

Klasifikasi *Human Activity Recognition* Menggunakan Metode CNN

Adil Abdul Hakim

Universitas Muhammadiyah Malang

adil.abd.h.ah@gmail.com

Abstrak

Manusia tidak bisa dilepaskan dari kegiatan kesehariannya yang mana itu merupakan bagian dari aktivitas kehidupan keseharian. *Human Activity Recognition* atau biasa dikenal pengenalan aktivitas manusia saat ini sudah dapat diteliti seiring dengan pesatnya kemajuan di bidang dunia Teknologi yang berkembang saat ini, yang mana lebih banyak dikenal dengan salah satu bagian dari *Artificial Intelligence*. Aktivitas fisik manusia adalah keadaan tubuh seperti tidur, berjalan, berbaring, makan, jogging dan berdiri.

Kata Kunci: *Human Activity Recognition, Artificial Intelligent*

Abstract

Humans cannot be separated from their daily activities which are part of the activities of daily life. *Human Activity Recognition* or commonly known as the introduction of human activity can now be researched along with the rapid progress in the field of technology that is currently developing, which is more commonly known as one part of *Artificial Intelligence*. Human physical activity is a state of the body such as sleeping, walking, lying down, eating, jogging and standing.

Keywords: *Human Activity Recognition, Artificial Intelligent*

1. Pendahuluan

Tugas pengenalan aktivitas manusia telah sangat menarik para pakar teknologi pemahaman berbasis data sains komunitas riset karena memiliki potensi revolusioner dalam pemantauan kesehatan jarak jauh, kebugaran pribadi, dan banyak lagi bidang lainnya [1]. Pendekatan pengenalan Aktivitas Manusia dapat dikategorikan secara luas menjadi sebuah pemahaman yang disebut *Human Activity recognition* [2].

Berbasis sensor metode pengenalan bekerja berdasarkan prinsip pemrosesan data direkam oleh sensor yang dapat disematkan [2]. Misalnya untuk memantau lansia atau orang cacat di bawah skenario di mana bantuan segera dari pengasuh, sensor yang bisa dipakai tertanam dalam gelang olahraga atau jam tangan pintar dapat menyediakan data yang berguna tentang aktivitas individu tersebut [3]. Data diperoleh dari sensor yang digunakan biasanya berguna untuk memantau kondisi individu tersebut dan untuk menentukan apakah suatu ada perbaikan segera diperlukan [4].

Convolution Neural network (CNN) merupakan salah satu jenis algoritma yang termasuk dalam *Deep learning* karena dapat menganalisis data set yang besar secara akurat [5]. *Convolution neural network* adalah model yang dapat digunakan dalam pengenalan aktivitas manusia (HAR) yang digambarkan melalui teknik jaringan saraf yang sangat kuat yaitu jaringan saraf convolutional untuk memodelkan fitur secara efektif [6].

Dalam banyak implementasinya pun tak jarang CNN digabungkan dengan metode lain, dan metode yang banyak sering digunakan dalam penggabungan ataupun pendekatannya yaitu metode LSTM serta ada pula yang membandingkan keduanya, dengan dimodifikasi guna mendukung penelitiannya. Seperti pada penelitian yang dilakukan oleh Kun Wang [7].

