

Analisis Existing Convolutional Neural Network Untuk Klasifikasi Usia Pengunjung Rumah Sakit: Studi Kasus Pemantauan Anak dan Dewasa

Herlina Harahap¹, Sayuti Rahman^{2*}, Muhammad Zen³, Suriati⁴

^{1,4} Prodi Teknik Informatika Universitas Harapan Medan, Medan, Indonesia

² Prodi Teknik Informatika Universitas Pembangunan Panca Budi, Medan, Indonesia

³Sains dan Teknologi, Sistem Komputer, Universitas Pembangunan Panca Budi, Medan, Indonesia

¹ herlina_hrp@yahoo.com, ²sayutirahman@staff.uma.ac.id, ³muhammadzen@dosen.pancabudi.ac.id,

⁴suriati_19@yahoo.com

^{*)} sayutirahman@staff.uma.ac.id

Abstrak-Penelitian ini bertujuan untuk menganalisis model Convolutional Neural Network (CNN) guna mengklasifikasikan kelompok usia anak dan dewasa pada pengunjung rumah sakit. Rumah sakit berfungsi sebagai fasilitas pengobatan untuk berbagai penyakit yang diakibatkan oleh virus, bakteri, luka kecelakaan, dan sejenisnya. Anak-anak dilarang mengunjungi rumah sakit karena hambatan dalam hal kenyamanan pasien serta risiko terkait imunitas dan trauma pada anak-anak. Oleh karena itu, diperlukan pendekatan digital untuk memantau kehadiran anak-anak di lingkungan rumah sakit. Dalam penelitian ini, digunakan konsep visi komputer dan Convolutional Neural Network (CNN) untuk mencapai tujuan tersebut. Dataset yang digunakan adalah All-Age-Faces (AAF), yang terdiri dari gambar wajah manusia dalam rentang usia 2 hingga 80 tahun. Dua arsitektur CNN, yaitu ResNet dan SqueezeNet diterapkan menggunakan metode fine-tuning (FT) dan full retraining (FR) untuk mengklasifikasikan pengunjung menjadi anak atau dewasa. Penelitian menghasilkan akurasi FR-ResNet yaitu 97,22% mengungguli akurasi penelitian sebelumnya FT-SqueezeNet dengan akurasi sebesar 93,09%, unggul 4,13%. Penelitian ini menegaskan bahwa penerapan CNN, terutama melalui pendekatan FR-ResNet, berhasil dalam mengklasifikasikan usia pengunjung rumah sakit secara akurat. Hal ini dapat membantu mencegah risiko penularan penyakit pada anak-anak dengan mengontrol akses mereka ke area rumah sakit.

Kata Kunci: Klasifikasi Citra, CNN, Klasifikasi Pengunjung, Rumah Sakit, Pembatasan Pengunjung

Abstract-The purpose of this study is to examine the Convolutional Neural Network (CNN) model for classifying the age groups of hospital visits, both children and adults. Hospitals serve as treatment facilities for a variety of ailments caused by viruses, germs, car accidents, and other factors. Children are not permitted to visit the hospital due to hurdles to patient comfort as well as hazards associated with immunity and trauma to children. As a result, a digital strategy is required to monitor the presence of youngsters in the hospital setting. The notion of computer vision and the Convolutional Neural Network (CNN) are employed in this study to attain this goal. The dataset utilized is All-Age-Faces (AAF), which includes photos of human faces ranging in age from 2 to 80 years. To categorize visitors into children or adults, two CNN architectures, ResNet and SqueezeNet, are used with fine-tuning (FT) and full retraining (FR) approaches. The accuracy of FR-ResNet was 97.22%, beating the accuracy of the previous research FT-SqueezeNet, which was 93.09%, better to 4.13%. This study confirmed that the use of CNN, namely the FR-ResNet technique, was effective in accurately categorizing the age of hospital visits. Controlling children's access to hospital areas can help reduce the danger of illness transmission.

Keywords: Image Classification, CNN, Visitor Classification, Hospitals, Visitor Restrictions

1. PENDAHULUAN

Rumah sakit berperan sebagai lokasi dimana pasien-pasien dengan berbagai jenis penyakit yang diakibatkan oleh virus, bakteri, trauma fisik, dan berbagai sebab lainnya mendapatkan perawatan. Virus dan bakteri yang bersifat patogen menginfeksi tubuh manusia dan menjadi penyebab utama terjadinya penyakit. Virus dapat menghasilkan gejala seperti demam [1], flu [2], kerusakan fungsi organ tubuh, perkembangan kanker [3], bahkan hingga fatalitas. Begitu pula dengan virus, bakteri juga memiliki potensi untuk menyebabkan gangguan kesehatan pada tubuh manusia. Namun, perbedaannya terletak pada fakta bahwa virus hanya dapat bertahan hidup jika berada dalam inangnya, sementara bakteri mampu hidup dalam berbagai lingkungan yang berbeda.

