

Teknik K-Fold Cross Validation untuk Mengevaluasi Kinerja Mahasiswa

Wijiyanto^{1*}, Afu Ichsan Pradana², Sopingi³, Vihi Atina⁴

^{1,2,3,4}Universitas Duta Bangsa Surakarta, Indonesia

*email: wijiyanto@udb.ac.id

Info Artikel

Dikirim: 19 Februari 2024

Diterima: 26 Maret 2024

Diterbitkan: 20 Mei 2024

Kata kunci:

Akurasi;

Cross Validation;

Kfold;

Kinerja Mahasiswa;

Machine Learning;

Mean.

ABSTRAK

Kemampuan seorang mahasiswa untuk menyelesaikan perkuliahan dipengaruhi oleh berbagai faktor, termasuk aspek akademik dan non-akademik. Memahami faktor yang mempengaruhinya menjadi sangat penting untuk diketahui dalam rangka mengantisipasi dan mencegah kemungkinan kegagalan studinya. Faktor yang bersifat non-akademik ternyata juga berpengaruh besar terhadap keberhasilan mahasiswa terutama dari faktor keluarga, seperti status jenjang pendidikan yang diperoleh orang tua, status pekerjaan yang dimiliki orang tua dan penghasilan kedua orang tua. Untuk dapat memahami faktor tersebut diperlukan studi untuk memprediksi kinerja mahasiswa berdasarkan faktor yang berlatar belakang keluarga menggunakan model *machine learning* algoritma *support vector machine*, *naïve bayes*, *neural network* dan *decision tree*. Data yang digunakan sebanyak 365 record dan 11 atribut dipisah untuk data train sebesar 70% dan untuk data test sebesar 30%, yang selanjutnya digunakan kfold cross validation untuk mengevaluasi hasil menggunakan parameter $n_split=10$ dan $random_state=42$. Pada parameter confusion matrix diperoleh nilai akurasi rata-rata (mean) untuk model *support vector machine* sebanyak 87,68%, *naïve bayes* sebanyak 90,97%, *neural network* sebesar 87,95% dan *decision tree* sebesar 85,75%. Sedangkan hasil fold terbaik untuk SVM terletak pada fold ke-10 dengan akurasi 94,44%, untuk NB terletak pada fold ke-4 dengan nilai akurasi 97,29%, untuk NN terletak di fold ke-4 dengan nilai akurasi 94,59% serta untuk DT terletak di fold ke-5 dengan nilai akurasi 91,89%. Dengan demikian evaluasi menggunakan k-fold cross validation dapat digunakan dalam memprediksi kinerja mahasiswa berdasarkan atribut keluarga menggunakan fold ke-4 yang memiliki akurasi tertinggi sebesar 97,29% pada algoritma model *naïve bayes* dalam rangka untuk lulus dengan tepat waktu.

1. PENDAHULUAN

Dalam beberapa tahun terakhir, teknik *machine learning* semakin populer dalam menganalisis data di berbagai bidang, termasuk pendidikan. Salah satu aplikasi menarik dari machine learning dalam konteks pendidikan adalah prediksi kinerja mahasiswa dan mengevaluasi kinerja mahasiswa tersebut merupakan aspek yang perlu diperhatikan karena dapat membantu dalam mengukur hasil belajar mereka dan mengidentifikasi area yang perlu ditingkatkan dalam menyelesaikan pendidikan secara tepat waktu. Faktor-faktor yang berkontribusi terhadap keberhasilan mahasiswa merupakan hal utama yang layak dipertimbangkan untuk mengantisipasi keberhasilan studinya. Memahami pengaruh dari faktor keluarga terhadap kinerja mahasiswa merupakan bidang yang semakin menarik untuk diteliti. Dengan menganalisis dampak faktor tersebut seperti tingkat

pendidikan yang dimiliki oleh orang tua, status ekonomi keluarga, struktur keluarga, dan keterlibatan orang tua terhadap keberhasilan mahasiswa [1], kita dapat memperoleh wawasan yang berharga tentang strategi yang efektif untuk mendukung mahasiswa dalam perjalanan akademis mereka. Salah satu teknik untuk mengeksplorasi akurasi prediksi kinerja mahasiswa berdasarkan atribut keluarga adalah menggunakan evaluasi *K-Fold Cross Validation* pada model *Machine Learning*. Evaluasi tersebut akan membantu dalam memastikan model dapat melakukan pengukuran hasil yang lebih stabil terhadap kinerjanya [2].

