

PENGEMBANGAN *DEEP LEARNING* UNTUK SISTEM DETEKSI DINI KOMPLIKASI KAKI DIABETIK MENGGUNAKAN CITRA TERMOGRAM

Medycha Emhandyksa^{*1}, Indah Soesanti², Rina Susilowati³

^{1,2,3}Universitas Gadjah Mada, Yogyakarta

Email: ¹medychaemhandyksa@mail.ugm.ac.id, ²indahsoesanti@ugm.ac.id, ³rina_susilowati@ugm.ac.id

^{*}Penulis Korespondensi

(Naskah masuk: 17 Juni 2023, diterima untuk diterbitkan: 28 November 2023)

Abstrak

Prevalensi komplikasi kaki diabetik secara global mencapai 66% dengan resiko amputasi 20 kali lebih tinggi pada pasien *diabetes mellitus*. Tindakan pencegahan melalui deteksi dini komplikasi kaki diabetik mutlak dilakukan untuk meminimalisasi resiko amputasi. Penelitian sebelumnya menunjukkan validitas dan akurasi yang tinggi (mencapai 100%) dari sistem deteksi dini komplikasi kaki diabetik menggunakan termografi berbasis kecerdasan buatan. Namun sebagian besar penelitian tersebut terlalu berfokus pada peningkatan performa dan tidak memperhatikan aspek biaya komputasi yang berperan penting pada proses *deployment model*. Pada penelitian ini dirancang empat model *deep convolutional neural network* dengan prinsip *Occam's razor* melalui pengaturan *hyperparameter* pada aspek struktur algoritma berupa jumlah *layer* dan aspek optimasi berupa tipe *optimizer*. Penelitian bertujuan mengembangkan algoritma *deep convolutional neural network* untuk menghasilkan sistem deteksi dini komplikasi kaki diabetik dengan biaya komputasi terendah (jumlah parameter paling sedikit) dan mempertahankan kemampuan deteksi tetap tinggi (nilai rata-rata parameter evaluasi tertinggi). Data yang digunakan merupakan data primer berupa citra termogram telapak kaki dari RSUP. Dr. Sardjito Yogyakarta yang terdiri dari 20 subjek diabetes mellitus dan 20 subjek kontrol (sehat). Pengambilan data primer dilakukan menggunakan kamera *thermal* merek HIKMICRO B20 dengan resolusi inframerah 256x192 yang telah memenuhi standar internasional (IACT) untuk menghasilkan citra termogram dua dimensi. Hasil penelitian menunjukkan model 4 dengan Adam *optimizer* dan pengaturan *hyperparameter* tertentu merupakan model terbaik dengan jumlah parameter model paling sedikit yaitu 1.570.594 juta dan nilai rata-rata parameter evaluasi tetap tinggi sebesar 96%. Selain arsitektur *deep convolutional neural network* model 4, kontribusi penelitian yang didapatkan dari penelitian ini adalah penggunaan variasi ukuran *filter* 3x3, 2x2, dan 1x1 dengan jumlah *convolutional layer* yang tetap dan pengurangan jumlah *hidden layer* pada struktur algoritma mampu menurunkan jumlah parameter model dengan tetap mempertahankan kemampuan deteksi yang tinggi. Selain itu penelitian yang dilakukan merupakan penelitian pembuka atau pendahuluan mengenai perancangan sistem deteksi dini komplikasi kaki diabetik menggunakan termografi berbasis kecerdasan buatan *deep learning* di Indonesia.

Kata kunci: *diabetes mellitus, amputasi, deteksi dini, termografi, deep learning, CNN.*

DEEP LEARNING DEVELOPMENT IN EARLY DETECTION SYSTEM OF DIABETIC FOOT COMPLICATIONS USING THERMOGRAPHIC TECHNIQUES

Abstract

The prevalence of diabetic foot complications globally reaches 66% with a 20 times higher risk of amputation in patients with diabetes mellitus. Preventive measures through early detection of diabetic foot complications are necessary to minimize the risk of amputation. Previous studies have shown high validity and accuracy (up to 100%) of the early detection system of diabetic foot complications using artificial intelligence-based thermography. However, most of these studies focused too much on improving performance and did not pay attention to the computational cost aspect. In this study, four deep convolutional neural network models were designed with Occam's razor principle through hyperparameter settings on the algorithm structure aspect in the form of number of layers and optimization aspect in the form of optimizer type. The research aims to develop a deep convolutional neural network algorithm to produce an early detection system for diabetic foot complications with the lowest computational cost (least number of parameters) and maintain high detection capability (highest average value of evaluation parameters). The data used is primary data in the form of foot thermogram images from the General Hospital. Dr. Sardjito Yogyakarta consisting of 20 diabetes mellitus subjects and 20 control (healthy) subjects. Primary data collection was carried out using a thermal camera brand HIKMICRO B20 with

256x192 infrared resolution that has met international standards (IAC) to produce a two-dimensional color thermogram image. The results show that model 4 with Adam optimizer and certain hyperparameter settings is the best model with the least number of model parameters, namely 1,570,594 million and the average value of evaluation parameters remains high at 96%. In addition to the deep convolutional neural network architecture model 4, the research contribution obtained from this research is the use of filter size variations of 3x3, 2x2, and 1x1 with a fixed number of convolutional layers and a reduction in the number of hidden layers in the algorithm structure can reduce the number of model parameters while maintaining high detection capability. In addition, the research conducted can be an opening or preliminary research on the design of an early detection system for diabetic foot complications using deep learning artificial intelligence-based thermography in Indonesia.

Keywords: *diabetes mellitus, amputation, early detection, thermography, deep learning, CNN*

1. PENDAHULUAN


Penyakit *diabetes mellitus* menempati peringkat ke-sembilan dari sepuluh penyakit penyebab kematian secara global dengan prevalensi 422 juta penduduk menurut *World Health Organization* (WHO) pada tahun 2019. Tingkat penderita *diabetes mellitus* di Indonesia mencapai 8,5% dari total penduduk berdasarkan pemeriksaan gula darah (Riset Kesehatan Dasar 2018).

Diabetes mellitus merupakan penyakit metabolik kronis dengan kondisi peningkatan kadar glukosa di dalam darah yang disebabkan adanya *autoimmune* (tipe 1) atau terjadi resistensi sel terhadap insulin (tipe 2) (Frykberg et al., 2006). Terdapat beberapa komplikasi penyakit *diabetes mellitus* diantaranya *retinopathy*, *neuropathy*, *peripheral arterial disease*, dan kaki diabetik (Frykberg et al., 2006). Komplikasi kaki diabetik merupakan komplikasi terbanyak yang dialami oleh pasien dengan prevalensi 16%-60% secara global dengan resiko amputasi 10 hingga 20 kali lebih tinggi pada pasien *diabetes mellitus* (IDF Diabetes Atlas 8th edition, 2017). Penyebab utama komplikasi kaki diabetik adalah *peripheral sensory neuropathy* yang mengakibatkan pasien *diabetes mellitus* tidak merasakan sakit pada luka yang terdapat di kaki (Frykberg et al., 2006). Luka yang tidak mendapat penanganan dengan baik akan membusuk hingga mengakibatkan terjadinya amputasi. Resiko amputasi dapat meningkat jika pasien mengalami *vascular disease* yang menyebabkan terhambatnya aliran darah menuju kaki untuk proses penyembuhan luka (Chawla et al., 2016).

