

Penentuan Learning Rate Terbaik CNN pada Pengenalan Individu Berbasis Analisis Gait

Septian Enggar Sukmana^{*1}, Deasy Sandhya Elya Ikawati², Habibie Ed Dien³, Ashafidz Fauzan Dianta⁴

^{1,2,3}Jurusan Teknologi Informasi, Politeknik Negeri Malang

⁴Departemen Teknologi Multimedia Kreatif, Politeknik Elektronika Negeri Surabaya

e-mail: ¹enggar@polinema.ac.id, ²deasysandhya@polinema.ac.id, ³habibie@polinema.ac.id,

⁴ashafidz.fauzan@pens.ac.id

*Penulis Korespondensi

Diterima: 18 Februari 2023; Direvisi: 20 Juni 2023; Disetujui: 23 Juni 2023

Abstrak

Trayektori tubuh manusia untuk analisis gait tidak terbatas pada kondisi permukaan medan yang rata. Hal ini berpengaruh pada analisis gait untuk penelitian pengenalan identitas individu yang terkait dengan kondisi medan yang dilalui. Pergelangan kaki menjadi bagian tubuh yang berkontribusi pada trayektori tubuh manusia terhadap medan yang dilalui melalui dua kondisi yaitu Heel-Strike (HS) dan Toe-Off (TO). HS dan TO memiliki pola trayektori yang saling berbeda untuk setiap individu sehingga membutuhkan penentuan parameter learning rate yang tepat. Penentuan learning rate terbaik merupakan salah satu langkah penting dalam menghasilkan pengenalan identitas individu terbaik. Hal ini penting karena kesesuaian antara data training dengan data testing diperlukan untuk klasifikasi data. Pada kegiatan penelitian ini, data yang digunakan adalah data berformat C3D yang direkam melalui perangkat motion capture dengan skenario berjalan lurus (WS/Walking Straight) oleh enam orang sebagai partisipan. Penentuan learning rate terbaik menggunakan metode convolutional neural network (CNN) dengan pretrain pembanding adalah ResNet18 dan ResNet50. Percobaan yang dilakukan menghasilkan performa terbaik diperoleh ResNet18 baik pada pengukuran Average Position (AP) maupun pendeteksian kondisi HS dan TO.

Kata kunci: gait event detection, penentuan learning rate, convolutional neural network, pola trayektori

Abstract

Human body trajectory for gait analysis is not limited to flat surface. It impacts to gait analysis for person identity recognition research activity that relates to any surfaces which is passed by that person. Ankle is one of human body part that contributes to its trajectory pattern which is different to each individual so it needs correct learning rate parameter tuning. Heel-Strike (HS) and Toe-Off (TO) are kind of lower human body trajectory event. These events detection requires correct learning rate determining. In this activity, we use C3D from motion capture device as data. The data is collected by using six participants to demonstrate Walking Straight (WS) scenario. Convolutional neural network (CNN) is implemented to find the best learning rate. In addition, ResNet18 and ResNet50 are utilized to be pretrain comparators. The result shows that the best perform to determine learning rate is obtained by ResNet18 in Average Position (AP) measurement and HS-TO event detection.

Keywords: gait event detection, learning rate determining, convolutional neural network, trajectory pattern

1. PENDAHULUAN

Klasifikasi membutuhkan data testing yang selaras terhadap data trainingnya. Keselarasan ini disesuaikan dengan fitur-fitur data yang dibutuhkan proses klasifikasi yang dijalankan. Fitur-fitur pada domain frekuensi menjadi penting untuk diselaraskan karena kemiripan data dapat sulit diidentifikasi jika frekuensi yang dianalisis terlalu Panjang sedangkan frekuensi dalam panjang gelombang yang pendek dapat mengakibatkan hasil analisis secara parsial kurang akurat. Hal ini juga berlaku pada analisis data gaya berjalan (gait). Analisis pola berjalan dalam satu siklus tidak dapat dilakukan secara parsial. Tantangan lainnya adalah perbedaan pola pada setiap partisipan sehingga penyelarasan data untuk klasifikasi sangat diperlukan, terutama untuk kasus data testing dan data training. Hal ini berfungsi untuk menghasilkan nilai akurasi yang lebih baik [8].

