasi pengenalan gambar pada semua varian gambar yang sudah dikenali. Namun jika dilihat pada Gambar 23, semua varian tidak menunjukkan performa kalsifikasi yang signifikan.

C. Resource Utilization



Gambar 24. Penggunaan sumber daya komputasi model A1A2A3B1B2 proporsional pada dataset A1A2A3 pada mesin dengan mesin *GPU T4* di *Google Colab*.

Pemanfaatan sumber daya, yang ditunjukkan pada Gambar 24, menyoroti penggunaan *GPU* dan memori selama pengujian, serta waktu yang dibutuhkan untuk setiap model. Model *ResNet18* memiliki kebutuhan sumber daya komputasi *GPU* paling rendah dan *ResNet152* memiliki kebutuhan sumber daya *GPU* tertinggi. Pengujian dilakukan menggunakan semua model yang dilakukan *testing* pada semua dataset yang tersedia dan semua pengujian menghasilkan performa dengan urutan kecepatan sama seperti pada bagian *Time Used (s) Comparison* pada Gambar 24. Hasil dari pengujian memberikan hasil bahwa *ResNet18* memiliki kebutuhan sumber daya komputasi paling kecil dan kecepatan tertinggi pada performa pengujian klasifikasi.

D. Hasil Penelitian

Pengujian yang telah dilakukan menghasilkan beberapa poin penting yang mencakup semua aspek pembahasan. Sehingga penelitian ini menunjukkan bahwa pemilihan model dan proporsi dataset memiliki pengaruh signifikan terhadap akurasi dan efisiensi klasifikasi. Berikut adalah hasil-hasil utama dari penelitian ini:

1. Akurasi Klasifikasi Berdasarkan Dataset:

- Dataset Testing dengan Banyak Persamaan dengan Dataset Training: Hasil klasifikasi pada dataset testing yang memiliki banyak persamaan dengan dataset training menunjukkan akurasi yang tinggi.

- b. Dataset dengan Kemiripan Rendah: Pengujian menggunakan dataset dengan kemiripan rendah terhadap dataset training menghasilkan akurasi yang rendah, berkisar antara 10%-30%.
 - c. Dataset Campuran Tidak Proporsional:
 - d. Proporsi Training dan Testing yang Besar: Akurasi mendekati 100%.
 - e. Proporsi Training dan Testing yang Kecil: Akurasi hanya sekitar 33%.
 - f. Variasi Proporsional: Peningkatan performa dengan variasi proporsional dapat mencapai akurasi antara 97%-100%.
2. Perbandingan Performa Klasifikasi Antar Model:
 - a. Keseragaman Performa: Performa klasifikasi antara satu varian model ResNet dengan varian lainnya tidak menunjukkan perbedaan yang signifikan.
 3. Penggunaan Sumber Daya Komputasi:
 - a. Memory & GPU RAM: Urutan penggunaan memori dan GPU RAM dari yang paling hemat hingga yang paling boros adalah: ResNet18 < ResNet34 < ResNet50 < ResNet101 < ResNet152.
 - b. Kecepatan: Urutan kecepatan dari yang tercepat hingga yang terlambat adalah: ResNet18 > ResNet34 > ResNet50 > ResNet101 > ResNet152.
 4. Pemilihan Varian Model ResNet Berdasarkan Sumber Daya Komputasi: ResNet18

4. PENUTUP

Pengujian memperlihatkan hasil klasifikasi model *resnet* terhadap dataset pose tidur dengan baik hanya pada dataset dengan tingkat kemiripan tinggi hampir mendekati 100% pada dataset yang dipakai untuk *training*. Performa pada penggunaan sumber daya komputasi juga memperlihatkan penggunaan *Memory RAM* dan *GPU RAM* *ResNet18*, diikuti secara berurutan oleh *ResNet34*, *ResNet50*, *ResNet101*, dan *ResNet152* yang menandakan semakin besar layer pada arsitektur model, maka semakin banyak sumber daya komputasi yang dibutuhkan dalam pengujian model. Sedangkan model yang memiliki kecepatan klasifikasi terbaik adalah *ResNet18*, diikuti secara berurutan oleh *ResNet34*, *ResNet50*, *ResNet101*, dan *ResNet152*.

Model yang di-*training* dan diuji menggunakan dataset dengan tingkat kemiripan rendah, menghasilkan akurasi klasifikasi yang rendah sekitar 10% sampai dengan 30%. Pengujian pada model dengan dataset campuran memperlihatkan hasil yang baik pada pengujian dengan dataset yang memiliki proporsi dataset *training* dan dataset *testing* mirip lebih besar seperti pada pengujian *testing* model A1A2A3B1B2 pada dataset testing A1A2A3 mencapai akurasi mendekati 100%, sedangkan pengujian *testing* model A1A2A3B1B2 pada dataset testing B1B2 hanya mencapai akurasi sebesar 33%. Hal ini menunjukkan indikasi bahwa dataset yang tidak proporsional, dalam hal ini adalah dataset A1A2A3 berjumlah jauh lebih banyak dibanding jumlah dataset B1B2, maka pengujian klasifikasi pada dataset B1B2 akan menunjukkan performa yang kurang efektif. Akan tetapi, ketika model dilakukan *training* dengan variasi dataset yang proporsional, maka akan menunjukkan adanya peningkatan akurasi pada testing. Pengujian B.9 yang menguji model yang sudah di-*train* dengan dataset dengan jumlah variasi yang proporsional, menunjukkan hasil pengujian yang sangat baik pada dataset B1B2 yang mencapai akurasi klasifikasi sebesar 97% hingga 98%.

