



Analisis Perbandingan Akurasi Pre-Trained Convolutional Neural Network Untuk Klasifikasi Kelompok Usia Pengunjung Rumah Sakit

Arnes Sembiring¹, Sayuti Rahman^{1,*}, Dodi Siregar¹, Muhammad Zen², Suriati¹

¹Prodi Teknik Informatika, Universitas Harapan Medan, Medan

Jl. HM. Joni No.70 C, Teladan Bar., Kec. Medan Kota, Kota Medan, Sumatera Utara, Indonesia

²Sains dan Teknologi, Sistem Komputer, Universitas Pembangunan Panca Budi, Medan

Jl. Gatot Subroto, Simpang Tj., Kec. Medan Sunggal, Kota Medan, Sumatera Utara, Indonesia

Email: ¹arnessembiring@gmail.com, ^{2,*}masay.ram@gmail.com, ³dodi.729ar@gmail.com,

⁴muhammadzen@dosen.pancabudi.ac.id, ⁵suriati_19@yahoo.com

Email Penulis Korespondensi: masay.ram@gmail.com

Submitted: 12/01/2023; Accepted: 26/01/2023; Published: 29/01/2023

Abstrak—Rumah sakit tidak boleh dikunjungi oleh anak-anak. Ada dua alasan mengapa anak-anak tidak seharusnya berkunjung ke rumah sakit yaitu dari sisi pasien dan sisi anak itu sendiri. Pada sisi pasien, pasien membutuhkan ketenangan selama menjalani pengobatan dan pemulihan. Kebisingan yang ditimbulkan anak-anak menjadikan suasana tidak kondusif dan meningkatkan tingkat stres pasien. Pada sisi anak, terdapat dua faktor yaitu imunitas dan trauma. Anak memiliki imunitas yang belum lengkap sehingga mudah tertular oleh virus dan bakteri. Gangguan imunitas anak akan memberi dampak negatif atas tumbuh kembang anak. Selain virus dan bakteri, dirumah sakit juga terdapat pasien yang luka besar seperti akibat kecelakaan. Anak yang memandang luka besar tersebut dapat timbul trauma pada dirinya dan mengganggu tumbuh kembang anak tersebut. Klasifikasi usia pengunjung merupakan pendukung pengelolahan rumah sakit untuk membatasi pengunjung berdasarkan usia. Pengunjung dikategorikan sebagai anak adalah pengunjung dengan usia 12 tahun atau lebih kecil. Metode yang digunakan untuk klasifikasi kelompok usia adalah pre-trained CNN antara lain Alexnet, VGGNet, GoogleNet, ResNet dan AqueezeNet. Kami melakukan penelitian awal dengan memanfaatkan dataset All-Age-Faces (AAF) sebagai data uji yang mewakili usia pengunjung rumah sakit. Dataset dibagi kedalam dua kelas yaitu anak dan dewasa. Berdasarkan pengujian SqueezeNet merupakan metode yang lebih baik dalam akurasi pelatihan maupun validasi. Berdasarkan urutan akurasi validasi SqueezeNet berhasil mengenali kelompok usia dengan akurasi 93,09 %, VGGNet 92,72%, AlexNet 91,44%, GoogleNet 90,92% dan ResNet 90,62%. Penelitian ini diharapkan memeberikan kontribusi dalam membantu penertiban pengunjung bagi rumah sakit.

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

Abstract—Children are not allowed to visit the hospital. Children should not visit the hospital for two reasons, namely the patient's side and the child's side. On the patient's side, patients need peace of mind during treatment and recovery. The noise generated by children makes the atmosphere not conducive and increases the patient's stress level. On the child's side, there are two factors, namely immunity, and trauma. Children have incomplete immunity so they are easily infected by viruses and bacteria. A child's immune disorder will harm the child's development. Apart from viruses and bacteria, in hospitals, there are also patients with major injuries such as those resulting from accidents. Children who see these large wounds can traumatize themselves and interfere with the child's growth and development. The age classification of visitors supports for hospital management to limit visitors based on age. Visitors categorized as children are visitors aged 12 years or younger. The method used for age group classification is the pre-trained CNN, including Alexnet, VGGNet, GoogleNet, ResNet, and AqueezeNet. We conducted a preliminary study using the All-Age-Faces (AAF) dataset as test data that represents the age of hospital visitors. The dataset is divided into two classes, namely children and adults. Based on the SqueezeNet test, it is a better method in terms of training accuracy and validation. Based on the order of accuracy validation, SqueezeNet succeeded in recognizing age groups with an accuracy of 93.09%, VGGNet 92.72%, AlexNet 91.44%, GoogleNet 90.92%, and ResNet 90.62%. This research is expected to contribute to helping control visitors to the hospital.