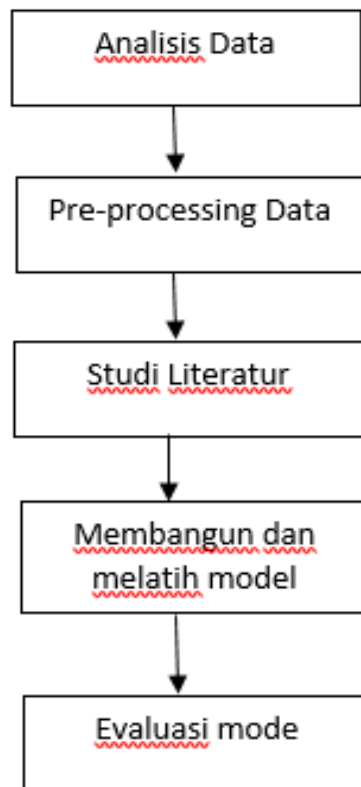
Dalam kerangka penelitian ini, menggunakan data public machine learning UCI-HAR Dataset yang mengacu data hasil dari *Accelerometers* dan *Gyroscope* yang disematkan di smartphone untuk mengekstrak fiturnya pengenalan aktivitas. Untuk mendapatkan output klasifikasi aktivitas manusia menggunakan mobile sensor yang dipasang pada smartphone android, Informasi yang dikumpulkan dari sensor menggunakan sensor *Accelerometers* dan *Gyroscope*. Pengolahan data akan dilanjutkan dengan menggunakan pendekatan *Convolutional Neural Networks (CNN)* [7]. Metode yang diusulkan dengan menambahkan menggunakan

hyperparameter yang ditambah dengan fitur dropout diharapkan dapat mencapai tingkat tingkat akurasi yang lebih baik dari penelitian sebelumnya serta mengurangi terjadinya overfitting [10].

2. Metode Penelitian

2.1 Method

Beberapa tahapan yang digunakan dalam metode ini untuk mendukung metode yang diusulkan yaitu dengan Convolutional Neural Network (CNN) dalam penelitian terangkum dan dapat dilihat pada Gambar 1.

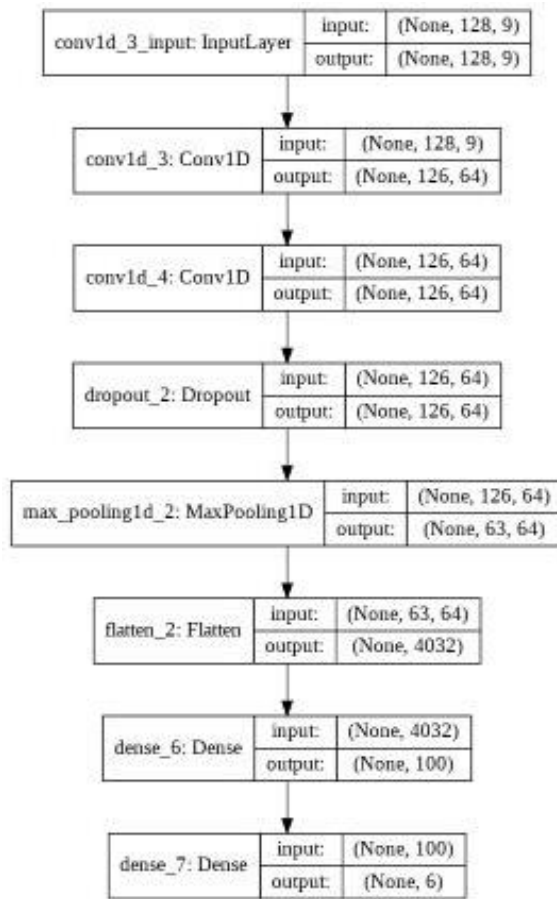


Gambar 1. Diagram alur penelitian

Dalam makalah ini Gambar 1 kami bertujuan untuk menyelesaikan aktivitas dalam dataset HAR. Dalam dataset ini terdapat 563 fitur yang menyertakan label subjek dan aktivitas pada setiap baris data. kami juga menggunakan fitur tanpa pengurangan ataupun pemilihan fitur. Fitur dari kumpulan data HAR diberi label dengan encoder label dan diubah ke setiap baris dalam data.

