

Pengaruh Warna *RGB* dan *HSV* Terhadap Model *Neural* dan *Non-Neural* pada Klasifikasi Kastengel

^{1*}Muhammad Fajrin Aswad Ad-Duali, ²Wahyu Cahyo Utomo, ³Danang Wahyu Widodo

^{1,2,3} Teknik Informatika, Universitas Nusantara PGRI Kediri
E-mail: ¹fajrinadduali@gmail.com, ²wahyu.utomo@unpkdr.ac.id,
³danangwahyuwidodo@unpkediri.ac.id

Penulis Korespondens : Muhammad Fajrin Aswad Ad-Duali

Abstrak— Permasalahan produksi kue kastengel adalah proses penyortiran kualitas secara manual yang rentan terhadap inkonsistensi penilaian visual dan kesalahan klasifikasi mutu. Penelitian ini membandingkan pengaruh representasi warna RGB dan HSV terhadap kinerja model neural Convolutional Neural Network dan non-neural algoritma Naive Bayes. Data uji menggunakan 960 gambar yang dibagi ke dalam tiga kelas. Hasil pengujian membuktikan penelitian ini mampu menghasilkan klasifikasi terbaik menggunakan model Convolutional Neural Network berformat RGB dengan akurasi 98,44 persen, mengalahkan format HSV di angka 90,62 persen. Sebagai pembanding, algoritma Naive Bayes hanya mendapat akurasi 89 persen pada HSV dan 77 persen pada RGB. Kesimpulannya, penelitian ini terbukti mampu mengatasi permasalahan penyortiran kualitas manual, di mana model Convolutional Neural Network berbasis RGB lebih unggul dalam mengenali pola cacat bentuk maupun warna.

Kata Kunci— Convolutional Neural Network, HSV, Kastengel, Naive Bayes, RGB

Abstract—The problem in kastengel production is the manual quality sorting process, which is prone to visual assessment inconsistencies and quality classification errors. This research compares the effect of RGB and HSV color representations on the performance of the neural Convolutional Neural Network model and the non-neural Naive Bayes algorithm. The test data uses 960 images divided into three classes. The test results prove that this research is able to produce the best classification using the Convolutional Neural Network model in RGB format with 98.44 percent accuracy, outperforming the HSV format at 90.62 percent. As a baseline, the Naive Bayes algorithm only achieved 89 percent accuracy on HSV and 77 percent on RGB. In conclusion, this research is proven capable of solving the manual quality sorting problem, where the RGB-based Convolutional Neural Network model is superior in recognizing shape and color defect patterns.

Keywords— Convolutional Neural Network, HSV, Kastengel, Naive Bayes, RGB

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Kue kastengel merupakan salah satu jenis kue kering yang populer dan banyak diproduksi oleh pelaku usaha skala rumahan. Kualitas visual seperti tingkat kematangan warna dan keutuhan bentuk fisik menjadi indikator utama dalam menentukan mutu produk ini. Namun, proses pengecekan kualitas kue kastengel pada tahap produksi masih dilakukan secara manual melalui pengamatan langsung. Alhasil, cara ini rentan terhadap inkonsistensi penilaian akibat

perbedaan persepsi visual pekerja. Kondisi tersebut memengaruhi proses pemisahan antara kue yang berkualitas baik, cacat bentuk, maupun cacat warna. Inkonsistensi penyortiran ini pada akhirnya berdampak pada standar mutu dari produk akhir yang dihasilkan [1].

Dalam menanggapi permasalahan tersebut, berbagai penelitian terdahulu telah mengeksplorasi implementasi teknologi komputasi. Salah satu metode yang banyak dikaji untuk klasifikasi citra adalah *Convolutional Neural Network* (CNN) [2]. *CNN* merupakan representasi arsitektur neural yang beroperasi dengan cara mengekstraksi fitur spasial dari sebuah citra melalui lapisan konvolusi [3]. Pendekatan tersebut memproses informasi komputasi berupa pola fisik atau karakteristik geometri dari objek yang diamati .

