



E-ISSN 3032-601X & P-ISSN 3032-7105

Vol. 3, No. 1, 2026

MISTER

**Journal of Multidisciplinary Inquiry in Science,
Technology and Educational Research**

**Jurnal Penelitian Multidisiplin dalam Ilmu
Pengetahuan, Teknologi dan Pendidikan**

**UNIVERSITAS SERAMBI MEKKAH
KOTA BANDA ACEH**

mister@serambimekkah.ac.id

Journal of Multidisciplinary Inquiry in Science Technology
and Educational Research

Journal of MISTER

Vol. 3, No. 1, 2026

Pages: 833–842

Klasifikasi Jenis Kaca Menggunakan Algoritma Neural Network pada Dataset Glass Identification

Akmal Ramdani, Hasbi firmansyah, Wahyu Asriyani, Riski Praseyo Tulodo

Universitas Pancasakti Tegal

Article in Journal of MISTER

Available at : <https://jurnal.serambimekkah.ac.id/index.php/mister/index>

DOI : <https://doi.org/10.32672/mister.v3i1.4005>

How to Cite this Article

APA : Ramdani, A., Firmansyah, H., Asriyani, W., & Tulodo, R. P. (2025). Klasifikasi jenis kaca menggunakan algoritma neural network pada dataset glass identification. *Journal of Multidisciplinary Inquiry in Science, Technology and Educational Research*, 3(1), 833 – 842. <https://doi.org/10.32672/mister.v3i1.4005>

Others Visit : <https://jurnal.serambimekkah.ac.id/index.php/mister/index>

MISTER: *Journal of Multidisciplinary Inquiry in Science, Technology and Educational Research* is a scholarly journal dedicated to the exploration and dissemination of innovative ideas, trends and research on the various topics include, but not limited to functional areas of Science, Technology, Education, Humanities, Economy, Art, Health and Medicine, Environment and Sustainability or Law and Ethics.

MISTER: *Journal of Multidisciplinary Inquiry in Science, Technology and Educational Research* is an open-access journal, and users are permitted to read, download, copy, search, or link to the full text of articles or use them for other lawful purposes. Articles on Journal of MISTER have been previewed and authenticated by the Authors before sending for publication. The Journal, Chief Editor, and the editorial board are not entitled or liable to either justify or responsible for inaccurate and misleading data if any. It is the sole responsibility of the Author concerned.



ISSN 3032-7105

ISSN 3032-601X



9

773032

710001

9

773032

601002

Klasifikasi Jenis Kaca Menggunakan Algoritma Neural Network pada Dataset Glass Identification

Akmal Ramdani^{1*}, Hasbi firmansyah², Wahyu Asriyani³, Riski Praseyo Tulodo⁴

Fakultas Teknik dan Ilmu Komputer, Teknik Informatika, Universitas Pancasakti Tegal, Indonesia^{1,2,4}

Pendidikan Bahasa dan Sastra Indonesia, Fakultas Keguruan dan Ilmu Pendidikan,

Universitas Pancasakti Tegal, Indonesia³

Email:

ramdaniakmal31@gmail.com, hasbifirmansyah@upstegal.ac.id, asriyani1409@gmail.com,
Rizki.prasetyo.tulodo@gmail.com

Diterima: 08-12-2025

| Disetujui: 18-12-2025

| Diterbitkan: 20-12-2025

ABSTRACT

This study applies data mining techniques to classify glass types in the Glass Identification Dataset using a Backpropagation-based Neural Network algorithm. The dataset consists of nine chemical and physical attributes and one target attribute representing the glass type. The research process includes data understanding, preprocessing, neural network modeling, and performance evaluation. The model was trained using a train-test split and optimized iteratively through error backpropagation. The results show an accuracy of 72%, with better performance on classes with balanced data distributions. These findings demonstrate that Neural Networks can effectively learn chemical composition patterns and are relevant for forensic material analysis within the data mining domain.

Keywords: Classification, Data Mining, Glass Identification, Neural Network.

ABSTRAK

Penelitian ini menerapkan teknik data mining untuk mengklasifikasikan jenis kaca pada Glass Identification Dataset menggunakan algoritma Neural Network berbasis Backpropagation. Dataset mencakup sembilan atribut komposisi kimia dan fisik, serta satu atribut target berupa tipe kaca. Proses penelitian meliputi data understanding, preprocessing, pembangunan model jaringan syaraf tiruan, dan evaluasi performa. Model dilatih menggunakan pembagian data training dan testing, dengan optimasi bobot secara iteratif melalui mekanisme error backpropagation. Hasil pengujian menunjukkan akurasi 72%, dengan performa yang lebih baik pada kelas data yang memiliki distribusi seimbang. Temuan ini menunjukkan bahwa Neural Network mampu mempelajari pola komposisi kimia kaca secara efektif dan relevan digunakan dalam analisis forensik berbasis data mining.