Penerapan analisis gait pada pengenalan identitas individu semakin berkembang hingga saat ini. Berbagai macam metode diperkenalkan sebagai bentuk kontribusi perbaikan hasil pengenalan individu tersebut. Metode yang umumnya diterapkan adalah metode-metode yang terkait dengan jaringan syaraf tiruan dan *Deep Learning*. Liao et.al[1] menerapkan *convolutional neural network* (CNN) untuk melakukan estimasi komposisi tubuh yang ideal. Penerapan *Deep Learning* pada analisis gait juga dilakukan oleh Cosma dan Radoi [2] untuk skenario gait yang kooperatif. Hal yang penting pada pengenalan identitas individu berbasis analisis gait ini adalah pendeteksian kejadian penting dari suatu trayektori tubuh manusia seperti *Toe-Off* (TO) dan *Heel-Strike* (HS) yang dilakukan pada kaki bagian bawah yaitu tumit sampai ujung depan jari kaki. Pendeteksian TO dan HS ini penting dalam rangka pengembangan sistem identitas individu yang lebih baik khususnya pada kasus gaya berjalan manusia di permukaan daratan yang tidak rata. Beberapa kegiatan penelitian telah melibatkan kondisi permukaan daratan yang tidak rata, seperti penggunaan data sensor *gyroscope* sebagai pengembangan baru analisis gait[3], pelacakan orang pada kondisi keramaian di tempat yang berbeda[4], analisis trayektori gaya berjalan naik dan turun tangga[5], serta analisis trayektori pada olahraga ice hockey[6]. Namun, kegiatan-kegiatan penelitian tersebut belum menjelaskan dengan rinci strategi penentuan learning rate yang digunakan.


Salah satu komponen penting yang digunakan oleh metode-metode yang diterapkan untuk pengenalan identitas individu berbasis analisis gait adalah learning rate . Learning rate berfungsi sebagai sebuah parameter untuk training sebagai penghitung jumlah langkah pada setiap iterasi untuk mendapatkan nilai yang paling minimal pada loss function [7]. Hal ini didasarkan pada upaya pencapaian suatu learning rate ditunjukkan melalui vektor gradien yang bernilai negatif yang mengindikasikan bahwa nilai learning rate terbaik berusaha mencapai nilai minimum yaitu nilai error pada output memiliki nilai rata-rata yang rendah [8]. Pemilihan learning rate terbaik tentu berdampak pada hasil akurasi suatu klasifikasi data gait untuk pengenalan identitas individu [9]. Secara lebih jauh, fungsi learning rate adalah untuk menguatkan komponen-komponen penting yang terdapat pada data masukan serta mengurangi keterlibatan varian-varian yang tidak relevan pada saat pengolahan data [10]. Hal ini juga berlaku pada learning rate di convolutional neural network (CNN) yang diterapkan pada pengolahan data gait yang dilakukan pada kegiatan penelitian ini. Keberagaman data koordinat titik yang dihasilkan dari perekaman data pergerakan tubuh manusia menjadikan setiap bagian tubuh memiliki penanganan yang unik dalam menentukan learning rate terbaik. Hal ini diperkuat oleh kondisi pola trayektori yang berbeda pada setiap anggota tubuh manusia dan juga berbeda pada antar individu [11]. Oleh karena itu, penentuan learning rate untuk HS dan TO menjadi sebuah tantangan dan menjadi langkah awal penelitian yang menarik karena bagian tubuh terjadinya HS dan TO adalah bagian tubuh yang menjadi titik tumpu trayektori kaki manusia pada medan yang dilalui [12].

Paper ini membahas skenario pemilihan learning rate terbaik pada CNN untuk kasus pendeteksian terjadinya HS dan TO. Kegiatan penelitian yang dibahas pada paper ini merupakan sebuah studi awal untuk pengembangan sistem pengenalan identitas individu berbasis analisis gait yang berfokus pada medan yang dilalui. Data trayektori yang digunakan pada penelitian ini

adalah data yang dihasilkan dari perangkat motion capture karena data trayektori dari video masih menyisakan noise yang dapat mempengaruhi penentuan learning rate terbaik [13].