Termografi merupakan perangkat elektronik pendeteksi suhu yang memiliki keunggulan bersifat non kontak, non invasif, non radiasi, dan pasif (Khandpur, 2003). Termografi mendeteksi gelombang inframerah yang dipancarkan objek untuk kemudian dikonversi menjadi besaran suhu. Termografi mampu menghasilkan citra atau gambar (termogram) secara *real time* yang menunjukkan distribusi suhu pada objek melalui proyeksi warna yang mewakili rentang suhu tertentu. Terkait penyakit *diabetes mellitus*, penelitian sebelumnya menunjukkan validitas dan akurasi tinggi dari termografi untuk deteksi dini komplikasi kaki

diabetik melalui pengukuran perubahan suhu kulit telapak kaki (Ring, 2010). Peningkatan suhu kulit berbanding lurus dengan kuantitas aliran darah. Semakin besar kuantitas aliran darah pada suatu pembuluh darah maka suhu kulit disekitar pembuluh darah tersebut akan meningkat dan berlaku sebaliknya (Ring, 2010).

Citra termogram telapak kaki yang terindikasi kaki diabetik memiliki pola yang tidak beraturan dibandingkan kaki normal yang memiliki pola menyerupai kupu-kupu (Gambar 1) (Mori et al., 2013; Nagase et al., 2011). Perbedaan pola tersebut disebabkan distribusi suhu kulit yang mengalami perubahan menyesuaikan dengan aliran darah. Selain itu kaki yang berpotensi mengalami kaki diabetik memiliki suhu lebih tinggi 2,22°C (4F) dibandingkan kaki lainnya (Frykberg et al., 2017). Otomatisasi deteksi pola perubahan suhu pada citra termogram dapat dilakukan menggunakan kecerdasan buatan. Kolaborasi antara termografi dengan kecerdasan buatan dapat menciptakan sistem deteksi dini kaki diabetik yang bersifat non kontak, otomatis, cepat, dan akurat.



Gambar 1. Perbandingan citra termogram non diabetik (a) dan diabetik (b) (Mori et al., 2013).

Penelitian sebelumnya mengenai sistem deteksi dini kaki diabetik menggunakan termografi berbasis kecerdasan buatan menunjukkan validitas dan akurasi yang tinggi. Hernandez-Contreras et al. merancang algoritma *Multilayer Perceptron* (MLP) dengan rata-rata parameter evaluasi mencapai 90% pada tahun 2015 (D. Hernandez-Contreras et al., 2015). Pada tahun 2019, Contreras et al. melakukan penelitian untuk membuat *database* citra termogram telapak kaki yang tersedia secara *online* dan bersifat publik (D. A. Hernandez-Contreras et al., 2019). Kombinasi algoritma *deep learning* DFTNet sebagai algoritma utama dan *Support Vector Machine* (SVM) sebagai

classifier menghasilkan akurasi sebesar 85,3% dan sensitivitas sebesar 91,67% (Cruz-Vega et al., 2020). DFU_QUTNet, algoritma *deep learning* rancangan Alzubaidi et al. yang dikombinasikan dengan SVM sebagai *classifier* mampu menghasilkan F1-Score sebesar 94,5% pada tahun 2020 (Alzubaidi et al., 2020). Kombinasi metode *machine learning* yaitu *adaboost* dan SVM memiliki sensitivitas mencapai 96,71%. (Khandakar et al., 2021). Perbandingan antara metode *machine learning* dan *deep learning* untuk deteksi dini komplikasi kaki diabetik menunjukkan metode *machine learning* sebagai metode terbaik pada tiga penelitian yang dilakukan oleh Khandakar et al. pada tahun 2021 dan 2022 (Khandakar et al., 2022; Khandakar et al., 2022; Khandakar et al., 2021). Pada tahun 2022 Munadi et al. menggabungkan dua algoritma *deep learning* yaitu *MobileNetV2* dan *ShuffleNet* yang mampu menghasilkan akurasi sebesar 100% (Munadi et al., 2022). Penelitian dengan mengadopsi struktur algoritma *AlexNet* pada bagian *input* mampu meningkatkan akurasi hingga mencapai 98% (Muralidhara et al., 2022).

Metode yang digunakan pada penelitian sebelumnya terbatas pada perbandingan antara metode *machine learning* dan *deep learning* (Cruz-Vega et al., 2020; Khandakar et al., 2021), dan perancangan algoritma *deep learning from scratch* secara praktis (Cruz-Vega et al., 2020; Muralidhara et al., 2022). Belum dilakukan penelitian mengenai metode perancangan algoritma *deep learning CNN from scratch* dengan fokus meminimalisasi biaya komputasi dengan tetap mempertahankan kemampuan deteksi sistem yang tinggi. Pengurangan jumlah *filter* yang tidak diperlukan pada lapisan konvolusi dapat mengurangi jumlah parameter model dengan tetap mempertahankan kemampuan prediksi yang tinggi (Verma et al., 2022). Penambahan *fully connected layers* dan peningkatan ukuran *filter* dapat mengurangi waktu eksekusi program (Shah & Bhavsar, 2022). Biaya komputasi sistem berkorelasi dengan jumlah parameter yang dihasilkan. Sedangkan kemampuan deteksi berkorelasi dengan nilai rata-rata parameter evaluasi. Melalui penelitian terkait biaya komputasi dapat mempermudah penyesuaian ketika proses *deployment* model pada perangkat keras. Selain itu dengan mengetahui biaya komputasi dapat dijadikan pertimbangan terkait *trade off* antara jenis model yang digunakan dengan tingkat akurasi yang dihasilkan.

Perbandingan secara praktis antara metode *machine learning* dan *deep learning* tidak dapat menghasilkan performa deteksi yang maksimal. Hal ini disebabkan tidak dilakukan eksplorasi pada arsitektur atau *hyperparameter* dari algoritma yang digunakan. Beberapa penelitian sebelumnya menunjukkan rekayasa struktur algoritma pada aspek *depth* dan *width* mampu meningkatkan performa deteksi sistem (He et al., 2015; Simonyan & Zisserman, 2014; Szegedy et al., 2014). Algoritma

machine learning dan *deep learning* memiliki kelebihan dan kelemahan tergantung pada permasalahan yang akan diselesaikan dan sumber daya komputasi yang dimiliki. Perancangan algoritma *deep learning from scratch* secara praktis pada penelitian sebelumnya belum mempertimbangkan dua aspek yang saling berkaitan yaitu karakteristik dari data penelitian dan biaya komputasi yang dihasilkan.

