



Klasifikasi Multilabel Pada Gaya Belajar Siswa Sekolah Dasar Menggunakan Algoritma *Machine Learning*

I Kadek Nicko Ananda¹, Ni Putu Novita Puspa Dewi², Ni Wayan Marti³, Luh Joni Erawati Dewi⁴

^{1,2,3,4}Teknik Informatika, Teknik dan Kejuruan, Universitas Pendidikan Ganesha

¹nicko@undiksha.ac.id, ²novita.puspa.dewi@undiksha.ac.id*, ³wayan.marti@undiksha.ac.id, ⁴joni.erawati@undiksha.ac.id

Abstract

Learning style plays a very important role in determining the success of a person's learning process. An individual generally has a combination of all three existing learning styles including Visual, Auditorial, and Kinesthetic. However, what distinguishes the abilities of individuals from each other is how the dominant combination of each learning style is or not, so it is important to identify. This study aims to build a multi-label classification model to classify the learning styles of elementary school students. The machine learning algorithms used to build the model are Decision Tree, K-Nearest Neighbors (KNN), Support Vector Machine (SVM), and Multi-Layer Perceptron (MLP). The performance of these four models is compared using the Hamming Loss, Accuracy, Precision, Recall, and F1-Score performance metrics. The Classifier Chains method is implemented to provide capabilities to KNNs and SVMs that cannot directly handle multi-label classification problems. The dataset used in this study is the Data Set of Learning Style Preference. The separation of the dataset was made into three different forms of data sizes, including: Data I: 90% training, 10% testing; Data II: 80% training 20% testing; and Data III: 70% training 30% testing. Cross-validation using K-Fold Cross Validation with a k-value of 10-fold was also applied to the training data. Based on testing, the best performance was obtained on the Decision Tree model with a hamming loss of 0.014, which indicates a very low prediction error rate per individual label. An accuracy value of 95% indicates the model's excellent ability to predict data labels according to actual labels. In addition, the precision value of 98% reflects the high accuracy in identifying positive labels that truly fall into the positive class. A recall value of 99% indicates that the model is able to detect almost all positive labels correctly, and an F1-score of 98% indicates that the model has excellent and balanced performance, without bias against both positive and negative label predictions. The performance of the Decision Tree model was followed by MLP, SVM, and KNN which showed lower results.

Keywords: Machine Learning, Learning Style, Multilabel Classification, Data Set of Learning Style Preference, Decision Tree

Abstrak

Gaya belajar merupakan salah satu kunci yang berperan sangat penting dalam menentukan keberhasilan proses pembelajaran dari seseorang. Seorang individu umumnya memiliki kombinasi dari ketiga gaya belajar yang ada meliputi Visual, Auditorial, dan Kinestetik. Namun, yang membedakan kemampuan individu satu dengan yang lainnya adalah bagaimana kombinasi dominan atau tidaknya setiap gaya belajar tersebut sehingga penting untuk dilakukan identifikasi. Penelitian ini bertujuan untuk membangun model klasifikasi multilabel untuk mengklasifikasikan gaya belajar siswa sekolah dasar. Algoritma *machine learning* yang digunakan untuk membangun model adalah *Decision Tree*, *K-Nearest Neighbors* (KNN), *Support Vector Machine* (SVM), dan *Multi-Layer Perceptron* (MLP). Kinerja keempat model ini dibandingkan dengan menggunakan metrik performa *Hamming Loss*, *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Metode *Classifier Chains* diimplementasikan untuk memberikan kemampuan pada KNN dan SVM yang tidak dapat secara langsung menangani permasalahan klasifikasi multilabel. Dataset yang digunakan dalam penelitian ini adalah *Data Set of Learning Style Preference*. Pemisahan dataset dibuat ke dalam tiga bentuk ukuran data yang berbeda meliputi Data I:90% pelatihan 10% pengujian; Data II:80% pelatihan 20% pengujian; dan Data III:70% pelatihan 30% pengujian. Validasi silang menggunakan *K-Fold Cross Validation* dengan nilai *k* sebesar 10-fold juga diterapkan pada data pelatihan. Berdasarkan pengujian, performa terbaik diperoleh pada model *Decision Tree* dengan *hamming loss* sebesar 0.014, yang menunjukkan tingkat kesalahan prediksi per label individu yang sangat rendah. Nilai *accuracy* sebesar 95% menunjukkan kemampuan model yang sangat baik dalam memprediksi label data sesuai dengan label sebenarnya. Selain itu, nilai *precision* sebesar 98% mencerminkan keakuratan yang tinggi dalam mengidentifikasi label positif yang benar-benar termasuk dalam kelas positif. Nilai *recall* sebesar 99% mengindikasikan bahwa model mampu mendeteksi hampir seluruh label positif dengan benar, dan *F1-score* sebesar 98% menunjukkan bahwa model memiliki kinerja yang sangat baik dan seimbang, tanpa bias terhadap prediksi label positif maupun negatif. Performa model *Decision Tree* diikuti oleh MLP, SVM, dan KNN yang menunjukkan hasil lebih rendah.

Kata kunci: Machine Learning, Gaya Belajar, Klasifikasi Multilabel, Data Set of Learning Style Preference, Decision Tree



Lisensi

Lisensi Internasional Creative Commons Attribution-ShareAlike 4.0.

1. Pendahuluan

Gaya belajar adalah sebuah kemampuan yang dimiliki oleh setiap individu dalam proses menyerap, mengatur, dan mengolah informasi yang diterimanya [1]. Gaya belajar merupakan salah satu kunci yang memegang peranan sangat penting dalam mempengaruhi kualitas keberhasilan seseorang selama proses pembelajaran. Salah satu dampak dari gaya belajar ini adalah dapat meningkatkan efektivitas dalam menyerap informasi selama proses pembelajaran dalam konteks apapun, sehingga penting untuk memahami gaya belajar yang paling dominan [1][2]. Di dalam gaya belajar terdapat tiga tipe yang dapat dibedakan terdiri dari gaya belajar Visual, Auditorial, dan Kinestetik [3]. Pada umumnya, seseorang menggunakan ketiga gaya belajar tersebut pada tahapan tertentu dalam pembelajaran, tetapi setiap orang dapat memiliki kecenderungan berbeda pada tingkatan kombinasi kemampuan dominan salah satu atau lebih gaya belajar.

Dalam menentukan gaya belajar seseorang, identifikasi dapat dilakukan dalam berbagai cara, salah satunya dengan menggunakan metode survei melalui kuesioner. Penentuan kategori dominan dan tidaknya suatu gaya belajar dengan metode ini dapat dilakukan dengan membandingkan setiap skor dari kuesioner gaya belajar dengan nilai rata-rata seluruh kuesioner, kemudian aturan pengkategorian menyatakan suatu gaya belajar dianggap dominan apabila skornya lebih besar atau sama dengan nilai rata-rata semua kuesioner [4].

Salah satu penelitian yang menggunakan pendekatan metode survei melalui kuesioner dalam identifikasi gaya belajar salah satunya telah dilakukan pada siswa sekolah dasar di Daerah Istimewa Yogyakarta [5]. Penelitian tersebut dilakukan karena gaya belajar sangat penting untuk diketahui oleh seorang guru agar dapat meningkatkan kualitas pembelajaran dari setiap siswa [5]. Namun, dilihat dari teknik identifikasi yang dilakukan melalui kuesioner dengan pengolahan data secara manual akan sedikit kurang efisien. Pengolahan data secara manual efektif apabila data yang diolah sedikit, tetapi apabila data berjumlah cukup besar maka pengolahan data secara komputasi merupakan cara yang lebih efektif [6]. Oleh karena itu, adapun solusi yang diterapkan untuk mengatasi permasalahan ini yaitu dengan menerapkan teknik otomatisasi melalui pembangunan sebuah model *machine learning*.

