

Optimasi Klasifikasi Gestur Tangan Menggunakan Metode CNN Dengan Implementasi Strategi *Landmark* Berbasis Warna Komplementer

Agus Nugroho^{1*}, Jasmir², M. Riza Pahlevi. B, S³, Roby Setiawan⁴

agusnugroho0888@gmail.com¹, ijay_jasmir@yahoo.com², rizapahlevi@unama.ac.id³,

roby.setiawan.jet@gmail.com⁴

^{1,2,3,4} Universitas Dinamika Bangsa

Informasi Artikel	Abstrak
Diterima : 13 Jan 2025 Direvisi : 25 Apr 2025 Disetujui : 30 Apr 2025	Pertumbuhan teknologi pengenalan gestur tangan telah memberikan dampak positif pada berbagai sektor. Namun, kesalahan klasifikasi sering terjadi akibat kemiripan bentuk gestur yang sulit dibedakan oleh model. Penelitian ini bertujuan untuk mengembangkan metode klasifikasi berbasis Convolutional Neural Network (CNN) dengan pendekatan modifikasi landmark menggunakan warna komplementer. Pendekatan ini menerapkan kontras warna yang signifikan untuk meningkatkan kemampuan model dalam mengekstraksi fitur unik dari gestur tangan yang serupa. Dataset yang digunakan mencakup gestur dengan modifikasi warna pada landmark menggunakan roda warna berbasis HSV untuk menciptakan kontras maksimum. Data kemudian diolah melalui bounding box, resizing, dan transfer learning menggunakan arsitektur Teachable Machine. Hasil penelitian menunjukkan peningkatan akurasi klasifikasi secara signifikan pada model dengan modifikasi landmark dibandingkan tanpa modifikasi. Analisis metrik, seperti precision, recall, dan F1-score, mengonfirmasi bahwa pendekatan ini mampu mengurangi kesalahan klasifikasi yang diakibatkan oleh kemiripan gestur tangan.
Kata Kunci	
Hand gesture recognition, sign language classification, complementary color, convolutional neural network, Indonesian sign language	
Keywords	Abstract
Hand gesture recognition, sign language classification, complementary color, convolutional neural network, Indonesian sign language	<i>The growth of hand gesture recognition technology has positively impacted various sectors. However, classification errors often occur due to the similarity of gesture shapes, which are challenging for models to differentiate. This study aims to develop a classification method based on Convolutional Neural Network (CNN) using a landmark modification approach with complementary colors. This approach applies significant color contrast to enhance the model's ability to extract unique features from similar hand gestures. The dataset used includes gestures with color modifications on landmarks using an HSV-based color wheel to create maximum contrast. The data is then processed through bounding box creation, resizing, and transfer learning using the Teachable Machine architecture. The study results show a significant improvement in classification accuracy for models with landmark modifications compared to those without. Metrics analysis, including precision, recall, and F1-score, confirms that this approach effectively reduces classification errors caused by similar hand gestures.</i>

A. Pendahuluan

Teknologi pengenalan tangan telah mengalami perkembangan yang pesat dalam beberapa tahun terakhir dan memberikan dampak yang signifikan dalam berbagai bidang, seperti sistem kontrol gestur, permainan interaktif, dan teknologi berbasis tangan lainnya. Namun, meskipun perkembangan teknologi ini membawa manfaat besar, muncul pula permasalahan yang kompleks, salah satunya adalah kesalahan klasifikasi yang disebabkan oleh kemiripan gestur tangan. Permasalahan ini menjadi lebih kompleks ketika diterapkan pada sistem pengenalan bahasa isyarat, seperti Sistem Isyarat Bahasa Indonesia (SIBI), di mana gestur tangan seringkali memiliki bentuk yang hampir serupa, seperti huruf B, F, M, N, dan S. Hal ini menyebabkan kesalahan deteksi yang berdampak pada kinerja sistem dan mengurangi akurasi pengenalan gestur tangan, yang sangat penting dalam aplikasi komunikasi menggunakan bahasa isyarat. Penelitian sebelumnya menunjukkan bahwa masalah serupa juga ditemukan pada bahasa isyarat SIBI, di mana beberapa gestur yang hampir identik menyebabkan kesalahan klasifikasi [1].