Mengunjungi rumah sakit tidaklah tepat untuk dilakukan oleh anak-anak. Terdapat dua alasan mendasar yang menjelaskan mengapa sebaiknya anak-anak tidak melakukan kunjungan ke lingkungan rumah sakit, baik dari perspektif pasien maupun anak itu sendiri. Dari sudut pandang pasien, situasi di rumah sakit mengharuskan pasien merasakan ketenangan dan ketentraman selama mereka menjalani perawatan dan pemulihan. Gangguan yang dapat timbul dari kegaduhan yang sering kali dibawa oleh anak-anak akan menciptakan suasana yang tidak kondusif dan dapat meningkatkan tingkat stres yang dirasakan oleh pasien. Dari perspektif anak, ada dua faktor penting yang perlu diperhatikan, yakni aspek kekebalan tubuh dan potensi trauma psikologis. Anak-anak memiliki sistem kekebalan tubuh yang masih belum sepenuhnya terbentuk, membuat mereka rentan terhadap

penularan virus dan bakteri. Ketidakstabilan imunitas ini dapat memiliki dampak yang merugikan terhadap perkembangan dan pertumbuhan anak [4]. Di lingkungan rumah sakit, tidak hanya terdapat mikroorganisme penyebab penyakit seperti virus dan bakteri, tetapi juga terdapat pasien dengan luka-luka serius akibat kecelakaan. Anak-anak yang tanpa sengaja melihat luka-luka yang parah ini bisa mengalami trauma psikologis yang berdampak buruk pada perkembangan emosional dan mental mereka [5]. Oleh karena itu, langkah bijak adalah menghindari anak-anak dari kunjungan ke rumah sakit demi menjaga kesehatan, kenyamanan pasien, dan kesejahteraan anak-anak itu sendiri..

Masyarakat Indonesia dikenal karena sifat ramah dan kesadaran sosial yang tinggi, yang tercermin dalam kunjungan mereka ke rumah sakit untuk menjenguk keluarga yang sedang dirawat. Meskipun positif, praktik membawa anak-anak, bahkan bayi, ke dalam ruang pasien membawa risiko besar terhadap perkembangan anak-anak tersebut, meskipun petugas keamanan hadir. Oleh karena itu, solusi inovatif seperti penggunaan kamera cerdas untuk pemantauan digital muncul sebagai alternatif yang berpotensi mengatasi masalah ini dengan mendeteksi keberadaan anak-anak di lingkungan rumah sakit.

Visi komputer merupakan teknologi di mana sebuah kamera memiliki kemampuan untuk memahami konten visual yang diamatinya [6]. Saat ini, visi komputer telah diimplementasikan dalam berbagai bidang yang mengharuskan pemantauan visual. Salah satu metode yang menjadi pionir dalam visi komputer adalah Deep Learning, yang mencakup konsep convolutional neural network (CNN). Para peneliti telah menghasilkan berbagai arsitektur CNN untuk melakukan klasifikasi objek dengan akurasi tinggi, yang dikenal sebagai existing CNN. Beberapa contoh existing CNN yang telah memperoleh pengakuan dan pengembangan luas termasuk Alexnet [7], VGGNet [8], GoogleNet [9], Resnet [10], MobileNetV2 [10], SqueezeNet [11], dan ShuffleNet [12], semuanya mampu menjalankan tugas klasifikasi objek dengan berhasil. Keberhasilan existing CNN ini telah terutama ditunjukkan dalam konteks klasifikasi 1.000 objek pada dataset Imagenet, mengharuskan penggunaan komputasi yang intensif dan penyimpanan yang luas. Existing CNN yang telah di-training dan memiliki bobot latihan yang tersimpan disebut sebagai pre-trained CNN. Namun, dalam situasi di mana jumlah kelas yang diperlukan lebih sedikit, peneliti seringkali memanfaatkan CNN melalui pendekatan seperti transfer learning [13], fine-tuning [14]–[16], atau pruning [17], baik terhadap existing CNN maupun dengan merancang arsitektur CNN yang baru.