Machine Learning adalah program komputer yang digunakan untuk mencapai kriteria tertentu dengan memanfaatkan sekumpulan data pengalaman masa lalu untuk belajar secara mandiri [7]. Pada penelitian ini, pemanfaatan *machine learning* memiliki keterkaitan langsung dengan bidang *Educational Data Mining* (EDM). EDM merupakan disiplin ilmu yang berkaitan dengan pengembangan sebuah metode untuk mengeksplorasi data unik dan berskala besar pada lingkungan pendidikan dengan tujuan memahami siswa

dan lingkungan tempat mereka belajar [8]. Pentingnya penerapan EDM salah satunya dalam kepentingan analisa gaya belajar, sebagaimana juga dijelaskan dalam penelitian [9]. Adapun penggunaan *machine learning* dalam EDM telah diterapkan pada penelitian klasifikasi gaya belajar sebelumnya [10][11][12][13][14].

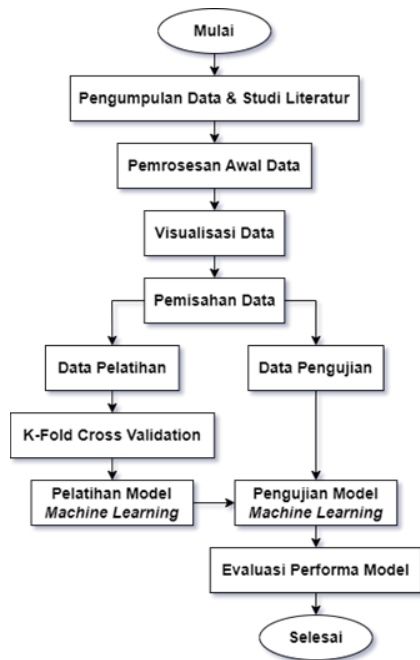
Dalam penelitian ini, model *machine learning* yang dibangun adalah model klasifikasi multilabel. Pendekatan ini dipilih karena memungkinkan klasifikasi data yang memiliki lebih dari satu label, sesuai dengan permasalahan yang dihadapi, yaitu bahwa seseorang dapat memiliki lebih dari satu gaya belajar yang dominan. Beberapa penelitian terdahulu telah membuktikan kemampuan *machine learning* dalam mengatasi tugas klasifikasi multilabel, tetapi dalam kasus yang berbeda [15][16][17][18]. Adapun dalam penelitian ini sebanyak empat model dibangun menggunakan algoritma yang berbeda meliputi *Decision Tree*, KNN, SVM, dan MLP agar dapat dilakukannya penilaian perbandingan untuk menemukan model *machine learning* dengan performa terbaik dalam mengatasi permasalahan klasifikasi ini. Penggunaan algoritma yang digunakan juga sudah pernah diterapkan pada penelitian klasifikasi multilabel pada kasus yang berbeda salah satunya menghasilkan *accuracy* model KNN 91%, SVM 94% [18]. Selain itu, klasifikasi diluar multilabel juga telah membuktikan kemampuan dari beberapa algoritma yang digunakan, sebagaimana seperti dalam penelitian [19]. Adapun untuk dataset yang digunakan dalam proses pelatihan dan pengujian model adalah *Data Set of Learning Style Preference* yang bersumber dari Mendeley Data [4].

Seperti yang telah dijelaskan sebelumnya, penelitian ini membangun model klasifikasi multilabel untuk menangani tugas klasifikasi gaya belajar siswa sekolah dasar menggunakan empat algoritma: *Decision Tree*, KNN, SVM, dan MLP. Tujuan membandingkan kinerja model adalah untuk menentukan model dengan kinerja terbaik. Setiap model dilatih dan diuji menggunakan *Data Set of Learning Style Preference* lalu setiap performa model yang diperoleh dibandingkan untuk menemukan model terbaik dalam mengatasi klasifikasi kombinasi dominan atau tidaknya gaya belajar siswa sekolah dasar.

Selain itu, hasil model yang diperoleh dibandingkan dengan model yang dibangun pada penelitian [14], yang juga menangani kasus serupa. Namun, terdapat perbedaan pada algoritma yang digunakan dan pendekatan klasifikasi yang diterapkan.

2. Metode Penelitian

Pada penelitian ini, proses pembangunan model *machine learning* dilakukan melalui beberapa tahapan pengembangan yang dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Pengembangan Model

Pada Gambar 1 dapat diamati alur penelitian diawali dengan proses pengumpulan data & studi literatur, dilanjutkan dengan pemrosesan awal data, visualisasi data, pemisahan data menjadi data pelatihan dan data pengujian, pelatihan model *machine learning*, pengujian model *machine learning*, dan diakhiri dengan evaluasi performa model.

2.1. Pengumpulan Data dan Studi Literatur

Pada proses ini, sumber data yang digunakan dalam penelitian adalah data Sekunder *Data Set of Learning Style Preference* yang diperoleh dari Mendeley Data [4]. Dataset ini berisikan data yang dikumpulkan dari siswa sekolah dasar (SD) kelas 4 dan 5 di Daerah Istimewa Yogyakarta, mencakup wilayah kabupaten Yogyakarta, Bantul, Sleman, Kulon Progo, dan Gunungkidul, yang dikumpulkan melalui kuesioner, dengan total data yang diperoleh sebanyak 992 baris data [4]. Adapun pada dataset ini terdiri dari 56 kolom fitur dan 3 kolom label, namun hanya 5 kolom fitur utama yang digunakan sebagai dasar dalam proses pelabelan. Kelima fitur utama yang dimaksud tersebut dapat dilihat pada Tabel 1.

Tabel 1. 5 Fitur Utama Dataset Yang Digunakan

No	Nama Fitur	Tipe Data	Deskripsi
1	Amount Visual	Numerik	Total skor pada kuesioner gaya belajar Visual.
2	Amount Auditorial	Numerik	Total skor pada kuesioner gaya belajar Auditorial.
3	Amount Kinestetik	Numerik	Total skor pada kuesioner gaya belajar Kinestetik.
4	Total Score	Numerik	Total skor keseluruhan dari ketiga kuesioner gaya belajar.
5	Average Per Study Style	Numerik	Total rata-rata skor keseluruhan dari ketiga kuesioner gaya belajar.

Tabel 2. 3 Label Dalam Dataset

No	Nama Label	Tipe Data	Deskripsi
1	Visual	String	Gaya belajar visual.
2	Auditorial	String	Gaya belajar Auditorial.
5	Kinestetik	String	Gaya belajar Kinestetik.

Adapun untuk 3 kolom label yang termasuk dalam dataset ini dapat diamati pada Tabel 2. Dimana menghasilkan 7 kombinasi label yang dapat terbentuk meliputi Visual (V), Auditorial (A), Kinestetik (K), Visual Auditorial (VA), Visual Kinestetik (VK), Auditorial Kinestetik (AK), dan Visual Auditorial Kinestetik (VAK). Selain itu, terkait kuesioner yang digunakan dalam pengumpulan dataset ini telah teruji validitas dan reliabilitasnya, sebagaimana dijelaskan dalam penelitian [20].

Selanjutnya, dalam proses studi literatur dilakukan dengan tujuan untuk mengumpulkan semua sumber literatur terkait yang digunakan sebagai acuan dalam pengembangan model klasifikasi yang dibangun, guna memastikan aspek keterbaruan dari penelitian ini. Keterbaruan dalam penelitian ini terletak pada penggunaan empat algoritma yaitu *Decision Tree*, KNN, SVM, dan MLP dengan jenis pendekatan klasifikasi yang dilakukan yaitu klasifikasi multilabel. Sementara itu, kesamaan dari penelitian ini dengan penelitian terkait sebelumnya terletak pada penggunaan dataset yang sama dengan penelitian [14]. Meskipun penelitian sebelumnya juga menggunakan algoritma *decision tree*, *decision tree* disebutkan sebagai bagian dari kebaruan juga karena cara kerja algoritma ini juga berbeda menyesuaikan dengan pendekatan jenis klasifikasi yang dilakukan.

