

# Penerapan metode hand gesture recognition dalam melakukan kontrol terhadap aplikasi powerpoint dan media player untuk kebutuhan online conference.

William Sean Wiyogo, Liliana

Program Studi Informatika Fakultas Teknologi Industri Universitas Kristen Petra

Jl. Siwalankerto 121 – 131 Surabaya 60236

Telp. (031) – 2983455, Fax. (031) – 8417658

E-mail: [williamsean123@yahoo.com](mailto:williamsean123@yahoo.com), [lilian@petra.ac.id](mailto:lilian@petra.ac.id)

## ABSTRAK

Semenjak pandemi COVID-19 yang berkepanjangan, sebagian besar aktivitas manusia digantikan dengan konsep *virtual meeting*. Konsep tersebut dibantu dengan penggunaan platform konferensi hybrid. Akibatnya, timbul kebutuhan-kebutuhan baru diantara masyarakat. Model pembelajaran pembelajaran hybrid atau pembelajaran campuran merupakan gabungan dari pembelajaran secara tatap muka dengan *e-learning*. Metode pembelajaran ini menurunkan performa mengajar akibat jarak gerak yang dibatasi. Dengan demikian, pengenalan gerakan tangan dapat dijadikan solusi untuk mengatasi masalah tersebut. Penelitian ini bertujuan untuk melakukan pemodelan sistem *gesture recognition* dengan penggabungan pengenalan statis dan dinamis.

Metode yang dimanfaatkan dalam penelitian ini adalah RT3D\_16F berbasis CNN yang digunakan sebagai prediksi gerakan dinamis serta pipeline Mediapipe hand yang digunakan sebagai prediksi gerakan statis. Dataset yang digunakan terdiri atas 27 label gerakan (termasuk 2 label gerakan yang seharusnya tidak dikenali sebagai gerakan tertentu).

**Kata Kunci:** Pengenalan gerakan tangan, RT3D\_16F, CNN, mediapipe, konferensi hybrid.

## ABSTRACT

*Since the prolonged COVID-19 pandemic, most human activities are seen with the concept of virtual meetings. This concept is helped by the use of an online conferencing platform. As a result, needs arise among the new society. The learning model of hybrid learning, or blended learning is a combination of face-to-face learning with e-learning. This learning method reduces teaching performance due to limited range of motion. Thus, hand tracking gesture recognition can be used as a solution to overcome this problem. This study aims to model a gesture recognition system with statistical and dynamic recognition.*

*The method used in this research is CNN-based RT3D\_16F which is used as dynamic motion prediction and Mediapipe hand pipeline which is used as static motion prediction. The data set used consists of 27 movement labels (includes 2 movement labels that shouldn't be recognized as specific moves).*

**Keywords:** *hand tracking gesture recognition, RT3D\_16F, CNN, mediapipe, online conference.*

## 1. PENDAHULUAN

Semenjak pandemi COVID-19 yang berkepanjangan, sebagian besar aktivitas manusia terganggu. Dengan tujuan untuk penurunan

penyebaran virus, maka proses tatap muka digantikan dengan *virtual meeting* menggunakan platform *online conference*. Pandemi ini memiliki dampak yang menghancurkan pada kehidupan manusia dan menghancurkan ekonomi di seluruh dunia [11]. Dunia pendidikan pun terkena imbasnya dan mengalami suatu turbulensi yang begitu hebatnya [6]. Maka dari itu munculah kebutuhan-kebutuhan baru diantara masyarakat. Platform online conference dimanfaatkan untuk menggantikan proses tatap muka contohnya pada proses belajar mengajar. Konsep pembelajaran *hybrid learning* berfokus pada optimalisasi pencapaian tujuan pembelajaran dengan menerapkan teknologi pembelajaran yang “benar” untuk mencocokkan pembelajaran yang “tepat” dengan orang yang “tepat” pada waktu yang “tepat” [7]. Meskipun begitu, kendala utama dalam konsep pembelajaran tersebut adalah penurunan performa pengajar dikarenakan jarak gerak yang terbatas dan pembagian fokus ke 2 arah berbeda.