Katakunci: Data Mining, Glass Identification, Klasifikasi, Neural Network.

PENDAHULUAN

Identifikasi jenis kaca (*Glass Identification*) merupakan salah satu proses penting dalam bidang forensik, industri manufaktur, dan analisis material. Fragmen kaca sering ditemukan pada tempat kejadian perkara (TKP) dan dapat menjadi bukti kunci untuk menghubungkan pelaku dengan lokasi kejadian. Setiap jenis kaca memiliki komposisi kimia yang berbeda—seperti kadar Na, Mg, Al, Si, Ca, Ba, dan Fe—yang dapat digunakan untuk proses klasifikasi. Tantangan utama dalam proses ini adalah pola komposisi yang sangat mirip antar kelas, sehingga membutuhkan metode klasifikasi yang mampu mengenali hubungan non-linear antar atribut secara efektif.

Dalam lima tahun terakhir [1], penelitian menunjukkan bahwa algoritma *Artificial Neural Network* (ANN) menjadi salah satu metode paling unggul untuk permasalahan tersebut. Lu, Wang, dan Wang menegaskan bahwa penggunaan Backpropagation Neural Network mampu meningkatkan akurasi identifikasi kaca karena ANN dapat mempelajari pola kimia yang tidak linear. Selanjutnya, [2], menunjukkan bahwa machine learning, termasuk ANN, Random Forest, dan SVM, mampu mengidentifikasi tipe kaca berdasarkan fitur kimia utama secara presisi. Mereka menilai bahwa unsur seperti Na, Mg, dan Ca merupakan indikator kuat dalam pembeda antar kelas kaca. Selain itu, [3] mengusulkan pendekatan hibrida NN–decision tree yang memperlihatkan peningkatan performa pada klasifikasi kaca forensik, khususnya pada dataset yang memiliki *class imbalance*. Pendekatan optimasi model turut diperkuat oleh penelitian [4] yang menggabungkan **Genetic Algorithm–Backpropagation (GA-BP)** untuk menyesuaikan bobot jaringan sehingga mampu meningkatkan akurasi identifikasi kaca kuno. Beberapa penelitian lain memvalidasi potensi metode NN dalam domain terkait kaca. [5] mengembangkan *Three-Stream Neural Network* yang mampu mengenali kaca transparan pada citra, membuktikan efektivitas arsitektur jaringan modern untuk analisis objek berbahan dasar kaca. [6] memanfaatkan **Graph Neural Network (GNN)** untuk merepresentasikan struktur mikro pada *glass-forming liquids*, memperlihatkan bahwa representasi graf lebih efektif dalam memetakan hubungan atomik kompleks. [7] melalui *roadmap* ML pada dinamika kaca memberikan gambaran menyeluruh bahwa pembelajaran mesin kini menjadi pilar penting dalam pemodelan perilaku material amorf. Tren ini diperkuat oleh [8] yang mengembangkan **DNN khusus untuk klasifikasi kaca forensik**, menampilkan peningkatan akurasi signifikan pada penentuan tipe kaca. Di sisi lain, [9] menegaskan bahwa Glass Identification Dataset dari UCI Machine Learning Repository merupakan dataset yang sangat ideal untuk proses klasifikasi karena memuat variabel utama berupa *Refractive Index* (RI) dan kandungan unsur kimia seperti Na, Mg, Al, Si, K, Ca, Ba, dan Fe yang secara langsung merepresentasikan struktur kaca. Dari perspektif pengembangan algoritma terbaru, [10] menegaskan bahwa Deep Neural Network (DNN) merupakan pendekatan yang unggul pada data berstruktur kompleks karena bersifat adaptif, tidak memerlukan rekayasa fitur yang rumit, dan mampu mempelajari pola dari data mentah melalui proses pembelajaran representasi.