Machine learning yang digunakan adalah algoritma *support vector machine* (SVM), *naïve bayes* (NB), *neural network* (NN) dan *decision tree* (DT). Dari keempat algoritma yang digunakan akan dievaluasi menggunakan *cross validation* yang merupakan salah satu cara yang dipakai untuk mengukur lebih akurat dalam model klasifikasi *machine learning* [3] karena, *cross validation* merupakan salah satu metode resampling data yang digunakan untuk memperkirakan kesalahan prediksi model yang sebenarnya serta untuk menyetel parameter model [4]. Selain itu *cv_kfold* adalah perintah pasca estimasi yang mengimplementasikan prosedur validasi silang k-lipatan setelah regresi yang memungkinkan untuk memilih jumlah fold "k" dan pengulangan yang akan dijalankan berdasarkan model yang telah diestimasi sebelumnya [5]. Menerapkan *k-fold cross validation*, dapat diperoleh pengetahuan tentang seberapa baik model yang kita gunakan dalam menggeneralisasi data baru dan membuat keputusan yang lebih tepat tentang kesesuaiannya untuk mengevaluasi kinerja mahasiswa [6]. Selain itu, validasi silang *k-fold* membantu mengurangi bias dan masalah *overfitting* yang dapat muncul saat mengevaluasi kinerja mahasiswa [7],[8] serta untuk menentukan jumlah iterasi yang maksimal untuk digunakan dalam memvalidasi silang *Kfold*-nya [9] dan dalam beberapa kondisi, *k-fold cross validation* dapat menaikkan nilai akurasi klasifikasi *ground-truth* hingga 25% [10].

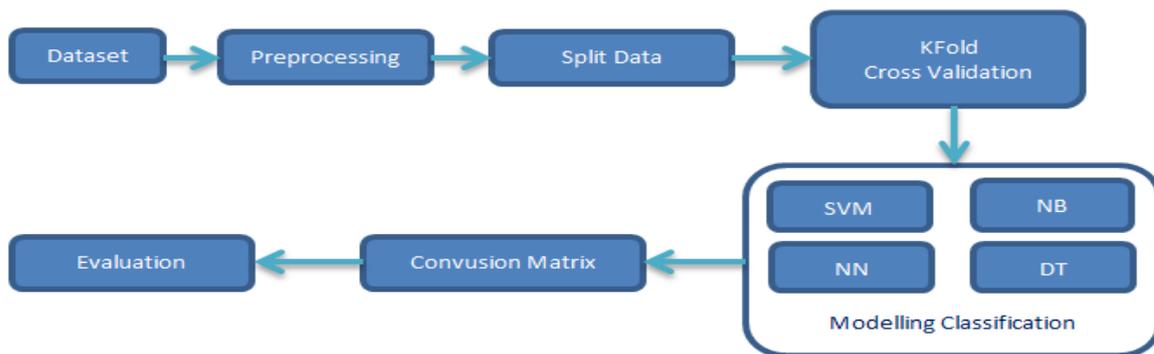
Penelitian sebelumnya yang menerapkan *k-fold cross validation* oleh [11] dengan memakai jumlah $k=30$ menggunakan *decision tree* C4.5 menghasilkan nilai akurasi sebanyak 96,00% dan algoritma KNN menghasilkan nilai akurasi sebanyak 95,33%, demikian juga halnya yang dilakukan oleh [12] dan [13] yang juga menggunakan *decision tree* diperoleh nilai akurasi sebanyak 87,1% dan 90,92%. Sementara dalam [14] yang menggunakan algoritma *support vector machine* menghasilkan nilai akurasi sebanyak 91,76%. Untuk algoritma *naïve bayes* menggunakan jumlah $k=10$ pada penelitian [6] diperoleh akurasi sebesar 96,12% dan hasil tertinggi sebesar 82,94% pada $k=5$ juga digunakan untuk klasifikasi status gizi balita [15] pada algoritma *neural network* diperoleh akurasi sebesar 79,48% pada $k=7$.

Dalam penelitian yang dilakukan oleh Huzain Azis dan kawan kawan [16] juga menerapkan metode *cross validation* dalam meningkatkan performa klasifikasinya menggunakan $k\text{-fold}=10$, hasil yang menggunakan perbandingan data 50:50 diperoleh akurasi sebesar 82%. Arisandi dan kawan kawan, menerapkan 10-fold *cross validation* untuk mengklasifikasikan data status gizi menggunakan pemodelan *naïve bayes* memperoleh hasil tertinggi pada $k=6$ dengan rata-rata akurasi pada setiap iterasi sebesar 88,46% [17]. Sementara teknik *cross validation* ($k=10$) juga digunakan untuk mengklasifikasikan bunga iris menggunakan perbandingan data 80% menggunakan pemodelan SVM diperoleh akurasi sebesar 92,6% [18].