Penelitian *gesture recognition* secara umum terbagi kedalam 2 metode: salah satunya didasarkan pada perangkat elektromagnetik profesional yang dapat dipakai seperti sarung tangan [1][12]. Yang lainnya menggunakan *computer vision*. Sifat alami dari *gesture recognition* adalah masalah pada klasifikasi. Terdapat banyak pendekatan untuk menangani 2D *gesture recognition*, termasuk orientation histogram [5], hidden markov model [9], particle filtering [3], support vector machine (SVM) [4], dan lain sebagainya[2][10].

## 2. TINJAUAN STUDI

Penelitian akan menggunakan penelitian-penelitian sebelumnya yang terkait sebagai suatu tinjauan studi. Beberapa penelitian-penelitian yang telah dilakukan dalam *hand tracking gesture recognition* adalah:

### 2.1 A Real-time Hand Gesture Recognition and Human-Computer Interaction System

Xu, P. [12] mengusulkan sistem HCI berbasis gerakan real-time yang memanfaatkan CNN yang dimodifikasi dari LeNet-5 untuk pengenalan *gesture*. Mempelajari fitur dan mengenali gerakan hanya menggunakan satu kamera monokuler murah. Setiap gambar yang tertangkap kamera akan melalui tahapan *preprocessing*, CNN classifier digunakan untuk mengenali gerakan sedangkan kalman estimator digunakan untuk. Dataset terdiri dari 16 label gerakan statis dengan 5 orang berbeda. Tiap *gesture* memiliki 1200 samples. Mendapat tingkat akurasi sebesar

99.8%. Kelemahan penelitian ini adalah sistem hanya mampu mendeteksi gerakan tangan statis, dimana gerakan tersebut lebih mudah dikenali dengan komputasi yang lebih ringan dan juga beresiko mengalami *predict infinite loop*.

## 2.2 Hand Gesture Recognition Sebagai Pengganti Mouse Komputer Menggunakan Kamera

Yunita & Setyati [13] memanfaatkan metode *convexhull algorithm* untuk mendapatkan jumlah jari tangan yang kemudian dapat dijadikan acuan dalam pengerjaan aksi mouse. Akurasi mencapai tingkat 68% dari 75 kali percobaan. Kelemahan penelitian ini adalah algoritma menentukan gambar jari tangan pengguna dengan mendeteksi titik pada tiap ujung jari tangan dan pangkal jari tangan, sehingga prediksi memiliki tingkat akurasi cukup rendah. Selain itu, label gerakan statis yang dikenali sedikit, tergantung pada kenaikan jari.

## 2.3 Implementation of Gesture Recognition Technology for Automated Education Service Kiosk

Makahaube, et al[8] memanfaatkan pipeline mediapipe hand untuk melakukan pengenalan gerakan tangan secara statis. Menyimpulkan 21 titik 3D *landmark* dan hanya mengambil dari 1 bingkai. Kelemahan dari penelitian ini adalah, sistem akan secara terus menerus memprediksi pergerakan pengguna tanpa berhenti (*predict infinite loop*) solusi yang ditawarkan (mengarahkan kamera webcam ke atas) dinilai tidak dapat menjawab masalah tersebut.

## 3. DATASET


Dataset yang digunakan pada penelitian ini merupakan dataset TwentyBN jester yang di unggah pada *qualcomm developer network* secara publik. Sebanyak 1376 aktor dipilih untuk melakukan *gesture* di depan kamera webcam. Terdapat sebanyak 27 label kelas gerakan (termasuk 2 label gerakan yang seharusnya tidak dikenali sebagai gerakan tertentu) dengan durasi video setiap gerakan rata-rata 3 detik. Sebanyak 4391 video tiap kelas gerakan dan tiap aktor rata-rata memperagakan sebanyak 43 video. Keseluruhan data terdiri dari 148.092 video berlabel dengan 5.331.312 total bingkai. Video tersebut memiliki *frame rate* 12 fps, resolusi 176 x 100, dan format ekstensi jpg. Jumlah *frame* pada tiap video adalah 37 *frame*. Rangkuman dataset dapat dilihat pada Tabel 1.