2.2. Pemrosesan Awal Data

Pemrosesan awal data dilakukan untuk memastikan kualitas data sebelum digunakan pada model yang dibangun. Pada tahap ini, terdapat tiga tahapan yang dilakukan untuk mengolah data mentah yang diperoleh, yaitu meliputi proses Pembersihan Data, Transformasi Data, dan Reduksi Data.

Pembersihan Data dilakukan untuk memastikan kelengkapan data, mendeteksi data terganggu serta mengidentifikasi bagian data yang kurang relevan.

Transformasi Data dilakukan untuk mengubah format data yang kurang sesuai agar dapat memenuhi kebutuhan yang diperlukan.

Reduksi Data dilakukan untuk mengurangi kompleksitas data dengan melakukan seleksi fitur melalui metode *Filter* dengan pendekatan *Pearson's Correlation Between Features* dimana, jika terdapat fitur yang memiliki korelasi sangat positif, ditunjukkan dengan nilai mendekati 1 maka salah satu fitur dapat untuk dihilangkan. Sebaliknya, jika korelasi yang terjadi sangat negatif, ditunjukkan dengan nilai mendekati -1 maka fitur tersebut tidak memiliki korelasi sama sekali dengan fitur lainnya.

Adapun dalam proses pemrosesan awal data ini dilakukan melalui pemrograman dengan bahasa pemrograman *Python* dengan memanfaatkan salah satu *library* yaitu *library Pandas*. Selain itu, tool aplikasi web *Jupyter Notebook* juga digunakan sebagai tempat pendukung selama proses pemrograman dilakukan.

2.3. Visualisasi Data

Visualisasi data dilakukan untuk mendukung analisis pola persebaran data yang diperlukan oleh algoritma SVM. Hasil visualisasi ini sangatlah penting dalam membantu proses pemilihan pendekatan kernel yang sesuai dari algoritma, apakah menggunakan *linear SVM* atau *nonlinear SVM*. Adapun untuk mendukung proses analisis pola persebaran data ini, plot sebar atau *scatter plot* dipilih untuk digunakan.

2.4. Pemisahan Data

Pemisahan Data merupakan bagian dari proses pemecahan data menjadi beberapa bagian yang terdiri atas Data Pelatihan, Data Validasi, dan Data pengujian.

Pada tahapan ini, data yang telah diolah dan siap untuk digunakan akan dibagi menjadi tiga bagian yang telah disebutkan. Adapun proses pembagian data pelatihan dan data pengujian, disiapkan ke dalam 3 bentuk porsi ukuran data yang berbeda dapat dilihat pada Tabel 4. Selain itu, setelah pembagian data dilakukan, pada bagian data pelatihan diimplementasikan teknik validasi silang yaitu *K-Fold Cross Validation* agar model dapat untuk divalidasi performanya selama proses pelatihan berlangsung.

2.5. Pelatihan dan Pengujian Model *Machine Learning*

Model *machine learning* dalam penelitian ini dibangun menggunakan bahasa pemrograman *Python* dengan *library Scikit-Learn* untuk membangun keempat model yang direncanakan. Metode *Classifier Chains*, salah satu teknik dari *Problem Transformation*, juga diterapkan pada algoritma KNN dan SVM yang tidak secara langsung mendukung kemampuan klasifikasi multilabel agar dapat melakukan tugas tersebut.

Pada tahapan ini, data yang telah dipersiapkan digunakan dalam melatih dan menguji model *machine learning* yang dibangun. Adapun model-model yang dibangun tersebut terdiri dari model *decision tree*, model KNN, model SVM, dan model MLP.

2.6. Evaluasi Model

Pada tahap terakhir, hasil performa model selama proses pelatihan dan pengujian dievaluasi menggunakan beberapa metrik performa *Hamming Loss*, *Accuracy*, *Precision*, *Recall*, *Confusion Matrix*, dan *ROC-AUC curve*.

Hamming Loss merupakan metrik yang bekerja dengan cara menilai prediksi data salah ketika seluruh prediksi label salah diprediksi. Sebaliknya, jika kondisi data prediksi terdapat prediksi yang benar dan salah maka

hamming loss hanya akan menghitung kesalahan secara label individu sehingga hal ini sesuai untuk digunakan dalam mengevaluasi model klasifikasi multilabel. Adapun rumus yang digunakan dalam menghitung nilai *hamming loss* dapat dilihat pada rumus 1.

$$HL(x_i, y_i) = \frac{1}{|D|} \sum_{i=1}^{|D|} \frac{xor(x_i, y_i)}{|L|} \quad (1)$$

dengan $|D|$ adalah jumlah total titik data, $|L|$ jumlah total label, y_i nilai target label sebenarnya, dan x_i nilai prediksi label.

Selain itu, terdapat aturan penilaian melalui metrik *hamming loss* yaitu jika mendekati nilai 0 maka model menunjukkan performa yang baik karena hanya melakukan prediksi salah yang sedikit. Sebaliknya, jika mendekati nilai 1 maka model memiliki performa yang kurang baik dengan melakukan prediksi salah yang tidak sedikit.

Confusion Matrix merupakan metrik yang digunakan untuk menilai performa model secara lebih detail dari sisi *accuracy*, *precision*, *recall*, dan *f1-score*. Hal ini dimungkinkan karena penyajian-penyajian nilai dari metrik ini dapat digunakan dalam melihat letak kesalahan prediksi yang dilakukan oleh model. Selain itu, nilai-nilai yang disajikan dalam *confusion matrix* ini dapat digunakan untuk menghitung nilai-nilai metrik diatas secara manual dengan rumus yang digunakan dalam menghitungnya dapat dilihat pada rumus 2, 3, 4, dan 5.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

$$Precision = \frac{TP}{TP+FP} \quad (3)$$

$$Recall = \frac{TP}{TP+FN} \quad (4)$$

$$F1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (5)$$

dengan TP adalah *True Positif*, TN adalah *True Negatif*, FP adalah *False Positif*, dan FN adalah *False Negatif*.

Pada metrik *confusion matrix*, evaluasi ditampilkan dalam bentuk setiap kolom label karena permasalahan klasifikasi yang diatasi adalah klasifikasi multilabel. Dasar teori cara penyajian *confusion matrix* dalam bentuk ini juga dijelaskan dalam penelitian [21] dan juga sudah diterapkan pada penelitian [15]. Selain itu, penyajian dalam bentuk ini juga memberikan kemudahan identifikasi untuk melihat letak kesalahan prediksi oleh model.

ROC-AUC Curve merupakan sebuah kurva yang digunakan untuk menilai kemampuan model dalam membedakan kelas positif dan kelas negatif. Terdapat rentangan nilai sebagai kriteria yang digunakan dalam metrik ini dalam penilaian ditunjukkan dengan mendekati nilai 1 yang mengindikasikan bahwa model memiliki kemampuan yang baik dalam membedakan

kelas positif dan negatif. Sebaliknya, jika mendekati nilai 0 maka menunjukkan kemampuan model kurang baik dalam membedakan kelas positif dan negatif.

3. Hasil dan Pembahasan

3.1. Hasil Pembersihan Data

Dari 992 baris data yang diperoleh, ditemukan adanya 52 baris data yang tidak lengkap setelah dianalisis. Ketidaklengkapan ini terjadi pada nilai-nilai jawaban dari beberapa pertanyaan di setiap kuesioner gaya belajar sehingga mempengaruhi hasil pelabelan. Untuk mengatasi tersebut, data yang tidak lengkap dipilih untuk dieliminasi secara langsung tanpa melakukan peningkatan data guna menghindari potensi terjadinya kesalahan perbaikan dan dari proses pembersihan data ini total data keseluruhan menjadi 940 baris data.