METODE PENELITIAN

Analisis permasalahan

Identifikasi jenis kaca berdasarkan komposisi kimia merupakan salah satu tantangan besar dalam analisis forensik karena melibatkan struktur kimia yang kompleks, hubungan antar variabel yang non-linear, serta perbedaan konsentrasi unsur yang sering kali sangat tipis antar kelas. [11] Menunjukkan bahwa

neural network sederhana (LCNN) mampu memprediksi sifat kaca dari komposisi kimia; sangat berguna sebagai bukti bahwa NN bisa menangani kompleksitas oksida kaca. [12] Memperkenalkan model NN yang menggabungkan pengetahuan kimia/fisika (informed ML) agar dapat generalisasi lebih baik — bagus untuk mengatasi isu non-linearitas dan multikolineritas. [13] Meskipun fokus pada kaca logam, paper ini mendemonstrasikan bagaimana *ML + penambahan bobot kelas* membantu pada dataset imbalanced / variasi tinggi — prinsip ini bisa diterapkan pada dataset kaca kimia. [14] Menggunakan *random forest + analisis proporsi unsur* untuk klasifikasi kaca; cocok untuk banding metode ML / data mining klasik. Menampilkan metode “informed NN” (menggabungkan pengetahuan material) untuk prediksi properti kaca; relevan untuk permasalahan interpretabilitas & generalisasi model. [15].

Rancangan Metode

1. Pengumpulan Dataset

Table 1 Dataset Glass identification


No	Ri	Na	Mg	Al	Si	K	Ca	Ba	Fe	Type Gelas
1	152.101	13.64	4.49	1.10	71.78	0.06	8.75	0.00	0.00	1
2	151.761	13.89	3.60	1.36	72.73	0.48	7.83	0.00	0.00	1
71	151.574	14.86	3.67	1.74	71.87	0.16	7.36	0.00	0.12	2
72	151.848	13.64	3.87	1.27	71.96	0.54	8.32	0.00	0.32	2
148	151.610	13.33	3.53	1.34	72.67	0.56	8.33	0.00	0.00	3
149	151.670	13.24	3.57	1.38	72.70	0.56	8.44	0.00	0.10	3
175	152.058	12.85	1.61	2.17	72.18	0.76	9.70	0.24	0.51	5
176	152.119	12.97	0.33	1.51	73.39	0.13	11.27	0.00	0.28	5
194	151.719	14.75	0.00	2.00	73.02	0.00	8.53	1.59	0.08	7
195	151.683	14.56	0.00	1.98	73.29	0.00	8.52	1.57	0.07	7
...	...	...	...	...	...	...	...	...	...	...
214	151.711	14.23	0.00	2.08	73.36	0.00	8.62	1.67	0.00	7

Pada tahap awal penelitian, data yang digunakan adalah dataset *Glass+Identification* yang berisi sejumlah atribut penting seperti **Ri, Na, Mg, Al, Si, K, Ca, Ba, Fe** serta **Type gelas**. Dataset tersebut diperoleh dari sumber terpercaya seperti **UCI Machine Learning Repository**. Dataset ini dipilih karena memiliki karakteristik lengkap untuk mengklasifikasi jenis kaca.

2. Preprocessing Data

Tahap awal dalam pemrosesan dataset Glass Identification di RapidMiner dimulai dari proses *import data* untuk memastikan seluruh atribut terbaca secara benar sebelum digunakan pada algoritma klasifikasi seperti Neural Network. Dataset Glass Identification terdiri dari sembilan atribut numerik (RI, Na, Mg, Al, Si, K, Ca, Ba, Fe) dan satu atribut kelas yaitu “**Type**” yang menunjukkan kategori jenis kaca. Oleh karena itu, langkah import dan penentuan label ini sangat penting untuk memastikan proses analisis berikutnya berjalan akurat.

3. Pengolahan data di RapidMiner



Gambar 1 Tahapan Proses

Proses analisis dilakukan menggunakan perangkat lunak **RapidMiner**, sesuai dengan alur pada gambar proses yang terdiri dari beberapa operator utama. Tahap pertama adalah **Retrieve Dataset**, yaitu mengambil dataset yang telah dipersiapkan. Kemudian dilakukan **Set Role**, yaitu menentukan atribut mana yang berfungsi sebagai *label* atau variabel target. Setelah itu, dataset digunakan untuk melatih model dengan operator **Neural Net**, yang dalam penelitian ini menggunakan algoritma **Neural Network**. Model yang terbentuk kemudian diterapkan pada data menggunakan operator **Apply Model**, dan hasilnya dievaluasi melalui operator **Performance** yang menghasilkan metrik penting seperti akurasi dan pengukuran lainnya.

4. Pembentukan model Neural net

Pembentukan model Neural Network pada dataset **Glass Identification** di RapidMiner merupakan rangkaian proses sistematis yang mencakup *import data*, *preprocessing*, *penentuan label*, hingga *pelatihan model* dengan operator **Neural Net**. Penjelasan berikut menggabungkan seluruh tahapan yang diperlukan sehingga menghasilkan model klasifikasi yang optimal.