Tabel 1. Rangkuman statistik dataset

| Spesifikasi dataset               | Jumlah    |
|-----------------------------------|-----------|
| Total jumlah video                | 148,092   |
| Total jumlah <i>frame</i>         | 5,331,312 |
| Jumlah kelas                      | 27        |
| Jumlah aktor                      | 1376      |
| Rata-rata durasi tiap video       | 3 detik   |
| Rata-rata jumlah video tiap kelas | 4391      |
| Rata-rata jumlah video tiap aktor | 43        |

## 4. METODE

Metode yang dimanfaatkan pada penelitian ini terbagi menjadi 2 yaitu metode berbasis CNN dan pipeline mediapipe hand. CNN digunakan untuk melakukan klasifikasi terhadap gerakan tangan dinamis dengan memanfaatkan *pretrained* model RT3D\_16F, sedangkan pipeline mediapipe digunakan untuk melakukan pengenalan gerakan tangan secara statis. Sistem prediksi akan disusun dengan alur sistem seperti pada Gambar 1.



Gambar 1. Alur Sistem *Hand Tracking and Gesture Recognition*

Sistem menerima input berupa video. Pertama, sistem akan dipisahkan kedalam bentuk *frames* individu. Kedua, setiap *frames* yang sudah terpisah akan melalui tahap *preprocessing* dengan *transformation* dan *augmentation* lalu dikonversikan dari format PIL Image ke bentuk tensor. Ketiga, setelah didapatkan sejumlah 16 *frames*, *frames* tersebut akan diprediksi dengan model *pretrained* RT3D\_16F untuk diambil nilai tengahnya. Terakhir, apabila nilai tengah dari gerakan tersebut didapat melebihi nilai *threshold of confidence* yang sudah ditetapkan, maka gerakan tersebut dikenali dan diberi label. Label gerakan yang dikenali tersebut kemudian menjalankan perintah yang telah ditetapkan pula.

### 4.1 Convolutional Neural Network

Sistem pelacakan tangan dinamis memanfaatkan CNN model RT3D\_16F. Menggabungkan 2DCNN, 3DCNN dan beberapa lapisan linear. Jaringan 2DCNN dimanfaatkan mengurangi kompleksitas *processing* video *frames* untuk mengurangi dimensi pada data dengan maksud untuk membantu ekstrak *spatial features*. Jaringan 3DCNN adalah jalur utama untuk mengekstrak karakteristik *spatio-temporal* dan juga mengekstrak lapisan linear menggunakan *features* untuk menghasilkan nilai tiap kelas gerakan. Sistem menggunakan 16 *frames* terbaru. Model lalu mengevaluasi window dan menyimpan softmax ke buffer yang berisi N prediksi terbaru. Tabel pembentuk *proposed model* dapat dilihat pada Tabel 2.

**Tabel 2. Tabel lapisan yang membentuk blok 2DCNN dan 3DCNN.**

| Lapisan | S. masuk | S. keluar | Filter  | Pooling |
|---------|----------|-----------|---------|---------|
| 2D Conv | 3        | 16        | [3,3]   | No      |
| 2D Conv | 16       | 32        | [3,3]   | No      |
| 2D Conv | 32       | 64        | [3,3]   | [2,2]   |
| 2D Conv | 64       | 128       | [3,3]   | [2,2]   |
| 2D Conv | 128      | 256       | [3,3]   | [2,2]   |
| 3D Conv | 256      | 256       | [3,3,3] | No      |
| 3D Conv | 256      | 256       | [3,3,3] | [2,2,2] |
| 3D Conv | 256      | 256       | [3,3,3] | [2,1,1] |
| 3D Conv | 256      | 256       | [3,3,3] | [2,2,2] |