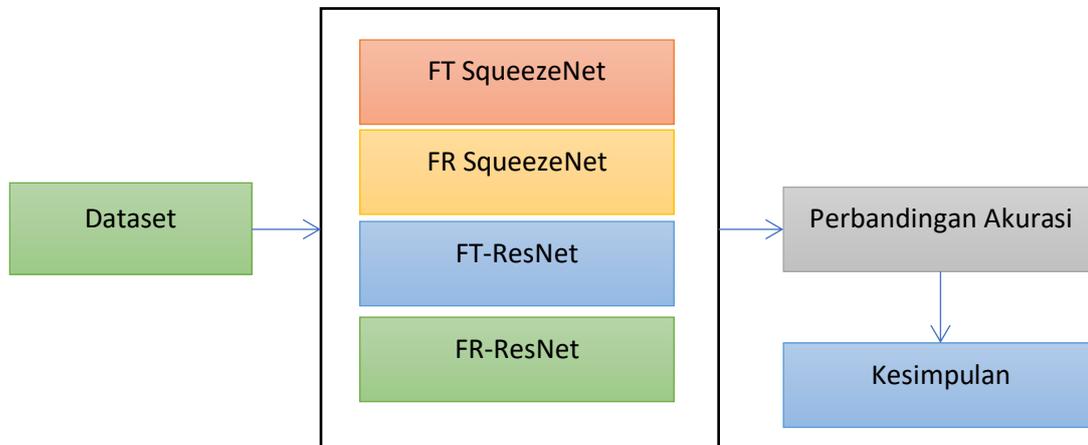
Beberapa arsitektur CNN yang dirancang secara khusus untuk melakukan klasifikasi usia manusia termasuk Al-Resnet [18], ROR-152 [19], dan AL-ROR-34 [20]. Ketiga arsitektur tersebut diuji dengan menggunakan dataset IMDB-WIKI-101, menghasilkan tingkat akurasi masing-masing sebesar 67,83%, 67,34%, dan 66,82%. OlatunbosunNet [21] berhasil mengklasifikasikan usia manusia pada dataset OIU-Adience dengan akurasi mencapai 83,1% untuk mengklasifikasikan seluruh rentang usia mulai dari 2 hingga 80 tahun. Dalam konteks pengunjung rumah sakit, mereka dapat dikelompokkan menjadi dua kategori utama, yaitu anak-anak dan dewasa. Melalui penerapan metode fine-tuning pada arsitektur SqueezeNet, berhasil tercapai tingkat akurasi sebesar 93,09% dalam mengklasifikasikan pengunjung ke dalam kategori tersebut [22]. Namun, penting untuk meningkatkan tingkat akurasi lebih lanjut guna menghasilkan sistem klasifikasi pengunjung yang lebih akurat. Tujuan utama dari penelitian ini adalah mengaplikasikan konsep CNN dalam klasifikasi usia, terutama dalam membedakan antara anak-anak dan dewasa dengan akurasi yang lebih tinggi. Penelitian ini memanfaatkan beberapa jenis existing CNN melalui fine-tuning dan full retraining, lalu dilakukan perbandingan kinerjanya. Diharapkan bahwa berbagai existing CNN yang diujikan dapat memberikan tingkat akurasi yang tinggi. Dengan akurasi yang handal, diharapkan CNN yang dipilih akan dapat memberikan dukungan bagi petugas keamanan dalam mencegah anak-anak masuk ke area rumah sakit. Tindakan ini bertujuan untuk mengurangi risiko penularan virus dan bakteri kepada anak-anak secara lebih efektif.

2. METODE PENELITIAN

Penelitian ini dimulai dengan tujuan awal untuk mengembangkan sebuah model atau arsitektur convolutional neural network (CNN) yang dapat diaplikasikan untuk mengklasifikasikan pengunjung rumah sakit berdasarkan kelompok usia mereka, yakni anak-anak dan dewasa. Dalam upaya ini, pendekatan yang diambil adalah dengan memanfaatkan existing CNN yang telah ada sebelumnya sebagai fondasi untuk sistem klasifikasi ini. Dua jenis existing CNN yang digunakan dalam penelitian ini adalah ResNet dan SqueezeNet, yang telah terbukti efektif dalam berbagai tugas klasifikasi visual.

Adaptasi dari existing CNN tersebut dilakukan dengan mengubah lapisan terakhir yang bertanggung jawab atas klasifikasi pada masing-masing model. Hal ini dilakukan untuk memastikan bahwa model-model ini sesuai dengan jumlah kelompok usia yang hendak diklasifikasikan, yaitu anak-anak dan dewasa. Proses pelatihan kemudian dilakukan dalam dua tahap yang berbedayaitu Fine-Tuning (FT) dan Full Retraining (FR). Tahap-tahap dari penelitian ini disajikan secara visual dalam Gambar 1, yang membantu memvisualisasikan alur kerja dan

pendekatan yang diambil dalam pengembangan model klasifikasi usia anak dan dewasa berbasis CNN. Dengan demikian, penelitian ini membuka jalan untuk mengembangkan sistem klasifikasi yang lebih presisi dalam membedakan antara pengunjung anak-anak dan dewasa di lingkungan rumah sakit.



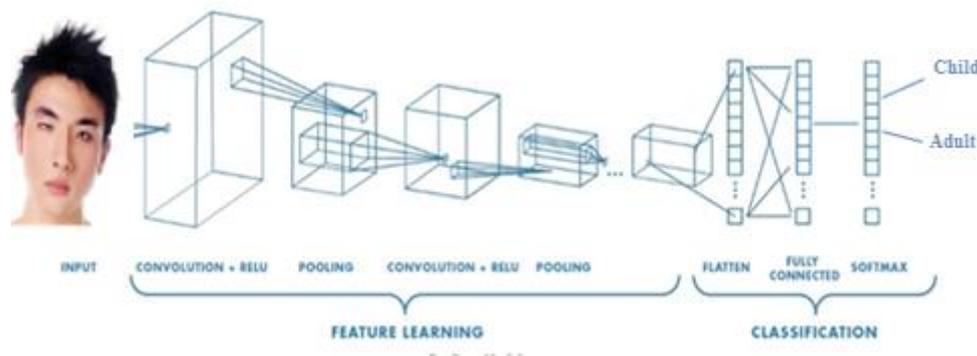
Gambar 1. Tahapan Penelitian

2.1 Convolutional Neural Network

Convolutional Neural Networks (CNN), yang juga dikenal sebagai Convolutional Networks (ConvNets), tengah menjadi pilihan utama dalam dunia arsitektur jaringan saraf tiruan. Dalam kaitannya dengan pengolahan citra digital, CNN merupakan varian dari Deep Neural Networks (DNN) [23] yang telah terbukti sangat efektif dalam tugas klasifikasi. Arsitektur CNN dapat diuraikan menjadi dua komponen utama, yaitu Feature Learning dan Classification [24].