Penelitian ini menghasilkan kesimpulan bahwa dampak pemilihan varian model *ResNet*

terhadap performa klasifikasi tidak menunjukkan perbedaan yang terlalu signifikan. Sehingga pemilihan model dapat dilakukan dengan pertimbangan performa komputasi. Dalam hal ini *ResNet18* unggul dalam penggunaan *GPU RAM* dan unggul dalam kecepatan klasifikasi. Maka dengan mementingkan penggunaan sumber daya komputasi terbaik, maka penggunaan model *ResNet18* adalah pilihan yang tepat. Selebihnya, kurangnya kualitas, variasi, kuantitas dan proporsi dari dataset juga sangat mempengaruhi performa klasifikasi menggunakan dataset baru yang berbeda dengan dataset *training* karena model gagal untuk melakukan generalisasi pada pose tidur

DAFTAR PUSTAKA

- Althnian, A., AlSaeed, D., Al-Baity, H., Samha, A., Dris, A. B., Alzakari, N., Abou Elwafa, A., & Kurdi, H. (2021). Impact of Dataset Size on Classification Performance: An Empirical Evaluation in the Medical Domain. *Applied Sciences*, 11(2), Article 2. <https://doi.org/10.3390/app11020796>
- Fisranda, F., Austin, F., & Sadrawi, M. (2023). Comparison Analysis of YOLO, ResNet, and EfficientNet for contagious skin diseases. *2023 5th International Conference on Cybernetics and Intelligent System (ICORIS)*, 1–5. <https://doi.org/10.1109/ICORIS60118.2023.10352306>
- Gao, L., Zhang, X., Yang, T., Wang, B., & Li, J. (2023). The Application of ResNet-34 Model Integrating Transfer Learning in the Recognition and Classification of Overseas Chinese Frescoes. *Electronics*, 12(17), Article 17. <https://doi.org/10.3390/electronics12173677>
- Hasanah, S. A., Pravitasari, A. A., Abdullah, A. S., Yulita, I. N., & Asnawi, M. H. (2023). A Deep Learning Review of ResNet Architecture for Lung Disease Identification in CXR Image. *Applied Sciences*, 13(24), Article 24. <https://doi.org/10.3390/app132413111>
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). *Deep Residual Learning for Image Recognition* (arXiv:1512.03385). arXiv. <https://doi.org/10.48550/arXiv.1512.03385>
- Li, Y.-Y., Wang, S.-J., & Hung, Y.-P. (2022). A Vision-Based System for In-Sleep Upper-Body and Head Pose Classification. *Sensors*, 22(5), Article 5. <https://doi.org/10.3390/s22052014>
- Liu, S., Huang, X., Marcenaro, L., & Ostadabbas, S. (2022). Privacy-Preserving in-Bed Human Pose Estimation: Highlights from the IEEE Video and Image Processing Cup 2021 Student Competition [SP Competitions]. *IEEE Signal Processing Magazine*, 39(3), 121–129. *IEEE Signal Processing Magazine*. <https://doi.org/10.1109/MSP.2021.3139587>
- Mandal, B., Okeukwu, A., & Theis, Y. (2021). *Masked Face Recognition using ResNet-50* (arXiv:2104.08997). arXiv. <https://doi.org/10.48550/arXiv.2104.08997>
- Mohammadi, S. M., Enshaeifar, S., Hilton, A., Dijk, D.-J., & Wells, K. (2021). Transfer Learning for Clinical Sleep Pose Detection Using a Single 2D IR Camera. *IEEE Transactions on Neural Systems and Rehabilitation Engineering: A Publication of the IEEE Engineering in Medicine and Biology Society*, 29, 290–299. <https://doi.org/10.1109/TNSRE.2020.3048121>
- Nurfita, R. D., & Ariyanto, G. (2018). *Implementasi Deep Learning Berbasis Tensorflow Untuk Pengenalan Sidik Jari* [S1, Universitas Muhammadiyah Surakarta]. <https://eprints.ums.ac.id/63025/>
- Odusami, M., Maskeliūnas, R., Damaševičius, R., & Krilavičius, T. (2021). Analysis of Features of

- Alzheimer's Disease: Detection of Early Stage from Functional Brain Changes in Magnetic Resonance Images Using a Finetuned ResNet18 Network. *Diagnostics*, 11(6), Article 6. <https://doi.org/10.3390/diagnostics11061071>
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A. C., & Fei-Fei, L. (2015). *ImageNet Large Scale Visual Recognition Challenge* (arXiv:1409.0575). arXiv. <https://doi.org/10.48550/arXiv.1409.0575>
- Santoso, A., & Ariyanto, G. (2018). *Implementasi Deep Learning Berbasis Keras Untuk Pengenalan Wajah* [S1, Universitas Muhammadiyah Surakarta]. <https://eprints.ums.ac.id/62956/>
- Tan, M., & Le, Q. V. (2021). *EfficientNetV2: Smaller Models and Faster Training* (arXiv:2104.00298). arXiv. <https://doi.org/10.48550/arXiv.2104.00298>
- Zhang, Q. (2021). A novel ResNet101 model based on dense dilated convolution for image classification. *SN Applied Sciences*, 4(1), 9. <https://doi.org/10.1007/s42452-021-04897-7>