## 4.2 Mediapipe Hands

Mediapipe hand merupakan solusi dari pelacakan atau pendeteksian tangan dan jari yang memiliki ketelitian tinggi. Mediapipe memanfaatkan pembelajaran machine learning (ML) untuk menyimpulkan 21 3D *landmark* dan diambil dari 1 *frame*. Mediapipe melakukan pelatihan detektor telapak tangan daripada detektor tangan, karena telapak tangan merupakan objek kaku dan lebih sederhana daripada melakukan deteksi tangan dengan jari yang diartikulasi. Solusi pelacakan tangan yang dimiliki mediapipe hand terdiri dari 2 model yang bekerja bersama, yaitu:

- *Palm detector* yang beroperasi pada *full input image* dan melokasikan telapak tangan melalui oriented hand bounding box
- *Hand landmark model* yang beroperasi pada *cropped hand bounding box* yang disediakan oleh *palm detector* dan menghasilkan 2.5D *landmark* dengan tepat.

## 4.3 Stochastic Gradient Descent

*Stochastic gradient descent* (SGD) merupakan metode optimasi sederhana namun efisien untuk mencari nilai koefisien untuk meminimalkan *loss function* pada skala besar. Beberapa metode yang menggunakan SGD dalam proses pembelajarannya adalah seperti Regresi Logistik, *Smoothed Hinge Loss Classifier*, *Linear Support Vector Regression*. Algoritma SGD dapat dilihat pada Persamaan (1)

$$\begin{aligned} &\text{for } i \text{ in range } (m) \\ \theta_j &= \theta_j - \alpha(y^i - \hat{y}^i)x_j^i \end{aligned} \quad (1)$$

Pada SGD, dihitung gradient *cost function* dari *single example* pada tiap iterasi daripada jumlah dari gradient *cost function* pada tiap *examples*. Pada SGD, karena hanya 1 *sample* dari dataset yang dipilih secara acak pada tiap iterasi. Sedangkan rumus untuk menentukan loss dapat dilihat pada Persamaan (2)

$$e = y - y' \quad (2)$$

## 4.4 LSTM

*Long Short-Term Memory* (LSTM) berbeda dengan RNN, jaringan LSTM termasuk ‘sel memori’ yang dapat menyimpan informasi dalam memori untuk jangka waktu yang lama. Sel memori ini memungkinkan mereka untuk mempelajari ketergantungan jangka panjang. Keunggulan LSTM dibanding dengan RNN biasa adalah terdapat input gate dan forget gate yang memungkinkan kontrol lebih baik (kemampuan untuk menentukan informasi mana yang akan disimpan dan di lupakan/ dibuang) atas aliran gradien. Ketergantungan jarak jauh di RNN diselesaikan dengan meningkatkan jumlah lapisan berulang di LSTM.

## 5. PENGUJIAN

Pengujian akan dilakukan pada beberapa kondisi yang berbeda. Pertama, pengujian akan dilakukan dengan parameter intensitas cahaya. Kedua, pengujian akan dilakukan dengan parameter jarak dari kamera webcam yang berbeda. Ketiga, pengujian akan dilakukan dengan parameter kondisi sisi tangan berbeda. Pengujian dilakukan oleh 4 penguji berbeda. Tiap gerakan diuji sebanyak 25 kali oleh tiap penguji dengan begitu menghasilkan sebanyak 100 pengujian (25 x 4) setiap gerakan.