2.2 Membangun dan Melatih model CNN

Hyperparameter dan arsitektur CNN dilakukan dengan mempertimbangkan bahwa semakin kompleks modelnya, semakin rendah kemungkinan terjadinya overfitting, terutama saat pelatihan dengan dataset berukuran kecil, atau dengan data yang tidak mewakili aktivitas target secara universal [3]. struktur CNN dalam penelitian ini terdiri dari convolution layer, max-pooling layer, fully connected layer dan softmax. Fungsi dropout juga digunakan dalam arsitektur ini, Dropout sendiri merupakan teknik regulasi untuk permasalahan dalam overfitting [9]. Oleh karena itu, evaluasi model yang sesuai dengan kombinasi dari hyperparameter tersebut secara berurut dilakukan mulai dari model sederhana dan kemudian secara bertahap meningkatkan kompleksitas untuk mencari hasil yang optimal antara akurasi dan kompleksitas model. Untuk model tahapan dalam arsitektur ini dapat dilihat seperti pada Gambar 2. Perbandingan mengevaluasi pengaruh jumlah layer.



Gambar 2. Model

Terdapat beberapa tahapan dalam model pengolahan metode CNN terhadap dataset pada penelitian ini guna memaksimalkan hasil akhir dari penelitian dan mendapatkan hasil akurasi terbaik. Python digunakan sebagai bahasa pemrograman dalam mengimplementasikan dalam penelitian ini, menggunakan beberapa package dan library seperti Tensorflow dan keras. Dari seluruh aktifitas manusia yang menerapkan sensor *Accelerometers* dan *Gyroscope* yang terdapat pada *smartphone*. Layer hyperparameter yang digunakan didukung dengan pengoptimalan *Adam* di dalamnya. Batch size di angka 100 dan epoch di angka 60 Konfigurasi hyperparameter single head metode CNN dapat dilihat pada Gambar 3.

Layer	Parameter
<u>Pengoptimalan</u>	Adam
Batch size	100
Epoch	60
Model compile	<u>crossentropy</u>

Gambar 3. Tabel hyperparameter CNN

3. Hasil Penelitian dan Pembahasan

Pada bagian ini, kami menyajikan hasil eksperimental yang ddi peroleh dalam deteksi aktivitas berdasarkan dataset publik. Performa tersebut diukur dari akurasi dan matriks konfusi dari metode CNN. Kami pertama kali melakukan perkenalkan pelatihan dan kumpulan data sebelum kami membandingkan dan menganalisis akurasi pengenalan beberapa pengklasifikasi. Dalam makalah ini, kami meverifikasi kinerja pendekatan baru yang kami maksudkan untuk meningkatkan CNN dengan penyetelan parameter.

3.1 Splitting Data Train dan Test

Penelitian ini merupakan pengembangan dari penelitian sebelumnya, Dalam penelitian tersebut dilakukan pengumpulan data aktivitas dengan menggunakan metode Convolutional Neural Network. Dataset UCI HAR merupakan sebuah rekaman kegiatan sehari-hari dalam percobaan telah dilakukan dengan 30 sukarelawan dalam kelompok 19-48 tahun. Setiap orang melakukan 6 aktivitas yaitu berjalan, naik tangga, turun tangga, duduk, berdiri, tidur. Dengan menggunakan Smartphone (Samsung Galaxy S II) di bagian pinggang dengan menggunakan Accelerometer dan Gyroscope. Data dari sensor ini di rekam menjadi 3 sumbu lurus dan sumbu kecepatan sudut pada sinyal konstan 50Hz. Dataset yang didapat telah dibagi secara acak menjadi 70% sebagai data training dan 30% sebagai data test.


Label encoder dan transformasi data digunakan dalam makalah ini, akurasi yang meningkat secara signifikan di setiap metode *Machine Learning*. Data yang telah ditransformasikan pada Langkah sebelumnya digunakanya untuk mendapatkan *parameter* terbaik. Dalam Langkah *training* dan *testing*, tidak digunakan *Feature Selection* ataupun *Feature Reduction*. Dari total 563 fitur hanya dilakukan pemisahan pada fitur *subject* dan *activity*.