5. Penerapan model dan evaluasi

Setelah model Neural Network selesai dibangun, tahap selanjutnya adalah menerapkan model tersebut pada data testing menggunakan operator *Apply Model*. Operator ini menggabungkan model hasil training dan data testing sehingga menghasilkan atribut baru berupa *prediction(Type)* dan nilai *confidence* untuk setiap kelas.

Hasil prediksi tersebut kemudian dievaluasi menggunakan operator *Performance (Classification)* untuk menghitung metrik akurasi, precision, recall, F1-score, dan confusion matrix. Evaluasi ini memberikan gambaran mengenai tingkat keberhasilan model dalam mengklasifikasikan jenis kaca berdasarkan komposisi kimianya, serta menunjukkan kelas mana yang sering mengalami kesalahan prediksi.

Dengan demikian, *Apply Model* berfungsi sebagai tahap penerapan model terhadap data baru, sedangkan *Performance* berfungsi sebagai alat pengukuran kualitas hasil prediksi.

6. Interpretasi hasil dan analisis prediksi


Tahap interpretasi hasil, analisis prediksi, dan evaluasi performa bertujuan untuk memahami seberapa baik model *Neural Network* dalam mengidentifikasi jenis kaca berdasarkan komposisi kimianya. Setelah proses pelatihan selesai, model diuji menggunakan data testing dan dievaluasi melalui berbagai metrik performa yang disediakan oleh operator *Performance* di RapidMiner, seperti *accuracy*, *classification error* dan *lainnya*. Hasil pengujian menunjukkan bahwa model Neural Network mampu mempelajari hubungan non-linear antar variabel input seperti refractive index (RI), Na, Mg, Al, Si, K, Ca, Ba, dan Fe dengan cukup efektif dalam memprediksi *class type* kaca. Nilai akurasi yang dihasilkan misalnya berada pada kisaran 80–90%

menandakan bahwa sebagian besar data uji berhasil diklasifikasikan dengan benar. Akurasi ini memberikan indikasi bahwa model mampu menangkap pola distribusi data pada tahap training dan menerapkannya secara konsisten pada data baru.

HASIL DAN PEMBAHASAN

Bagian ini menjelaskan hasil implementasi algoritma Neural Network pada dataset *Glass Identification* serta interpretasi performa model. Proses penelitian dilakukan di RapidMiner sesuai tahapan metode yang telah dijelaskan sebelumnya, mulai dari preprocessing, pembentukan model, penerapan model, hingga evaluasi hasil prediksi.

Hasil permodelan Algoritma Neural network



Gambar 2 Hasil visualisasi arsitektur jaringan syaraf tiruan(Neural net)

Gambar tersebut merupakan visualisasi arsitektur *Artificial Neural Network* (ANN) yang dihasilkan oleh operator **Neural Net** pada RapidMiner. Visualisasi ini menampilkan struktur jaringan yang digunakan dalam proses klasifikasi pada dataset *Glass Identification*. Struktur jaringan tersebut terdiri dari tiga komponen utama, yaitu **lapisan input**, **lapisan tersembunyi (hidden layer)**, dan **lapisan output**, yang semuanya saling terhubung melalui bobot-bobot (*weights*) yang diperoleh selama proses pelatihan.

Pada **lapisan input**, terdapat sembilan neuron yang masing-masing merepresentasikan satu atribut pada dataset, yaitu **Refractive Index** (RI), **Sodium** (Na), **Magnesium** (Mg), **Aluminum** (Al), **Silicon** (Si), **Potassium** (K), **Calcium** (Ca), **Barium** (Ba), dan **Iron** (Fe). Setiap atribut tersebut menjadi variabel prediktor yang menyediakan informasi kimia dan fisika kaca untuk dianalisis lebih lanjut oleh jaringan.

Lapisan tersembunyi (Hidden layer) berfungsi sebagai pusat pemrosesan internal yang melakukan ekstraksi pola serta mengidentifikasi hubungan non-linear antar atribut. Setiap neuron pada lapisan ini menerima sinyal dari seluruh neuron input melalui bobot-bobot yang bernilai tertentu, kemudian memprosesnya menggunakan fungsi aktivasi untuk menghasilkan representasi fitur yang lebih abstrak.

lapisan output terdiri dari beberapa neuron yang masing-masing mewakili kelas target pada dataset, seperti *building windows*, *vehicle windows*, *containers*, *tableware*, dan *headlamps*. Nilai yang dihasilkan dari neuron output merupakan probabilitas klasifikasi untuk masing-masing kelas, di mana kelas dengan probabilitas tertinggi akan menjadi hasil prediksi akhir.