Untuk mengatasi permasalahan tersebut, penelitian ini mengusulkan penggunaan pendekatan modifikasi landmark dengan warna komplementer untuk meningkatkan akurasi klasifikasi pada sistem pengenalan gestur tangan. Pendekatan ini bertujuan untuk menghasilkan kontras yang jelas antar gestur yang mirip, sehingga model Convolutional Neural Network (CNN) dapat lebih efektif dalam mengekstrak fitur unik dari gestur tangan. Modifikasi dataset dengan menggunakan warna komplementer, yang dikenal dalam teori warna sebagai pasangan warna yang saling menetralkan satu sama lain, diharapkan dapat memperkuat kemampuan model untuk membedakan antara gestur tangan yang mirip, seperti kepalan tangan dan tangan menunjuk ke depan, atau huruf K dan P dalam SIBI.

Chevreul menjelaskan bahwa warna komplementer adalah pasangan warna yang, ketika dipadukan, saling menetralkan satu sama lain, menghasilkan warna netral seperti abu-abu. Sebagai contoh, merah dan hijau adalah pasangan komplementer yang, ketika dicampur, menghasilkan warna netral. Pemahaman tentang warna komplementer sangat penting dalam menciptakan harmoni dan kontras dalam karya seni, desain, dan aplikasi visual lainnya. Selain itu, Chevreul juga membahas bagaimana penggunaan warna komplementer dapat memengaruhi persepsi visual dan estetika sebuah karya. Dengan memahami interaksi antara warna-warna ini, seniman dan desainer dapat menciptakan efek visual yang lebih dinamis dan menarik [2]. Pendekatan ini tidak hanya relevan dalam seni visual, tetapi juga dapat diadaptasi dalam bidang teknologi, seperti pengenalan gestur tangan menggunakan model CNN. Salah satu solusi untuk mengatasi permasalahan kemiripan gestur tangan yang sering mengakibatkan kesalahan klasifikasi adalah dengan memodifikasi informasi landmark pada dataset menggunakan metode warna komplementer.

Salah satu pendekatan yang digunakan adalah memodifikasi informasi landmark pada dataset dengan metode warna komplementer, yang mengacu pada penggunaan dua warna yang berlawanan pada roda warna untuk menciptakan kontras maksimum [3]. Pendekatan ini meningkatkan kemampuan model CNN dalam membedakan gestur yang mirip. Dengan menerapkan warna komplementer, landmark pada dataset tidak hanya berfungsi sebagai penanda posisi, tetapi juga

memberikan informasi visual tambahan berupa kontras warna yang signifikan. Konsep ini memungkinkan model untuk lebih mudah mengidentifikasi fitur unik dari masing-masing pose tangan, terutama pada gestur yang memiliki pola serupa, seperti kepalan tangan dan tangan menunjuk ke depan, atau huruf K dan P dalam SIBI.

Sebagai contoh, pembagian warna pada roda warna dapat dilakukan dengan teknik HSV (Hue, Saturation, Value), di mana warna-warna seperti merah (#ff0000), hijau-kekuningan (#cbff00), dan biru (#0065ff) dipilih untuk menciptakan kontras maksimum. Strategi ini memastikan bahwa setiap warna memiliki jarak yang sama pada roda warna, sehingga memberikan informasi visual yang konsisten dan membantu model CNN mengekstrak fitur secara lebih efisien. Dengan pendekatan ini, penelitian diharapkan mampu meningkatkan akurasi pengenalan pose tangan yang mirip sekaligus memberikan kontribusi signifikan terhadap pengembangan teknologi pengenalan tangan yang lebih andal dan presisi dalam berbagai aplikasi, termasuk pengenalan bahasa isyarat