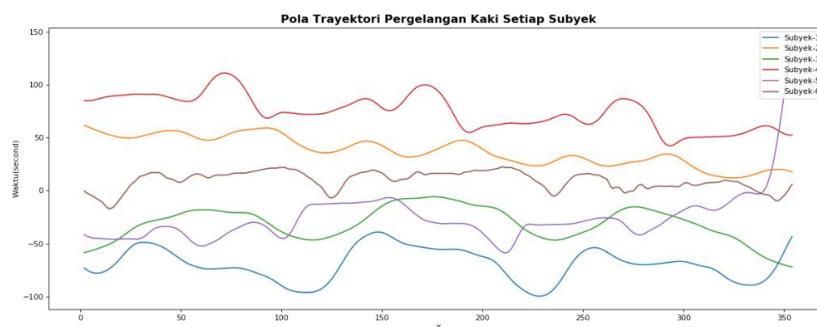
2. METODE PENELITIAN

Percobaan yang dilakukan pada kegiatan penelitian ini melibatkan enam subyek partisipan yang terbagi menjadi tiga orang subyek berjenis kelamin laki-laki dan tiga orang subyek lainnya berjenis kelamin perempuan. Seluruh partisipan merupakan subyek yang berbadan sehat dengan rentang usia antara 19-21 tahun dan tidak memiliki catatan permasalahan kesehatan yang terkait kaki dan pergerakannya. Perekaman data dilakukan melalui perangkat motion capture, setiap partisipan mengenakan pakaian khusus dengan enam belas buah sensor melekat di pakaian tersebut (gambar 1). Untuk mencegah rasa ketidaknyamanan pada setiap partisipan yang berakibat pada kurang validnya data yang diperoleh maka setiap partisipan melakukan percobaan sebanyak 5 kali sebagai pembiasaan. Perekaman data dilakukan setelah aktivitas pembiasaan, hasil perekaman data menghasilkan tiga buah data untuk setiap partisipan sehingga total data yang digunakan pada kegiatan penelitian ini sebanyak delapan belas buah data. Komposisi data latih dan data uji terdiri dari satu buah data latih dan dua buah data lainnya digunakan sebagai data uji. Titik gait yang digunakan pada penelitian ini juga terbatas pada titik pergelangan kaki (ankle) karena titik ini merupakan titik yang paling dekat dengan terjadinya TO dan HS. Percobaan yang dilibatkan pada kegiatan ini terbatas pada berjalan lurus/walking straight (WS). Pada aktivitas penghimpunan dataset, label HS dan TO dilakukan melalui penentuan vektor probabilitas dalam bentuk distribusi Gaussian satu dimensi pada setiap titik ankle yang berasosiasi dengan kejadian HS dan TO [14].



Gambar 1. Pola trayektori pada pergelangan kaki kiri dan kanan

Bentuk data yang diolah kegiatan penelitian ini adalah pola trayektori pada setiap titik pergelangan kaki. Penggunaan data *motion capture* mempermudah percobaan yang dilakukan karena label setiap titik pergelangan kaki telah terdefinisi dengan jelas. Pengamatan terhadap terjadinya HS dan TO pada setiap titik pergelangan kaki dilakukan melalui pola trayektori pada setiap sumbu koordinat x, y, dan z (gambar 2). Pola trayektori merupakan pola dari deret nilai koordinat setiap sumbu x, y, dan z pada setiap subyek.



Gambar 2. Contoh ekstraksi sumbu x pada setiap subyek pada kaki kiri

Untuk mengetahui distribusi probabilitas antara data uji dengan data latih, penentuan skoring pada nilai deret pada setiap sumbu koordinat dilakukan dengan skema penentuan nilai. Penentuan skoring untuk data gait juga pernah dilakukan oleh Shehata et.al[15] untuk estimasi atribut pada gait. Nilai +2 diberikan untuk nilai deret yang naik (bergerak ke arah positif) dari suatu waktu (detik) tertentu terhadap waktu berikutnya, nilai +1 diberikan untuk kondisi sebaliknya. Rata-rata dari skoring ini yang akan diolah untuk menemukan distribusi probabilitas. Fitur untuk pengolahan data mengacu pada nilai deret setiap pola trayektori.



Gambar 3. Skema CNN untuk pengolahan data gait pada penelitian ini

Fitur-fitur yang diperoleh pada tahap ekstraksi data kemudian diolah menggunakan metode *convolutional neural network* (CNN) (gambar 3). Penerapan CNN melibatkan layer konvolusi dengan ukuran 1x1. Proses pengolahan pada layer konvolusi 1x1 dilanjutkan ke blok konvolusi sejumlah tujuh buah blok dimana setiap blok konvolusinya berisi layer konvolusi 3x3, normalisasi *batch*, fungsi *Rectified Linear Unit* (ReLU), dan layer *max-pooling* (gambar 4). Korespondensi antara frame pada data masukan dengan hasil *learning* untuk kondisi HS dan TO pada setiap kaki dilakukan pada layer *fully-connected* (FC). ResNet18 dan ResNet15 diterapkan sebagai model percobaan untuk mengetahui tingkat keberhasilan dari penerapan CNN yang dilakukan pada kegiatan ini.