3.2 Karakteristik Dataset

Dataset yang digunakan dalam penelitian ini adalah berupa dataset publik HAR dari UCI machine learning yaitu 6 aktivitas dari kumpulan subjek aktivitas yaitu berdiri, duduk, tidur, berjalan, naik tangga dan turun tangga [10]. Dataset UCI berisi dari nilai yang di dapat dari sensor *Accelerometers* dan *Gyroscope* yang terdapat pada *smartphone*. Dari setiap sensor memiliki tiga sumbu *x,y,z* yang mana menghasilkan data time series, data dari hasil keseluruhan digabung dan dan nantinya menjadi kelompok data *train* dan data *test*, yang mana data train 70% dan data test 30%. Informasi mengenai data aktivitas dilihat pada Gambar 4 dan Gambar 5.


<u>Aktivitas</u>	<i>train data</i>	<i>test data</i>
Walking	1226	496
Upstair	1073	471
Downstair	987	420
Sitting	1228	491
Standing	1374	532
Laying	1407	537

Gambar 4. Sebaran data Per aktivitas




Gambar 5. Sebaran data aktifitas dalam data diagram


Dataset lalu dilakukan pengurangan dimensi menggunakan *autoencoder*. Autoencode adalah sebuah jaringan Neural Network yang dilatih untuk menyalin input maupun outputnya [9]. Dengan menggunakan mengurangi dimensi dari fitur. Autoencode dapat menjadikan sebuah dataset lebih ringan dalam penerapan kedalam model. Hasil dari proses encorder menggunakan t-SNE pada Gambar 6, Gambar 7, Gambar 8, Gambar 9, Gambar 10




Gambar 6. Visualisasi hasil penggunaan t-SNE Perplexity : 2 dan max iterasi : 1000




Gambar 7. Visualisasi hasil penggunaan t-SNE Perplexity : 5 dan max iterasi : 1000



Gambar 8. Visualisasi hasil penggunaan *t*-SNE Perplexity : 10 dan max iterasi : 1000



Gambar 9. Visualisasi hasil penggunaan *t*-SNE Perplexity : 20 dan max iterasi : 1000



Gambar 10. Visualisasi hasil penggunaan *t*-SNE Perplexity : 20 dan max iterasi : 1000

3.3 Perbandingan Dengan Penelitian Sebelumnya

Penelitian-penelitian sejenis telah banyak dilakukan oleh banyak pihak oleh karena itu penelitian terdahulu dapat digunakan menjadi acuan pembelajaran dalam penelitian ini. Beberapa penelitian terdahulu yang menjadi dasar dari penelitian pada Tabel 1 berikut.

No.	Nama Peneliti	Tahun	Judul	Hasil
1.	Kun Wang, Jun He, Lei Zhang	2019	Attention-Based Convolutional Neural Network for Weakly Labeled Human Activities' Recognition With Wearable Sensors	Hasil dari penelitian ini adalah pengujian antara penggunaan metode CNN dengan LSTM guna mendapatkan hasil akurasi terbaik dan hasil akurasi akhir dari kedua metode tersebut dengan menggunakan dataset UCI. CNN 93,21%, LSTM 93,54%
2.	H. Nematallah, S. Rajan	2020	Comparative Study of Time Series-based Human Activity Recognition using Convolutional Neural Networks	Hasil dari penelitian ini adalah pengumpulan data oleh sensor dipasang di dada dianggap, mengikuti hal yang sama metode segmentasi yang dijelaskan sebelumnya. M-Health dataset digunakan untuk evaluasi lintas dataset untuk memastikan bahwa kinerja sistem adalah platform dan pengguna independen. Dengan hasil akhir akurasi 93,09%
3.	Federico Cruciani, Anastasios Vafeiadis, Chris Nugent, Ian Cleland, Paul McCullagh, Konstantinos Votis, Dimitrios Giakoumis, Dimitrios Tzovaras, Liming Chen, Raouf Hamzaoui	2019	Feature learning for Human Activity Recognition using Convolutional Neural Networks	Hasil dari penelitian ini adalah pengoptimalan dari arsitektur lapisan convolutional dan ukuran kernel. Dengan hasil akurasi akhir 91,98%.