Data penelitian khususnya berbentuk citra atau gambar memiliki karakteristik tertentu yang menghasilkan perbedaan tingkat kompleksitas sesuai dengan objek permasalahan. Sebagai contoh karakteristik dari citra wajah manusia yang memiliki fitur berupa bentuk mata, hidung, dan mulut tentu lebih kompleks dibandingkan karakteristik dari citra bentuk kaki manusia. Tingkat kompleksitas dari data penelitian berbanding lurus pada tingkat kompleksitas algoritma yang akan dirancang. Data penelitian dengan kompleksitas rendah dapat diselesaikan dengan kompleksitas algoritma yang rendah pula untuk menghindari *overfitting* (Krohn, 2020). Dengan mengetahui tingkat kompleksitas dari algoritma maka dapat diketahui biaya komputasi yang dibutuhkan untuk merancang algoritma tersebut melalui rumus perhitungan jumlah parameter model (Krohn, 2020). Semakin tinggi kompleksitas algoritma maka biaya komputasi yang dibutuhkan akan semakin tinggi pula dan berlaku sebaliknya.

Pada penelitian ini dilakukan perancangan empat algoritma *deep convolutional neural network* (CNN) berdasarkan prinsip *Occam's razor* melalui pengaturan *hyperparameter* pada aspek struktur algoritma dan optimasi. Penelitian dilakukan sebagai upaya pencegahan tindakan amputasi melalui deteksi dini resiko terbentuknya ulserasi pada telapak kaki. Pengaturan *hyperparameter* pada aspek struktur algoritma terdiri dari variabel jumlah *convolutional layer*, *hidden layer*, dan ukuran *filter* pada *convolutional layer*. Sedangkan pengaturan *hyperparameter* pada aspek optimasi terdiri dari pemilihan tipe *optimizer*. Penelitian menggunakan data primer citra termogram telapak kaki dua kelompok subjek yaitu subjek *diabetes mellitus* tipe dua sebanyak 20 orang dan subjek kontrol (sehat) sebanyak 20 orang. Data primer tersebut berasal dari Rumah Sakit Umum Pemerintah (RSUP) Dr. Sardjito Yogyakarta, Indonesia. Sistem yang dirancang akan dilatih dan diuji menggunakan metode *k-fold cross validation* dengan nilai $k=5$ dan 50 *epochs*. Kemudian dilakukan evaluasi performa menggunakan empat parameter evaluasi standar yaitu *accuracy*, *precision*, *sensitivity*, dan F1-score. Kemampuan prediksi sistem pada setiap kelas akan divisualisasikan menggunakan *confusion matrix*. Hasil evaluasi performa keempat model akan dibandingkan dengan empat model *transfer learning* yaitu *DenseNet* (Huang et al., 2016), *InceptionV3* (Szegedy et al., 2015), *MobileNetV2* (Sandler et al., 2018),

ResNetRS50 (Bello et al., 2021), dan *Xception* (Chollet, 2016).

2. METODE PENELITIAN

Metode penelitian yang digunakan adalah metode kuantitatif tipe *true experimental design* dengan pengambilan data primer di Rumah Sakit Umum Pemerintah (RSUP) Dr. Sardjito, Sleman, Yogyakarta. Alat yang digunakan untuk pengambilan data adalah kamera *thermal* termografi dengan merek HIKMICRO B20 (Hangzhou Microimage Software Co., Ltd., China) yang memiliki resolusi inframerah sebesar 256x192 dengan pengaturan sebagai berikut:

- *Emissivity*: 0,97
- *Measure range*: -20 - 150°C
- *Palettes*: Rainbow
- *Distance*: 1.0m
- *Unit*: Celcius
- *Preview mode*: Thermal
- *Parallax correction*: 1.0m

Perangkat komputer yang digunakan untuk pengolahan data dan perancangan sistem memiliki beberapa spesifikasi yaitu komputer Lenovo AIO 3, *processor* AMD Ryzen 5 3500U with Radeon Vega Mobile Gfx @2.10GHz, 64-bit *operating system*, SSD 215GB, dan RAM 8GB. Bahan penelitian yang digunakan berupa citra termogram telapak kaki subjek *diabetes mellitus* dan kontrol (sehat) dengan jumlah yang sama yaitu 20 subjek.

Pada masing-masing subjek dilakukan empat kali pengambilan data dengan rincian dua data pada masing-masing telapak kaki sehingga didapatkan 80 data pada masing-masing kelompok subjek. Alat termografi dan prosedur pengambilan data mengadopsi ketentuan yang ditetapkan oleh *The International Academy of Clinical Thermology* (IACT). Metode analisis suhu citra termogram yang digunakan adalah *temperature distribution analysis*. Metode tersebut relevan dengan jenis algoritma *deep learning* yang digunakan yaitu *convolutional neural network* dengan tingkat risiko paling minimal (D. Hernandez-Contreras et al., 2016).

Penelitian telah mendapatkan persetujuan etik dari Komisi Etik Penelitian Kedokteran dan Kesehatan, Fakultas Kedokteran dan Kesehatan Masyarakat (FKKMK) Universitas Gadjah Mada dengan nomor protokol KE/1132/09/2022. Pengambilan seluruh data dilakukan pada Bulan Oktober 2022. Subjek yang bersedia mengikuti penelitian harus memenuhi kriteria inklusi dan eksklusi yang ditetapkan. Prosedur pengambilan data beserta kriteria inklusi dan eksklusi dapat dilihat pada lembar lampiran.

Terdapat lima tahapan penelitian yang dilakukan yaitu pengambilan data, pengolahan data, perancangan sistem, pelatihan dan pengujian, evaluasi. Alur penelitian dimulai dari pengambilan data primer di Rumah Sakit Umum Pemerintah (RSUP) Dr. Sardjito Yogyakarta. Kemudian dilakukan tahap *preprocessing* yaitu augmentasi