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

1. PENDAHULUAN

Rumah sakit merupakan tempat dirawatnya pasien dengan berbagai penyakit yang diakibatkan oleh virus, bakteri, luka kecelakaan dan lain sebagainya. Virus dan bakteri jahat menginfeksi dan menyebabkan manusia menjadi sakit. Virus dapat menyebabkan demam [1], flue [2], gangguan fungsi organ tubuh, kanker [3], dan bahkan hingga kematian. Sama halnya dengan virus, bakteri juga menyebabkan penyakit pada tubuh manusia. Perbedaannya, virus hanya bertahan hidup jika berada pada inangnya sedangkan bakteri dapat hidup dalam berbagai jenis lingkungan.

Rumah sakit tidak boleh dikunjungi oleh anak-anak. Ada dua alasan mengapa anak-anak tidak seharusnya berkunjung ke rumah sakit yaitu sisi pasien dan sisi anak itu sendiri. Pada sisi pasien, pasien membutuhkan ketenangan selama menjalani pengobatan dan pemulihan. Kebisingan yang ditimbulkan anak-anak menjadikan suasana tidak kondusif dan menaikkan tingkat stres pasien. Pada sisi anak, terdapat dua faktor yaitu imunitas dan trauma. Anak memiliki imunitas yang belum lengkap sehingga mudah tertular oleh virus dan bakteri. Gangguan imun anak akan memberi dampak negatif atas tumbuh kembang anak [4]. Selain virus dan bakteri, dirumah sakit

juga terdapat pasien yang luka besar seperti akibat kecelakaan. Anak yang memandang luka besar tersebut dapat timbul trauma pada dirinya dan mengganggu tumbuh kembang anak tersebut [5].

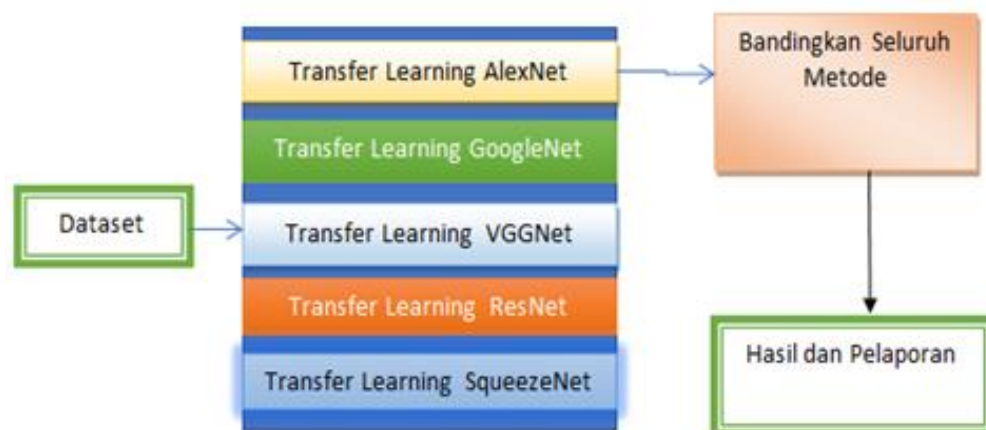
Masyarakat Indonesia dikenal dengan keramahan dan jiwa sosial yang tinggi. hal ini juga terlihat saat mereka yang sedang berkunjung menjenguk keluarga di rumah sakit. Banyak ibu yang membawa anak bahkan bayi masuk ke ruang pasien. Hal ini tentunya memiliki resiko yang sangat besar bagi perkembangan anak tersebut. walaupun ada petugas keamanan, tetap saja mereka kewalahan untuk mengatasi ini. Oleh karena itu perlu adanya pemantauan secara digital melalui sebuah kamera cerdas yang dapat mendeteksi keberadaan anak di rumah sakit.