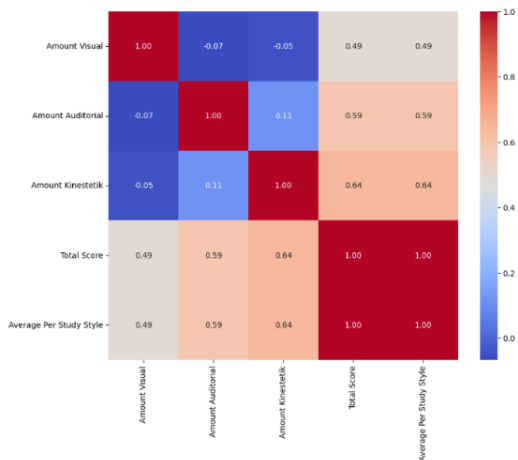
3.2. Hasil Transformasi Data

Transformasi data dilakukan dengan mengubah format data pada setiap nilai label yang sebelumnya diwakili dengan nilai bertipe data string. *Machine learning* dapat menghasilkan performa model yang akurat dengan salah satu syarat khusus yaitu data yang diinputkan harus bernilai numerik [22]. Oleh karena itu, maka nilai-nilai pada label sebelumnya dirubah menjadi nilai dengan tipe data numerik.

Adapun untuk format data sebelumnya untuk nilai “n” pada semua kolom label menyatakan data tidak termasuk ke dalam gaya belajar yang dituju sebagai dominan dirubah nilainya menjadi 0. Berikutnya, untuk nilai “Visual”, “Auditorial”, atau “Kinestetik” pada setiap kolom label sebelumnya yang menyatakan data termasuk ke dalam gaya belajar yang dominan dirubah nilainya menjadi 1.


3.3. Hasil Reduksi Data

Pada tahap reduksi data, hasil seleksi fitur yang dilakukan memperoleh adanya korelasi antar fitur dengan nilai 1 sempurna pada dua fitur yang dapat dilihat pada Gambar 2.



Gambar 2. Hasil Analisis *Pearson's Correlation Between Features*

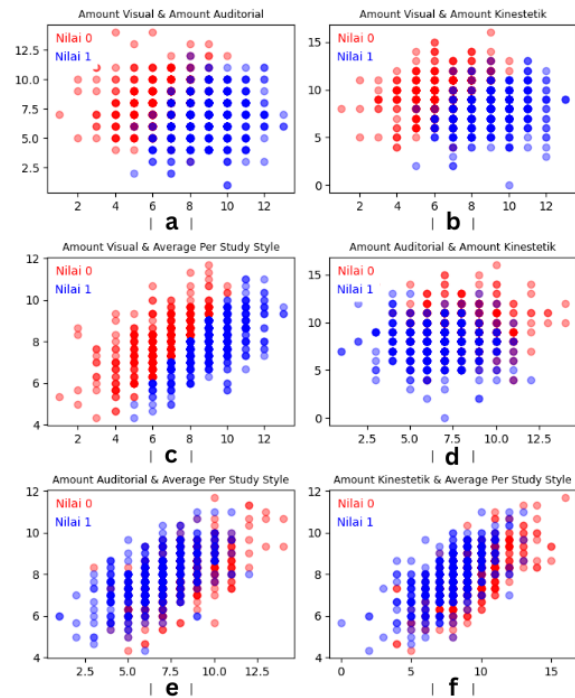
Korelasi fitur sempurna tersebut terjadi di antara fitur “Total Score” dengan “Average Per Study Style”. Berdasarkan hasil korelasi tersebut, fitur “Total Score” dipilih untuk dieliminasi karena nilai pada kolom fitur ini diperoleh dari kolom fitur “Amount Visual”, “Amount Auditorial”, dan “Amount Kinestetik” yang dijumlahkan. Adapun setelah fitur “Total Score” dieliminasi, hasil yang diperoleh membuktikan dengan tidak terjadinya perubahan korelasi setelah fitur tersebut dieliminasi dapat diamati pada Gambar 3.



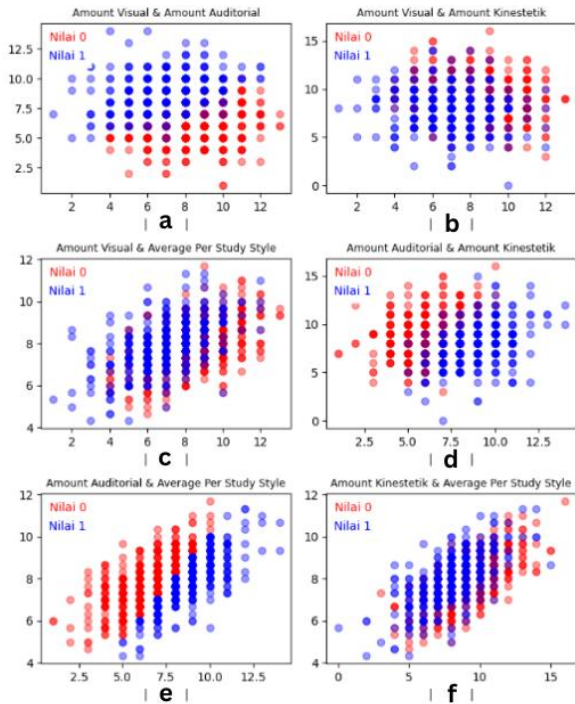
Gambar 3. Hasil Korelasi dari Eliminasi Fitur Total Score

Setelah semua proses pemrosesan awal data selesai dilakukan, adapun bentuk dataset akhir yang diperoleh terdiri atas 4 kolom fitur yaitu “Amount Visual”, “Amount Auditorial”, “Amount Kinestetik”, dan “Average Per Study Style” serta 3 kolom label yaitu “Visual”, “Auditorial”, dan “Kinestetik”.

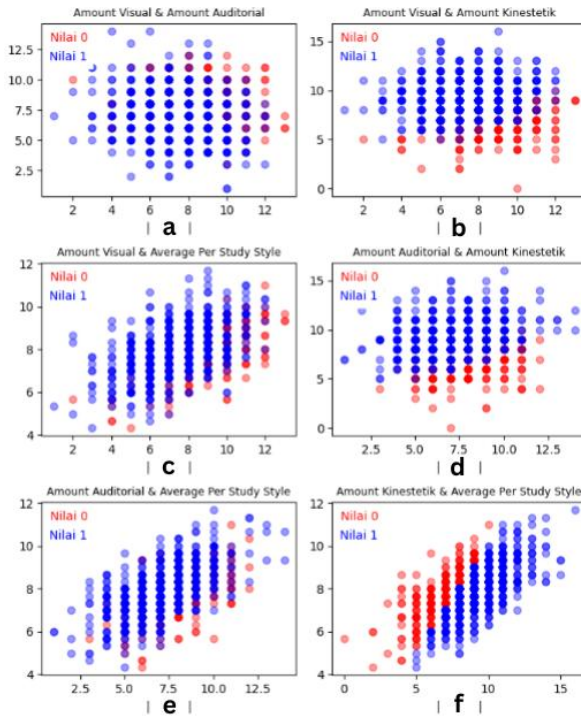
3.4. Hasil Visualisasi Data



Gambar 4. Visualisasi Pola Persebaran Data Pada Label Visual



Gambar 5. Visualisasi Pola Persebaran Data Pada Label Auditorial



Gambar 6. Visualisasi Pola Persebaran Data Pada Label Kinestetik

Visualisasi data dilakukan dengan menganalisis pola persebaran data berdasarkan perbandingan antar fitur dalam dataset. Hasil visualisasi melalui plot sebar yang telah dilakukan dapat dilihat pada Gambar 4, 5, dan 6.

Pada Gambar 4, 5, dan 6 visualisasi data diwakili dengan data berwarna merah untuk data dengan nilai 0 dan titik data berwarna biru untuk data dengan nilai 1.

Gambar 4 menunjukkan bahwa visualisasi data antar fitur pada label Visual memiliki pola persebaran data yang lebih banyak tercampur, seperti terlihat pada bagian visualisasi a, b, d, e, dan f. Kondisi ini juga terjadi pada visualisasi Gambar 5, yang ditunjukkan pada bagian visualisasi a, b, c, d, f, dan juga pada Gambar 6 visualisasi data pada label Kinestetik yang dibuktikan pada bagian visualisasi a, b, c, d, e.