B. Metode Penelitian

Dataset

Dataset merujuk pada kumpulan data yang telah diorganisir, terdiri dari sejumlah sampel atau pengamatan yang relevan untuk tujuan tertentu. Dalam konteks pengolahan data dan pembelajaran mesin, dataset umumnya terdiri dari sekumpulan informasi yang digunakan untuk proses pelatihan, pengujian, atau evaluasi model pembelajaran mesin. Sumber dataset dapat bervariasi, melibatkan berbagai asal data seperti eksperimen ilmiah, survei, catatan pengamatan, atau pengumpulan data dari berbagai bentuk sumber lainnya[4]. Dataset ini disesuaikan untuk memiliki dimensi yang tetap sebesar 256×256 , sejalan dengan kebutuhan sistem kami. Sebagai perbandingan, ImageNet terdiri dari gambar-gambar dengan resolusi yang bervariasi. Untuk mencapai dimensi input yang konstan, kami melakukan pengecilan resolusi pada gambar-gambar tersebut. Proses ini dimulai dengan mengubah ukuran gambar sehingga sisi yang lebih pendek memiliki panjang 256. Selanjutnya, kami melakukan pemotongan pada bagian tengah gambar sehingga mendapatkan ukuran akhir 256×256 . Selama pengolahan gambar ini, tidak ada langkah pre-processing tambahan yang diterapkan, kecuali pengurangan aktivitas rata-rata dari set pelatihan terhadap setiap piksel. Dengan demikian, kami melatih jaringan kami menggunakan nilai RGB mentah yang telah di-center pada piksel-pikselnya[5].

Convolutional Neural Network

Jenis Convolutional Neural Network (CNN) yang umum digunakan, menyerupai multi-layer perceptron (MLP), terdiri dari serangkaian lapisan konvolusi diikuti oleh lapisan sub-sampling (pooling), sementara lapisan terakhirnya adalah lapisan fully-connected (FC). Sebagai contoh, arsitektur CNN untuk tugas klasifikasi gambar dapat dijelaskan sebagai berikut [6].




Gambar 1. Contoh arsitektur CNN untuk klasifikasi gambar [6]

Dua penelitian menunjukkan efektivitas Convolutional Neural Network (CNN) dalam klasifikasi citra. Penelitian pertama mengoptimalkan CNN untuk klasifikasi kualitas buah apel hijau dengan mencapai akurasi 96,88% pada data latih dan 98,44% pada data validasi, serta mampu mengklasifikasikan 93,75% data testing secara benar [7]. Penelitian kedua mengaplikasikan preprocessing standard deviasi pada klasifikasi pneumonia dari citra X-ray paru, yang meningkatkan akurasi sebesar 8% dibandingkan tanpa preprocessing, mencapai 100% akurasi pada epoch 7 dengan waktu komputasi per epoch sekitar 68 detik [8]. Hasil ini menegaskan pentingnya pemilihan teknik preprocessing dan optimasi hyperparameter untuk meningkatkan akurasi dan efisiensi CNN.

Melihat hasil dari kedua penelitian tersebut, penelitian selanjutnya yang akan fokus pada optimasi dari sisi pengolahan dataset dapat memberikan kontribusi penting. Pengolahan dataset yang optimal dapat mencakup pemilihan data yang tepat, penanganan outlier, dan penyesuaian parameter untuk memaksimalkan kinerja model. Dengan demikian, optimasi pada tahap ini diharapkan dapat meningkatkan performa model klasifikasi pada berbagai jenis dataset.