Di samping itu, model non-neural berbasis statistik seperti algoritma *Naïve Bayes* [4] juga banyak diimplementasikan dalam pemrosesan klasifikasi gambar . Berbeda dengan pendekatan arsitektur *neural*, *Naïve Bayes* bekerja dengan mengklasifikasikan kelas objek berdasarkan hitungan peluang probabilitas dari kemunculan warna pada setiap piksel gambar [5]. Pendekatan ini memproses distribusi warna pada citra tanpa melibatkan ekstraksi struktur atau bentuk utuh dari objek tersebut .

Dalam proses klasifikasi citra, representasi ruang warna [6] yang digunakan menjadi variabel yang menentukan bagaimana model komputasi memproses data. Sebagian besar penelitian klasifikasi selama ini menggunakan representasi warna *RGB* [7] (Red, Green, Blue) . Di sisi lain, terdapat representasi warna *HSV* [8] (Hue, Saturation, Value) yang memiliki karakteristik memisahkan nilai warna dari tingkat pantulan cahayanya. Penerapan format representasi warna yang berbeda ini akan memberikan efek yang berbeda ketika diproses oleh algoritma komputasi [9].

Berdasarkan paparan tersebut, penelitian ini bertujuan untuk mengevaluasi pengaruh modifikasi ruang warna terhadap dua paradigma algoritma klasifikasi citra. Secara spesifik, penelitian ini membandingkan performa antara model *neural* (CNN) dan non-neural (*Naïve Bayes*) menggunakan ruang warna *RGB* dan *HSV* dalam memilah kualitas kue kastengel. Melalui pengujian ini, diharapkan penerapan ruang warna *RGB* dan *HSV* dapat memberikan gambaran yang jelas mengenai respons komputasi dari masing-masing model saat dihadapkan pada karakteristik kelas gambar yang berbeda.

II. METODE

A. Akuisisi Data dan Subjek Penelitian

Subjek pada penelitian ini berupa citra digital kue kastengel dengan jumlah keseluruhan sebanyak 960 citra. Data dikumpulkan secara primer melalui pengambilan gambar menggunakan perangkat kamera. Dataset dikelompokkan ke dalam tiga kelas utama berdasarkan karakteristik visualnya, yaitu: *Grade A* (kualitas Baik), *Grade B* (Cacat Bentuk), dan *Grade C* (Cacat Warna). Pada tahap pembagian data komputasi, dialokasikan himpunan data uji (*testing set*) secara statis dan merata, yakni sebanyak 192 citra (masing-masing 64 citra per kelas) untuk mengevaluasi performa mesin di akhir pelatihan.



Kualitas Baik



Kualitas Cacat Bentuk



Kualitas Cacat Warna


Gambar 1. Dataset Citra Kue Kastengel

B. Teknik Pra-Pemrosesan Data

Sebelum tahap klasifikasi, matriks citra mentah harus melalui serangkaian proses pra-pemrosesan komputasi dasar. Seluruh citra diseragamkan dimensi resolusinya menjadi 320 x 320 piksel untuk menstabilkan beban matriks pada lapisan input algoritma. Untuk mengatasi ketimpangan jumlah sampel pada pengumpulan data awal, diterapkan teknik penyeimbangan menggunakan teknik *random sampling* [10] dasar. Citra pada kelas minoritas diduplikasi secara acak hingga setiap kelas berjumlah tepat 256 citra. Setelah distribusi data seimbang, dataset diduplikasi ke dalam dua skenario ruang warna, yaitu format matriks *RGB* (Red, Green, Blue) dan format konversi *HSV* (Hue, Saturation, Value).

C. Implementasi dan Konfigurasi Arsitektur

Pengujian dilakukan dengan membandingkan dua pendekatan komputasi dasar, yakni model neural dan non-neural. Pada model *neural*, arsitektur *Convolutional Neural Network* (CNN) yang menerima masukan citra berdimensi 320 x 320 piksel. Visualisasi struktur jaringan, susunan lapisan konvolusi, hingga lapisan luaran yang diimplementasikan dalam penelitian ini ditunjukkan secara rinci pada Gambar 2:



Gambar 2. Arsitektur *Convolutional Neural Network* [11]