untuk memperbanyak jumlah variasi data pada tahap pelatihan. Proses augmentasi dilakukan menggunakan tujuh metode yaitu *rotation*, *width shift*, *height shift*, *horizontal flip*, *vertical flip*, *shear*, dan *zoom*. Pada tahap ketiga dilakukan perancangan algoritma *deep convolutional neural network* (CNN) dengan paradigma arsitektur *sequential* sebanyak empat model yang memiliki perbedaan komposisi arsitektur. Perancangan algoritma *deep CNN* dilakukan dengan prinsip *Occam's razor* yaitu algoritma paling sederhana dengan performa deteksi tertinggi. Selain itu perancangan algoritma *deep CNN* menggunakan metode *trial and error* untuk mencari komposisi terbaik. Setelah tahap perancangan model selesai kemudian dilakukan tahap pelatihan dan pengujian menggunakan metode *k-fold cross validation* dengan nilai $k=5$ dan 50 *epochs*. Tahap terakhir dilakukan uji performa keempat model menggunakan empat parameter evaluasi standar yaitu *accuracy*, *precision*, *sensitivity*, dan *F1-score*. Empat parameter evaluasi standar tersebut didapatkan dari perhitungan empat variabel yang dihasilkan *confusion matrix* yaitu *true positive* (TP), *true negative* (TN), *false positive* (FP), dan *false negative* (FN) (Suyanto, 2018). *Confusion matrix* menunjukkan kemampuan prediksi label data dari model dibandingkan dengan label aktual (*ground truth*). Hasil parameter evaluasi dari keempat model tersebut akan dibandingkan dengan hasil parameter evaluasi dari lima model *transfer learning* yaitu *DenseNet*, *InceptionV3*, *MobileNetV2*, dan *Xception*. Gambar 2 menunjukkan *confusion matrix* pada permasalahan klasifikasi biner. Pada penelitian ini kelas 0 mewakili kelompok subjek diabetes dan kelas 1 mewakili kelompok subjek kontrol.

True Positive (TP)	False Positive (FP)
False Negative (FN)	True Negative (TN)

Gambar 2. *Confusion matrix* untuk permasalahan klasifikasi biner dua kelas.

Berikut merupakan rumus perhitungan dari empat parameter evaluasi standar yaitu *accuracy*, *sensitivity*, *precision*, dan *F1-score* berdasarkan empat variabel *confusion matrix*:

$$accuracy = \frac{TP+TN}{P+N} \quad (1)$$

$$sensitivity(recall) = \frac{TP}{P} \quad (2)$$

$$precision = \frac{TP}{TP+FP} \quad (3)$$

$$F1\ score = \frac{2 \times precision \times sensitivity}{precision + sensitivity} \quad (4)$$

Keterangan:

- TP = *True Positive*
- TN = *True Negative*
- FP = *False Positive*
- FN = *False Negative*
- P = TP + FN
- N = FP + TN

3. PERANCANGAN SISTEM

Sistem deteksi dini kaki diabetik yang dirancang berbasis kecerdasan buatan (*artificial intelligent*) dengan **Teknik Learning**. Metode teknik *learning* yang dipilih adalah *machine learning* dengan algoritma *deep convolutional neural network* (CNN). Algoritma *deep CNN* dirancang menggunakan paradigma arsitektur *sequential algorithm* atau *plain network* dengan prinsip *Occam's razor* yaitu algoritma paling sederhana dengan kemampuan deteksi tertinggi. Algoritma *deep learning CNN* mampu menghasilkan abstraksi tingkat tinggi dari karakteristik suatu data secara otomatis melalui *representation learning* yang berjenjang (Goodfellow et al., 2016). Pengaturan *hyperparameter* dilakukan pada aspek struktur algoritma yaitu jumlah lapisan (*layer*) dan aspek optimasi yaitu jenis *optimizers*. Perancangan algoritma *deep CNN* terdiri dari tiga bagian yaitu pemilihan *framework*, perancangan algoritma *deep CNN* beserta pengaturan *hyperparameter* struktur algoritma, dan pengaturan *hyperparameter* optimasi. Jumlah algoritma *deep CNN* yang dirancang sebanyak empat model dengan komposisi arsitektur yang berbeda-beda. Subbab berikut menjelaskan secara detail perancangan algoritma *deep CNN*.

3.1. Framework

Algoritma *deep convolutional neural network* yang dirancang pada penelitian ini menggunakan kombinasi dua *framework* yaitu Keras dan TensorFlow. TensorFlow merupakan *open-source library* yang dirancang oleh Perusahaan Google untuk proses komputasi numerik dan perancangan model *machine learning*. TensorFlow mengubah data masukan berupa tensor menjadi data keluaran tertentu seperti probabilitas suatu kelas. Tensor merupakan matriks yang terdiri dari dua atau *n*-dimensi baris dan kolom yang merepresentasikan suatu bentuk data (Goodfellow et al., 2016). Contoh data yang berbentuk tensor adalah citra atau gambar. Data citra terdiri dari gabungan nilai-nilai piksel tertentu yang menunjukkan derajat keabuan. Gabungan nilai piksel tersebut membentuk tensor *n*-dimensi yang menjadi data masukan dari algoritma *deep convolutional neural network*.

TensorFlow juga menggunakan konsep komputasi graf untuk mengubah data tensor menjadi data keluaran tertentu. Konsep komputasi graf memanfaatkan beberapa lapisan (*layer*) untuk melakukan komputasi berjenjang yang saling

berkaitan sehingga didapatkan representasi fitur data yang berbeda pada setiap *layer* (Goodfellow et al., 2016). Semakin banyak lapisan *layer* yang digunakan maka semakin tinggi representasi fitur yang dihasilkan sehingga model bisa melakukan proses pelatihan secara lebih akurat.

3.2. Deep Convolutional Neural Network (CNN) dan Pengaturan Hyperparameter

Pada penelitian ini dirancang algoritma *deep convolutional neural network* menggunakan prinsip *Occam's razor* melalui rekayasa pada komposisi arsitektur. *Occam's razor* merupakan prinsip perancangan suatu algoritma yang memiliki struktur paling sederhana yang mampu menghasilkan performa tertinggi. Pengaturan *hyperparameter* pada struktur algoritma *deep Convolutional Neural Network* (CNN) yang dirancang terdiri dari jumlah *convolutional layer*, *maxpooling layer*, *hidden layer*, *neurons*, *filter*, *dropout layer*, *output layer*, serta ukuran *filter* dan *strides* pada *convolutional layer* dan *maxpooling layer*. Jumlah *convolutional layer*, jumlah *hidden layer*, dan ukuran *filter* pada *convolutional layer* menjadi *hyperparameter* yang dilakukan variasi sedangkan *hyperparameter* lainnya menjadi variabel terkendali. Struktur algoritma *deep Convolutional Neural Network* (CNN) yang dirancang memiliki tiga variasi ukuran *filter* yaitu 3x3, 2x2, dan 1x1. Selain itu terdapat tiga variasi jumlah *layer* yang digunakan yaitu 8 *layers*, 9 *layers*, dan 10 *layers*. Dalam proses perancangan algoritma digunakan metode *Goldilock and a thhree bears* atau *trial and error* untuk mendapatkan komposisi struktur algoritma yang mampu menghasilkan performa deteksi tinggi (Goodfellow et al., 2016; Kelleher, 2019; Krohn, 2020). Oleh sebab itu pada penelitian ini dirancang empat model dengan komposisi *hyperparameter* yang berbeda-beda yang diberikan nama model 1, model 2, model 3, dan model 4.