Gambar 4. Urutan proses pada *convolution block*

Pra-pengolahan data dilakukan dengan melibatkan tensor masukan berupa informasi koordinat trayektori titik gait yang digunakan (titik gait lainnya tidak digunakan). Tidak ada kegiatan khusus dalam melakukan pra-pengolahan data. *Dataset* dibagi menjadi dua jenis yaitu data dua partisipan dari setiap jenis kelamin sebagai data uji dan data satu partisipan dari setiap jenis kelamin. Data yang digunakan untuk validasi melibatkan satu data uji dan satu data latih pada setiap jenis kelamin. Kegiatan pelatihan data menggunakan bobot CNN untuk setiap empat kondisi gait (TO pada kaki kiri dan kanan serta HS pada kaki kiri dan kanan). Nilai *learning rate* yang digunakan adalah 0,0001 dengan skenario pengurangan *learning rate* sebanyak dua kali setiap tiga epoch. Evaluasi hasil percobaan pada kegiatan ini menggunakan *Average Precision* (AP) yang berfungsi untuk mengukur keakuratan yang terjadi di antara perbedaan antara frame target dengan frame prediksi. Batasan (*threshold*) untuk menentukan kondisi HS dan TO yang tepat adalah perbedaan frame antara target dan prediksi kurang dari empat frame seperti yang diterapkan oleh Jamsrandorj dkk. [16].

3. HASIL DAN PEMBAHASAN

Kegiatan percobaan yang dilaksanakan pada penelitian ini melibatkan enam data subyek sehat (tidak ada riwayat sakit pada bagian kaki) yang terdiri dari tiga subyek laki-laki dan tiga subyek perempuan, data yang direkam diperoleh dari tiga kali percobaan untuk setiap subyek sehingga total data yang diperoleh ada delapan belas buah data. Setiap data subyek memiliki satu siklus gait yang terdiri dari 550-600 buah frame. Berdasarkan jenis data gait yang digunakan pada kegiatan ini yaitu data c3d, maka tidak ada sudut pandang khusus yang dipakai sebagai acuan

penentuan titik koordinat x, y, dan z. Analisis probabilitas pada gambar 5 menunjukkan contoh hasil penerapan CNN bahwa model yang diujikan mampu menyesuaikan frame secara presisi ketika HS dan TO terjadi.



Gambar 5. Distribusi probabilitas jenis jalan lurus (*walking straight*) pada gait event: a) *Toe Off* pada kaki kiri; b) *Heel Strike* pada kaki kanan

Tabel 1 menunjukkan performa dari penerapan beberapa model CNN yang digunakan pada kegiatan ini. RestNet18 masih menunjukkan hasil performa terbaik pada setiap data yang diuji walaupun nilai performa yang dihasilkan masih di bawah Jamsrandorj dkk[16]. Penggunaan C3D pada ResNet50 ini menunjukkan hasil performa yang masih kurang dibandingkan CNN dan ResNet18, namun demikian nilai performa dari ResNet50 ini masih dapat dikatakan baik karena nilai probabilitas sebagai standar nilai performa menunjukkan nilai lebih dari 0,8.

Tabel 1. Hasil Pengukuran Performa Deteksi HS dan TO menggunakan *Average Precision* (AP)

Model	Hasil
ResNet18	0,92
ResNet50	0,89
CNN	0,90

Hasil deteksi HS dan TO pada setiap model yang diujikan ditunjukkan pada Tabel 2. Hasil ini diperoleh dari implementasi *Average Precision* (AP). Hasil yang ditunjukkan dalam bentuk skala probabilitas menunjukkan bahwa tidak terdapat selisih yang besar antara kaki kiri dengan kanan, nilai hasil dengan angka di atas 0,8 menunjukkan bahwa deteksi pada kedua kaki oleh setiap model berhasil dicapai dengan baik. Berdasarkan rata-rata yang dihasilkan pada setiap kaki, kaki kiri cenderung memiliki hasil yang lebih konsisten daripada kaki kanan sebagai akibat hasil deteksi kaki kanan menapak (*right heel strike/RHS*) lebih tinggi dibandingkan hasil deteksi kaki kiri menapak (*left heel strike/LHS*). Kondisi sebaliknya terjadi pada deteksi kaki kiri mengayun (*left toe off/LTO*) yang menunjukkan hasil lebih tinggi dibandingkan deteksi kaki kanan mengayun (*right toe off/RTO*).