Berdasarkan tahapan arsitektur jaringan pada Gambar 2, proses ekstraksi fitur pola dan bentuk dari objek gambar beroperasi melalui lapisan konvolusi dengan persamaan matematis sebagai berikut:

$$S(i, j) = \sum_m \sum_n I(i + m, j + n) K(m, n) \quad (1)$$

Untuk menambahkan sifat non-linearitas dalam jaringan agar mampu mengidentifikasi fitur yang lebih kompleks, diterapkan fungsi aktivasi *Rectified Linear Unit* (ReLU) dengan persamaan:

$$f(x) = \max(0, x) \quad (2)$$

Hasil ekstraksi fitur spasial tersebut kemudian dihubungkan ke lapisan *fully connected* yang diakhiri dengan fungsi klasifikasi *Softmax* untuk menentukan probabilitas citra ke dalam kelas mutu yang sesuai, dengan persamaan:

$$P(y = j | \mathbf{z}) = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \quad (3)$$

Algoritma pelatihan pada model *CNN* ini dieksekusi secara dinamis menggunakan *optimizer Adam* dan perhitungan kesalahan menggunakan *Categorical Crossentropy*. Pembaruan bobot (*weights*) dilakukan secara iteratif melalui proses komputasi *feedforward* dan *backpropagation* hingga mencapai batas 100 *epoch* yang telah ditetapkan.

Sebagai perbandingan dari pendekatan *non-neural*, penelitian ini mengimplementasikan algoritma *Naïve Bayes*. Model ini beroperasi dengan cara meratakan (*flattening*) matriks citra dua dimensi menjadi vektor satu dimensi untuk menghitung nilai probabilitas statistik dari sebaran piksel warna, tanpa melibatkan ekstraksi fitur bentuk maupun iterasi pembaruan bobot secara berulang. Komputasi probabilitas untuk menentukan kelas kue kastengel (C_k) berdasarkan nilai fitur piksel masukan (X) dihitung menggunakan persamaan *Teorema Bayes*:

$$P(C_k | X) = \frac{P(X | C_k)P(C_k)}{P(X)} \quad (4)$$

Seluruh proses pelatihan pada metode ini dilakukan secara statis dengan memproses data latih dalam satu arah kalkulasi untuk menentukan parameter rata-rata dan varians dari tiap kelas secara independen.

D. Teknik Analisis data dan Evaluasi Model

Pada tahap akhir komputasi, performa dari kedua algoritma dievaluasi secara kuantitatif menggunakan 192 data uji. Hasil prediksi dari masing-masing model direpresentasikan ke dalam *Confusion Matrix* yang memetakan parameter *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Berdasarkan matriks pengujian tersebut, komparasi kinerja dievaluasi menggunakan empat persamaan metrik utama, yaitu:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

$$Precision = \frac{TP}{TP + FP} \quad (6)$$

$$Recall = \frac{TP}{TP + FN} \quad (7)$$

$$F1 - Score = 2 \times \frac{Precision + Recall}{Precision + Recall} \quad (8)$$

Analisis hasil klasifikasi ini difokuskan pada perbandingan evaluasi metrik secara menyeluruh guna menjawab sejauh mana pengaruh representasi algoritma *Neural* (CNN) dan *Non-Neural* (*Naïve Bayes*) dalam mengenali mutu citra berdasarkan penggunaan ruang warna *RGB* dan *HSV*.


III. HASIL DAN PEMBAHASAN

A. Hasil Pengujian dan Confusion Matrix

Pengujian ini membandingkan penggunaan dua ruang warna, yaitu *RGB* dan *HSV*. Hasil tebakan dari setiap pengujian dicatat langsung ke dalam grafik *Confusion Matrix* untuk melihat persentase akurasi dan letak kesalahan prediksi model.

1) Skenario Ruang Warna *RGB*

Pada skenario pertama menggunakan ruang warna *RGB*, hasil prediksi dan akurasi dari kedua model dapat dilihat pada Gambar berikut.