Bagian pertama, Feature Learning, mencakup serangkaian lapisan yang bekerja sama untuk mengidentifikasi fitur-fitur penting dalam citra. Lapisan-lapisan ini meliputi lapisan konvolusi yang menerapkan operasi konvolusi dengan filter pada citra, diikuti oleh fungsi aktivasi yang memperkenalkan non-linearitas. Proses ini membantu jaringan belajar memahami pola-pola yang kompleks dalam citra. Setelah itu, lapisan pooling digunakan untuk mengurangi dimensi spasial dari fitur-fitur yang dihasilkan, menghasilkan representasi yang lebih efisien. Pengaturan lapisan-lapisan ini dapat disesuaikan sesuai dengan kebutuhan dan kompleksitas arsitektur yang diinginkan.

Komponen kedua, Classification, bertanggung jawab atas pengambilan keputusan berdasarkan fitur-fitur yang telah ditemukan oleh lapisan sebelumnya. Bagian ini melibatkan lapisan Flatten yang mengubah matriks fitur menjadi vektor, yang kemudian dihubungkan ke lapisan Fully Connected (FC). Lapisan FC memainkan peran kunci dalam mengklasifikasikan citra, dengan modifikasi bobot dan bias agar sesuai dengan data yang ada. Fungsi aktivasi juga diterapkan di lapisan ini untuk menambahkan aspek non-linear ke dalam proses klasifikasi. Keseluruhan, pemilihan parameter dan konfigurasi dalam struktur CNN sangat mempengaruhi performa jaringan yang dihasilkan. Gambar 2 mengilustrasikan contoh sederhana dari arsitektur Convolutional Neural Network, menyoroti tahapan-tahapan yang telah dijelaskan sebelumnya.

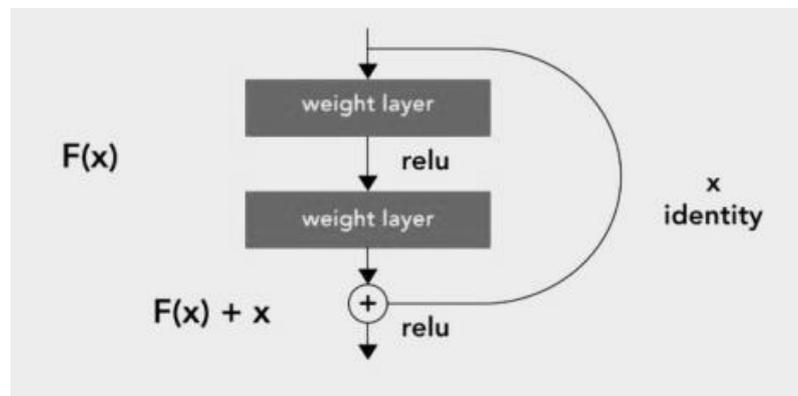


Gambar 2. Arsitektur CNN [6]

2.2 Resnet

Resnet (Residual Network) merupakan sebuah jaringan pembelajaran mendalam yang diperkenalkan pada tahun 2015 melalui makalah berjudul "Deep Residual Learning for Image Recognition" yang ditulis oleh Kaiming He dan rekan-rekannya [25]. Resnet berhasil meningkatkan performa akurasi jaringan sebelumnya, dan prestasinya terlihat dalam kemenangan pertama dalam kompetisi ILSVRC dan COCO 2015 dalam berbagai aspek seperti deteksi data ImageNet, lokalisasi data ImageNet, deteksi data Coco, dan segmentasi data Coco. Selain itu, penambahan lapisan Resnet-101 pada model Faster R-CNN dengan dasar VGG-16 menghasilkan peningkatan signifikan dalam akurasi, dengan peningkatan mencapai 28%.

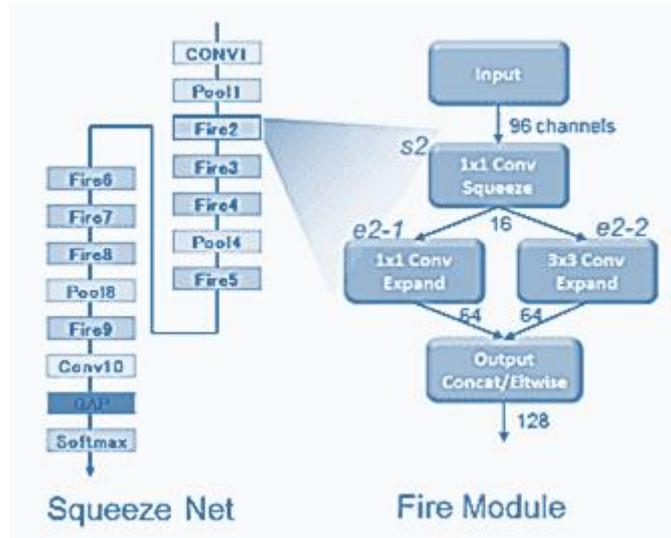
Resnet memperkenalkan konsep arsitektur yang lebih dalam dengan menambahkan blok-blok Resnet tambahan pada struktur deep neural network. Penambahan ini dilakukan untuk memberikan kemampuan jaringan dalam mempelajari fitur-fitur yang lebih kompleks. Kedalaman lapisan dalam CNN disesuaikan dengan jumlah data yang digunakan dalam pelatihan. Dalam situasi di mana data pelatihan terbatas, penggunaan lapisan yang sangat dalam bisa mengakibatkan overfitting yang pada akhirnya menghasilkan kesalahan yang lebih besar. Resnet, melalui penggunaan Residual Blocks [26]–[28], berhasil mengatasi tantangan yang muncul akibat kompleksitas arsitektur yang berlebihan. Blok-blok residual ini memiliki peran yang krusial dalam konsep Resnet. *Residual block* pada jaringan *residual learning* ditampilkan pada Gambar 3 Berikut.