Tabel 2 Perbandingan Hasil Deteksi HS dan TO pada gerak jalan lurus (*Walking Straight/WS*)

Model	RTO	RHS	LTO	LHS	Rata-rata
ResNet18	0,87	0,93	0,87	0,85	0,88
ResNet50	0,80	0,91	0,86	0,88	0,86
CNN	0,82	0,83	0,83	0,82	0,82
Rata-rata	0,83	0,89	0,85	0,85	

Hal menarik yang dapat ditemukan pada hasil kegiatan penelitian ini adalah hasil deteksi pada setiap model memiliki nilai rata-rata yang lebih rendah daripada hasil pengukuran performa. Walaupun korelasi antara dua hal ini perlu diteliti lebih lanjut, namun pola kedua hasil ini

menunjukkan kondisi yang berbeda. Hasil pengukuran performa menunjukkan hasil pada CNN lebih tinggi daripada ResNet50, namun pada hasil deteksi menunjukkan kondisi yang berbeda yaitu hasil pada CNN menunjukkan nilai yang lebih kecil daripada ResNet50 bahkan menjadi nilai hasil terkecil di antara model yang lain. ResNet18 masih menjadi model dengan perolehan nilai tertinggi di antara model yang lain. Pada kegiatan penelitian ini diketahui bahwa jumlah deep layer suatu model tidak menjamin hasil deteksi dan performa yang lebih baik.

4. KESIMPULAN DAN SARAN

Kegiatan penelitian ini menunjukkan TO dan HS dapat terdeteksi dengan baik pada setiap kaki yang dibuktikan dengan nilai rata-rata hasil deteksi lebih dari 0,80. Keberhasilan deteksi TO dan HS ini juga dibuktikan melalui hasil pengukuran performa dan kesesuaian model dengan data yang diuji. Hasil pada kegiatan penelitian ini juga menunjukkan bahwa jumlah layer yang lebih banyak tidak selalu menjamin hasil yang lebih baik melalui nilai hasil deteksi dan pengukuran performa ResNet18 yang selalu di atas ResNet50.

Kegiatan penelitian ini merupakan studi awal (*preliminary study*), variabel dan model yang masih terbatas perlu ditambah untuk mendapatkan hasil yang lebih akurat serta temuan-temuan yang muncul dapat menjadi bahan strategi yang tepat untuk mencapai pengembangan deteksi individu melalui gait yang lebih akurat dan reliabel.

Percobaan menggunakan medan yang tidak landai seperti jalan yang berbatu atau berlumpur perlu dilakukan supaya studi pada penelitian ini menjadi lebih reliabel. Hal ini penting karena sistem deteksi individu melalui gait juga perlu diterapkan ke tempat-tempat selain perkotaan. Untuk percobaan pada jalan yang tidak landai tersebut diperlukan teknik dan prosedur khusus jika menggunakan data berbasis *motion capture* karena derau juga mungkin muncul pada saat perekaman data. Hal lain yang mungkin dilakukan adalah deteksi TO dan HS berbasis *computer vision*, namun strategi yang berbeda seperti pengaturan pemasangan sensor kamera perlu dilakukan. Uji coba terhadap jenis subyek yang berbeda seperti disabilitas atau subyek dengan perawatan pemulihan dari cedera kaki perlu menjadi studi lanjutan untuk penelitian ini. *Recurrent neural network* (RNN) perlu dilibatkan pada studi berikutnya karena data yang digunakan pada kegiatan ini merupakan data berbentuk deret nilai.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada UPT P2M Politeknik Negeri Malang yang telah memberi dukungan financial terhadap penelitian ini melalui Dana Hibah Swadaya Reguler Kompetisi.