Metode Penelitian

Penelitian ini bertujuan untuk mengembangkan metode klasifikasi gestur tangan berbasis Convolutional Neural Network (CNN) dengan strategi modifikasi landmark menggunakan warna komplementer. Proses yang diusulkan dirancang secara sistematis melalui beberapa tahapan sebagai berikut:



Gambar 2. Desain Penelitian

Akuisisi Data dan Penandaan Landmark

Gambar yang berisi objek tangan diambil sebagai data masukan (input). Pada tahap awal, dilakukan deteksi landmark menggunakan algoritma pendeteksian pose tangan. Landmark ini merupakan titik-titik signifikan yang merepresentasikan struktur geometris tangan, seperti posisi ujung jari, buku-buku jari, atau titik artikulasi lainnya.

Implementasi Warna Komplementer pada Landmark

Setelah landmark berhasil dideteksi, dilakukan modifikasi warna landmark dengan menerapkan metode warna komplementer. Setiap titik landmark diubah menjadi warna yang berlawanan dalam spektrum warna. Langkah ini bertujuan untuk meningkatkan kontras visual dan mempermudah model CNN dalam mengekstraksi fitur yang unik dari landmark yang diberikan.

Metode Warna Komplementer

Metode warna komplementer adalah teknik dalam teori warna yang mengacu pada penggunaan dua warna yang berada pada posisi berlawanan dalam roda warna. Warna-warna ini disebut sebagai "komplementer" karena ketika digabungkan, mereka menciptakan kontras maksimum dan saling melengkapi satu sama lain. Dalam konteks visual, penggunaan warna komplementer dapat menciptakan keseimbangan visual yang kuat dan menarik perhatian, karena kombinasi warna tersebut sangat berbeda satu sama lain.[2],[3],[9].



Gambar 3. Warna Paling Berbeda Dari Roda Warna yang Dibagi 5

Berikut adalah 5 warna paling berbeda dari roda warna yang dibagi menggunakan teknik komplementer:

1. Merah: #ff0000
2. Hijau-kekuningan: #cbff00
3. Hijau-kebiruan: #00ff66
4. Biru: #0065ff
5. Ungu: #cc00ff

Untuk membagi warna secara komplementer dalam roda warna yang terbagi menjadi 5 bagian, kita menggunakan sistem warna HSV (Hue, Saturation, Value). Di sini, kita memanfaatkan nilai Hue (H) yang merepresentasikan posisi warna pada roda warna (0° – 360°). Dengan membagi roda warna menjadi 5 bagian, kita membagi rentang hue menjadi 5 bagian yang sama. Langkah-langkah rumus pembagian roda warna dalam HSV Hue H berada dalam rentang $0 \leq H < 1$ dalam sistem HSV. Nilai ini mewakili sudut dalam roda warna (sebanding dengan 0° – 360° dalam derajat). Saturation S dan Value V umumnya diset ke 1 (maksimum) untuk menghasilkan warna yang paling jenuh. Pembagian Hue Untuk membagi roda warna

menjadi 5 warna komplementer yang berbeda, Penulis membagi nilai H menjadi 5 bagian yang sama besar:

$$H_i = \frac{i}{5}, \quad i = 0,1,2,3,4 \quad (1)$$

Dengan ini, nilai-nilai Hue akan menjadi

$$H_0 = 0, H_1 = \frac{1}{5}, H_2 = \frac{2}{5}, H_3 = \frac{3}{5}, \text{ dan } H_4 = \frac{4}{5} \quad (2)$$

setelah nilai-nilai hue ini didapatkan, kita bisa mengonversinya ke format RGB melalui sistem warna HSV, dan dari RGB ke hexacode. Mengonversi 0 derajat (merah) menjadi kode warna #ff0000 melibatkan langkah-langkah berikut, dengan konversi dari sistem warna HSV (Hue, Saturation, Value) ke RGB (Red, Green, Blue), lalu ke Hexadecimal. Nilai Hue dalam Derajat Hue (H) dalam sistem HSV adalah sudut pada roda warna, berkisar antara 0° dan 360° . Pada 0° , warna yang sesuai adalah merah.