Gambar 3. *Residual Blok* [25]

2.5 SqueezeNet

Arsitektur SqueezeNet diciptakan dengan fokus pada implementasi pada perangkat-perangkat tertanam seperti mobil. Dibandingkan dengan arsitektur AlexNet yang dikenal besar dan kompleks, SqueezeNet menghadirkan pendekatan yang jauh lebih ringkas dengan ukuran yang bahkan lebih kecil hingga 50 kali lipat. Dalam pengembangannya, SqueezeNet mempertimbangkan batasan perangkat keras yang mungkin memiliki keterbatasan dalam hal kapasitas memori dan daya komputasi yang terbatas [11]. Untuk mencapai hal ini, SqueezeNet mengusulkan beberapa pendekatan penting, termasuk strategi yang bertujuan untuk mengurangi jumlah parameter yang diperlukan oleh arsitektur serta pengenalan modul fire yang menjadi elemen kunci dalam struktur arsitektur ini. Modul fire dirancang khusus untuk mengoptimalkan keseimbangan antara pengurangan parameter dan mempertahankan kualitas fitur yang relevan dalam proses ekstraksi fitur. Modul fire pada SqueezeNet diilustrasikan pada Gambar 4.



Gambar 4. Modul Fire pada AqueezeNet

2.3 Full Retraining dan Fine Tuning

Melatih ulang seluruh bobot pada CNN yang ada disebut full retraining. Ini melibatkan pelatihan ulang seluruh jaringan pada kumpulan data baru, termasuk lapisan convolutional dan lapisan klasifikasi. Fine tuning melibatkan pelatihan ulang hanya lapisan klasifikasi pada CNN yang ada. Lapisan convolutional tetap tidak berubah. Fine-tuning dapat menjadi pilihan yang baik ketika memiliki data pelatihan yang terbatas. Dengan menyesuaikan lapisan klasifikasi, kinerja model pada tugas baru dapat ditingkatkan tanpa perlu melatih ulang seluruh jaringan. Berikut adalah tabel yang merangkum perbedaan utama antara full retraining dan fine tuning, Seperti terlihat pada Tabel 1.

Tabel 1. Perbedaan Full Training dan Fine Tuning

Full Retraining	Fine Tuning
Melatih ulang seluruh jaringan	Hanya melatih ulang lapisan klasifikasi
Baik untuk data pelatihan yang terbatas	Baik untuk data pelatihan yang lebih banyak
Dapat membutuhkan waktu yang lama	Lebih cepat daripada melatih ulang dari awal
Dapat membuat model terlalu spesifik untuk kumpulan data pelatihan	Dapat membuat model lebih umum

3. HASIL DAN PEMBAHASAN

Klasifikasi usia untuk pengunjung rumah sakit perlu dikembangkan. Anak usia 12 tahun kebawah dilarang memasuki rumah sakit dikarenakan beberapa hal yang telah dijabarkan pada latar belakang sebelumnya. Penelitian ini memanfaatkan CNN untuk klasifikasi usia anak dan dewasa. Dataset yang digunakan untuk pengujian adalah All-Age- Faces (AAF). *Existing* CNN yang digunakan adalah ResNet dan SqueezeNet dengan melakukan full retraining dan fine tuning.