K-Fold Cross Validation telah diimplementasikan dalam menilai kinerja model machine learning pada penelitian sebelumnya dengan hasil yang beragam dengan cara memisahkan dataset menjadi data train dan data test. Proses ini dapat membantu menentukan apakah model memiliki kinerja yang baik dan mencegah *overfitting* atau *underfitting*. Dengan demikian, studi ini diharapkan dapat memberikan dampak penting dalam penerapan machine learning menggunakan validasi silang *k-fold cross validation* untuk meningkatkan akurasi, khususnya algoritma SVM, NB, NN dan DT sebagai model klasifikasi dalam memprediksi kinerja mahasiswa supaya dapat menyelesaikan pendidikannya secara tepat waktu.

2. METODE PENELITIAN

Untuk memberikan arah penelitian yang lebih baik, pada gambar 1 terlihat tahapan yang dilakukan dengan pengumpulan dataset, *preprocessing*, *split data*, *penentuan K-fold cross validation*, *modelling*, *confusion matrix* dan *evaluation*.



Gambar 1. Tahapan penelitian

1) Dataset

Dataset merupakan kumpulan data terstruktur terdiri atas entitas relevan untuk dianalisis dan memiliki peranan yang sangat penting dalam ha hasil akhir atas suatu pemodelan yang digunakan. Dataset privat yang digunakan dalam penelitian eksperimen ini menggunakan 365 record dan 11 atribut termasuk labelnya yang berasal dari data lulusan 2023 di Fakultas Ilmu Komputer Universitas Duta Bangsa Surakarta yang berbentuk *csv*. Tabel 1 menunjukkan ringkasan statistik deskriptif tentang Dataset yang digunakan terdiri dari Count yang merupakan Jumlah entri non-null dalam setiap atribut, Mean merupakan nilai rata-rata dari setiap atribut, Std (Standard Deviation) nilai dari setiap atribut, Min merupakan Nilai minimum dari setiap atribut, 25% merupakan Kuartil pertama (25th percentile) dari data setiap atribut, 50% merupakan Median (50th percentile) dari data setiap atribut, 75% merupakan Kuartil ketiga (75th percentile) dari data setiap atribut dan Max yang merupakan nilai maksimal dari setiap atribut.

Tabel 1. Distribusi statistik dataset yang digunakan

	jk	asal	umur	pendidikan_ayah	id_pekerjaan_ayah	keterangan
count	365.000.000	365.000.000	365.000.000	365.000.000	365.000.000	365.000.000
mean	0.315068	0.150685	23.010.959	2.723.288	3.821.918	0.876712
std	0.465181	0.358233	2.028.611	1.214.668	1.971.935	0.329218
min	0.000000	0.000000	20.000.000	0.000000	0.000000	0.000000
25%	0.000000	0.000000	22.000.000	2.000.000	2.000.000	1.000.000
50%	0.000000	0.000000	23.000.000	3.000.000	4.000.000	1.000.000
75%	1.000.000	0.000000	23.000.000	3.000.000	5.000.000	1.000.000
max	1.000.000	1.000.000	43.000.000	6.000.000	7.000.000	1.000.000

2) Preprocessing

Preprocessing merupakan kegiatan dalam menganalisis data sebelum melakukan langkah membangun model *machine learning* dalam rangka untuk meningkatkan kualitas data serta memastikan data cocok digunakan dengan proses pembuatan model. Tahap ini melakukan penseleksian atribut yang tidak memiliki relevansi data yang berhubungan dengan keluarga. kedua adalah membersihkan data yang tidak memiliki nilai atau kosong (*missing value*).

3) Split Data

Pemisahan data merupakan langkah untuk membagi data menjadi dua kelompok yang berbeda yang digunakan sebagai data *training* dan kelompok data untuk *testing*. Tujuannya untuk mengukur kinerja dari model pada data *testing* yang tidak dipergunakan dalam proses *training*, sehingga dapat memperkirakan kemampuan model yang digunakan dalam mengeneralisasi data *testing* yang akan diuji. Dataset di bagi menggunakan perbandingan 70:30 dimana 70% untuk data *training* dan 30% untuk data *testing*.