Untuk konversi $H = 0^\circ$ Nilai Hue dinormalisasi dalam sistem HSV, di mana rentang hue 0° – 360° diubah menjadi rentang 0 hingga 1. Untuk 0° :

$$H = \frac{0^\circ}{360^\circ} = 0 \quad (3)$$

Saturation (S) dan Value (V) keduanya diatur ke 1 untuk mendapatkan warna yang penuh dan paling jenuh. $S=1, V=1$, Dengan $H=0$, $S=1$, dan $V=1$, hasil RGB untuk hue 0 (merah) adalah:

$R = V = 1$ (nilai maksimal, yaitu merah penuh)

$G = 0$ (tidak ada komponen hijau)

$B = 0$ (tidak ada komponen biru)

Dalam RGB: $(R, G, B) = (1, 0, 0)$. RGB dengan nilai $(1, 0, 0)$ perlu dikonversi ke kode hex. Pertama, konversi komponen RGB dari rentang $[0, 1]$ ke $[0, 255]$:

$R = 1 \times 255 = 255$ (FF dalam hex)

$G = 0 \times 255 = 0$ (00 dalam hex)

$B = 0 \times 255 = 0$ (00 dalam hex)

Jadi, warna merah dalam hex adalah: #ff0000. Pembagian ini memastikan bahwa setiap warna memiliki jarak yang sama satu sama lain pada roda warna.

- | | |
|------------------------------------|------------------------------|
| 1. Hue $H_0 = 0$ (0°) | : Merah #ff0000 |
| 2. Hue $H_1 = 1/5$ (72°) | : Hijau-kekuningan - #cbff00 |
| 3. Hue $H_2 = 2/5$ (144°) | : Hijau-kebiruan - #00ff66 |
| 4. Hue $H_3 = 3/5$ (216°) | : Biru #0065ff |
| 5. Hue $H_4 = 4/5$ (288°) | : Ungu #cc00ff |

Deteksi Bounding Box dan Praproses Gambar

Berdasarkan koordinat landmark yang telah dimodifikasi, bounding box dibuat untuk mengisolasi area tangan secara spesifik. Proses pemotongan (cropping) dilakukan untuk memastikan hanya bagian tangan yang menjadi fokus analisis, sehingga mengurangi noise dari latar belakang.

Penyesuaian Ukuran Gambar

Gambar hasil pemotongan diubah ukurannya menjadi 244x244 piksel. Dimensi ini dipilih untuk memastikan konsistensi resolusi selama proses pelatihan dan kompatibilitas dengan arsitektur standar deep learning.

Pelatihan Model CNN dengan Pendekatan Transfer Learning

Data yang telah diproses dan dimodifikasi digunakan untuk melatih model CNN. Proses pelatihan memanfaatkan pendekatan transfer learning dengan arsitektur berbasis Teachable Machine. Transfer learning dipilih karena dapat mempercepat proses pelatihan serta meningkatkan akurasi, terutama dalam kondisi data terbatas.


Klasifikasi Gestur Tangan

Model yang telah dilatih digunakan untuk mengklasifikasikan gestur tangan dari data uji. Model ini dirancang untuk mendeteksi pola signifikan dalam distribusi warna dan bentuk landmark, sehingga menghasilkan keluaran berupa kategori gestur yang sesuai.

C. Hasil dan Pembahasan


Visualisasi Pemetaan Landmark

Gambar berikut menunjukkan sebuah proses pemetaan tangan menggunakan landmark detection tanpa adanya modifikasi warna pada visualisasi.



Gambar 4. Landmark detection tanpa adanya modifikasi warna


Setiap titik (landmark) yang ditandai pada gambar merepresentasikan posisi sendi jari tangan, dan digambarkan menggunakan garis penghubung untuk merepresentasikan struktur jari-jari. Berikut merupakan beberapa hasil dari dataset yang dihasilkan.