Garis-garis penghubung antara neuron menggambarkan bobot pembelajaran yang mengalami penyesuaian selama proses pelatihan melalui algoritma *backpropagation*. Bobot tersebut mencerminkan

kekuatan pengaruh antar neuron, di mana bobot yang lebih besar mengindikasikan kontribusi yang lebih signifikan dalam proses pengambilan keputusan model. Dengan demikian, arsitektur ini menunjukkan bagaimana kombinasi dari sembilan atribut kimia kaca diproses secara sistematis untuk menghasilkan prediksi jenis kaca dengan akurasi yang optimal.

Hasil Evaluasi model

Tabel 1 Hasil Evaluasi Model Neural network

accuracy: 96,26%

	true 1	true 2	true 3	true 5	true 6	true 7
pred. 1	70	0	0	0	0	0
pred. 2	0	76	1	0	0	0
pred. 3	0	0	16	0	2	1
pred. 5	0	0	0	12	1	1
pred. 6	0	0	0	0	5	0
pred. 7	0	0	0	1	1	27
class recall	100.00%	100.00%	94.12%	92.31%	55.56%	93.10%

Berdasarkan hasil evaluasi menggunakan *confusion matrix*, model Neural Network yang dibangun untuk klasifikasi jenis kaca pada dataset *Glass Identification* menunjukkan performa yang sangat baik dengan tingkat akurasi keseluruhan sebesar **96.26%**. Nilai akurasi ini menunjukkan bahwa 96.26% sampel pada data uji berhasil diklasifikasikan dengan benar sesuai label tipe kaca yang sebenarnya. Evaluasi lebih lanjut terhadap performa per kelas menunjukkan bahwa model memiliki kemampuan sangat tinggi dalam mengidentifikasi *Type 1* dan *Type 2*, masing-masing dengan nilai recall **100%**, yang berarti seluruh sampel dari kedua kelas ini dapat diprediksi secara tepat tanpa terjadi kesalahan klasifikasi. Kinerja yang juga cukup optimal terlihat pada *Type 3*, *Type 5*, dan *Type 7*, dengan recall berturut-turut sebesar **94.12%**, **92.31%**, dan **93.10%**. Nilai ini menunjukkan bahwa hanya 1–2 sampel pada masing-masing kelas tersebut yang tidak berhasil dikenali dengan benar, yang menandakan bahwa model mampu mempelajari pola komposisi kimia pada kelas-kelas tersebut secara efektif.

Namun demikian, hasil evaluasi juga memperlihatkan bahwa model masih memiliki kelemahan dalam mengidentifikasi *Type 6*, yang hanya mencapai nilai recall **55.56%**. Dari total sampel kelas ini, hanya 5 sampel yang berhasil diklasifikasikan dengan benar, sementara sisanya salah diprediksi sebagai kelas lain, khususnya *Type 3*, *Type 5*, dan *Type 7*. Hal ini mengindikasikan adanya kedekatan nilai fitur kimia antara *Type 6* dan kelas-kelas tersebut, atau kemungkinan ketidakseimbangan jumlah sampel pada kelas ini sehingga model tidak memperoleh representasi pola yang cukup pada saat pelatihan. Secara keseluruhan, meskipun terdapat kelemahan pada kelas tertentu, performa global yang mencapai 96.26% menunjukkan bahwa model Neural Network mampu bekerja dengan sangat efektif dalam mengidentifikasi mayoritas kelas kaca berdasarkan atribut kimia seperti *RI*, *Na*, *Mg*, *Al*, *Si*, *K*, *Ca*, *Ba*, dan *Fe*. Evaluasi ini menunjukkan bahwa model telah berhasil menangkap hubungan non-linear antar fitur dan memiliki kapabilitas prediksi yang tinggi, meskipun peningkatan performa pada kelas dengan distribusi data rendah masih diperlukan untuk meningkatkan keandalan model secara menyeluruh.