Visi komputer adalah teknik dimana sebuah kamera dapat mengerti apa yang dilihatnya [6]. Saat ini, visi komputer telah digunakan diberbagai bidang yang membutuhkan pemantauan penglihatan. Deep Learning adalah metode yang paling populer dalam visi komputer, salah satunya adalah convolutional neural network (CNN). Para peneliti telah banyak membuat arsitektur CNN untuk berbagai klasifikasi objek dengan akurasi yang tinggi, yang disebut existing CNN. Existing CNN yang terkenal dan banyak dikembangkan antara lain seperti Alexnet [7], GoogleNet [8], VGGNet [9], Resnet [10], SqueezeNet [11], MobileNetV2 [12], dan ShuffleNet [13] berhasil mengklasifikasi objek dengan baik. Existing CNN ini dibuat untuk mengklasifikasi 1000 objek pada dataset Imagenet yang memerlukan komputasi dan ruang penyimpanan yang besar. Existing CNN yang sudah dilatih dan bobot latih telah disimpan disebut pre-trained CNN. Pada kasus kelas yang lebih sedikit, para peneliti mengeksplorasi CNN seperti transfer learning [14], fine-tuning [15]–[17] atau pruning [18] terhadap existing CNN atau bahkan membuat arsitektur CNN baru.

Arsitektur CNN khusus untuk klasifikasi kelompok usia manusia diantaranya AI-Resnet [19], ROR-152 [20], dan AL-ROR-34 [21]. Arsitektur tersebut diuji pada dataset IMDB-WIKI-101 menghasilkan akurasi 67,83%, 67,34% dan 66,82%. OlatunbosunNet [22] berhasil mengklasifikasi usia pada dataset OIU-Adience dengan akurasi 83,1%. Penelitian sebelumnya untuk mengklasifikasi seluruh usia dari 2 sampai 80 tahun. Penelitian ini kami mengelempokkan usia berdasarkan kebutuhan rumah sakit yaitu anak dan dewasa. Motivasi dari penelitian ini adalah bagaimana menerapkan CNN untuk klasifikasi usia, khususnya dapat membedakan anak dan dewasa. Penelitian ini menggunakan transfer learning beberapa existing CNN dan membandingkan kinerjanya. Kinerja dari beberapa existing CNN diharapkan memiliki akurasi yang tinggi. CNN yang akurat diharapkan mampu membantu petugas keamanan untuk menghentikan anak masuk area rumah sakit. Dengan demikian, resiko penularan virus dan bakteri terhindar dari anak.

2. METODOLOGI PENELITIAN

Penelitian ini bertujuan sebagai penelitian awal dalam mengembangkan model atau arsitektur CNN dalam mengklasifikasi kelompok usia anak dan dewasa. Penelitian ini memanfaatkan existing CNN untuk klasifikasi pengunjung rumah sakit. existing CNN yang digunakan adalah Alexnet, GoogleNet, VGGNet, ResNet, SqueezeNet. Kami hanya mengganti fully connected terakhir dari setiap Existing CNN untuk menyesuaikan jumlah kelas pengunjung, proses ini adalah transfer learning pre-trained CNN. Tahap penelitian seperti terlihat pada Gambar 1 berikut.




Gambar 1. Tahapan Penelitian

2.1 Convolutional Neural Network

Convolutional neural networks (CNN) yang sering disebut convolutional networks (ConvNets) merupakan arsitektur jaringan saraf tiruan yang sedang populer. CNN adalah multi-layer perceptron yang merupakan salah satu varian dari Deep neural networks yang sering digunakan sebagai metode untuk mengklasifikasi data citra digital. Arsitektur CNN memiliki dua bagian utama yaitu Feature Learning dan Classification. Feature learning terdiri dari lapisan konvolusi, fungsi aktivasi, dan Pooling. Lapisan ini sering disusun beberapa lapis sesuai kebutuhan arsitektur yang dibuat. Bagian klasifikasi terdiri dari Flatten, Fully Connected dan fungsi aktivasi.

Komposisi pemilihan parameter dalam menyusun CNN mempengaruhi kinerja jaringan CNN yang dibangun. Berikut arsitektur CNN sederhana Convolutional Neural Network ditampilkan pada Gambar 2.