4) K-Fold Cross Validation

K-fold cross validation merupakan cara statistik yang digunakan dalam evaluasi performan dari model yang akan dibangun[19]. Selain itu *k-fold cross validation* adalah cara yang efektif dalam menggabungkan atribut dan setting parameter *machine learning* dalam melatih model *prediction* yang lebih baik[20]. Dataset akan dibagi menggunakan 10-fold dengan ukuran yang sama pada setiap fold-nya, sehingga mempunyai 10 subset data. Untuk setiap 1 k-fold data *testing* akan di *cross*

validation dengan 9 k-fold data training[21] [11] seperti yang terlihat pada skema *k-fold cross validation* gambar 2. Kelebihan menggunakan *K-Fold Cross Validation* adalah dalam rangka untuk meningkatkan estimasi kinerja yang lebih stabil dan akurat dengan cara menghitung rata rata hasil dari “k” iterasi dan mencapai resiko empiris yang lebih rendah, daripada hanya membaginya ke dalam data training dan data testing saja [22]. Kelebihan lain menggunakan *K-Fold Cross Validation* dapat meminimalisasi resiko *overfitting* dengan cara melatih dan menguji model dengan berbagai kombinasi data[10].

KFold	Cross Validation									
1	Test	Train								
2	Train	Test	Train							
3	Train	Train	Test	Train						
4	Train	Train	Train	Test	Train	Train	Train	Train	Train	Train
5	Train	Train	Train	Train	Test	Train	Train	Train	Train	Train
6	Train	Train	Train	Train	Train	Test	Train	Train	Train	Train
7	Train	Train	Train	Train	Train	Train	Test	Train	Train	Train
8	Train	Train	Train	Train	Train	Train	Train	Test	Train	Train
9	Train	Train	Train	Train	Train	Train	Train	Train	Test	Train
10	Train	Train	Train	Train	Train	Train	Train	Train	Train	Test

Gambar 2. skema kfold cross validation

5) Modelling Classification

a. Support Vector Machine

Metode *Machine Learning* yang sering digunakan adalah *Support Vector Machine (SVM)*, terutama dalam mengatasi masalah klasifikasi dan regresi di ruang dimensi tinggi [23]. SVM bertujuan utama untuk menemukan *hyperplane* optimal yang dapat memisahkan kelas-kelas yang berbeda secara efisien di dalam ruang fitur.

b. Naïve Bayes

Algoritma *Naïve Bayes* merupakan model probabilistik yang bertujuan untuk memprediksi kategori dari data sampel yang dinyatakan dengan probabilitas. Pengklasifikasi Bayes didasarkan pada teorema probabilitas bersyarat Bayes. Teorema ini mengukur probabilitas bersyarat dari sebuah variabel acak atau variabel kelas yang diberikan pengamatan yang diketahui tentang nilai-nilai dari sekumpulan variabel acak lainnya atau variabel karakteristik [24].

$$P(Y|X) = \frac{P(X|Y)P(Y)}{P(X)} \tag{1}$$

c. Neural Network

Sebagian besar penelitian yang dilakukan dalam jaringan syaraf tiruan terinspirasi dan dipengaruhi oleh pengetahuan tentang sistem biologis karena didasarkan pada ide meniru otak manusia, dengan *neuron* yang berfungsi sebagai elemen komputasi (dasar) dalam sistem. *Neural Network* merupakan serangkaian unit pemrosesan kecil yang memiliki inspirasi dari cara kerja sistem saraf pada manusia. Keunggulan utama jaringan saraf tiruan terletak pada adaptabilitasnya yang tinggi; mereka dapat menyesuaikan struktur dan memecahkan masalah dengan memproses informasi eksternal dan internal melalui koneksi yang kompleks di dalam jaringannya [25].

d. Decision Tree

Decision Tree (DT) adalah *machine learning algorithms* sederhana yang diawasi untuk tugas regresi dan klasifikasi. namun demikian, DT digunakan untuk mengklasifikasikan masalah.

Bentuknya seperti pohon, di mana simpul bagian dalam mencirikan fitur-fitur dataset, cabang-cabang menandakan aturan keputusan, dan setiap simpul daun menandakan hasil [3] [13].