Berdasarkan hasil analisis yang diperoleh tersebut, secara keseluruhan kondisi pola persebaran dari data yang terjadi cenderung tidak dapat dipisahkan secara *linear* sehingga pendekatan *linear* SVM kurang tepat untuk digunakan. Oleh sebab itu, pendekatan kernel yang digunakan pada algoritma SVM adalah *nonlinear* SVM yang memiliki kemampuan untuk memisahkan data dengan kondisi pola persebaran yang tercampur.

3.5. Hasil Pemisahan Data

Sebelum melakukan pemisahan data, dataset yang telah disiapkan dengan jumlah 940 baris data terlebih dahulu diperiksa keseimbangannya untuk menilai kondisi distribusi data pada setiap label. Berdasarkan hasil analisis, ditemukan adanya ketidakseimbangan pada label Auditorial dan label Kinestetik. Perbandingan ketidakseimbangan ini dapat dilihat pada Tabel 3.

Keterangan	Visual	Auditorial	Kinestetik
Nilai 0	471 baris	574 baris	271 baris
Nilai 1	469 baris	366 baris	669 baris

Ketidakseimbangan data pada label Auditorial dan label Kinestetik yang ditunjukkan pada Tabel 3, memiliki kondisi yang relatif kecil. Data yang tidak seimbang sebenarnya tidak selalu buruk untuk digunakan selama kondisi tersebut relatif rendah [23]. Oleh karena itu, peningkatan data dengan teknik tertentu tidak dilakukan untuk menghindari potensi *overfitting* dan menjaga keaslian informasi dari data asli.

Setelah meninjau keseimbangan data, tahap pemisahan dataset dilakukan menggunakan modul *train_test_split* dari *library scikit-learn* dengan pengaturan parameter “*random_state=42*”. Dataset dibagi menjadi data pelatihan dan data pengujian dalam tiga ukuran data yang berbeda, seperti yang dapat dilihat pada Tabel 4.

Ukuran Data	Pelatihan	Pengujian
Data I	90% = 846 baris	10% = 94 baris
Data II	80% = 752 baris	20% = 188 baris
Data II	70% = 658 baris	30% = 282 baris

Tujuan pembagian data dilakukan dalam tiga ukuran berbeda adalah untuk mengamati pola performa setiap model, apakah stabil atau tidak dengan ukuran data yang bervariasi, serta untuk menemukan ukuran data yang paling sesuai untuk model. Selain itu, setelah data dibagi menjadi data pelatihan dan data pengujian, diterapkan teknik validasi silang *K-Fold Cross Validation* dengan

nilai k sebesar 10-fold pada data pelatihan. Teknik ini digunakan untuk memvalidasi kemampuan model selama proses pelatihan dan diterapkan untuk menghindari dari risiko terjadinya *overfitting*, dimana model dapat menunjukkan hasil performa yang sangat baik selama pelatihan tetapi sangat buruk saat pengujian dilakukan.

Adapun kondisi proporsi data yang terbentuk dari setiap lipatan (*fold*) dalam data pelatihan dengan nilai 10-fold dapat dilihat pada Tabel 5.

Tabel 5. Proporsi Data Pada Setiap *Fold*

Nilai k -fold	<i>fold</i>	Data I	Data II	Data III
10	1	85 baris	76 baris	66 baris
	2	85 baris	76 baris	66 baris
	3	85 baris	75 baris	66 baris
	4	85 baris	75 baris	66 baris
	5	85 baris	75 baris	66 baris
	6	85 baris	75 baris	66 baris
	7	84 baris	75 baris	66 baris
	8	84 baris	75 baris	66 baris
	9	84 baris	75 baris	65 baris
	10	84 baris	75 baris	66 baris

3.6. Model *Decision Tree*

Algoritma *decision tree*, memiliki kemampuan secara langsung dalam mengatasi permasalahan klasifikasi multilabel. Dalam proses pembangunan model algoritma ini, beberapa parameter disetel untuk mencapai performa paling baik dengan diperoleh setelah parameter terbaik pada “*max_depth=9*”, “*random_state=42*”, dan “*class_weight=‘balanced’*” sementara beberapa parameter lainnya ditetapkan secara bawaan atau *default*.

Performa pelatihan dan pengujian model *decision tree* yang diperoleh dengan setelan ini dapat dilihat pada Tabel 6 dan 7.

Tabel 6. Performa Pelatihan Model *Decision Tree*

Metrik	Data I	Data II	Data III
<i>Average Accuracy</i>	94%	92%	93%

Tabel 7. Performa Pengujian Model *Decision Tree*

Metrik	Data I	Data II	Data III
<i>Hamming Loss</i>	0.014	0.023	0.016
<i>Accuracy</i>	95%	93%	95%
<i>Precision</i>	98%	97%	98%
<i>Recall</i>	99%	98%	98%
<i>F1-Score</i>	98%	97%	98%

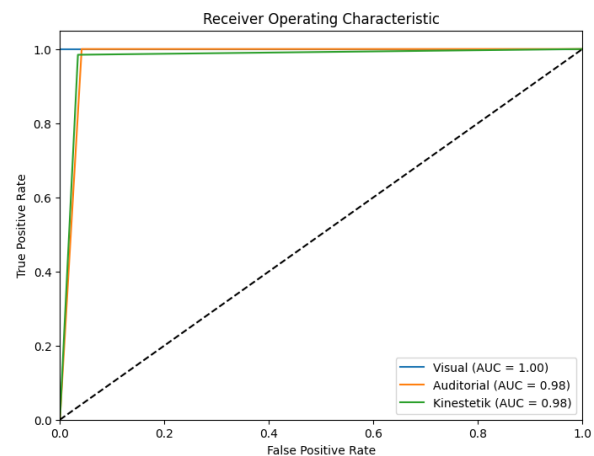
Performa model ketika pelatihan pada Tabel 6, menunjukkan kinerja *accuracy* yang baik disetiap ukuran data. Untuk hasil pengujian model pada Tabel 7, performa model terbaik ditunjukkan pada model Data I dengan *hamming loss* 0.014 paling rendah dibandingkan model Data II dan Data III.

Adapun untuk gambaran *confusion matrix* yang dihasilkan dari seluruh hasil pengujian tersebut dapat diamati pada Tabel 8.

Tabel 8. *Confusion Matrix* Model *Decision Tree*

Keterangan	Visual	Auditorial	Kinestetik	Total
Data I				
<i>True Positif</i>	43	46	64	153
<i>False Positif</i>	0	2	1	3
<i>True Negatif</i>	51	46	28	125
<i>False Negatif</i>	0	0	1	1
Data II				
<i>True Positif</i>	93	70	131	294
<i>False Positif</i>	0	5	3	8
<i>True Negatif</i>	94	110	53	257
<i>False Negatif</i>	1	3	1	5
Data III				
<i>True Positif</i>	151	109	191	451
<i>False Positif</i>	0	0	8	8
<i>True Negatif</i>	130	170	81	381
<i>False Negatif</i>	1	3	2	6

Model terbaik Data I, yang ditunjukkan dalam *confusion matrix* Tabel 8, menunjukkan kemampuan yang baik dalam mengatasi kondisi data tidak seimbang dibuktikan dengan tidak mengalami salah prediksi yang berlebih. Hal ini dapat dilihat dari rendahnya tingkat kesalahan prediksi data minoritas, yaitu *false negatif* sebanyak 0 pada label Auditorial dan *false positif* sebanyak 1 pada label Kinestetik. Temuan ini membuktikan model mampu menangani data yang tidak seimbang dengan baik, dan kemampuan ini juga diperkuat melalui hasil kurva *roc-auc* pada Gambar 7 yang menunjukkan kemampuan model dalam membedakan kelas positif dan kelas negatif sebesar 0.98 pada label Auditorial dan label Kinestetik tidak terpaut jauh juga dengan label Visual yang memiliki nilai sempurna 1.00.



Gambar 7. Kurva ROC-AUC Model *Decision Tree* Terbaik

Dengan demikian, model *decision tree* Data I dapat dikatakan memiliki performa yang baik, stabil, dan mampu dalam mengatasi kondisi data yang tidak seimbang.