Gambar 2. Arsitektur CNN [6]

2.2 Alexnet

Pada tahun 2012, Alexnet yang dikembangkan oleh Alex Krizhevsky dkk mampu mengenali objek [7] dengan signifikan dan mengungguli semua metode pada saat itu. Alexnet mampu mengurangi tingkat error hingga 15,3% menjadi 10,8% lebih baik dari runner up pada kontes image recognition. Arsitektur Alexnet saat ini telah banyak digunakan dan dikembangkan oleh peneliti lainnya. Alexnet telah menjadi referensi banyak penelitian lainnya dengan total rujukan lebih dari 71 ribu sitasi saat penulisan laporan disertasi ini.

Banyak aplikasi yang dibangun dengan Alexnet dengan memanfaatkan klasifikasi objek. Aplikasi ini digunakan dalam beragam bidang kedokteran seperti deteksi dini kanker payudara [23], ramuan pengobatan cina [24], gangguan irama jantung [25] dan lainnya. Aplikasi yang digunakan dalam pertanian seperti mengenali hama daun jagung [26], pengenalan penyakit jeruk [27], dan banyak bidang lainnya. Arsitektur Alexnet ditampilkan pada Gambar 3 berikut:



Gambar 3. Ilustrasi Arsitektur Alexnet [7]

2.3 VGGNet

VGGNet dibuat oleh peneliti dari Visual Geometry Group (VGG) Oxford university [9], VGGNet merupakan runner-up pertama pada ILSVRC tahun 2014 setelah googlenet. VGGNet berhasil mengungguli tingkat akurasi Alexnet dalam urusan klasifikasi secara signifikan, meskipun bukan pemenang saat itu. Pada tahun 2014 ini merupakan tahun pertama deep learning mampu mengklasifikasi dengan tingkat kesalahan dibawah 10%. Selain itu, hal yang paling penting adalah terdapat banyak Arsitektur lain yang dibangun dengan mengembangkan VGGNet atau berdasarkan ide konvolusi dengan filter 3×3 VGGNet untuk berbagai kasus lainnya. Pada saat ini artikel VGGNet yang berjudul “Very deep convolutional networks for large-scale image recognition” telah dikutip lebih dari 45 ribu kali.


Citra input dapat berukuran berapa saja, namun harus diskalakan kedalam ukuran tetap yaitu $224 \times 224 \times 3$. Citra latihan yang melebihi ukuran tersebut dilakukan poroses pemotongan (crop). Proses mengurangi nilai citra input dengan nilai rata-rata RGB merupakan satu-satunya proses tahap pengolahan data. Augmentasi digunakan untuk meningkatkan jumlah data latihan untuk memperoleh variasi gambar. Selain itu, kernel yang kecil yaitu 3×3 digunakan untuk mengurangi jumlah parameter latihan, misalkan sebuah filter 7×7 menghasilkan 49 parameter

diganti dengan tiga layer ukuran 3×3 sama dengan $3 \times 3 \times 3$ menjadi 27 parameter, sehingga (49-27)/49 proses ini mereduksi 48% jumlah parameter.

2.4 Resnet

Resnet (Residual Network) adalah jaringan pembelajaran mendalam yang dipublikasikan pada tahun 2015 dalam sebuah makalah mereka yang berjudul “Deep Residual Learning for Image Recognition” oleh Kaiming He dkk [10]. Resnet berhasil meningkatkan akurasi jaringan sebelumnya. Resnet juga berhasil meraih Juara pertama dalam lomba ILSVRC dan COCO 2015 bidang deteksi data ImageNet, lokalisasi data ImageNet, deteksi data Coco dan segmentasi data Coco. Selain itu, menambah lapisan VGG-16 di Faster R-CNN dengan Resnet-101 meningkatkan akurasi secara signifikan hingga 28%.

Resnet memiliki arsitektur yang lebih mendalam dengan menambah lapisan blok resnet tambahan pada deep neural network. Intuisi menambahkan lapisan agar dapat mempelajari fitur yang lebih kompleks. Kedalaman lapisan CNN disesuaikan dengan jumlah data yang dilatih. Lapisan yang sangat dalam untuk data yang sedikit dapat menyebabkan overfitting sehingga menimbulkan error yang lebih besar. Resnet dengan Residual Networks mampu mengatasi masalah yang ditimbulkan akibat arsitektur terlalu dalam. Residual Bloks [28]–[30] merupakan bagian penting dalam Resnet. Residual block pada jaringan residual learning ditampilkan pada Gambar 4 Berikut.