Gambar 5. Cuplikan dataset tanpa modifikasi warna yang dihasilkan


Untuk mencegah overfitting, beberapa penelitian menunjukkan bahwa teknik seperti augmentasi data, dropout, dan regularisasi L2 dapat meningkatkan kemampuan model dalam *menggeneralisasi* data baru. Augmentasi data dilakukan dengan menambahkan variasi pada data pelatihan, seperti flipping, rotating, Gaussian Noise, Random Erasing, dan GridMask, untuk memperbesar dataset tanpa menambah data baru. Teknik-teknik ini membantu model belajar dari pola yang lebih beragam, sehingga tidak terlalu "mengingat" data pelatihan. Selain itu, menggunakan arsitektur yang lebih sederhana atau melakukan fine-tuning pada model pre-trained juga dapat mengurangi risiko overfitting, seperti pada model MobileNet dan VGG16. Pemantauan akurasi pada data validasi dan pelatihan selama pelatihan model juga penting untuk mendeteksi overfitting sejak dini, misalnya ketika akurasi pelatihan sangat tinggi tetapi akurasi validasi rendah. Penelitian juga menekankan pentingnya dataset yang representatif dan kompleks untuk memastikan model dapat bekerja secara stabil dan efektif pada data dunia nyata.[10], [11], [12], [13]

Dapat disimpulkan mencegah overfitting dapat dilakukan dengan teknik seperti augmentasi data, dropout, regularisasi L2, dan fine-tuning model, serta memastikan dataset yang beragam dan representatif untuk meningkatkan kemampuan model dalam menggeneralisasi data baru. Pada gambar berikut, terlihat proses pemetaan landmark pada tangan telah dimodifikasi dengan penggunaan warna komplementer untuk setiap bagian jari.



Gambar 6. Landmark detection dengan modifikasi warna komplementer

Warna-warna tersebut digunakan untuk menandai masing-masing jari dengan jelas, membuat visualisasi lebih informatif dan mudah dibedakan antara satu jari dengan yang lainnya. Berikut merupakan beberapa hasil dari dataset yang dihasilkan.



Gambar 7. Cuplikan dataset modifikasi warna yang dihasilkan

Analisis Peningkatan Visualisasi dengan Warna Komplementer

Berdasarkan hasil dari beberapa penelitian, percobaan ini bertujuan untuk mengatasi kesalahan klasifikasi pada bahasa isyarat SIBI. Posisi yang dipilih untuk eksperimen diambil dari referensi kamus Kementerian Pendidikan dan Kebudayaan Republik Indonesia tentang abjad SIBI[14]. Beberapa gestur yang akan digunakan menunjukkan potensi kesalahan klasifikasi menurut penelitian terdahulu, termasuk observasi baru dari penulis. Adapun dataset Pengujian terdiri dari gestur bahasa isyarat untuk huruf-huruf:

1. S,M,N
2. K, P

3. U, R, V

Semua gestur akan dilakukan secara statis (pose diam), mengikuti format abjad SIBI.

Evaluasi Akurasi Klasifikasi

Analisis Confusion Matrix

Pada bagian ini, ditampilkan perbandingan hasil dari kedua model yang telah diuji dalam penelitian ini, yaitu model dengan dan tanpa penerapan landmark menggunakan metode warna komplementer.

-----Confusion Matrix-----									
[	604	0	0	0	0	0	0	0	0]
[	26	299	29	0	0	0	0	0	0]
[	8	46	503	0	0	0	0	0	0]
[	2	0	17	244	0	3	0	44	]
[	3	0	0	0	228	0	0	0	]
[	1	0	16	0	0	412	0	14	]
[	2	1	44	5	0	167	254	3	]
[	0	0	25	0	0	70	0	321	]

-----Confusion Matrix-----									
[	632	0	0	0	0	0	0	0	0]
[	36	274	2	62	0	0	0	4	]
[	25	186	304	3	0	0	0	17	]
[	0	0	1	96	0	22	0	202	]
[	56	0	0	0	240	0	0	0	]
[	0	0	0	2	0	428	9	7	]
[	0	0	0	16	0	241	146	34	]
[	0	0	0	23	0	217	0	253	]