### 5.1 Pengujian Dengan Kondisi Pencahayaan.

Uji coba ini memiliki tujuan untuk menentukan performa terbaik dari sistem dinilai dari tingkat intensitas sumber cahaya pada ruangan. Pengukuran tingkat cahaya memanfaatkan aplikasi pada *smartphone* yang mampu mengukur tingkat intensitas sumber cahaya dari 0 hingga 60000 lux. Tingkatan kelas cahaya disesuaikan dengan kondisi dalam ruangan kelas Universitas Kristen Petra pada gedung P. Dibagi pada 3 kelompok yaitu:

- Sangat terang, diukur menggunakan light meter dengan rata-rata ukuran cahaya diatas 140 lux. Kondisi ruangan adalah lampu menyala
- Kurang terang, diukur menggunakan light meter dengan rata-rata ukuran cahaya diatas 40 di bawah 140 lux. Kondisi ruangan adalah lampu tidak menyala dan tirai terbuka.
- Redup, diukur menggunakan light meter dengan rata-rata ukuran cahaya dibawah 40 lux. Kondisi ruangan adalah lampu tidak menyala dan tirai tertutup.

Hasil dari pengujian dengan metode RT3D\_16F menyatakan bahwa pada kelompok sangat terang, sistem menghasilkan performa terbaik dengan tingkat akurasi 93,9%. Sedangkan pada kelompok kurang terang dan redup, sistem menghasilkan akurasi sebesar 93,4% dan 89,9%. Tabel perbandingan akurasi dapat dilihat pada Tabel 3.

**Tabel 3. Perbandingan tingkat akurasi metode RT3D\_16F terhadap intensitas cahaya ruangan.**

| Kondisi (lux)  | Akurasi (%) |
|----------------|-------------|
| Diatas 140 lux | 93,9%       |
| Diatas 40 lux  | 93,4%       |
| Dibawah 40 lux | 89,9%       |

Analisa dari hasil pengujian membuktikan bahwa sistem dapat bekerja dengan baik pada kondisi ruangan yang memiliki tingkat cahaya diatas 40 lux.

Sedangkan untuk pengujian pada akurasi pipeline mediapipe hand untuk kontrol mouse. Pada kelompok sangat terang, didapatkan tingkat akurasi sebesar 95,8%. Pada kelompok kurang terang, didapatkan akurasi sebesar 94,67%. Dan untuk kelompok redup, didapatkan akurasi sebesar 94,5. Perbandingan tingkat akurasi dapat dilihat pada Tabel 4.

**Tabel 4. Perbandingan tingkat akurasi mediapipe hand terhadap intensitas cahaya ruangan.**

| Kondisi (lux)  | Akurasi (%) |
|----------------|-------------|
| Diatas 140 lux | 95,8%       |
| Diatas 40 lux  | 94,67%      |
| Dibawah 40 lux | 94,5%       |

Analisa dari hasil pengujian membuktikan bahwa sistem bekerja dengan baik pada setiap kelompok kelas cahaya ruangan. Hal ini terjadi karena biaya komputasi pada pengenalan gerakan tangan statis lebih murah dibanding pengenalan gerakan tangan dinamis.

## 5.2 Pengujian dengan kondisi jarak dari kamera webcam.

Uji coba ini memiliki tujuan untuk menentukan performa terbaik sistem mampu melakukan prediksi dengan akurasi tinggi dihitung pada jarak dari kamera webcam ke pengguna. Jarak dibagi kedalam tiga kelompok:

- Jarak diantara 30 hingga 60 cm dari kamera webcam.
- Jarak diantara 60 hingga 100 cm dari kamera webcam.
- Jarak diatas 100 cm dari kamera webcam.

Hasil dari pengujian dengan metode RT3D\_16F menyatakan bahwa pada kelompok jarak 30-60 cm, prediksi mampu mencapai akurasi 93,9%, sedangkan untuk jarak 60-100 cm, prediksi mampu mencapai akurasi 89,7%. Dan untuk jarak diatas 100 cm sistem sudah tidak mampu memprediksi sebuah gerakan. Tabel perbandingan akurasi dapat dilihat pada Tabel 5.