Gambar 4. Residual Blok [10]

2.5 GoogleNet

GoogleNet dikenal dengan Inception V1 dikenalkan oleh para peneliti dari perusahaan bekerjasama dengan beberapa universitas pada tahun 2014. GoogleNet dipublikasi dalam makalah penelitian berjudul "Going Deeper with Convolutions" [8] dan telah dikutip lebih dari 24 ribu kali. Arsitektur ini adalah pemenang pada tantangan kompetisi klasifikasi citra ILSVRC (ImageNet Large Scale Visual Recognition Competition) tahun 2014. GoogleNet berhasil menurunkan tingkat error secara signifikan dan mengungguli pemenang ILSVRC tahun 2012 yaitu Alexnet. Googlenet juga memiliki tingkat kesalahan yang jauh lebih kecil daripada VGG (runner up tahun 2014).

Arsitektur GoogleNet sangat berbeda dari arsitektur existing CNN sebelumnya seperti Alexnet dan ZF-Net. Karena tingkat akurasi yang tinggi, GoogleNet diterapkan untuk mengenali objek dalam citra telah banyak dipelajari dan diteliti [31]–[33]. GoogleNet pertama kalinya menggunakan lapisan konvolusi dengan filter 1×1 , selain itu global average pooling membuat arsitektur googlenet yang lebih dalam. Dalam arsitekturnya, ada beberapa metode populer menjadi cikal bakal penelitian berikutnya diantaranya adalah konvolusi 1×1 , Global Average Pooling, dan modul Inception.

2.6 SqueezeNet

SqueezeNet merupakan arsitektur yang didesain untuk perangkat tertanam seperti pada mobil. SqueezeNet merupakan arsitektur yang lebih kecil, bahkan 50 kali lebih kecil dibandingkan dengan Alexnet. Metode ini dibuat untuk hardware dengan memori dan komputasi terbatas [11]. Beberapa pertimbangan yang digunakan dalam membangun arsitektur SqueezeNet diantaranya adalah strategi menurunkan jumlah parameter dan membuat fire modul.

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 Alexnet, GoogleNet, VGGNet, ResNet dan SqueezeNet.

3.1 Dataset

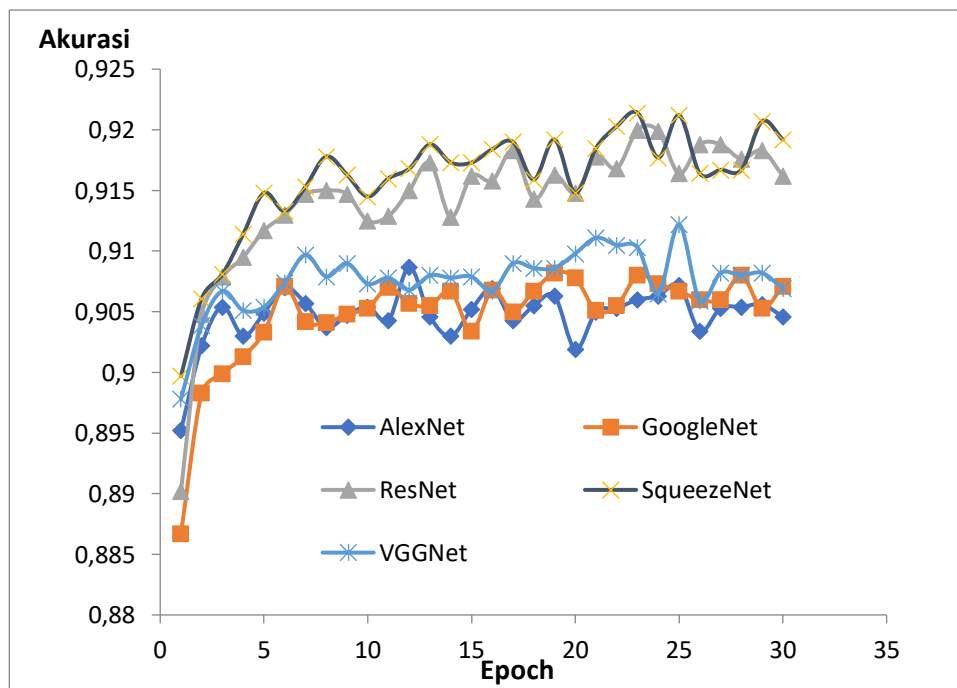
AAF merupakan dataset yang terdiri dari 13.322 wajah orang-orang asia yang berusia antara 2 sampai 80 tahun. Dataset ini terdiri dari 7.381 wajah pria dan 5.941 wajah wanita [34]. Dataset AAF dibagi kedalam dua kelas yaitu anak dan dewasa. Kelas anak merupakan kumpulan data antara 1 sampai 12 tahun dan 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 berikut.