3.7. Model *K-Nearest Neighbors*

Pada algoritma KNN diterapkan metode *classifier chains* karena tidak memiliki kemampuan secara langsung dalam menangani tugas klasifikasi multilabel. Dalam proses pembangunan model ini, beberapa

parameter disetel untuk mencapai performa paling baik diperoleh pada setelan parameter “*n_neighbors=1*”, “*weights=distance*”, dan beberapa parameter lainnya ditetapkan secara setelan bawaan atau *default*.

Performa pelatihan dan pengujian model KNN yang diperoleh dengan setelan ini dapat dilihat pada Tabel 9 dan 10.

Tabel 9. Performa Pelatihan Model KNN

Metrik	Data I	Data II	Data III
Average Accuracy	94%	94%	92%

Tabel 10. Performa Pengujian Model KNN

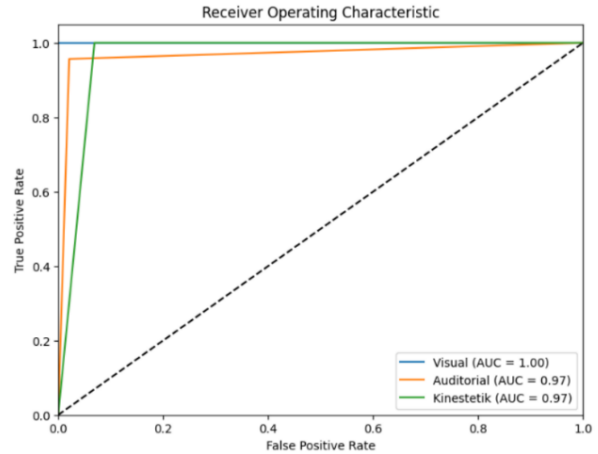
Metrik	Data I	Data II	Data III
Hamming Loss	0.017	0.017	0.022
Accuracy	94%	94%	93%
Precision	98%	97%	97%
Recall	98%	99%	98%
F1-Score	98%	98%	97%

Performa model ketika pelatihan pada Tabel 9, menunjukkan kinerja *accuracy* yang baik disetiap ukuran data. Untuk hasil pengujian model pada Tabel 10, performa model terbaik ditunjukkan pada model Data I dengan keseimbangan yang lebih baik dari sisi *precision* 98% dan *recall* 98% dibandingkan model Data II. Adapun gambaran *confusion matrix* yang dihasilkan dari seluruh hasil pengujian tersebut dapat diamati pada Tabel 9.

Tabel 11. Confusion Matrix Model KNN

Keterangan	Visual	Auditorial	Kinestetik	Total
Data I				
True Positif	43	44	65	152
False Positif	0	1	2	3
True Negatif	51	47	27	125
False Negatif	0	2	0	2
Data II				
True Positif	93	72	132	297
False Positif	0	4	4	8
True Negatif	94	111	52	257
False Negatif	1	1	0	2
Data III				
True Positif	147	109	193	449
False Positif	0	5	6	11
True Negatif	130	165	83	378
False Negatif	5	3	0	8

Pada Tabel 11, model KNN Data I memiliki kemampuan baik dalam mengatasi kondisi data yang tidak seimbang dengan tidak mengalami salah prediksi yang berlebih. Kondisi tersebut dapat diamati pada rendahnya tingkat kesalahan prediksi data minoritas di label Auditorial dengan *false negatif* sebanyak 2 dan di label Kinestetik dengan *false positif* sebanyak 2. Kemampuan ini juga diperkuat pembuktiannya melalui kurva *roc-auc* pada Gambar 8 yang menunjukkan kemampuan model baik dalam membedakan kelas positif dan kelas negatif dengan nilai 0.97 pada label Auditorial dan label Kinestetik dengan tidak terpaut jauh dengan label Visual yang memiliki nilai 1.00.



Gambar 8. Kurva ROC-AUC Model KNN Terbaik

Sehingga, berdasarkan kinerja model KNN Data I yang diperoleh dapat dikatakan memiliki performa yang baik, stabil, dan mampu dalam mengatasi kondisi data yang tidak seimbang meskipun tidak lebih baik dibandingkan model *decision tree*.

3.8. Model Support Vector Machine

Pada algoritma SVM diterapkan juga metode *classifier chains* untuk memberikan kemampuan menangani tugas klasifikasi multilabel seperti algoritma KNN sebelumnya. Beberapa parameter yang disetel untuk mencapai performa paling baik dari algoritma ini diperoleh pada setelan “*kernel=rbf*”, “*gamma=0.3*”, “*max_iter=500*” dengan beberapa parameter lainnya peneliti ditetapkan secara setelan secara bawaan atau *default*.

Performa pelatihan dan pengujian model SVM yang telah diperoleh dari setelan ini, dapat dilihat pada Tabel 12 dan 13.

Tabel 12. Performa Pelatihan Model SVM

Metrik	Data I	Data II	Data III
Average Accuracy	94%	93%	92%

Tabel 13. Performa Pengujian Model SVM

Metrik	Data I	Data II	Data III
Hamming Loss	0.017	0.035	0.024
Accuracy	95%	93%	92%
Precision	97%	97%	97%
Recall	99%	95%	97%
F1-Score	98%	96%	97%


Pada Tabel 12, performa model memiliki kinerja *accuracy* yang baik disetiap ukuran data pelatihan. Untuk hasil pengujian model pada Tabel 13, performa model terbaik ditunjukkan pada model Data I dengan *hamming loss* 0.017 paling rendah dibandingkan model Data II dan Data III. Adapun untuk gambaran *confusion matrix* dari setiap performa pengujian tersebut dapat diamati pada Tabel 14.

Tabel 14. Confusion Matrix Model SVM

Keterangan	Visual	Auditorial	Kinestetik	Total
Data I				

<i>True Positif</i>	43	45	65	153
<i>False Positif</i>	1	0	3	4
<i>True Negatif</i>	50	48	26	124
<i>False Negatif</i>	0	1	0	1
Data II				
<i>True Positif</i>	89	69	128	286
<i>False Positif</i>	0	3	4	7
<i>True Negatif</i>	94	112	52	258
<i>False Negatif</i>	5	4	4	13
Data III				
<i>True Positif</i>	147	109	193	449
<i>False Positif</i>	0	5	6	11
<i>True Negatif</i>	130	165	83	378
<i>False Negatif</i>	5	3	0	8

Model SVM Data I yang memiliki performa terbaik juga memiliki kemampuan dalam mengatasi kondisi data yang tidak seimbang sama seperti kedua algoritma sebelumnya. Kondisi tersebut dapat diamati pada Tabel 14, yang menunjukkan rendahnya tingkat kesalahan prediksi data minoritas di label Auditorial dengan *false negatif* sebanyak 1 dan di label Kinestetik dengan *false positif* sebanyak 3.



Gambar 9. Kurva ROC Model SVM Terbaik

Selain itu, kemampuan dari model juga diperkuat pembuktiannya pada hasil kurva *roc-auc* Gambar 9 yang menunjukkan kemampuan model baik dalam membedakan kelas positif dan kelas negatif dengan nilai 0.99 pada label Visual dan label Auditorial sedangkan pada label Kinestetik 0.95 tidak terpaat jauh dari kedua label tersebut.

Sehingga, berdasarkan kinerja model SVM Data I dapat dikatakan memiliki performa yang baik, stabil dan juga mampu dalam mengatasi kondisi data yang tidak seimbang dengan keunggulan 1% lebih baik dari sisi *accuracy* dibandingkan model KNN, namun tidak lebih baik dibandingkan model *decision tree* dengan *hamming loss* 0.014 lebih rendah daripada SVM.

3.9. Model Multi-Layer Perceptron

Algoritma MLP, memiliki kemampuan secara langsung dalam mengatasi tugas klasifikasi multilabel. Pada pembangunan model ini didapatkan setelan parameter

yang menghasilkan performa model paling baik dengan “*solver=‘sgd’*”, “*max_iter=2000*”, “*random_state=42*”, “*n_iter_no_change=2*”, dan beberapa parameter lainnya ditetapkan secara setelan bawaan atau *default*.