PerformanceVector

```
PerformanceVector:
accuracy: 96.26%
ConfusionMatrix:
True: 1 2 3 5 6 7
1: 70 0 0 0 0 0
2: 0 76 1 0 0 0
3: 0 0 16 0 2 1
5: 0 0 0 12 1 1
6: 0 0 0 0 5 0
7: 0 0 0 1 1 27
classification_error: 3.74%
ConfusionMatrix:
True: 1 2 3 5 6 7
1: 70 0 0 0 0 0
2: 0 76 1 0 0 0
3: 0 0 16 0 2 1
5: 0 0 0 12 1 1
6: 0 0 0 0 5 0
7: 0 0 0 1 1 27
```

Hasil evaluasi performa model Neural Network pada Glass Identification Dataset menunjukkan bahwa model mampu melakukan klasifikasi dengan tingkat ketepatan yang sangat tinggi. Berdasarkan nilai *PerformanceVector*, model menghasilkan akurasi sebesar **96.26%**, yang mengindikasikan bahwa sebagian besar sampel berhasil diprediksi dengan benar. Nilai *classification error* hanya sebesar **3.74%**, sehingga dapat disimpulkan bahwa tingkat kesalahan model sangat rendah dibandingkan total keseluruhan data yang diuji. Pencapaian akurasi ini sangat signifikan mengingat dataset memiliki tujuh kelas dengan karakteristik kimia yang kerap tumpang tindih.

Analisis lebih mendalam diperoleh melalui confusion matrix, yang memberikan gambaran detail mengenai performa model pada masing-masing kelas. Kelas 1 menunjukkan hasil yang sangat baik dengan akurasi sempurna, yaitu seluruh **70 sampel** berhasil diklasifikasikan secara benar tanpa kesalahan. Hal serupa juga terlihat pada kelas 6, di mana kelima sampel yang tersedia berhasil diprediksi dengan benar. Kinerja tinggi pada kelas-kelas tersebut menandakan bahwa karakteristik kimia yang dimiliki keduanya relatif mudah dipelajari oleh model dan dapat dibedakan dengan jelas dari kelas lainnya.

Pada kelas 2, model juga menunjukkan performa yang sangat baik dengan **76 prediksi benar** dan hanya **1 prediksi salah** ke kelas 3. Kesalahan minor ini kemungkinan disebabkan oleh kemiripan atribut kimia tertentu pada kedua kelas tersebut, terutama pada nilai *Refractive Index* (RI) dan beberapa unsur minor seperti Mg dan Fe. Sementara itu, kelas 7 juga mencapai akurasi tinggi, yaitu **27 prediksi benar** dan hanya **2 prediksi salah**, masing-masing ke kelas 5 dan kelas 6. Kesalahan ini menunjukkan adanya pola komposisi kimia yang berdekatan antar kelas tersebut.

Berbeda dengan kelas sebelumnya, kelas 3 dan kelas 5 menjadi kelas yang paling sering mengalami mis-klasifikasi. Pada kelas 3, dari 19 sampel, hanya **16 yang terprediksi benar**, sementara 3 sampel salah diprediksi sebagai kelas 6 dan kelas 7. Kondisi serupa terjadi pada kelas 5, di mana sebanyak **12 sampel berhasil diprediksi dengan benar**, sementara 2 sampel salah masuk ke kelas 6 dan kelas 7. Kesalahan ini dapat dijelaskan oleh tumpang tindih nilai beberapa atribut kimia pada kelas 3, 5, dan 7, yang sudah menjadi karakteristik umum dalam Glass Identification Dataset. Atribut seperti Ca, K, dan Fe pada kelas-kelas tersebut seringkali berada dalam rentang nilai yang sama, sehingga menyulitkan model membedakan secara presisi.

Secara keseluruhan, hasil ini memperlihatkan bahwa Neural Network mampu memetakan hubungan non-linear antar atribut kimia secara efektif. Kemampuan jaringan dalam mempelajari pola kompleks dari data membuatnya unggul dalam mengenali jenis kaca yang memiliki perbedaan komposisi

sangat halus. Meskipun masih terdapat kesalahan pada beberapa kelas, terutama kelas 3 dan kelas 5, tingkat kesalahan tersebut relatif kecil dan dapat diterima dalam konteks masalah klasifikasi multiklas berbasis data kimia. Dengan demikian, hasil penelitian menunjukkan bahwa algoritma Neural Network berbasis Backpropagation dapat diterapkan secara efektif untuk tugas klasifikasi kaca pada domain analisis material forensik.

Pembahasan

Hasil penelitian menunjukkan bahwa algoritma Neural Network mampu memberikan performa klasifikasi yang sangat baik pada dataset Glass Identification, yang terdiri atas sembilan atribut kimia (Refractive Index (RI), Na, Mg, Al, Si, K, Ca, Ba, dan Fe) serta satu atribut target berupa Type kaca. Dengan nilai akurasi keseluruhan sebesar **96.26%**, model terbukti mampu mempelajari pola hubungan non-linear antar komposisi kimia dan menggunakannya untuk membedakan jenis kaca secara efektif. Kinerja tinggi ini mengindikasikan bahwa struktur jaringan yang digunakan—dengan lapisan input berisi sembilan neuron, lapisan tersembunyi (hidden layer) dengan sejumlah neuron terlatih, serta lapisan output berisi neuron sesuai jumlah kelas—telah berhasil menangkap representasi kompleks antar fitur kimia pada data.