Gambar 3. *Confusion Matrix* Skenario Ruang Warna *RGB*

Berdasarkan bagian grafik *Naïve Bayes* pada Gambar 3, sebaran prediksi benar dan salah dari total 64 gambar tiap kelas. Pada kelas *Grade A* terdapat 56 gambar diprediksi benar, kelas *Grade B* terdapat 36 gambar diprediksi benar, dan kelas *Grade C* terdapat 56 gambar diprediksi benar. Kesalahan prediksi paling banyak pada model ini terjadi pada kelas *Grade B*, di mana 20 gambar salah tertebak sebagai *Grade A* dan 8 gambar salah tertebak sebagai *Grade C*. Sementara itu, bagian grafik *CNN* pada Gambar 2 menunjukkan jumlah prediksi benar di semua kelas. Rinciannya adalah 62 gambar diprediksi benar pada *Grade A*, 63 gambar diprediksi benar pada *Grade B*, dan 64 gambar diprediksi secara sempurna pada *Grade C*. Kesalahan pada model *CNN* ini sangat minim, yaitu hanya 1 gambar *Grade A* yang salah

ditebak menjadi *Grade B* dan 1 gambar menjadi *Grade C*, serta hanya 1 gambar *Grade B* yang salah ditebak menjadi *Grade A*.

2) Skenario Ruang Warna *HSV*

Pada skenario kedua menggunakan ruang warna *HSV*, hasil prediksi dan akurasi dari kedua model dapat dilihat pada Gambar berikut.



Gambar 4. *Confusion Matrix* Skenario Ruang Warna *HSV*

Pada Gambar 4, pengubahan format warna ke *HSV* menghasilkan pada kelas *Grade A* terdapat 61 gambar ditebak benar, namun ada 1 gambar salah masuk ke kelas *Grade B* dan 2 gambar salah ke kelas *Grade C*. Pada kelas *Grade B*, terdapat 51 gambar diprediksi benar, dengan kesalahan 11 gambar terprediksi sebagai *Grade A* dan 2 gambar sebagai *Grade C*. Selanjutnya, pada kelas *Grade C* terdapat 58 gambar diprediksi benar, sedangkan 3 gambar salah terprediksi sebagai *Grade A* dan 3 gambar salah sebagai *Grade B*. Pada bagian grafik *CNN* di Gambar 3, hasil tebakan menunjukkan pada kelas *Grade A* terdapat 63 gambar yang ditebak benar, dengan hanya 1 gambar yang salah diprediksi menjadi kelas *Grade C*. Pada kelas *Grade B*, model berhasil memprediksi 47 gambar dengan benar, sedangkan 17 gambar lainnya salah diprediksi masuk ke kelas *Grade A*. Hasil prediksi terbaik ada pada kelas *Grade C* yang berhasil diprediksi dengan sempurna tanpa ada kesalahan sama sekali, yaitu 64 gambar diprediksi benar.

B. Analisis Perbandingan Performa Model

Secara keseluruhan, ringkasan hasil akurasi dari keempat skenario pengujian di atas dirangkum secara komprehensif sejauh mana pengaruh representasi warna terhadap kinerja komputasi dalam pengenalan fitur citra, ringkasan hasil pengujian yang mencakup nilai akurasi keseluruhan serta rincian metrik presisi, *recall*, dan *f1-score* untuk masing-masing kelas kualitas (*Grade A*, *Grade B*, dan *Grade C*) dari keempat skenario eksperimen telah dirangkum secara utuh pada Tabel 1

Tabel 1. Hasil Akurasi Keseluruhan Model

Arsitektur Model	Skenario Warna	Kelas Kualitas	Precision(%)	Recall (%)	F1-Score (%)	Akurasi Total (%)
<i>Naïve Bayes</i>	<i>RGB</i>	<i>Grade A</i>	68	88	77	77
		<i>Grade B</i>	80	56	66	
		<i>Grade C</i>	86	88	87	
<i>Convolutional Neural Network</i>	<i>RGB</i>	<i>Grade A</i>	98	97	98	98
		<i>Grade B</i>	98	98	98	
		<i>Grade C</i>	98	100	99	
<i>Naïve Bayes</i>	<i>HSV</i>	<i>Grade A</i>	81	95	88	89
		<i>Grade B</i>	93	80	86	
		<i>Grade C</i>	94	91	92	
<i>Convolutional Neural Network</i>	<i>HSV</i>	<i>Grade A</i>	79	98	88	91
		<i>Grade B</i>	100	73	85	
		<i>Grade C</i>	98	100	99	