Performa pelatihan dan pengujian model MLP yang diperoleh dari setelan ini, dapat dilihat pada Tabel 15 dan 16.

Tabel 15. Performa Pelatihan Model MLP

MetriK	Data I	Data II	Data III
<i>Average Accuracy</i>	94%	92%	91%

Tabel 16. Performa Pengujian Model MLP


MetriK	Data I	Data II	Data III
<i>Hamming Loss</i>	0.024	0.014	0.017
<i>Accuracy</i>	92%	95%	94%
<i>Precision</i>	96%	98%	97%
<i>Recall</i>	98%	99%	98%
<i>F1-Score</i>	97%	98%	98%

Performa *accuracy* model saat pelatihan dilakukan pada Tabel 15, menunjukkan performa yang baik pada setiap ukuran data. Performa model terbaik pada Tabel 16 hasil pengujian model ditunjukkan pada model Data II dengan *hamming loss* 0.014 paling rendah dibandingkan model Data II dan Data III. Adapun untuk gambaran *confusion matrix* yang dihasilkan dari setiap performa pengujian tersebut dapat diamati pada Tabel 17.

Tabel 17. *Confusion Matrix* Model MLP

Keterangan	Visual	Auditorial	Kinestetik	Total
Data I				
<i>True Positif</i>	43	44	65	152
<i>False Positif</i>	0	0	5	5
<i>True Negatif</i>	51	48	24	123
<i>False Negatif</i>	0	2	0	2
Data II				
<i>True Positif</i>	94	71	132	297
<i>False Positif</i>	0	0	6	6
<i>True Negatif</i>	94	115	50	259
<i>False Negatif</i>	0	2	0	2
Data III				
<i>True Positif</i>	151	108	193	452
<i>False Positif</i>	0	0	10	10
<i>True Negatif</i>	130	170	79	379
<i>False Negatif</i>	1	4	0	5

Model MLP Data II memiliki kemampuan yang baik dalam mengatasi kondisi data yang tidak seimbang dengan tidak mengalami salah prediksi yang berlebih ditunjukkan dalam Tabel 17. Hal ini dibuktikan dengan kesalahan prediksi yang dilakukan model pada data minoritas di label Auditorial dengan *false negative* sebanyak 2 dan data minoritas di label Kinestetik dengan *false positif* sebanyak 6. Kemampuan model Data II ini juga ditunjukkan pada hasil kurva *roc-auc* Gambar 10 yang menunjukkan, kemampuan model baik dalam membedakan kelas positif dan kelas negatif dengan nilai 1.00 pada label Visual, 0.99 pada label Auditorial dan label Kinestetik dengan nilai 0.95.



Gambar 10. Kurva ROC Model MLP Terbaik

Dilihat dari performa tersebut, model MLP Data II dapat dikatakan memiliki performa yang baik dan stabil dalam mengatasi kondisi data yang tidak seimbang. Akan tetapi, tidak lebih baik jika dibandingkan dengan model *decision tree*.

3.10. Performa Model Terbaik

Berdasarkan hasil performa keempat model yang telah dibangun, diperoleh model *decision tree* sebagai model dengan performa paling baik dibandingkan model MLP, KNN, dan SVM. Hal ini dibuktikan dari perbandingan Tabel 8 dan Tabel 17, yang menunjukkan model *decision tree* sedikit lebih baik pada sisi menangani ketidakseimbangan data dibandingkan model MLP dengan prediksi salah yang tidak cenderung pada data minoritas.

Model *decision tree* juga dibuktikan sebagai model terbaik berdasarkan hasil analisis melalui kurva *roc-auc* yang menunjukkan model *decision tree* sedikit lebih unggul dalam kemampuan membedakan kelas data positif dan kelas data negatif yang dapat diamati perbandingan pada Tabel 18 yang menunjukkan kemampuan model tetap dapat menyamakan prioritas data minoritas sama pentingnya seperti data mayoritas.

Model	Visual	Auditorial	Kinestetik
<i>Decision Tree</i>	1.00	0.98	0.98
<i>Multi-Layer Perceptron</i>	1.00	0.99	0.95

Kinerja terbaik model machine learning dengan algoritma *decision tree* menghasilkan nilai hamming loss sebesar 0.014, yang mengindikasikan sangat sedikit kesalahan prediksi pada label per individu. Nilai accuracy sebesar 95% menunjukkan kemampuan model yang sangat baik dalam memprediksi data dengan label sebenarnya. Selain itu, nilai precision sebesar 98% menunjukkan bahwa model mampu dengan akurat mengidentifikasi prediksi positif yang benar-benar termasuk dalam kelas positif. Nilai recall sebesar 99% mengindikasikan kemampuan model dalam mengukur total keseluruhan label positif yang berhasil diprediksi dengan benar. Sedangkan nilai F1-score sebesar 98%

menunjukkan bahwa model memiliki kinerja yang seimbang dan tidak bias terhadap salah satu label tertentu.

Selanjutnya, hasil kinerja model machine learning yang diperoleh dibandingkan dengan penelitian sebelumnya [14] yang juga menggunakan algoritma *decision tree* dengan dataset yang sama, namun dengan pendekatan klasifikasi multikelas. Penelitian tersebut menghasilkan model dengan accuracy sebesar 99.78%. Meskipun accuracy pada penelitian tersebut lebih tinggi, validitasnya diragukan karena data yang digunakan dalam pengujian model adalah data yang juga digunakan dalam pelatihan. Hal ini dapat menyebabkan accuracy yang dihasilkan lebih tinggi dari yang seharusnya. Selain itu, pendekatan klasifikasi multikelas yang digunakan dianggap kurang tepat, karena label-label multilabel yang seharusnya tetap dipertahankan, diubah menjadi label multikelas, sementara label multilabel tersebut tetap digunakan sebagai fitur. Kondisi ini secara tidak langsung menyediakan kunci jawaban bagi model, yang berpotensi membuat model hanya "mengingat" label yang telah diberikan, sehingga kehandalan model dalam melakukan klasifikasi tidak dapat dipastikan sepenuhnya.

4. Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, peneliti menyimpulkan bahwa penelitian ini telah berhasil dalam membangun sebuah model *machine learning* dalam mengatasi permasalahan klasifikasi gaya belajar. Dari empat model yang dihasilkan, *Decision Tree* menunjukkan kinerja terbaik. Model ini mencapai hamming loss sebesar 0.014, yang menunjukkan sangat sedikit kesalahan prediksi pada setiap label individu. Nilai accuracy sebesar 95% mengindikasikan kemampuan model yang sangat baik dalam memprediksi label data yang sebenarnya. Selain itu, nilai precision sebesar 98% mencerminkan akurasi tinggi dalam mengidentifikasi label positif yang benar-benar termasuk dalam kelas positif. Nilai recall sebesar 99% menunjukkan kemampuan model dalam mendeteksi hampir seluruh label positif yang ada, sementara nilai F1-score sebesar 98% menegaskan bahwa model memiliki kinerja yang sangat baik dan seimbang, tanpa adanya bias prediksi terhadap label tertentu. Selain itu, dari sisi kelemahan adapun penelitian ini memiliki kelemahan yang perlu ditinjau kembali lebih lanjut yaitu dari sisi dataset yang digunakan tidak terlalu seimbang sehingga peneliti menyarankan untuk penelitian berikutnya dapat mempertimbangkan untuk melakukan *Balancing Dataset* seperti menggunakan metode *Oversampling* atau *Undersampling* untuk melihat performa model pada kondisi data yang seimbang. Selain itu, peneliti juga menyarankan untuk mencoba mengeksplorasi metode *Problem Transformation* yang lainnya seperti *Binary Relevance* atau *Label Powerset* untuk diterapkan pada algoritma yang tidak dapat

menangani tugas klasifikasi multilabel dan menilai bagaimana perbandingan performanya dengan metode *Classifier Chains*.