3.1 Dataset

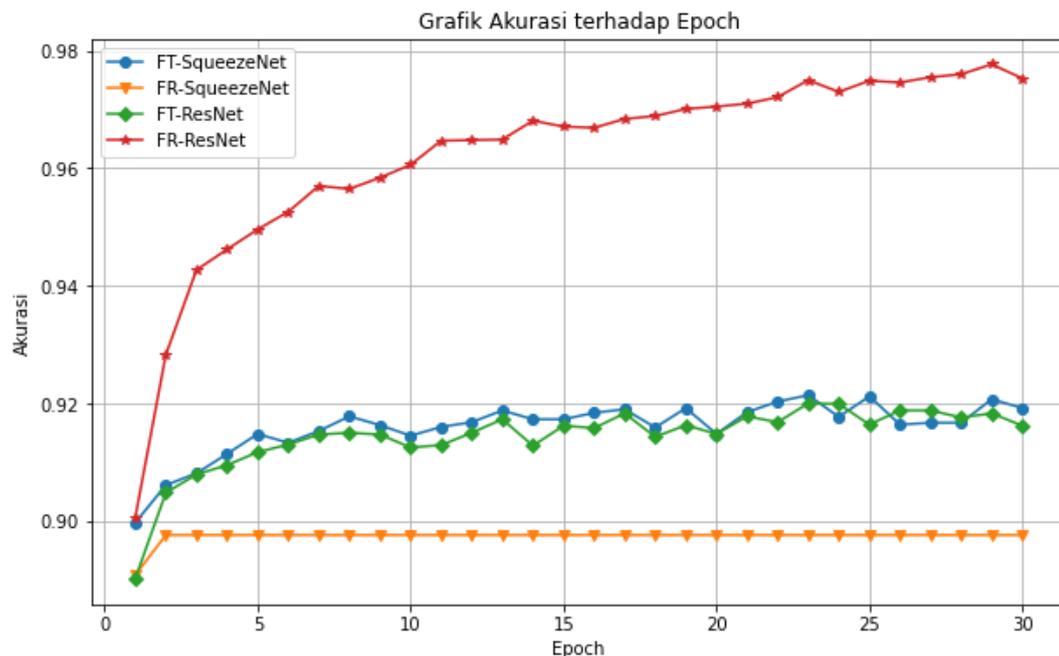
AAF merupakan dataset yang terdiri dari 13.322 wajah orang-orang asia yang berusia antara 2 sampai 80 tahun. Dataset ini terdiri dari 7.381 wajah pria dan 5.941 wajah wanita [29]. Dataset AAF dibagi kedalam dua kelas yaitu anak dan dewasa. Kelas anak merupakan kumpulan data antara 1 sampai 12 tahun dan kelas dewasa berada 13 sampai 80 tahun. Dalam pengujian CNN, kami membagi 90% data sebagai data latih dan 10% sebagai data validasi. Contoh dataset AAF disajikan pada Gambar 5.



Gambar 5. Contoh Dataset All-Age-Faces (AAF)

3.2 Perbandingan Akurasi Pelatihan CNN

Dataset All Age Faces (AAF) sebagai data latih dan data validasi yang dibagi kedalam dua kelas. Bahasa pemrograman yang digunakan adalah Python dan framework pytorch. Kami membagi dataset 90% untuk data latih dan 10% untuk data validasi, ini berlaku untuk seluruh pengujian CNN. Jumlah epoch yang digunakan adalah 30. Pengujian dilakukan untuk mencari hasil akurasi yang lebih baik dari *existing* CNN yang diuji dengan full retraining dan fine tuning. Hasil akurasi pelatihan existing CNN ditampilkan pada Gambar 6.



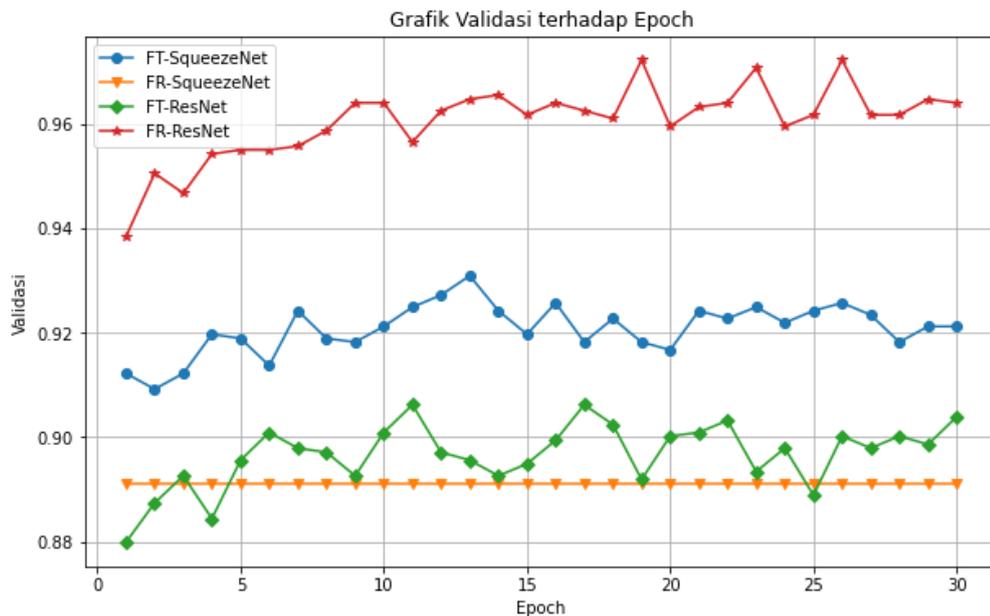
Gambar 6. Hasil Pelatihan Existing CNN

Dapat dilihat pada Gambar 6, Pelatihan dataset AAF dengan SqueezeNet dan ResNet dengan teknik Fine Tuning (FT) dan Full Retraining (FR). Hasil menunjukkan bahwa FR-ResNet memiliki akurasi pelatihan yang lebih baik dari pada percobaan lainnya. Akurasi pelatihan terbaik dari masing-masing pengujian yaitu FR-ResNet memiliki akurasi 97,77%, FT-SqueezeNet sebesar 92,14%, FT-Resnet sebesar 92,00% dan FR-SqueezeNet sebesar 89,76%.