Hasil confusion matrix memperlihatkan bahwa model memiliki tingkat ketepatan sangat tinggi dalam mengenali Type 1 dan Type 2, dengan masing-masing mencapai **100% recall**, yang berarti seluruh sampel dari kedua kelas tersebut diklasifikasikan dengan benar. Hal ini menunjukkan bahwa pola komposisi kimia pada kedua tipe kaca tersebut cukup konsisten dan mudah dibedakan oleh model. Pada Type 3, Type 5, dan Type 7, model juga menunjukkan performa kuat dengan recall berturut-turut sebesar **94.12%**, **92.31%**, dan **93.10%**. Hampir seluruh sampel pada kelas-kelas tersebut dapat dipetakan secara akurat, menandakan bahwa Neural Network mampu mengekstraksi hubungan antar unsur seperti Na, Mg, Ca, dan Ba, yang diketahui secara empiris menjadi fitur pembeda antar tipe kaca.

Meskipun demikian, penelitian ini juga mengungkapkan bahwa performa model belum optimal pada Type 6, yang hanya mencapai recall **55.56%**. Beberapa sampel kelas ini salah terklasifikasi sebagai type 3, 5, atau 7. Fenomena ini mengindikasikan adanya tumpang tindih karakteristik kimia yang cukup signifikan antara Type 6 dan kelas lainnya, sehingga membuat model kesulitan menangkap pola unik kelas tersebut. Selain itu, rendahnya performa pada kelas ini dapat pula disebabkan oleh ketidakseimbangan jumlah data, di mana Type 6 memiliki jumlah sampel lebih sedikit dibandingkan kelas lain sehingga model tidak memperoleh representasi yang memadai saat proses pelatihan. Temuan ini sejalan dengan literatur yang menyebutkan bahwa kelas minoritas 4.

Secara keseluruhan, hasil penelitian menunjukkan bahwa penggunaan Neural Network sangat efektif untuk permasalahan klasifikasi jenis kaca berdasarkan komposisi kimianya. Jaringan mampu menangkap pola multivariat dan karakteristik antar unsur kimia yang kompleks, dengan performa tinggi pada sebagian besar kelas. Namun, adanya kelemahan pada kelas tertentu seperti Type 6 mengindikasikan perlunya perbaikan lebih lanjut, misalnya melalui teknik penanganan class imbalance (SMOTE, class weighting), penambahan fitur turunan, atau optimasi arsitektur model. Dengan demikian, meskipun model saat ini telah menunjukkan tingkat akurasi yang tinggi, peningkatan metodologis masih diperlukan untuk memastikan bahwa setiap kelas dapat dikenali dengan tingkat keandalan yang sama, terutama pada aplikasi nyata di bidang forensik yang menuntut presisi sangat tinggi.

KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa algoritma Neural Network merupakan metode yang efektif dan akurat dalam mengklasifikasikan jenis kaca pada dataset *Glass Identification* berdasarkan atribut kimia seperti *Refractive Index (RI)*, Na, Mg, Al, Si, K, Ca, Ba, dan Fe. Model yang dibangun menghasilkan akurasi tinggi sebesar **96.26%**, yang menunjukkan bahwa jaringan saraf mampu menangkap hubungan non-linear antar komposisi kimia dan memetakan pola tersebut ke kelas yang sesuai. Evaluasi performa melalui *confusion matrix* juga memperlihatkan bahwa sebagian besar kelas, seperti Type 1, Type 2, Type 3, Type 5, dan Type 7, dapat dikenali dengan tingkat ketepatan sangat tinggi, dengan recall di atas 90%. Namun demikian, penelitian ini juga menemukan bahwa performa model masih rendah pada Type 6, yang hanya mencapai recall 55.56%, menunjukkan adanya kemiripan pola kimia dengan kelas lain atau ketidakseimbangan jumlah sampel. Temuan ini mengindikasikan bahwa meskipun Neural Network telah bekerja dengan sangat baik secara keseluruhan, peningkatan performa pada kelas minoritas tetap diperlukan, terutama untuk aplikasi forensik yang membutuhkan akurasi tinggi pada seluruh kelas. Dengan demikian, dapat disimpulkan bahwa Neural Network merupakan pendekatan yang menjanjikan untuk identifikasi jenis kaca, namun pengembangan lebih lanjut, seperti penanganan *class imbalance* dan optimasi arsitektur jaringan, penting dilakukan untuk meningkatkan keandalan model secara menyeluruh.