**Tabel 5. Perbandingan tingkat akurasi metode RT3D\_16F terhadap jarak dari kamera webcam.**

| Kondisi (cm)                   | Akurasi (%) |
|--------------------------------|-------------|
| Diantara 30-60 cm dari kamera  | 93,9%       |
| Diantara 60-90 cm dari kamera  | 89,7%       |
| Diantara 90-100 cm dari kamera | 30,4%       |
| Diatas 90 cm dari kamera       | 0%          |

Analisa dari hasil pengujian membuktikan bahwa jarak paling ideal untuk melakukan prediksi dengan akurasi tertinggi adalah 30 hingga 60 cm dihitung dari jarak kamera webcam ke pengguna. Sedangkan untuk pengujian pada akurasi pipeline mediapipe hand untuk kontrol mouse. Didapatkan akurasi sebesar 93,9 % untuk jarak antara 30 - 60 cm. Untuk jarak 60-100 cm, akurasi didapatkan pada angka 97,5%. Sistem didesain untuk hanya dapat melakukan prediksi pada jarak dibawah 100cm. Perbandingan tingkat akurasi dapat dilihat pada Tabel 6.

**Tabel 6. Perbandingan tingkat akurasi mediapipe hand terhadap jarak dari kamera webcam.**

| Kondisi (cm)                  | Akurasi (%) |
|-------------------------------|-------------|
| Diantara 30-60 cm dari kamera | 95,8%       |
| Diantara 60-90 cm dari kamera | 97,5%       |
| Diatas 100 cm dari kamera     | -           |

Analisa dari hasil pengujian membuktikan bahwa pada jarak 60-100 cm sistem mampu memperoleh akurasi tertinggi pada 97,5%.

## 5.3 Pengujian dengan kondisi sisi berbeda

Uji coba ini memiliki tujuan untuk membuktikan apakah kondisi sisi berbeda dari tangan mampu mempengaruhi tingkat akurasi pada prediksi. Keterangan dari sisi berbeda sendiri memiliki beberapa contoh, seperti:

- Menggunakan sisi tangan berlainan
- Menggunakan punggung tangan daripada telapak tangan
- Menggunakan jari yang berbeda
- Menggunakan posisi tangan berbeda

Hasil pengujian didapatkan bahwa label kelas gerakan *swiping up* dan *swiping down* berdampak cukup besar pada sistem prediksi, dimana dicatat akurasi hanya mencapai 50% dikarenakan sistem tidak mampu memprediksi gerakan tersebut apabila pengguna menggunakan punggung tangan. *Thumb up* dan *thumb down* memiliki akurasi lebih tinggi apabila menggunakan sisi tangan berbeda. Sedangkan untuk label gerakan lain tidak ditemukan perbedaan tingkatan akurasi yang signifikan. Dan keseluruhan pengujian mendapat nilai akurasi sebesar 77,7%.

## 6. KESIMPULAN

Pada penelitian ini, dilakukan pemodelan sistem pengenalan gerakan tangan secara realtime hanya melalui kamera RGB dengan menggunakan CNN model RT3D\_16F dengan *stochastic gradient descent* (SGD) sebagai *optimizer*. Pada pengujian, didapati bahwa sistem pengenalan dinamis mampu melakukan algoritma terbaik pada kondisi cahaya ruangan diatas 40 lux.

Selain itu, jarak dari kamera webcam juga mempengaruhi keakuratan prediksi dinamis, dimana didapati jarak terbaik untuk melakukan prediksi adalah 30 hingga 60 cm dari kamera webcam. Pada penelitian kondisi sisi berbeda, terdapat beberapa gerakan yang mengalami penurunan akurasi yaitu *swiping up* dan *swiping down* karena kedua gerakan tersebut sukar diprediksi dengan penggunaan punggung tangan daripada telapak tangan. Sedangkan untuk pengujian pada pengenalan gerakan statis dengan mediapipe, akurasi dianggap baik pada semua kondisi pencahayaan, jarak akibat biaya komputasi yang lebih ringan dan tidak kompleks dibanding dinamis.