Ucapan Terimakasih

Terima kasih peneliti ucapkan kepada Ibu Vera Yuli Erviana selaku peneliti *Data Set of Learning Style Preference* yang telah memberikan akses untuk menggunakan dataset dalam penelitian ini. Publikasi ini didanai secara parsial dari DIPA Penelitian Undiksha.

Daftar Rujukan

- [1] I. Maryani, L. Fatmawati, V. Y. Erviana, M. N. Wangid, and A. Mustadi, *Model Intervensi Gangguan Kesulitan Belajar*. Yogyakarta: K-Media, 2018.
- [2] M. R. Sofian, "Psikoedukasi Pentingnya Mengetahui Gaya Belajar Siswa," *Abdima Jurnal Pengabdian Mahasiswa*, vol. 2, no. 1, pp. 1609–1615, Feb. 2023.
- [3] M. Fendrik, D. F. Putri, P. H. Pebriana, G. S. Sidik, and D. Ramdhani, "Analisis Kecenderungan Gaya Belajar Siswa Sekolah Dasar," *Jurnal Pendidikan dan Konseling*, vol. 4, no. 3, pp. 793–809, Jun. 2022, doi: <https://doi.org/10.31004/jpdk.v4i3.4094>.
- [4] V. Y. Erviana and S. Sukirno, "Data Set of Learning Style Preference," *Mendeley Data*, vol. V2, Jul. 2020, doi: [10.17632/mtvfdwm3dt.2](https://doi.org/10.17632/mtvfdwm3dt.2).
- [5] V. Y. Erviana and S. Fajaruddin, "Exploring Diverse Learning Styles In Elementary Schools: A Study On Student Preferences," *International Journal Of Education And Learning*, vol. 5, no. 2, pp. 124–131, Aug. 2023, doi: <https://doi.org/10.31763/ijele.v5i2.1241>.
- [6] S. M. Rezkia, "Metode Pengolahan Data: Tahapan Wajib Yang Dilakukan Sebelum Analisis Data," *DQLab*, vol. 6, no. 29, Jun. 2021, [Online]. Available: <https://dqlab.id/metode-pengolahan-data-tahapan-wajib-yang-dilakukan-sebelum-analisis-data>
- [7] G. N. Kurniawati, "Apa itu Machine Learning?," *DQLab*, vol. 1, no. 7, Jan. 2021.
- [8] International Educational Data Mining Society, "Educational Data Mining," International Educational Data Mining. [Online]. Available: <https://educationaldatamining.org/>
- [9] S. A. A. Kharis and A. H. A. Zili, "Learning Analytics dan Educational Data Mining pada Data Pendidikan," *Jurnal Riset Pembelajaran Matematika Sekolah*, vol. 6, no. 1, pp. 12–22, Mar. 2022, doi: <https://doi.org/10.21009/jrpms.061.02>.
- [10] Oscario, Jasmir, and Y. Novianto, "Penerapan Algoritma C4.5 Untuk Memprediksi Kecocokan Gaya Belajar Bagi Siswa Siswi Sekolah Dasar (Studi Kasus : SD Sariputra Jambi)," *Processor: Jurnal Ilmiah Sistem Informasi, Teknologi Informasi dan Sistem Komputer*, vol. 14, no. 2, pp. 141–152, Oct. 2019, doi: <https://doi.org/10.33998/processor.2019.14.2.637>.
- [11] A. T. Jatmiko, W. S. Wardhono, and S. H. Wijoyo, "Analisis Komparasi Algoritma C4.5 dan Naive Bayes dalam Kasus Klasifikasi Kecenderungan Gaya Belajar Visual Auditori Kinestetik (VAK)," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 7, no. 7, pp. 3507–3516, Jul. 2023.
- [12] A. K. Darmawan, Kurdianto, Bakir, and M. Makruf, "Deteksi Gaya Belajar Siswa SMA pada Virtual Based Learning Environment (VBLE) dengan Decision Tree C4.5 dan Naive Bayes," *Kajian Ilmiah Informatika dan Komputer*, vol. 3, no. 5, pp. 532–544, Apr. 2023, doi: <https://doi.org/10.30865/klik.v3i5.760>.
- [13] B. D. Pranata, U. Mahdiyah, and P. Kasih, "Pemodelan Gaya Belajar Siswa dengan Menggunakan Support Vector Machine," *Nusantara of Engineering (NOE)*, vol. 6, no. 2, pp. 144–150, Oct. 2023, doi: [10.29407/noe.v6i2.20884](https://doi.org/10.29407/noe.v6i2.20884).
- [14] I. A. Prasetyo, H. Mustofa, S. Supriadi, R. H. Prasetyo, M. Y. L., and Fitriyani, "Metode Decision Tree Dalam Pemilihan Gaya Belajar Pada Siswa Sekolah Dasar," *Jurnal Ilmiah Sains dan Teknologi Industri*, vol. 5, no. 1, pp. 21–29, Jul. 2021, doi: <https://doi.org/10.32524/saintek.v5i1.248>.
- [15] E. Rizkyani, I. Ernawati, and N. Chamidah, "Klasifikasi Multi-Label Menggunakan Metode Multi-Label K-Nearest Neighbors Pada Penyakit Kanker Serviks," *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 7, no. 4, pp. 1281–1293, Nov. 2022, doi: [10.29100/jupi.v7i4.3260](https://doi.org/10.29100/jupi.v7i4.3260).
- [16] A. Hanafi, Adiwijaya, and W. Astuti, "Klasifikasi Multi Label Pada Hadis Bukhari Terjemahan Bahasa Indonesia Menggunakan Mutual Information dan K-Nearest Neighbors," *SISFOKOM (Sistem Informasi dan Komputer)*, vol. 9, no. 3, pp. 357–364, 2020, doi: <https://doi.org/10.32736/sisfokom.v9i3.980>.
- [17] Sudianto, A. D. Sripamuji, I. Ramadhanti, R. R. Amalia, J. Saputra, and B. Prihatnowo, "Penerapan Algoritma Support Vector Machine dan Multi-Layer Perceptron Pada Klasifikasi Topik Berita," *Jurnal Nasional Pendidikan Informatika*, vol. 11, no. 2, pp. 84–91, Jul. 2022.
- [18] L. G. Irham, Adiwijaya, and U. N. Wisesty, "Klasifikasi Berita Bahasa Indonesia Menggunakan Mutual Information dan Support Vector Machine," *Jurnal Media Informatika Budidarma*, vol. 3, no. 4, pp. 284–292, Oct. 2019, doi: <http://dx.doi.org/10.30865/mib.v3i4.1410>.
- [19] J. Kusuma, R. Rosnelly, Hartono, and B. H. Hayadi, "Klasifikasi Penyakit Daun Tanaman Jagung Menggunakan Algoritma Support Vector Machine, K-Nearest Neighbors dan Multilayer Perceptron," *Journal of Applied Computer Science and Technology*, vol. 4, no. 1, pp. 1–6, Jun. 2022, doi: <https://doi.org/10.52158/jacost.v4i1.484>.
- [20] I. Maryani, L. Fatmawati, V. Y. Erviana, D. Kartika, M. N. Wangid, and A. Mustadi, "Validity and reliability of learning style scale of the elementary school students," *Proceedings The 2017 International Conference on Research in Education-Sanata Dharma University*, pp. 364–382, 2017.
- [21] M. Heydarian, T. E. Doyle, and R. Samavi, "MLCM: Multi-Label Confusion Matrix," *IEEE Access*, vol. 10, pp. 19083–19095, 2022, doi: [10.1109/ACCESS.2022.3151048](https://doi.org/10.1109/ACCESS.2022.3151048).
- [22] D. Feby, "Tipe Encoding di Machine Learning Categorical Data," *DQLab*. [Online]. Available: <https://dqlab.id/tipe-encoding-di-machine-learning-categorical-data>
- [23] H. Tripathi, "What Is Balanced And Imbalanced Dataset?," Medium. [Online]. Available: <https://medium.com/analytics-vidhya/what-is-balance-and-imbalance-dataset-89e8d7f46bc5>