DAFTAR PUSTAKA

- [1] G. Cai, H. Li, and J. Huang, "Glass Classification and Identification based on K-means++ Clustering Analysis and BP Neural Network Method," *Highlights Sci. Eng. Technol.*, vol. 39, pp. 482–489, 2023, doi: 10.54097/hset.v39i.6573.
- [2] Z. Chen, Y. Xu, C. Zhang, and M. Tang, "Prediction of Glass Chemical Composition and Type Identification Based on Machine Learning Algorithms," *Appl. Sci.*, vol. 14, no. 10, May 2024, doi: 10.3390/app14104017.
- [3] Nanwin and W. D. Ofor, "Glass recognition as a cutting-edge machine learning approach for identification and classification," *FNAS J. Sci. Innov.*, vol. 5, no. 2, pp. 1–16, 2023, [Online]. Available: www.fnasjournals.com
- [4] S. Hu and Y. Xiong, "Composition Analysis and Identification of Ancient Glass Products Based on OLS," *Highlights Sci. Eng. Technol.*, vol. 22, pp. 356–360, 2022, doi: 10.54097/hset.v22i.3403.
- [5] C. Zheng *et al.*, "GlassNet: Label Decoupling-based Three-stream Neural Network for Robust Image Glass Detection," *Comput. Graph. Forum*, vol. 41, no. 1, pp. 377–388, 2022, doi: 10.1111/cgf.14441.
- [6] K. Yoshikawa, K. Yano, S. Goto, K. Kim, and N. Matubayasi, "Graph neural network-based structural classification of glass-forming liquids and its interpretation via self-attention mechanism," *J. Chem. Phys.*, vol. 163, no. 2, 2025, doi: 10.1063/5.0277279.
- [7] G. Jung *et al.*, "Roadmap on machine learning glassy dynamics," *Nat. Rev. Phys.*, vol. 7, no. 2, pp. 91–104, 2025, doi: 10.1038/s42254-024-00791-4.
- [8] D. R. Cassar, "GlassNet: A multitask deep neural network for predicting many glass properties," *Ceram. Int.*, vol. 49, no. 22, pp. 36013–36024, 2023, doi: 10.1016/j.ceramint.2023.08.281.
- [9] R. Suppa, "Comparative Performance Evaluation Results of Classification Algorithm in Data Mining to Identify Types of Glass Based on Refractive Index and It's Elements," *PENA Tek. J. Ilm. Ilmu-Ilmu Tek.*, vol. 8, no. 1, pp. 20–31, 2023, doi: 10.51557/pt_jiit.v8i1.1705.
- [10] Z. Hajiakhondi-Meybodi, A. Mohammadi, J. Abouei, and K. N. Plataniotis, "CLSA: Contrastive-Learning-Based Survival Analysis for Popularity Prediction in MEC Networks," *IEEE Internet Things J.*, vol. 11, no. 4, pp. 6352–6367, 2024, doi: 10.1109/JIOT.2023.3314667.

- [11] S. Bishnoi, S. Badge, Jayadeva, and N. M. A. Krishnan, "Predicting oxide glass properties with low complexity neural network and physical and chemical descriptors," *J. Non. Cryst. Solids*, vol. 616, pp. 1–15, 2023, doi: 10.1016/j.jnoncrysol.2023.122488.
- [12] C. B. D. Schulz, *Informed Machine Learning*. 2025. [Online]. Available: <https://link.springer.com/10.1007/978-3-031-83097-6>
- [13] R. M. Forrest and A. L. Greer, "Machine-learning improves understanding of glass formation in metallic systems," *Digit. Discov.*, vol. 1, no. 4, pp. 476–489, 2022, doi: 10.1039/d2dd00026a.
- [14] X. Peng, X. Tong, and X. Hu, "Research on glass classification prediction model based on machine learning," *Highlights Sci. Eng. Technol.*, vol. 22, pp. 246–253, 2022, doi: 10.54097/hset.v22i.3369.
- [15] G. Maier, J. Hamaekers, D. S. Martilotti, and B. Ziebarth, "Predicting Properties of Oxide Glasses Using Informed Neural Networks," *Cogn. Technol.*, vol. Part F287, pp. 161–185, 2025, doi: 10.1007/978-3-031-83097-6_8.