DAFTAR PUSTAKA

- [1] R. Liao, K. Moriwaki, Y. Makihara, D. Muramatsu, N. Takemura, and Y. YAGI, "Health indicator estimation by video-based gait analysis," *IEICE Trans. Inf. Syst.*, vol. E104D, no. 10, pp. 1678–1690, 2021, doi: 10.1587/transinf.2020ZDP7502.
- [2] A. Cosma and I. E. Radoi, "Wildgait: Learning gait representations from raw surveillance streams," *Sensors*, vol. 21, no. 24, 2021, doi: 10.3390/s21248387.
- [3] R. Caldas, M. Mundt, W. Potthast, F. Buarque de Lima Neto, and B. Markert, "A systematic review of gait analysis methods based on inertial sensors and adaptive algorithms," *Gait Posture*, vol. 57, no. February, pp. 204–210, 2017, doi: 10.1016/j.gaitpost.2017.06.019.
- [4] S. V. A. Kumar, E. Yaghoubi, A. Das, B. S. Harish, and H. Proenca, "The P-DESTRE: A

- Fully Annotated Dataset for Pedestrian Detection, Tracking, and Short/Long-Term Re-Identification from Aerial Devices,” *IEEE Trans. Inf. Forensics Secur.*, vol. 16, pp. 1696–1708, 2021, doi: 10.1109/TIFS.2020.3040881.
- [5] Z. Deng, P. Wang, D. Yan, and K. Shang, “Foot-Mounted Pedestrian Navigation Method Based on Gait Classification for Three-Dimensional Positioning,” *IEEE Sens. J.*, vol. 20, no. 4, pp. 2045–2055, 2020, doi: 10.1109/JSEN.2019.2949060.
- [6] B. J. Stetter, E. Buckeridge, S. R. Nigg, S. Sell, and T. Stein, “Towards a wearable monitoring tool for in-field ice hockey skating performance analysis,” *Eur. J. Sport Sci.*, vol. 19, no. 7, pp. 893–901, 2019, doi: 10.1080/17461391.2018.1563634.
- [7] H. Wang, C. Xiao, J. Kossaifi, Z. Yu, A. Anandkumar, and Z. Wang, “AugMax: Adversarial Composition of Random Augmentations for Robust Training,” no. NeurIPS, pp. 1–14, 2021, [Online]. Available: <http://arxiv.org/abs/2110.13771>.
- [8] A. Loukas, M. Poiitis, and S. Jegelka, “What training reveals about neural network complexity,” no. NeurIPS, 2021, [Online]. Available: <http://arxiv.org/abs/2106.04186>.
- [9] G. Giorgi *et al.*, “Walking Through the Deep : Gait Analysis for User Authentication Through Deep Learning,” pp. 0–14, 2019.
- [10] M. Yatsura, J. H. Metzen, and M. Hein, “Meta-Learning the Search Distribution of Black-Box Random Search Based Adversarial Attacks,” no. NeurIPS, pp. 1–15, 2021, [Online]. Available: <http://arxiv.org/abs/2111.01714>.
- [11] Y. Luo, S. M. Coppola, P. C. Dixon, S. Li, J. T. Dennerlein, and B. Hu, “A database of human gait performance on irregular and uneven surfaces collected by wearable sensors,” *Sci. Data*, vol. 7, no. 1, pp. 1–9, 2020, doi: 10.1038/s41597-020-0563-y.
- [12] H. G. Chambers and D. H. Sutherland, “A practical guide to gait analysis.,” *J. Am. Acad. Orthop. Surg.*, vol. 10, no. 3, pp. 222–231, 2002, doi: 10.5435/00124635-200205000-00009.
- [13] O. Elharrouss, N. Almaadeed, S. Al-Maadeed, and A. Bouridane, “Gait recognition for person re-identification,” *J. Supercomput.*, vol. 77, no. 4, pp. 3653–3672, 2021, doi: 10.1007/s11227-020-03409-5.
- [14] J. a Blaya, H. M. Herr, T. Supervisor, D. J. Newman, W. C. Flowers, and A. Sonin, “Force-Controllable Ankle Foot Orthosis (AFO) to Assist Drop Foot Gait,” *Mech. Eng.*, no. June, 2003.
- [15] A. Shehata, Y. Hayashi, Y. Makihara, D. Muramatsu, and Y. Yagi, “Does My Gait Look Nice? Human Perception-Based Gait Relative Attribute Estimation Using Dense Trajectory Analysis,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 12047 LNCS, no. February, pp. 90–105, 2020, doi: 10.1007/978-3-030-41299-9_8.
- [16] A. Jamsrandorj, M. D. Nguyen, M. Park, K. S. Kumar, K. R. Mun, and J. Kim, “Vision-Based Gait Events Detection Using Deep Convolutional Neural Networks,” *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS*, pp. 1936–1941, 2021, doi: 10.1109/EMBC46164.2021.9630431.
-