6) Confusion Matrix

Confusion matrix adalah tabel untuk dipergunakan dalam mengevaluasi klasifikasi model dalam mencari performa model pada sebuah data testing yang telah diketahui labelnya. *Confusion matrix* terdiri dari empat sel yaitu *true positif* (TP), *true negative* (TN), *false positif* (FP) dan *false negative* (FN). *Confusion matrix* berisi informasi yang sebenarnya dan perkiraan untuk sistem pengklasifikasian, urutan pengujian ditabulasikan dalam matriks kerancuan di mana class yang akan diprediksi ditampilkan dahulu di atas matriks dan class yang diamati terdapat di sebelah kiri. Tiap sel berisikan angka yang mencerminkan jumlah kasus aktual dari kelas yang diamati yang ingin diprediksi [26] [27].

7) Evaluation

Akurasi adalah metrik yang membantu untuk mengetahui seberapa tepat atau dekat hasilnya dengan nilai sebenarnya, memberikan informasi tentang kemungkinan kesalahan yang dapat ditemukan dalam klasifikasi. Persamaan (2) menunjukkan rumus untuk menentukan akurasi algoritma klasifikasi, di mana akurasi bergantung pada jumlah TP, TN, FP, FN [28].

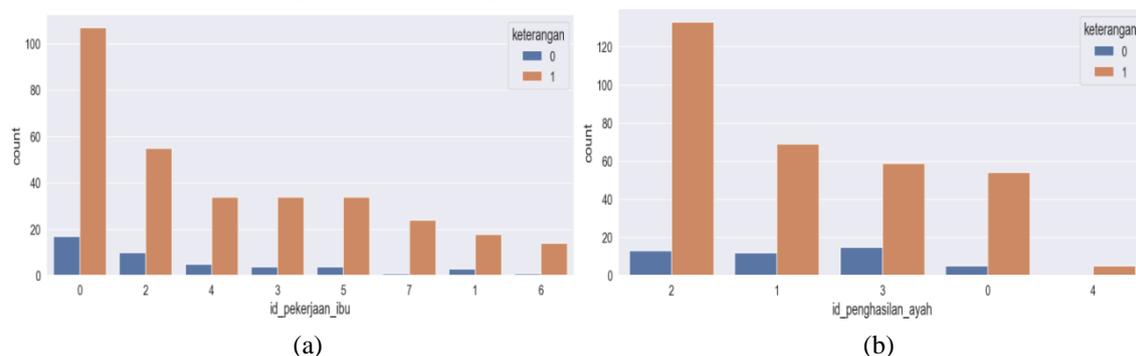
$$\text{accuracy}(\%) = \left(\frac{TP + TN}{TP + TN + FP + FN} \right) \times 100 \quad (2)$$

3. HASIL DAN PEMBAHASAN

Hasil dan pembahasan dalam penelitian ini menggunakan data berdasarkan atribut keluarga yang memiliki kontribusi yang besar dalam menentukan hasil kinerja mahasiswa selama perkuliahan. Evaluasi menggunakan 10 Fold *cross Validation* menggunakan model *machine learning* yaitu *Support Vector Machine* (SVM), *Naive Bayes*, *Neural Network* dan *Decision Tree*.