Berdasarkan data pada Tabel 1, model *CNN* memberikan tingkat akurasi yang lebih tinggi dibandingkan *Naïve Bayes*, baik saat menggunakan warna *RGB* maupun *HSV*. Kinerja paling rendah dicapai oleh model *Naïve Bayes* dengan format warna *RGB*, yaitu dengan akurasi keseluruhan sebesar 77%. Sebaliknya, kinerja tertinggi berhasil dicapai oleh model *CNN* yang menggunakan format warna *RGB*, dengan akurasi mencapai 98%. Jika dilihat lebih rinci pada setiap kelasnya, terlihat jelas perbedaan kemampuan model dalam mengenali gambar. Pada pengujian *Naïve Bayes* berformat *RGB*, model ini terlihat sangat kesulitan saat mengenali kelas *Grade B*. Hal ini dibuktikan dengan nilai *recall* yang turun drastis hingga 56%. Artinya secara data, model tersebut gagal mengenali hampir separuh dari total gambar *Grade B* yang diujikan, dan malah salah menebaknya sebagai kelas lain.

Berbeda dengan itu, model *CNN* berformat *RGB* mampu mencapai nilai *recall* 100% pada kelas *Grade C*, yang membuktikan bahwa seluruh gambar *Grade C* di dalam dataset berhasil ditebak dengan benar tanpa ada satu pun data yang terlewat. Secara keseluruhan, data pengujian membuktikan bahwa pengubahan warna dari format asli *RGB* menjadi format *HSV* memberikan dampak yang berbeda pada tiap model. Akurasi *Naïve Bayes* naik tajam sebesar 12% (dari 77% menjadi 89%) karena format *HSV* memisahkan unsur cahaya (*Value*) dari unsur warna murni (*Hue* dan *Saturation*), sehingga model komputasi probabilistik tidak kebingungan oleh gambar yang terlalu terang atau gelap. Namun sebaliknya, akurasi *CNN* justru turun sebesar 7% (dari 98% menjadi 91%), di mana *recall* kelas *Grade B* anjlok menjadi 73%. Hal ini menyimpulkan bahwa ekstraksi fitur otomatis pada model *CNN* bekerja jauh lebih maksimal dalam mengenali warna dan tekstur asli kue menggunakan ruang warna *RGB* dibandingkan *HSV*.

IV. KESIMPULAN

Penelitian ini menyimpulkan bahwa model *Convolutional Neural Network* (CNN) yang dikombinasikan dengan pengolahan ruang warna *RGB* merupakan pendekatan komputasi yang paling optimal dalam membedakan kelas kualitas visual kue kastengel. Berdasarkan pengujian akhir, model *Naïve Bayes* menghasilkan akurasi sebesar 77,00% pada ruang warna dasar *RGB* dan meningkat menjadi 89,00% pada ruang warna *HSV*. Sementara itu, arsitektur *CNN* berhasil mencapai tingkat performa tertinggi dengan akurasi sebesar 98,44% pada ruang warna *RGB*, namun mengalami penurunan performa menjadi 90,62% saat dikombinasikan dengan ruang warna *HSV*. Pengujian ini membuktikan bahwa metode ekstraksi fitur spasial pada *CNN* mampu mengenali struktur objek secara lebih akurat dibandingkan perhitungan probabilitas piksel konvensional. Selain itu, pemisahan unsur intensitas pencahayaan dari nilai warna murni pada format *HSV* terbukti mampu menaikkan nilai akurasi pada model *Naïve Bayes*, meskipun pada model *CNN*, batas keputusan algoritma justru terbentuk lebih tegas dan presisi saat mengekstraksi nilai piksel dari ruang warna dasar *RGB*.

Saran untuk pengembangan penelitian komputasi di masa mendatang adalah perlunya evaluasi model terhadap variasi sudut pengambilan gambar yang lebih beragam. Peneliti selanjutnya disarankan untuk menerapkan teknik augmentasi transformasi geometri guna melatih ketahanan model dasar ini terhadap perubahan orientasi fisik objek uji. Di samping itu, pengujian pada kondisi fluktuasi pencahayaan yang ekstrem juga diperlukan untuk mengukur batas pergeseran nilai warna pada ruang *RGB* maupun saturasi pada ruang *HSV*, sehingga keandalan performa algoritma dapat terus dievaluasi pada skenario pengujian komputasi yang lebih dinamis.