Model 1 dengan ukuran *filter* 3x3 ditujukan untuk menurunkan ukuran piksel citra *input* secara cepat dan konsisten. Model 2 dengan ukuran *filter* 2x2 ditujukan untuk menurunkan ukuran piksel citra *input* secara tidak terlalu cepat dan konsisten. Model 3 dengan ukuran *filter* 1x1 ditujukan untuk menurunkan ukuran piksel citra *input* secara lambat dan konsisten. Model 4 dengan urutan kombinasi ukuran *filter* 3x3, 2x2, dan 1x1 ditujukan untuk menurunkan ukuran piksel citra *input* secara perlahan yaitu penurunan secara cepat, tidak terlalu cepat, dan lambat pada setiap *layers*-nya. Jumlah *layer* dan komposisi pada masing-masing model secara garis besar dapat dilihat pada Tabel 1.

Tabel. 1 Jumlah Layer dan Komposisi Arsitektur Empat Model.

Model (Jumlah Layer)	Komposisi
1 (8 layer)	5 <i>convolutional layer</i> , 2 <i>hidden layer</i> , dan 1 <i>output layer</i> dengan ukuran <i>filter</i>

Model (Jumlah Layer)	Komposisi
	3x3, serta 512, 1024, dan 2 neurons
2 (9 layer)	5 convolutional layer, 3 hidden layer, dan 1 output layer dengan ukuran filter 2x2, serta 512, 1024, dan 2 neurons
3 (10 layer)	6 convolutional layer, 3 hidden layer, dan 1 output layer dengan ukuran filter 1x1, serta 512, 1024, dan 2 neurons
4 (9 layer)	6 convolutional layer, 2 hidden layer, dan 1 output layer dengan kombinasi ukuran filter 3x3, 2x2, dan 1x1 serta 512, 1024, dan 2 neurons

3.3. Pengaturan Hyperparameter Optimasi

Pengaturan *hyperparameter* dilakukan menggunakan metode *Goldilock and a thhree bears* atau *trial and error*. Pengaturan *hyperparameter* optimasi terdiri dari jumlah *epochs*, jumlah *batch size*, *activation function*, *loss function* dan *optimizers*. Pada penelitian ini terdapat satu *hyperparameter* yang dilakukan penelitian yaitu *optimizers*. Pemilihan tipe *optimizers* sangat berpengaruh dalam perancangan algoritma *deep learning* untuk meminimalkan tingkat kesalahan (*error*) antara hasil prediksi sistem dengan data acuan (*ground truth*). Pada *hyperparameter optimizers* digunakan dua tipe untuk diteliti yaitu *Adaptive Moment Estimation* (Adam) (Kingma & Ba, 2014) dan *Stochastic Gradient Descent* (SGD) (Ruder, 2016). *Hyperparameter* selain *optimizers* ditetapkan sebagai variabel terkendali. Berikut merupakan pengaturan *hyperparameter* tambahan yang ditetapkan sebagai variabel terkendali pada keseluruhan model yang dirancang.


- Pengaturan *hyperparameter* pada *convolutional layer* sebagai berikut:
 - *Activation function*: ReLU
 - *Padding*: Same
 - *Input shape*: 240x320x3
 - *Pooling layer*: MaxPooling 2x2, stride 2
 - *Stride* pada *convolutional layer*: 1x1
- Pengaturan *hyperparameter* pada *hidden layer* sebagai berikut:
 - *Activation function*: ReLU
- Pengaturan *hyperparameter* pada *output layer* sebagai berikut:
 - *Activation function*: Softmax
- Pengaturan *hyperparameter* pada proses pelatihan dan pengujian sebagai berikut:
 - *Epochs*: 50
 - *Batch size*: 64
 - *Loss function*: categorical cross entropy
 - *Optimizers*: Adaptive Moment (Adam) dan Stochastic Gradient Descent (SGD).

4. HASIL DAN PEMBAHASAN


Hasil penelitian terdiri dari empat bagian yaitu hasil pengambilan data primer, perbandingan antara jumlah parameter dengan nilai parameter evaluasi antar model, *confusion matrix* dua model terbaik, dan perbandingan hasil parameter evaluasi menggunakan dua jenis *optimizers*. Pada hasil pengambilan data primer hanya disajikan satu contoh data dari kedua kelompok subjek.

4.1. Data Primer RSUP. Dr. Sardjito

Gambar 3 menunjukkan contoh data subjek *diabetes mellitus* sedangkan Gambar 4 menunjukkan contoh data subjek kontrol. Tabel 2 menunjukkan jumlah dan usia dari kedua kelompok subjek.



Gambar 3. Citra termografi kaki kanan (a) dan kaki kiri (b) subjek *diabetes mellitus* tipe 2 kode H1_3.



Gambar 4. Citra termografi kaki kanan (a) dan kaki kiri (b) subjek kontrol kode H1_2.

Tabel. 2 Jumlah dan Usia Subjek Data Primer RSUP.Dr. Sardjito.


	Kelompok Kontrol	Kelompok Diabetik
Total	20	20
Jumlah Wanita	6	14
Jumlah Pria	14	6
Usia (tahun)	30,1	56,5

4.2. Perbandingan Jumlah Parameter dan Nilai Parameter Evaluasi Antar Model

Tabel 3 menunjukkan perbandingan jumlah parameter dan nilai parameter evaluasi antar model. Analisa *confusion matrix* diperlukan sebagai parameter pendukung untuk melihat kemampuan prediksi model pada setiap kelas (kelompok subjek).

4.3. Confusion Matrix Model 4 dan Model DenseNet

Gambar 5 menunjukkan *confusion matrix* dari dua model terbaik yang mendekati target penelitian yaitu model 4 dan model *DenseNet*.



Gambar 5. Confusion matrix (a) model 4 dan (b) model DenseNet.

4.4. Perbandingan Hasil Parameter Evaluasi Menggunakan Dua Jenis Optimizers

Pada penelitian ini digunakan dua jenis optimizer yaitu *Adaptive Moment Estimation* (Adam) dan *Stochastic Gradient Descent* (SGD). Tabel 4 merupakan perbandingan hasil parameter evaluasi menggunakan optimizers Adam dan SGD.

4.5 Diskusi

Gambar 3 dan Gambar 4 secara berurutan menunjukkan hasil pengambilan data primer subjek *diabetes mellitus* dan subjek kontrol di RSUP. Dr. Sardjito Yogyakarta. Bagian citra yang berwarna merah hingga putih memiliki suhu lebih tinggi dibandingkan bagian citra yang berwarna biru hingga hitam. Data citra termogram telapak kaki pada subjek *diabetes mellitus* tipe dua sebagian besar menunjukkan distribusi suhu yang tidak merata (heterogen) sehingga membentuk suatu pola distribusi suhu yang tidak beraturan. Hal tersebut berbanding terbalik dengan pola menyerupai kupu-kupu (*butterfly*) yang dihasilkan pada kelompok subjek kontrol.