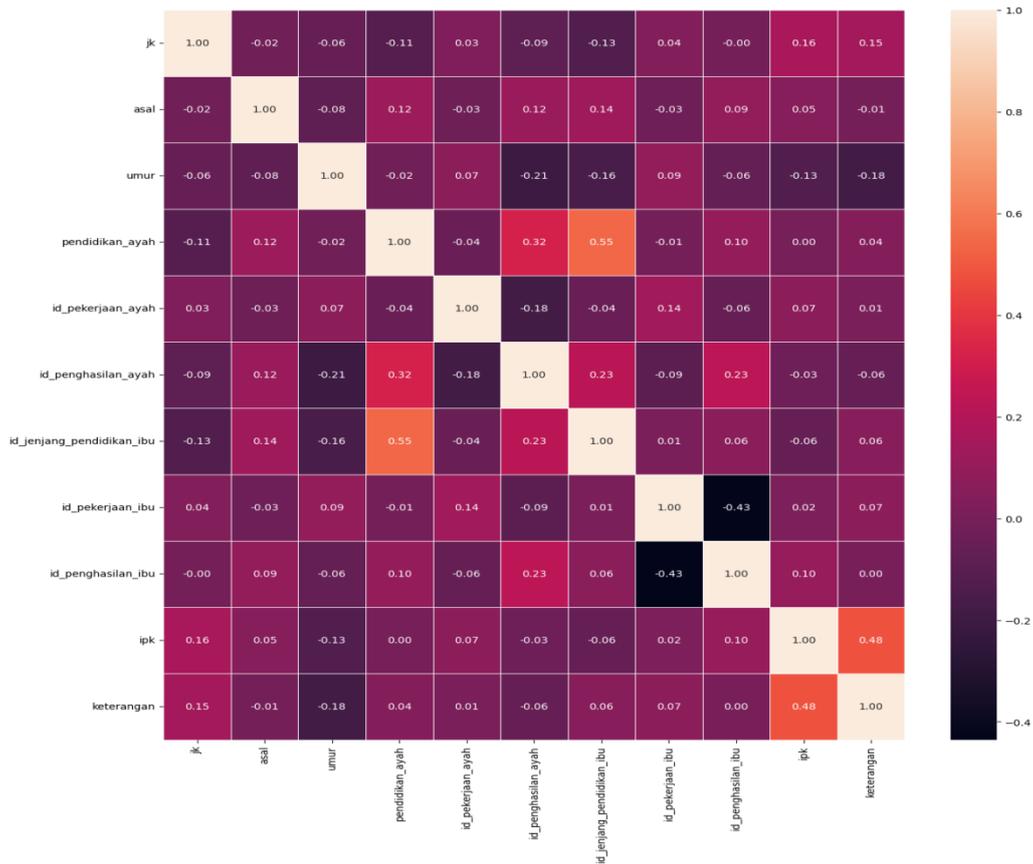
3.1 Dataset Preparation

Dari dataset yang digunakan tersebut telah di cek setiap atributnya untuk mengetahui distribusi dari masing masing atribut yang digunakan. Seperti pada gambar 3 terdapat temuan bahwa mahasiswa yang ibunya tidak bekerja lebih banyak yang lulus tepat waktu, demikian pula dari mahasiswa yang lulus tepat waktu semua, mereka memiliki ayah yang mempunyai penghasilan paling besar.



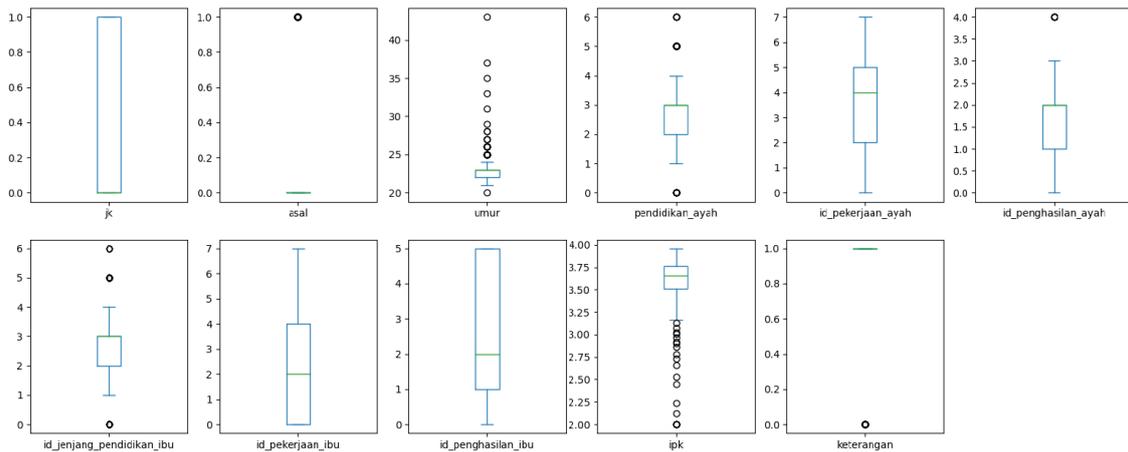
Gambar 3. (a). Hasil cek atribut id pekerjaan ibu (b). Hasil cek atribut id pekerjaan ayah.

Selain distribusi setiap atribut dicek, juga dilakukan cek korelasi antar atribut dan distribusi data untuk semua atribut menggunakan *boxplot* yang terdapat pada Gambar 4 dan 5.



Gambar 4. Korelasi antar atribut

Dari gambar 4 terlihat bahwa warna terang pada heatmap mengindikasikan bahwa kovariansnya tinggi seperti pada atribut `id_jenjang_pendidikan_ibu`, sedangkan warna gelap pada heatmap menunjukkan bahwa kovariansnya rendah seperti pada atribut `id_penghasilan_ibu`.