4. Kesimpulan

Teknologi dan aktivitas manusia menjadi acuan utama dalam banyaknya segmen pembelajaran khususnya penelitian dalam pengenalan gerak tubuh manusia seiring dengan berkembangnya teknologi yang mana menciptakan sensor yang dapat disematkan pada smartphone maupun smartwatch. Penelitian ini menggunakan satu dataset publik HAR dari UCI machine learning yaitu 6 aktivitas dari kumpulan subjek aktivitas yaitu berdiri, duduk, tidur, berjalan, naik tangga dan turun tangga. Dalam pengimplentasinya penelitian ini menggunakan sensor *Accelerometers* dan *Gyroscope* yang terdapat pada *smartphone*. Pada tahap pengerjaannya terdapat pula konfigurasi hyperparameter dengan fitur dropout pada model pada *Convolutional Neural Network* (CNN) guna mendapatkan hasil akhir penelitian dengan meminimalisir overfitting.[10]

Referensi

- [1] W. Ahmad, B. M. Kazmi, and H. Ali, "Human Activity Recognition using Multi-Head CNN followed by LSTM," *arXiv*, pp. 0–5, 2020.
- [2] H. Nematallah and S. Rajan, "Comparative study of time series-based human activity recognition using convolutional neural networks," *I2MTC 2020 - Int. Instrum. Meas. Technol. Conf. Proc.*, pp. 1–6, 2020, doi: 10.1109/I2MTC43012.2020.9128582.
- [3] F. Cruciani *et al.*, "Feature learning for Human Activity Recognition using Convolutional Neural Networks," *CCF Trans. Pervasive Comput. Interact.*, vol. 2, no. 1, pp. 18–32, 2020, doi: 10.1007/s42486-020-00026-2.
- [4] S. M. Lee, S. M. Yoon, and H. Cho, "Human activity recognition from accelerometer data using Convolutional Neural Network," *2017 IEEE Int. Conf. Big Data Smart Comput. BigComp 2017*, pp. 131–134, 2017, doi: 10.1109/BIGCOMP.2017.7881728.
- [5] A. Ignatov, "Real-time human activity recognition from accelerometer data using Convolutional Neural Networks," *Appl. Soft Comput. J.*, vol. 62, pp. 915–922, 2018, doi: 10.1016/j.asoc.2017.09.027.
- [6] J. Salminen, S. gyo Jung, J. An, H. Kwak, L. Nielsen, and B. J. Jansen, "Confusion and information triggered by photos in persona profiles," *Int. J. Hum. Comput. Stud.*, vol. 129, no. July 2018, pp. 1–14, 2019, doi: 10.1016/j.ijhcs.2019.03.005.
- [7] K. Wang, J. He, and L. Zhang, "Attention-based convolutional neural network for weakly labeled human activities recognition with wearable sensors," *arXiv*, vol. 19, no. 17, pp. 7598–7604, 2019.
- [8] K. Xia, J. Huang, and H. Wang, "LSTM-CNN Architecture for Human Activity Recognition," *IEEE Access*, vol. 8, pp. 56855–56866, 2020, doi: 10.1109/ACCESS.2020.2982225.
- [9] R. A. Putri and N. Rochmawati, "Penerapan Algoritma Support Vector Machine untuk Klasifikasi Motif Citra Batik Solo Berdasarkan Fitur Multi-Autoencoders," *J. Informatics Comput. Sci.*, vol. 01, pp. 56–63, 2019.
- [10] M. M. Hassan, M. Z. Uddin, A. Mohamed, and A. Almogren, "A robust human activity recognition system using smartphone sensors and deep learning," *Futur. Gener. Comput. Syst.*, vol. 81, pp. 307–313, 2018, doi: 10.1016/j.future.2017.11.029.