Pola citra termogram telapak kaki yang dihasilkan dari penelitian ini bersesuaian dengan hasil penelitian sebelumnya yang dilakukan oleh Nagase et al. pada tahun 2011 dan Mori et al. pada tahun 2013. Pada penelitiannya Nagase et al. menyatakan “*In the normal group, thermographic patterns of more than 65% of feet were allocated to the two typical categories, including the ‘butterfly pattern’ among the 20 categories, whereas 225 feet (87.2%) of the diabetic groups were variously allocated to 18 out of the 20 categories. This is the first study, which describes detailed plantar thermographic patterns, showing wider variations in the diabetic patients than in the normal subjects.*” (Nagase et al., 2011). Penemuan yang sama didapatkan oleh Mori et al. (2013) yang menyatakan “*In patients with DM, the system showed that the wholehigh pattern was most frequent (46%), followed by the butterfly pattern (12%). In the control group, the butterfly pattern was most frequent (44%), followed by the whole-high pattern (19%)*” (Mori et al., 2013). Selain itu data yang diambil di RSUP. Dr. Sardjito tersebut bersesuaian dengan *dataset online* hasil penelitian Hernandez-Contreras et al. pada tahun 2019 yang menjadi acuan banyak peneliti dalam mengembangkan penelitian terkait sistem deteksi dini komplikasi kaki diabetik. Pola citra termogram inilah yang akan dipelajari oleh sistem *deep CNN* yang dirancang sehingga mampu memprediksi data baru secara otomatis, cepat, dan akurat.

Citra termogram telapak kaki yang diperoleh memiliki dua pola yaitu pola telapak kaki dan distribusi warna. Citra termogram tersebut memiliki pola dua dimensi yang berasal dari perpaduan garis sedemikian rupa hingga terbentuk pola telapak kaki. Pada bagian dalam pola telapak kaki terbentuk pola distribusi warna dua dimensi menyerupai kupu-kupu (subjek kontrol) dan tidak beraturan (subjek diabetik) yang juga merupakan perpaduan dari berbagai bentuk garis. Terbentuknya kedua pola tersebut disebabkan adanya perbedaan distribusi suhu kulit akibat perbedaan kuantitas aliran darah. Pola distribusi suhu yang tidak beraturan pada pasien *diabetes mellitus* mengindikasikan terjadinya *stenosis* pada pembuluh arteri yang menghubungkan antar *angiosome* (Nagase et al., 2011).

Apabila dibandingkan dengan citra lain seperti citra wajah yang memiliki banyak pola seperti pola mata, hidung, dan mulut, citra termogram telapak kaki cenderung lebih sederhana yang hanya memiliki dua pola yaitu pola telapak kaki dan persebaran suhu kulit. Struktur algoritma *deep CNN* yang dirancang menyesuaikan dengan kedua pola yang terbentuk pada citra termogram telapak kaki. Hal ini berarti struktur algoritma *deep CNN* yang dirancang tidak terlalu kompleks pada aspek jumlah *convolutional layers* dan *hidden layers*. Jumlah *convolutional layers* dan *hidden layers* yang berlebih akan menyebabkan algoritma membuat abstraksi fitur karakteristik data latih terlalu detail sehingga ketika terdapat data baru

(data uji) tidak mampu mengenali pola dari data baru tersebut (*overfitting*). Dibutuhkan beberapa percobaan *trial and error* untuk mendapatkan komposisi jumlah *convolutional layers* dan *hidden layers* yang tepat untuk menghasilkan sistem dengan kemampuan generalisasi yang tinggi (Goodfellow et al., 2016; Kelleher, 2019; Krohn, 2020).

Berdasarkan hasil perbandingan jumlah parameter dan nilai parameter evaluasi antara empat model yang dirancang dan lima model *transfer learning* (Tabel 3), didapatkan dua model terbaik yang mendekati target penelitian yaitu model 4 dan *DenseNet*. Model 4 memiliki jumlah parameter sebanyak 1.570.594 juta dengan nilai parameter evaluasi 96%. Sedangkan model *DenseNet* memiliki jumlah parameter sebanyak 7.430.914 juta dengan nilai parameter evaluasi 100%. Berdasarkan aspek jumlah parameter, model 4 memiliki jumlah parameter yang lebih sedikit daripada model *DenseNet* dengan selisih sebesar 5.860.320 juta. Pada aspek nilai parameter evaluasi, model *DenseNet* lebih unggul 4% dari model 4. Dibutuhkan analisa *confusion matrix* dari kedua model tersebut untuk menentukan model terbaik. *Confusion matrix* dapat menunjukkan jumlah prediksi benar dan salah yang dikeluarkan model pada kedua kelas (kelompok subjek). Pada penelitian ini kelas 0 mewakili kelompok diabetik dan kelas 1 mewakili kelompok kontrol. *Confusion matrix* model 4 terdiri dari 14 *true negative*, 18 *true positive*, 0 *false positive*, dan 0 *false negative* (Gambar 5 (a)). *Confusion matrix* model *DenseNet* terdiri dari 12 *true negative*, 20 *true positive*, 0 *false positive*, dan 0 *false negative* (Gambar 5 (b)).

Berdasarkan *confusion matrix* kedua model tersebut terlihat bahwa model 4 memiliki jumlah *true negative* yang lebih banyak daripada model *DenseNet* dengan selisih 2 angka. Jumlah *true negative* mencerminkan kemampuan model dalam memprediksi jumlah aktual kelas 0 (diabetik) yang benar diprediksi sebagai kelas 0. Jumlah *false positive* pada *confusion matrix* model *DenseNet* lebih banyak daripada model 4 dengan selisih 2 angka. Jumlah *true positive* mencerminkan kemampuan model dalam memprediksi jumlah aktual kelas 1 (kontrol) yang benar diprediksi sebagai kelas 1. Selain itu berdasarkan pada *false positive* dan *false negative* yang berjumlah nol menunjukkan bahwa kedua model tidak melakukan kesalahan deteksi pada kedua kelas.