Gambar 8. Perbandingan hasil 2 confusion matrix

Pada gambar kiri diatas, landmark yang menerapkan metode warna komplementer mendapatkan hasil Kelas S (0) memiliki akurasi tinggi dengan seluruh kelas diidentifikasi dengan benar (604 benar). Kelas M dan N menunjukkan tingkat kesalahan yang relatif rendah. Kelas P (4) menunjukkan akurasi sempurna di model ini, serta kelas R (6) dan V (7) dengan nilai recall yang baik.

Pada gambar kanan diatas, landmark yang tidak menerapkan metode warna komplementer Kelas S (0) juga memiliki deteksi yang hampir sempurna (632 benar). Kelas M mengalami kesalahan yang lebih signifikan, dengan banyak contoh yang salah untuk kelas lainnya. Kelas N menunjukkan lebih banyak kebingungan dengan kelas lain, terutama kelas 1 dan kelas 2. Kelas K (3) menunjukkan kesulitan dengan recall yang lebih rendah, dengan banyak kesalahan deteksi.

	precision	recall	f1-score	support
0	0.93	1.00	0.97	604
1	0.86	0.84	0.85	354
2	0.79	0.90	0.84	557
3	0.98	0.79	0.87	310
4	1.00	0.99	0.99	231
5	0.63	0.93	0.75	443
6	1.00	0.53	0.70	476
7	0.84	0.77	0.80	416
accuracy			0.84	3391
macro avg	0.88	0.84	0.85	3391
weighted avg	0.87	0.84	0.84	3391

	precision	recall	f1-score	support
0	0.84	1.00	0.92	632
1	0.60	0.72	0.65	378
2	0.99	0.57	0.72	535
3	0.48	0.30	0.37	321
4	1.00	0.81	0.90	296
5	0.47	0.96	0.63	446
6	0.94	0.33	0.49	437
7	0.49	0.51	0.50	493
accuracy			0.67	3538
macro avg	0.73	0.65	0.65	3538
weighted avg	0.73	0.67	0.66	3538

Gambar 9. Perbandingan hasil uji akurasi

Berikut adalah tabel perbandingan antara 2 model dengan landmark yang menerapkan metode warna komplementer (kiri) dan landmark tanpa metode warna komplementer (kanan) berdasarkan data model dari gambar diatas.

Tabel 1. Perbandingan hasil akurasi

Kelas [Index]	Implementasi warna komplementer				Tanpa warna komplementer			
	Precision	Recall	F1-Score	Support	Precision	Recall	F1-Score	Support
S [0]	0.93	1.00	0.97	604	0.84	1.00	0.92	632
M [1]	0.86	0.84	0.85	354	0.60	0.72	0.65	378
N [2]	0.79	0.90	0.84	557	0.99	0.57	0.72	535
K [3]	0.98	0.79	0.87	310	0.48	0.30	0.37	321
P [4]	1.00	0.99	0.99	231	1.00	0.81	0.90	296
U [5]	0.63	0.93	0.75	443	0.47	0.96	0.63	446
R [6]	1.00	0.53	0.70	476	0.94	0.33	0.49	437
V [7]	0.84	0.77	0.80	416	0.49	0.51	0.50	493

D. Simpulan

Hasil penelitian menunjukkan bahwa penerapan modifikasi landmark menggunakan metode warna komplementer dalam pengenalan gestur tangan secara signifikan meningkatkan akurasi klasifikasi dibandingkan dengan model yang tidak menerapkan landmark. Dengan mengintegrasikan kontras warna yang jelas, model Convolutional Neural Network (CNN) dapat lebih efektif dalam membedakan fitur unik dari gestur yang mirip, seperti antara huruf K dan P dalam Sistem Isyarat Bahasa Indonesia (SIBI). Hasil evaluasi metrik menunjukkan bahwa pendekatan ini berhasil mengurangi kesalahan klasifikasi yang diakibatkan oleh kemiripan bentuk gestur, memberikan kontribusi positif terhadap pengembangan teknologi pengenalan tangan yang lebih andal dan presisi, terutama dalam aplikasi pengenalan bahasa isyarat.