3.3 Perbandingan Akurasi Validasi CNN

Akurasi Validasi merupakan salah satu alat ukur performa CNN, semakin baik akurasi validasi maka semakin baik arsitektur. Dataset untuk validasi digunakan sebagai data yang mewakili keadaan nyata, sehingga

CNN dengan akurasi validasi tertinggi yang digunakan untuk klasifikasi objek pada saat implementasi. Hasil perbandingan akurasi validasi existing CNN untuk klasifikasi pengunjung rumah sakit berdasarkan usia ditampilkan pada Gambar 7.



Gambar 7. Akurasi Validasi Existing CNN

Gambar 6 menunjukkan akurasi *existing* CNN pada tiap *epoch*. FR-Resnet memiliki akurasi yang tertinggi sejak epoch pertama hingga akhir, diikuti FT-SqueezeNet. FT-Resnet memiliki akurasi yang lebih rendah dan FR-SqueezeNet memiliki akurasi terendah. Akurasi validasi tertinggi dalam 30 epoch ditampilkan pada Tabel 2 Berikut.

Tabel 2. Perbandingan Akurasi Validasi CNN

Metode	Akurasi Validasi
FT-SqueezeNet [22]	93,09%
FR-SqueezeNet	89,11%
FT-ResNet	90,62%
FR-ResNet	97,22%

Tabel 2 menyajikan perbandingan akurasi validasi dari berbagai metode arsitektur Convolutional Neural Network (CNN) yang diterapkan pada dataset yang sama. Dalam 30 epoch pelatihan, hasil akurasi validasi tertinggi tercatat pada metode FR-ResNet dengan angka 97,22%. Metode ini menunjukkan kinerja yang sangat baik dalam memberikan prediksi yang akurat pada data validasi. Sementara itu, FT-SqueezeNet dan FT-ResNet menunjukkan hasil yang kompetitif dengan akurasi masing-masing sebesar 93,09% dan 90,62%. Di sisi lain, metode FR-SqueezeNet mencapai akurasi validasi terendah dengan angka 89,11%. Hasil ini menggambarkan perbedaan dalam kemampuan prediksi dan kinerja antara berbagai arsitektur CNN yang dievaluasi dalam eksperimen ini.

4. KESIMPULAN

Penelitian ini bertujuan meningkatkan akurasi Convolutional Neural Network (CNN) dalam mengklasifikasikan kelompok usia anak dan dewasa pada pengunjung rumah sakit. Dalam konteks ini, rumah sakit dianggap sebagai tempat di mana pasien dirawat dan virus serta bakteri berpotensi menyebabkan penyakit. Dalam penelitian ini, dua arsitektur CNN yang diterapkan adalah ResNet dan SqueezeNet dengan Full Retraining (FT) dan Fine Tuning

(FT). Hasil dan pembahasan penelitian mengungkapkan bahwa dalam mengklasifikasikan usia pengunjung rumah sakit, metode FR-ResNet memiliki akurasi pelatihan tertinggi sebesar 97,77%, diikuti oleh FT-SqueezeNet dengan akurasi 92,14%. Dalam hal akurasi validasi, FR-ResNet juga mendominasi dengan akurasi validasi tertinggi 97,22%, sementara FT-SqueezeNet mencapai akurasi validasi sebesar 93,09% [22]. Di sisi lain, metode FR-SqueezeNet memiliki akurasi validasi terendah sebesar 89,11%. Capaian dari penelitian ini adalah bahwa penerapan Convolutional Neural Network (CNN), terutama pada metode FR-ResNet, dapat berhasil dalam mengklasifikasikan usia pengunjung rumah sakit, khususnya dalam memisahkan anak-anak dan dewasa. FR-ResNet mengungguli akurasi pada penelitian sebelumnya yaitu FT-SqueezeNet sebesar 4,13%, peningkatan akurasi ini menunjukkan potensi untuk mengembangkan sistem klasifikasi yang dapat membantu menjaga kebersihan dan ketenangan lingkungan rumah sakit serta mencegah risiko penularan penyakit pada anak-anak.