Gambar 5. Distribusi data semua atribut

Selain itu juga dilakukan seleksi atribut yang tidak memiliki relevansi data yang berhubungan dengan keluarga dan membersihkan data yang tidak memiliki nilai atau kosong (*missing value*).

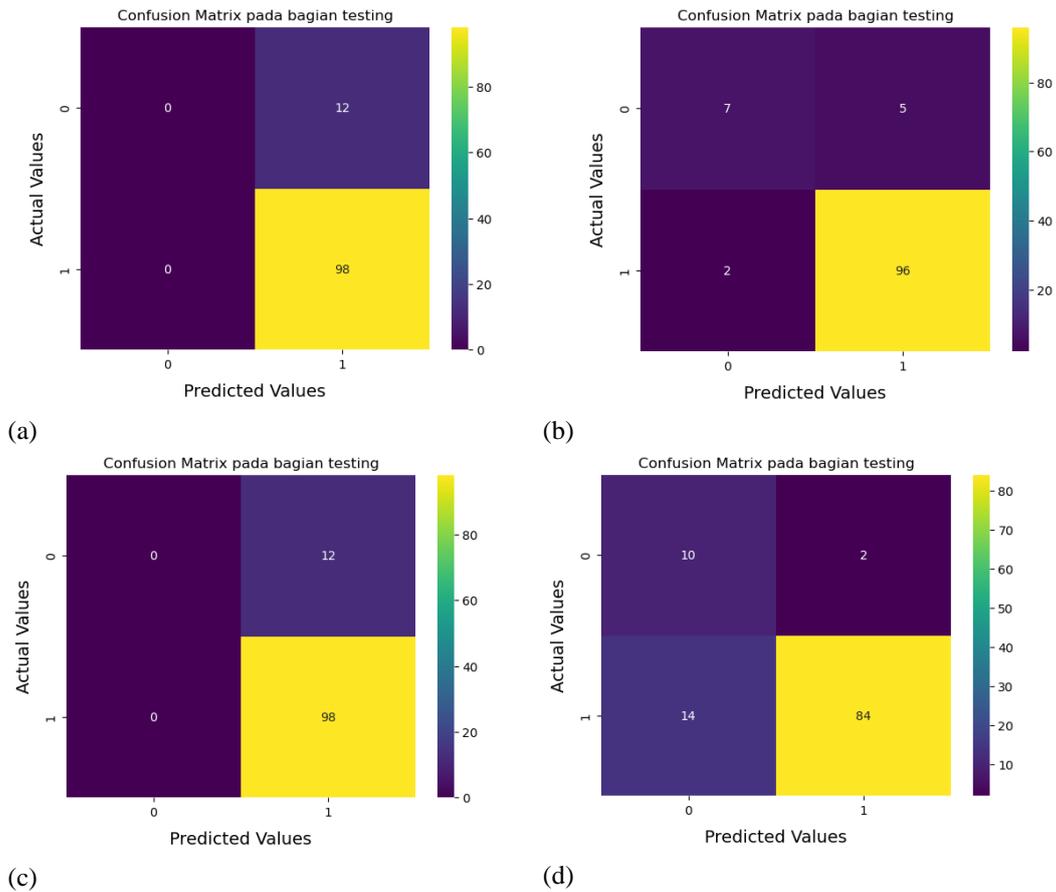
3.2 Modelling

Dataset dibagi menjadi data training dan data testing dengan perbandingan 70:30, di mana 70% (255 record) digunakan sebagai data training dan 30% (110 record) sebagai data testing. Selanjutnya masing masing model pada *machine learning* (SVM, NB, NN dan DT) diuji coba menggunakan nilai parameter *random_state=42* dan *n_split=10* pada *k-fold cross validation* dan hasilnya terlihat di tabel 2.

Tabel 2. Hasil kinerja pada masing masing model

Fold	Accuracy model			
	SVM	NB	NN	DT
1	81.08	83.78	81.08	83.78
2	89.18	89.18	83.78	78.37
3	89.18	86.48	89.18	86.48
4	83.78	97.29	94.59	89.18
5	89.18	91.89	89.18	91.89
6	91.66	91.66	88.88	83.33
7	83.33	88.88	83.33	80.55
8	86.11	88.88	86.11	83.33
9	88.88	97.22	88.88	88.88
10	94.44	94.44	94.44	91.66
Mean	87.68	90.97	87.95	85.75

Dari Tabel 2 terlihat bahwa masing masing model telah memiliki kinerja akurasi yang baik, dimana masing masing model memiliki rata rata nilai akurasi untuk support vector machine sebesar 87.68%, naive naves sebesar 90.97%, neural network sebesar 87.95% dan decision tree sebesar 85.75%. sedangkan hasil confusion matrix untuk data test terlihat di Gambar 6 untuk masing masing model yang digunakan.