E. Referensi

- [1] M. Sholawati, K. Auliasari, and F. X. Ariwibisono, "Pengembangan Aplikasi Pengenalan Bahasa Isyarat Abjad Sibi Menggunakan Metode Convolutional Neural Network (CNN)," 2022.
- [2] Michel Eugène Chevreul, "The Principles of Harmony and Contrast of Colours, and Their Applications to the Arts: Including Painting, Interior Decoration, Tapestries, Carpets, Mosaics, Coloured Glazing, Paper-staining, Calico-printing, Letterpress Printing, Map-colouring, Dress, Landscape and Flower Gardening, Etc", Accessed: Dec. 27, 2024. [Online]. Available: https://books.google.co.id/books/about/The_Principles_of_Harmony_and_Contrast_o.html?id=LIMOAAAQAAJ&redir_esc=y
- [3] Johannes. Itten, *The art of color: the subjective experience and objective rationale of color*. Van Nostrand Reinhold, 20041973.
- [4] W. McKinney, *Python for data analysis: data wrangling with pandas, NumPy, and IPython*.
- [5] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks."
- [6] L. Alzubaidi *et al.*, "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions," *J Big Data*, vol. 8, no. 1, Dec. 2021, doi: 10.1186/s40537-021-00444-8.

- [7] R. Setya Nugraha and A. Hermawan, "OPTIMASI AKURASI METODE CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI KUALITAS BUAH APEL HIJAU," 2023.
- [8] U. P. Sanjaya *et al.*, "Optimasi Convolutional Neural Network dengan Standard Deviasi untuk Klasifikasi Pneumonia pada Citra X-rays Paru," 2023.
- [9] J. Gage, *Color and Meaning: Art, Science, and Symbolism*. 1999. Accessed: Oct. 12, 2024. [Online]. Available: https://books.google.co.id/books?id=EU74cB7kMMsC&printsec=frontcover&redir_esc=y#v=onepage&q&f=false
- [10] W. A. Firmansyach, U. Hayati, and Y. A. Wijaya, "Analisa Terjadinya Overfitting Dan Underfitting Pada Algoritma Naive Bayes Dan Decision Tree Dengan Teknik Cross Validation," 2023.
- [11] Google, "Overfitting." Accessed: Jan. 11, 2025. [Online]. Available: <https://developers.google.com/machine-learning/crash-course/overfitting/overfitting?hl=id>
- [12] R. Z. Fadillah, A. Irawan, M. Susanty, and I. Artikel, "Data Augmentasi Untuk Mengatasi Keterbatasan Data Pada Model Penerjemah Bahasa Isyarat Indonesia (BISINDO)," *JURNAL INFORMATIKA*, vol. 8, no. 2, 2021, [Online]. Available: <http://ejournal.bsi.ac.id/ejurnal/index.php/ji>
- [13] C. Uswatun Khasanah, A. Kusuma Pertiwi, F. Witamajaya, P. Akbara Surakarta, and J. Sumbing Raya, "Implementasi Data Augmentation Random Erasing dan GridMask pada CNN untuk Klasifikasi Batik Implementation of Random Erasing and GridMask Data Augmentations on CNN for Batik Classification," vol. 13, no. 1, 2023, doi: 10.30700/jst.v13i1.1274.
- [14] Lembaga Penelitian dan Pengembangan Sistem Isyarat Bahasa Indonesia, "Kamus SIBI." Accessed: Dec. 27, 2024. [Online]. Available: <https://pmpk.kemdikbud.go.id/sibi/kosakata>