## 7. SARAN

Berikut adalah beberapa saran yang dapat dijadikan masukan untuk mengembangkan penelitian lebih lanjut:

- Memanfaatkan atau menambahkan dataset yang mendukung jarak jauh untuk ditrain pada model RT3D\_16F
- Menguji jenis CNN lain untuk melakukan *recognition* terhadap dynamic gesture
- Menambahkan variasi sisi berbeda pada dataset
- Menggabungkan beberapa *gesture* untuk diartikan menjadi satu *gesture* baru

## 8. REFERENSI

- [1] Abraham, L., Urru, A., Normani, N., Wilk, M. P., Walsh, M., & O'Flynn, B. (2018). Hand tracking and gesture recognition using lensless smart sensors. *Sensors*, 18(9), 2834. DOI: 10.3390/s18092834.
- [2] Agusti, R., Alcaraz, C., Au, R., Barin, K., Bernardo, F., Bertino, E., ... & Dakopoulos, D. (2010). 2010 Index IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews) Vol. 40. IEEE TRANSACTIONS ON SYSTEMS, MAN, AND CYBERNETICS—PART C: APPLICATIONS AND REVIEWS, 40(6), 697. DOI: 10.1109/TSMCC.2010.2085992.
- [3] Bretzner, L., Laptev, I., & Lindeberg, T. (2002, May). Hand gesture recognition using multi-scale colour features, hierarchical models and particle filtering. In *Proceedings of fifth IEEE international conference on automatic face gesture recognition* (pp. 423-428). IEEE.
- [4] Dardas, N. H., & Georganas, N. D. (2011). Real-time hand gesture detection and recognition using bag-of-features and support vector machine techniques. *IEEE Transactions on Instrumentation and measurement*, 60(11), 3592-3607. DOI: 10.1109/TIM.2011.2161140.
- [5] Freeman, W. T., & Roth, M. (1995, June). Orientation histograms for hand gesture recognition. In *International workshop on automatic face and gesture recognition* (Vol. 12, pp. 296-301).
- [6] Ganjar, M., Mardiko, S. (2022). Hybrid Learning: Suatu Solusi Di Tengah Ancaman Dan Tantangan Pendidikan Di Masa Pandemi. <https://smn.sch.id/blog/hybrid-learning-suatu-solusi-di-tengah-ancaman-dan-tantangan-pendidikan-di-masa-pandemi/>.
- [7] Graham, C. R. (2005). Blended learning systems: Definition, current trends, and future directions. In C. J. Bonk & C. R. Graham (Eds.). *Handbook of blended learning: Global perspectives, local designs* (pp. 3-21). San Francisco: Pfeiffer Publishing.
- [8] Makahaube, S. S. et al. (2021). Implementation of Gesture Recognition Technology for Automated Education Service Kiosk. *Jurnal Teknik Informatika*, 14(4), 465-472. <https://ejournal.unsrat.ac.id/index.php/informatika>.
- [9] Starner, T., & Pentland, A. (1997). Real-time american sign language recognition from video using hidden markov models. In *Motion-based recognition* (pp. 227-243). Springer, Dordrecht. DOI: 10.1007/978-94-015-8935-2\_10.
- [10] Wu, Y., & Huang, T. S. (1999, March). Vision-based gesture recognition: A review. In *International gesture workshop* (pp. 103-115). Springer, Berlin, Heidelberg. DOI: 10.1007/3-540-46616-9\_10.
- [11] Xiang, Y. T., Li, W., Zhang, Q., Jin, Y., Rao, W. W., Zeng, L. N., et al. (2020). *Timely research papers about COVID-19 in China. The Lancet*. DOI: 10.1016/S0140-6736(20)30375-5.
- [12] Xu, P. (2017). A real-time hand gesture recognition and human-computer interaction system. *arXiv preprint arXiv:1704.07296*.
- [13] Yunita, H., Setyati, E. (2019). Hand Gesture Recognition Sebagai Pengganti Mouse Komputer Menggunakan Kamera. *Pusat Penelitian dan Pengabdian kepada Masyarakat (P3M) Politeknik Negeri Banjarmasin*. DOI: 10.31961/eltikom.v3i2.114.