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. Hasil pelatihan seluruh existing CNN yang diuji ditampilkan pada Gambar 6 berikut.

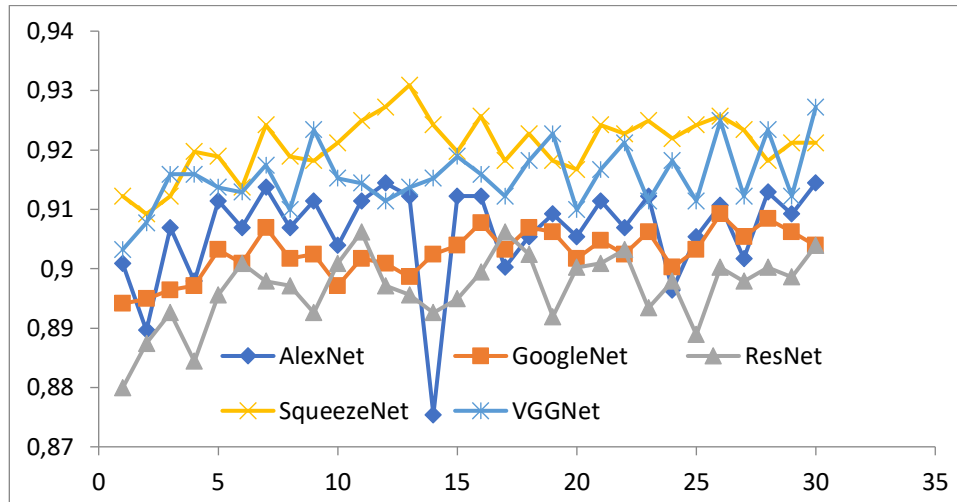


Gambar 6. Hasil Pelatihan Existing CNN

Hasil pelatihan CNN seperti yang terlihat pada Gambar 6, SqueezeNet merupakan existing CNN yang paling baik dalam pelatihan. Berdasarkan urutan akurasi pelatihan SqueezeNet 92,14 %, Resnet 92%, VGGNet 91,22 %, Alexnet 90,87% dan GoogleNet 90,82%.

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 berikut.



Gambar 7. Akurasi Validasi Existing CNN

Gambar 6 menunjukkan akurasi existing CNN pada tiap epoch. SqueezeNet merupakan arsitektur yang paling stabil sejak epoch pertama. SqueezeNet memiliki akurasi tertinggi dengan 93,09% mengungguli VGGNet dan beberapa metode lainnya. Akurasi validasi tertinggi dalam 30 epoch ditampilkan pada Tabel 1 Berikut.

Tabel 1. Perbandingan Akurasi Validasi CNN

Metode	Akurasi Validasi
AlexNet	91,44%
GoogleNet	90,92%
ResNet	90,62%
SqueezeNet	93,09%
VGGNet	92,72%