DAFTAR PUSTAKA

- [1] M. S. Medho, E. V. Muhammad, and M. K. Salli, “PERBEDAAN PENAMBAHAN BAHAN PENUNJANG COOKIES PADA METODE CREAMING TERHADAP PENERIMAAN SENSORIK COOKIES TEPUNG KOMPOSIT JAGUNG PUTIH LOKAL TIMOR DAN DAUN KELOR (*Moringa oleifera*),” *Partner*, vol. 27, no. 1, p. 1747, 2022, doi: [10.35726/jp.v27i1.565](https://doi.org/10.35726/jp.v27i1.565)
- [2] A. Nurfitri, R. Munandar, and A. Fauzan, “Analisis Arsitektur Convolutional Neural Network Untuk Klasifikasi Citra Bunga,” vol. 6, no. 3, pp. 522–531, 2024, doi: <https://doi.org/10.47233/jteksis.v6i3.1413>
- [3] A. Faizah, S. Imron, A. Rahel, P. Rewur, J. N. Makasunggal, and P. H. Saputro, “Komparasi Algoritma Support Vector Machine (SVM) dan Convolutional Neural Network (CNN) untuk Klasifikasi Ekspresi Wajah,” vol. 4221, no. April 2025, pp. 13–24, 2027, doi: <https://doi.org/10.52958/iftk.v21i1.11091>
- [4] K. Akmal, A. Faqih, F. Dikananda, “PERBANDINGAN METODE ALGORITMA NAÏVE BAYES DAN K-NEAREST NEIGHBORS UNTUK KLASIFIKASI PENYAKIT STROKE,” vol. 7, no. 1, pp. 470–477, 2023, doi: <https://doi.org/10.36040/jati.v7i1.6367>
- [5] M. Afriansyah, J. Saputra, V. Yoga, P. Ardhana, and Y. Sa, “ALGORITMA NAIVE BAYES YANG EFISIEN UNTUK KLASIFIKASI BUAH PISANG RAJA BERDASARKAN FITUR WARNA,” vol. 1, no. 2, pp. 236–248, 2024, doi: <https://doi.org/10.59407/jismdb.v1i2.438>
- [6] E. Aji, A. Nasution, and Y. R. Nasution, “Klasifikasi Kematangan Buah Kelapa Sawit Berdasarkan Fitur Citra Warna Kulit Menggunakan Metode Transformasi Ruang Warna HSV dan K-Nearest Neighbor,” vol. 19, no. 1, pp. 38–48, 2026, doi: <https://doi.org/10.21107/rekayasa.v19i1.33679>
- [7] A. Zulkarnaen, T. Zagita, N. Asri, and U. Sriwijaya, “Pembuatan Aplikasi Android Pembelajaran Warna RGB Untuk Edukasi Pengolahan Citra Digital Dasar,” vol. 28, no. April, pp. 1–7, 2026, doi: <https://doi.org/10.56064/jps.v28i1.1330>
- [8] S. P. Agustiardani, D. Maharani, and E. Y. Puspaningrum, “Segmentasi Warna Batik Pesisir Jawa Menggunakan HSV dan Metode Linkage Average pada Hierarchical Clustering,” vol. 5, pp. 60–65, 2025, doi: <https://doi.org/10.33005/santika.v5i1.737>
- [9] A. D. Fareza, R. Toyib, P. Studi, T. Informatika, F. Teknik, and U. M. Bengkulu, “ANALISIS DAN IMPLEMENTASI CITRA DIGITAL PADA BUKU ISHIHARA UNTUK MELIHAT TINGKAT BUTA WARNA,” vol. 8, no. 5, pp. 11043–11049, 2024, doi: <https://doi.org/10.36040/jati.v8i5.11823>
- [10] P. P. Batam, P. N. Semarang, and U. Mulawarman, “Pengaruh Keseimbangan Kehidupan Kerja , Lingkungan Kerja , dan Keterlibatan Kerja terhadap Kinerja Karyawan Kedai Kopi,” vol. 7, no. April, pp. 1132–1143, 2023, doi: [10.33395/remik.v7i2.12330](https://doi.org/10.33395/remik.v7i2.12330)
- [11] X. Zhao, L. Wang, Y. Zhang, X. Han, M. Deveci, and M. Parmar, “A review of convolutional neural networks in computer vision,” *Artif. Intell. Rev.*, vol. 57, no. 4, pp. 99–, Mar. 2024, doi: <https://doi.org/10.1007/s10462-024-10721-6>