Berdasarkan perbandingan parameter evaluasi menggunakan dua jenis *optimizer* (Tabel 4), metode *optimizer* Adam memiliki rata-rata hasil parameter evaluasi yang lebih baik (94,3%) dibandingkan metode *optimizer* SGD (84,47%). Metode *optimizer* SGD merupakan metode *optimizer* pertama yang ditemukan untuk melatih algoritma *deep learning* dengan prinsip kerja mempertahankan *learning rate* yang sama untuk memperbarui parameter (*weight*) selama tahap pelatihan (Ruder, 2016). Sedangkan metode *optimizer* Adam merupakan metode *adaptive*

learning rate dengan menggabungkan kelebihan dari dua metode *optimizer* yaitu *Adaptive Gradient* (AdaGrad) dan *Root Mean Square Propagation* (RMSProp) (Kingma & Ba, 2014). Metode *optimizer* Adam memiliki keunggulan dengan mengubah atau mengadaptasi *learning rate* secara individu pada setiap parameter menggunakan estimasi *moment gradient* pertama dan kedua. Penggunaan estimasi *moment gradient* pertama dan kedua tersebut meningkatkan kemampuan *optimizer* Adam dalam mengatasi permasalahan *sparse gradient* dan *non-constant gradient (noise)*. Dalam penelitian sebelumnya, metode *optimizer* Adam terbukti mampu mengungguli metode *optimizer* lainnya termasuk *optimizer* SGD dengan tingkat konvergensi *error* terbaik dan tercepat pada model yang kompleks dan *dataset* yang besar. Penggunaan metode *optimizer* Adam pada model 4 dan model *DenseNet* yang merupakan dua model terbaik pada data primer menunjukkan nilai parameter evaluasi yang lebih tinggi dibandingkan penggunaan metode *optimizer* SGD.

Hasil pengembangan algoritma yang dilakukan memiliki kelemahan yang dapat dilakukan pengembangan pada penelitian selanjutnya. Beberapa kelemahan tersebut diantaranya belum dilakukan penelitian terkait waktu eksekusi program, performa yang belum mencapai 100%, dan diperlukan pengujian pada *dataset* dengan jumlah data yang lebih banyak. Selain itu penelitian yang dilakukan terbatas pada klasifikasi biner yang membedakan dua kelas, belum dilakukan penelitian pada klasifikasi multikelas. Diharapkan hasil dari penelitian ini dapat menjadi penelitian pembuka atau pendahuluan sebagai landasan untuk pengembangan pada penelitian selanjutnya.

5. KESIMPULAN

Algoritma *deep learning* untuk sistem deteksi dini komplikasi kaki diabetik menggunakan citra termogram berhasil dirancang dan dikembangkan dengan meminimalisasi jumlah parameter dan mempertahankan kemampuan deteksi tetap tinggi. Algoritma *deep Convolutional Neural Network* (CNN) model 4 yang didukung dengan Adam *optimizer* dan pengaturan *hyperparameter* tertentu menjadi algoritma terbaik yang mampu menghasilkan biaya komputasi terendah yaitu sebanyak 1.570.594 juta dan performa rata-rata deteksi tertinggi yaitu sebesar 96%. Hasil pada model 4 tersebut membuktikan penggunaan variasi ukuran *filter* 3x3, 2x2, dan 1x1 dengan jumlah *convolutional layer* yang tetap serta pengurangan jumlah *hidden layer* di dalam struktur algoritma mampu menurunkan jumlah parameter model dengan tetap mempertahankan kemampuan deteksi yang tinggi. Metode Adam *optimizer* memiliki rata-rata hasil parameter evaluasi yang lebih tinggi (94,3%) dibandingkan metode SGD *optimizer* (84,47%)

Tabel. 3 Perbandingan Jumlah Parameter dan Nilai Parameter Evaluasi Antar Model.

	Algoritma (model)								
	Model 1	Model 2	Model 3	Model 4	DenseNet	Inception V3	MobileNetV 2	ResNetRS5 0	Xception
<i>Accuracy</i>	98%	97%	95%	96%	100%	98%	99%	57%	98%
<i>Precision</i>	98%	98%	96%	97%	100%	98%	99%	87%	98%
<i>Sensitivity</i>	98%	97%	95%	96%	100%	98%	99%	57%	98%
<i>F1-Score</i>	98%	97%	95%	96%	100%	98%	99%	67%	98%
Rata-rata	98%	97%	95%	96%	100%	98%	99%	67%	98%
Jumlah parameter	3.427.074	6.288.674	2.592.802	1.570.594	7.430.914	22.327.266	2.749.698	34.482.914	21.648.106
<i>Confusion Matrix</i>	-	-	-	TN: 14	TN: 12				

Tabel. 4 Perbandingan Parameter Evaluasi Menggunakan Optimizer Adam dan SGD

Model	Parameter Evaluasi (%)									
	<i>Accuracy</i>		<i>Precision</i>		<i>Sensitivity (Recall)</i>		<i>F1-Score</i>		<i>Rata-rata</i>	
	Adam	SGD	Adam	SGD	Adam	SGD	Adam	SGD	Adam	SGD
Model 1	98	78	98	84	98	78	98	79	98	79,75
Model 2	97	67	98	82	97	67	97	70	97,25	71,5
Model 3	95	59	96	95	95	59	95	69	95,25	70,5
Model 4	96	73	97	95	96	73	96	78	96,25	79,75
DenseNet	100	98	100	99	100	98	100	98	100	98,25
InceptionV3	98	96	98	96	98	96	98	96	98	96
MobileNetV2	99	99	99	99	99	99	99	99	99	99
ResNetRS50	57	64	87	89	57	64	67	72	67	72,25
Xception	98	93	98	94	98	93	98	93	98	93,25

DAFTAR PUSTAKA

- ALZUBAIDI, L., FADHEL, M. A., OLEIWI, S. R., AL-SHAMMA, O., & ZHANG, J., 2020. DFU_QUTNet: diabetic foot ulcer classification using novel deep convolutional neural network, *Multimedia Tools and Applications*, 79(21–22), 15655–15677.
- CHAWLA, A., CHAWLA, R., & JAGGI, S., 2016. Microvascular and macrovascular complications in diabetes mellitus: Distinct or continuum?, In *Indian Journal of Endocrinology and Metabolism*, Vol. 20, Issue 4, pp. 546–553). Medknow Publications.
- CHOLLET, F., 2016. *Xception: Deep Learning with Depthwise Separable Convolutions*. <http://arxiv.org/abs/1610.02357>
- CRUZ-VEGA, I., HERNANDEZ-CONTRERAS, D., PEREGRINA-BARRETO, H., RANGEL-MAGDALENO, J. DE J., & RAMIREZ-CORTES, J. M., 2020. Deep learning classification for diabetic foot thermograms. *Sensors (Switzerland)*, 20(6).
- FRYKBERG, R. G., GORDON, I. L., REYZELMAN, A. M., CAZZELL, S. M., FITZGERALD, R. H., ROTHENBERG, G. M., BLOOM, J. D., PETERSEN, B. J., LINDERS, D. R., NOUVONG, A., & NAJAFI, B., 2017. Feasibility and efficacy of a smart mat technology to predict development of diabetic plantar ulcers, *Diabetes Care*, 40(7), 973–980.
- FRYKBERG, R. G., ZGONIS, T., ARMSTRONG, D. G., DRIVER, V. R., GIURINI, J. M., KRAVITZ, S. R., LANDSMAN, A. S., LAVERY, L. A., MOORE, J. C., SCHUBERTH, J. M., WUKICH, D. K., ANDERSEN, C., & VANORE, J. V., 2006. DIABETIC FOOT DISORDERS: A