4. KESIMPULAN

Klasifikasi usia pengunjung sebagai pendukung pengelola rumah sakit untuk membatasi pengunjung berdasarkan usia. Pengunjung dikategorikan sebagai anak adalah pengunjung dengan usia 12 tahun atau lebih kecil dan dilarang berkunjung ke rumah sakit. Metode yang digunakan adalah existing CNN antara lain Alexnet, VGGNet, GoogleNet, ResNet dan AqueezeNet. Kami melakukan penelitian awal dengan memanfaatkan dataset All-Age-Faces (AAF) sebagai data uji yang mewakili usia pengunjung rumah sakit. Dataset dibagi kedalam dua kelas yaitu anak dan dewasa. Berdasarkan pengujian SqueezeNet merupakan metode yang lebih baik dalam akurasi pelatihan maupun validasi. Berdasarkan urutan akurasi validasi SqueezeNet berhasil mengenali kelompok usia dengan akurasi 93,09 %, VGGNet 92,72%, AlexNet 91,44%, GoogleNet 90,92% dan ResNet 90,62%. Penelitian ini diharapkan memeberikan kontribusi dalam membantu penertiban pengunjung bagi rumah sakit. Akurasi validasi SqueezeNet merupakan akurasi tertinggi, namun belum optimal. Pada penelitian yang akan datang diharapkan mampu meningkatkan akurasi dari penelitian ini dengan melakukan fine-tuning atau membuat arsitektur baru. Pada masa yang akan datang diharapkan sistem dapat diimplementasikan secara nyata dan real time. Sehingga pengawasan terhadap kinerja rumah sakit benar-benar terlaksana dengan baik.

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] C. Szegedy et al., “Going deeper with convolutions,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 1–9.
- [9] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” *arXiv preprint arXiv:1409.1556*, 2014.
- [10] 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.
- [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] 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.
- [13] 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.
- [14] 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.
- [15] 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.
- [16] 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.
- [17] 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.
- [18] H. Li, A. Kadav, I. Durdanovic, H. Samet, and H. P. Graf, “Pruning filters for efficient convnets,” *arXiv preprint arXiv:1608.08710*, 2016.
- [19] 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.
- [20] 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.
- [21] K. Zhang et al., “Age group and gender estimation in the wild with deep RoR architecture,” *IEEE Access*, vol. 5, pp. 22492–22503, 2017.
- [22] O. Agbo-Ajala and S. Viriri, “Deeply learned classifiers for age and gender predictions of unfiltered faces,” *The Scientific World Journal*, vol. 2020, 2020.
- [23] A. Tituriya and S. Sachdeva, “Breast Cancer Histopathology Image Classification using AlexNet,” in *2019 4th International Conference on Information Systems and Computer Networks (ISCON)*, 2019, pp. 708–712.
- [24] F. Huang, L. Yu, T. Shen, and L. Jin, “Chinese Herbal Medicine Leaves Classification Based on Improved AlexNet Convolutional Neural Network,” in *2019 IEEE 4th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)*, 2019, vol. 1, pp. 1006–1011.
- [25] F. R. Mashrur, A. D. Roy, and D. K. Saha, “Automatic Identification of Arrhythmia from ECG Using AlexNet Convolutional Neural Network,” in *2019 4th International Conference on Electrical Information and Communication Technology (EICT)*, 2019, pp. 1–5.
- [26] M. Lv, G. Zhou, M. He, A. Chen, W. Zhang, and Y. Hu, “Maize Leaf Disease Identification Based on Feature Enhancement and DMS-Robust Alexnet,” *IEEE Access*, vol. 8, pp. 57952–57966, 2020.
- [27] C. Dong et al., “Convolutional Neural Network-Based Approach for Citrus Diseases Recognition,” in *2019 IEEE Intl Conf on Parallel & Distributed Processing with Applications, Big Data & Cloud Computing, Sustainable Computing & Communications, Social Computing & Networking (ISPA/BDCloud/SocialCom/SustainCom)*, 2019, pp. 1495–1499.
- [28] 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.
- [29] 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.
- [30] 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.
- [31] Z. Zhu, J. Li, L. Zhuo, and J. Zhang, “Extreme weather recognition using a novel fine-tuning strategy and optimized GoogLeNet,” in *2017 International Conference on Digital Image Computing: Techniques and Applications (DICTA)*, 2017, pp. 1–7.
- [32] L. Balagourouchetty, J. K. Pragatheeswaran, B. Pottakkat, and G. Ramkumar, “GoogLeNet based ensemble FCNet classifier for focal liver lesion diagnosis,” *IEEE Journal of Biomedical and Health Informatics*, 2019.
- [33] P. Aswathy and D. Mishra, “Deep GoogLeNet Features for Visual Object Tracking,” in *2018 IEEE 13th International Conference on Industrial and Information Systems (ICIIS)*, 2018, pp. 60–66.
- [34] 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.