REFERENCES

- [1] A. S. Fauci and D. M. Morens, "Zika virus in the Americas—yet another arbovirus threat," *New England journal of medicine*, vol. 374, no. 7, pp. 601–604, 2016.
- [2] N. Jones, "How COVID-19 is changing the cold and flu season," *Nature*, vol. 588, no. 7838, pp. 388–390, 2020.
- [3] A. Morales-Sánchez and E. M. Fuentes-Pananá, "Human viruses and cancer," *Viruses*, vol. 6, no. 10, pp. 4047–4079, 2014.
- [4] A. Suryawan and A. Endaryanto, "Perkembangan Otak dan Kognitif Anak: Peran Penting Sistem Imun pada Usia Dini," *Sari Pediatri*, vol. 23, no. 4, pp. 279–284, 2021.
- [5] D. Widiastuti and R. Sekartini, "Deteksi dini, faktor risiko, dan dampak perlakuan salah pada anak," *Sari Pediatri*, vol. 7, no. 2, pp. 105–112, 2016.
- [6] S. Rahman, M. Ramli, F. Arnia, R. Muharar, M. Zen, and M. Ikhwan, *Convolutional Neural Networks Untuk Visi Komputer Jaringan Saraf Konvolusional untuk Visi Komputer (Arsitektur Baru, Transfer Learning, Fine Tuning, dan Pruning)*. Deepublish, 2021.
- [7] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," in *Advances in neural information processing systems*, 2012, pp. 1097–1105.
- [8] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv preprint arXiv:1409.1556*, 2014.
- [9] C. Szegedy *et al.*, "Going deeper with convolutions," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 1–9.
- [10] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "Mobilenetv2: Inverted residuals and linear bottlenecks," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 4510–4520.
- [11] F. N. Iandola, S. Han, M. W. Moskewicz, K. Ashraf, W. J. Dally, and K. Keutzer, "SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size," *arXiv preprint arXiv:1602.07360*, 2016.
- [12] N. Ma, X. Zhang, H.-T. Zheng, and J. Sun, "Shufflenet v2: Practical guidelines for efficient cnn architecture design," in *Proceedings of the European conference on computer vision (ECCV)*, 2018, pp. 116–131.
- [13] M. Hussain, J. J. Bird, and D. R. Faria, "A study on cnn transfer learning for image classification," in *UK Workshop on Computational Intelligence*, 2018, pp. 191–202.
- [14] R. Roslidar, K. Saddami, F. Arnia, M. Syukri, and K. Munadi, "A study of fine-tuning CNN models based on thermal imaging for breast cancer classification," in *2019 IEEE International Conference on Cybernetics and Computational Intelligence (CyberneticsCom)*, 2019, pp. 77–81.
- [15] S. Rahman, M. Ramli, F. Arnia, A. Sembiring, and R. Muharar, "Convolutional Neural Network Customization for Parking Occupancy Detection," in *2020 International Conference on Electrical Engineering and Informatics (ICELTICs)*, Oct. 2020, pp. 1–6, doi: 10.1109/ICELTICs50595.2020.9315509.
- [16] S. Rahman, M. Ramli, F. Arnia, R. Muharar, and A. Sembiring, "Performance Analysis of mAlexnet by Training Option and Activation Function Tuning on parking images," *accepted for publication on Journal Of Physics Conference Series*. IOP Publishing, 2020.
- [17] H. Li, A. Kadav, I. Durdanovic, H. Samet, and H. P. Graf, "Pruning filters for efficient convnets," *arXiv preprint arXiv:1608.08710*, 2016.
- [18] K. Zhang, N. Liu, X. Yuan, X. Guo, C. Gao, and Z. Zhao, "Fine-grained age group classification in the wild," in *2018 24th International Conference on Pattern Recognition (ICPR)*, 2018, pp. 788–793.

-
- [19] K. Zhang *et al.*, “Fine-grained age estimation in the wild with attention LSTM networks,” *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 30, no. 9, pp. 3140–3152, 2019.
- [20] K. Zhang *et al.*, “Age group and gender estimation in the wild with deep RoR architecture,” *IEEE Access*, vol. 5, pp. 22492–22503, 2017.
- [21] O. Agbo-Ajala and S. Viriri, “Deeply learned classifiers for age and gender predictions of unfiltered faces,” *The Scientific World Journal*, vol. 2020, 2020.
- [22] A. Sembiring, S. Rahman, D. Siregar, M. Zen, and S. Suriati, “Analisis Perbandingan Akurasi Pre-Trained Convolutional Neural Network Untuk Klasifikasi Kelompok Usia Pengunjung Rumah Sakit,” *Journal of Information System Research (JOSH)*, vol. 4, no. 2, pp. 515–521, 2023.
- [23] L. Mohammadpour, T. C. Ling, C. S. Liew, and C. Y. Chong, “A convolutional neural network for network intrusion detection system,” *Proceedings of the Asia-Pacific Advanced Network*, vol. 46, no. 0, pp. 50–55, 2018.
- [24] S. Rahman and H. Dafitri, “Aplikasi Simulasi Deteksi Lokasi Parkir Kosong Menggunakan Ekstraksi Ciri Objek,” *InfoTekJar: Jurnal Nasional Informatika dan Teknologi Jaringan*, vol. 4, no. 1, pp. 99–104, 2019.
- [25] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770–778.
- [26] S. Xie, R. Girshick, P. Dollár, Z. Tu, and K. He, “Aggregated residual transformations for deep neural networks,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 1492–1500.
- [27] K. He, X. Zhang, S. Ren, and J. Sun, “Identity mappings in deep residual networks,” in *European conference on computer vision*, 2016, pp. 630–645.
- [28] A. Veit, M. J. Wilber, and S. Belongie, “Residual networks behave like ensembles of relatively shallow networks,” *Advances in neural information processing systems*, vol. 29, pp. 550–558, 2016.
- [29] J. Cheng, Y. Li, J. Wang, L. Yu, and S. Wang, “Exploiting effective facial patches for robust gender recognition,” *Tsinghua Science and Technology*, vol. 24, no. 3, pp. 333–345, 2019.