- CLINICAL PRACTICE GUIDELINE (2006 revision), *The Journal of Foot & Ankle Surgery*, 45(5).
- GOODFELLOW, I., BENGIO, Y., & COURVILLE, A., 2016. *DEEP LEARNING*, MIT Publisher. www.deeplearningbook.org
- HE, K., ZHANG, X., REN, S., & SUN, J., 2015. *Deep Residual Learning for Image Recognition*. <http://arxiv.org/abs/1512.03385>
- HERNANDEZ-CONTRERAS, D. A., PEREGRINA-BARRETO, H., RANGEL-MAGDALENO, J. D. J., & RENERO-CARRILLO, F. J., 2019. Plantar Thermogram Database for the Study of Diabetic Foot Complications, *IEEE Access*, 7, 161296–161307.
- HERNANDEZ-CONTRERAS, D., PEREGRINA-BARRETO, H., RANGEL-MAGDALENO, J., & GONZALEZ-BERNAL, J., 2016. Narrative review: Diabetic foot and infrared thermography, In *Infrared Physics and Technology*, Vol. 78, pp. 105–117. Elsevier B.V.
- HERNANDEZ-CONTRERAS, D., PEREGRINA-BARRETO, H., RANGEL-MAGDALENO, J., RAMIREZ-CORTES, J., & RENERO-CARRILLO, F., 2015. Automatic classification of thermal patterns in diabetic foot based on morphological pattern spectrum, *Infrared Physics and Technology*, 73, 149–157. <https://doi.org/10.1016/j.infrared.2015.09.022>
- HUANG, G., LIU, Z., VAN DER MAATEN, L., & WEINBERGER, K. Q., 2016. *Densely Connected Convolutional Networks*. <http://arxiv.org/abs/1608.06993>
- KELLEHER, D. J., 2019. *Deep Learning*, The MIT Press.
- KHANDAKAR, A., CHOWDHURY, M. E. H., IBNE REAZ, M. BIN, MD ALI, S. H., HASAN, M. A., KIRANYAZ, S., RAHMAN, T., ALFKEY, R., BAKAR, A. A. A., & MALIK, R. A., 2021. A machine learning model for early detection of diabetic foot using thermogram images, *Computers in Biology and Medicine*, 137.
- KHANDAKAR, A., CHOWDHURY, M. E. H., REAZ, M. B. I., ALI, S. H. M., ABBAS, T. O., ALAM, T., AYARI, M. A., MAHBUB, Z. B., HABIB, R., RAHMAN, T., TAHIR, A. M., BAKAR, A. A. A., & MALIK, R. A., 2022. Thermal Change Index-Based Diabetic Foot Thermogram Image Classification Using Machine Learning Techniques, *Sensors*, 22(5).
- KHANDAKAR, A., CHOWDHURY, M. E. H., REAZ, M. B. I., ALI, S. H. M., KIRANYAZ, S., RAHMAN, T., CHOWDHURY, M. H., AYARI, M. A., ALFKEY, R., BAKAR, A. A. A., MALIK, R. A., & HASAN, A., 2022. A Novel Machine Learning Approach for Severity Classification of Diabetic Foot Complications Using Thermogram Images, *Sensors*, 22(11).
- KHANDPUR, R. S., 2003. *Handbook of Second Edition Biomedical Instrumentation* (Second Edition), Tata McGraw-Hill Publishing Company Limited.
- KINGMA, D. P., & BA, J., 2014. *Adam: A Method for Stochastic Optimization*. <http://arxiv.org/abs/1412.6980>
- KROHN, JON., 2020. *Deep Learning Illustrated* (J. Lander, Ed.), Pearson Education, Inc.
- MORI, T., NAGASE, T., TAKEHARA, K., OE, M., OHASHI, Y., AMEMIYA, A., NOGUCHI, H., UEKI, K., KADOWAKI, T., & SANADA, H., 2013., Morphological pattern classification system for plantar thermography of patients with diabetes, *Journal of Diabetes Science and Technology*, 7(5), 1102–1112.
- MUNADI, K., SADDAMI, K., OKTIANA, M., ROSLIDAR, R., MUCHTAR, K., MELINDA, M., MUHARAR, R., SYUKRI, M., ABIDIN, T. F., & ARNIA, F., 2022. A Deep Learning Method for Early Detection of Diabetic Foot Using Decision Fusion and Thermal Images, *Applied Sciences (Switzerland)*, 12(15).
- MURALIDHARA, S., LUCIERI, A., DENGEL, A., & AHMED, S., 2022. Holistic multi-class classification & grading of diabetic foot ulcerations from plantar thermal images using deep learning, *Health Information Science and Systems*, 10(1).
- NAGASE, T., SANADA, H., TAKEHARA, K., OE, M., IIZAKA, S., OHASHI, Y., OBA, M., KADOWAKI, T., & NAKAGAMI, G., 2011. Variations of plantar thermographic patterns in normal controls and non-ulcer diabetic patients: Novel classification using angiosome concept, *Journal of Plastic, Reconstructive and Aesthetic Surgery*, 64(7), 860–866.
- RING, F., 2010. Thermal Imaging Today and Its Relevance to Diabetes. In *J Diabetes Sci Technol*, Vol. 4, Issue 4. www.journalofdst.org
- RUDER, S., 2016. *An overview of gradient descent optimization algorithms*. <http://arxiv.org/abs/1609.04747>
- SANDLER, M., HOWARD, A., ZHU, M., ZHMOGINOV, A., & CHEN, L.-C., 2018. *MobileNetV2: Inverted Residuals and Linear Bottlenecks*. <http://arxiv.org/abs/1801.04381>
- SHAH, B., & BHAVSAR, H., 2022. Time Complexity in Deep Learning Models, *Procedia Computer Science*, 215, 202–210.
- SIMONYAN, K., & ZISSERMAN, A., 2014. *Very Deep Convolutional Networks for Large-Scale Image Recognition*. <http://arxiv.org/abs/1409.1556>
- SUYANTO., 2018. *Machine Learning*, Informatika Bandung.
- SZEGEDY, C., LIU, W., JIA, Y., SERMANET, P., REED, S., ANGUELOV, D., ERHAN, D.,

- VANHOUCKE, V., & RABINOVICH, A., 2014. *Going Deeper with Convolutions*. <http://arxiv.org/abs/1409.4842>
- SZEGEDY, C., VANHOUCKE, V., IOFFE, S., & SHLENS, J., 2015. *Rethinking the Inception Architecture for Computer Vision*.
- VERMA, A., MEENPAL, T., & ACHARYA, B., 2022. Computational Cost Reduction of Convolution Neural Networks by Insignificant Filter Removal, In *ROMANIAN JOURNAL OF INFORMATION SCIENCE AND TECHNOLOGY*, Vol. 25, Issue 2.

Halaman ini sengaja dikosongkan.