Gambar 6. Confusion matrix data testing (a) SVM, (b) NB, (c) NN, (c) DT

Dari gambar 6 terlihat hasil visualisasi kinerja masing masing model dengan membandingkan nilai prediksi dengan nilai aktual menggunakan data testing.

3.3 Evaluation

Pada tahap ini, dapat dilihat hasil akurasi pada data training dan data testing yang lebih stabil. Dari Gambar 7 dapat dilihat bahwa akurasi untuk data testing lebih tinggi dibanding dengan data training kecuali untuk model yang menggunakan *decision tree*, dimana hasil data test lebih rendah dari hasil dari data training.



Gambar 7. Hasil akurasi data train dan data test

Sedangkan dari masing-masing model yang dievaluasi dengan *K-Fold Cross Validation* dapat diketahui fold terbaik dan akurasi tertingginya.

Tabel 3. Hasil fold terbaik

Model	Fold Terbaik	Akurasi
Suport Vector Machines with KFold	10	94.44
Naïve Bayes with KFold	4	97.29
Neural Network with KFold	4	94.59
Decision Tree with KFold	5	91.89

Dari tabel 3 dapat dilihat bahwa untuk pemodelan *support vector machine* fold terbaik terdapat pada 10-Fold dengan akurasi mencapai 94,44%, pemodelan menggunakan *naïve bayes* fold terbaik terdapat pada 4-Fold dengan akurasi mencapai 97,29%, pemodelan menggunakan *neural network* fold terbaik terdapat pada 4-Fold dengan akurasi mencapai 94.59% dan pemodelan menggunakan *decision tree* fold terbaik terdapat pada 5-Fold dengan akurasi mencapai 91,89%.

4. KESIMPULAN

Berdasarkan hasil eksperimen yang telah dilakukan, bahwa model klasifikasi yang bangun dengan *K-Fold Cross Validation* memiliki kestabilan akurasi yang lebih baik, sehingga dapat digunakan untuk memprediksi kinerja mahasiswa untuk selesai tepat waktu. Dataset sebanyak 365 record dipisah dengan perbandingan 70:30 menggunakan nilai parameter *random_state=42* dan *n_split=10* pada *k-fold cross validation*. Berdasarkan parameter *confusion matrix* menunjukkan rata-rata (*mean*) akurasi untuk setiap model, dimana *support vector machine* besarnya 87,68%, *naïve bayes* besarnya 90,97%, *neural network* sebesar 87,95% dan *decision tree* sebesar 85,75%. Sedangkan hasil fold terbaik untuk SVM terletak di fold ke-10 dengan nilai akurasi 94,44%, NB terletak di fold ke-4 dengan niali akurasi 97,29%, NN terletak di fold ke-4 dengan nilai akurasi 94.59% serta DT terletak di fold ke-5 dengannilai akurasi 91,89%. Selain itu untuk pemodelan *decision tree* ditemukan perbedaan perbandingan yang cukup besar antara akurasi data testing lebih kecil dibandingkan dengan akurasi

pada data trainingnya. Dengan demikian evaluasi menggunakan k-fold cross validation dapat digunakan dalam memprediksi kinerja mahasiswa menggunakan fold ke-4 yang memiliki akurasi tertinggi sebesar 97,29% pada algoritma *naïve bayes*. Untuk penelitian selanjutnya dapat digunakan pemodelan machine learning lain dengan menambah fold yang lebih besar dalam rangka meningkatkan akurasi yang lebih tinggi.

REFERENSI

- [1] A. Salam and J. Zeniarja, “Classification of deep learning convolutional neural network feature extraction for student graduation prediction,” *Indones. J. Electr. Eng. Comput. Sci.*, vol. 32, no. 1, p. 335, Oct. 2023, doi: 10.11591/ijeecs.v32.i1.pp335-341.
- [2] J. M. Gorriz, F. Segovia, J. Ramirez, A. Ortiz, and J. Suckling, “Is K-fold cross validation the best model selection method for Machine Learning?,” Jan. 29, 2024, *arXiv*: arXiv:2401.16407. Accessed: Feb. 07, 2024. [Online]. Available: <http://arxiv.org/abs/2401.16407>
- [3] Department of Computer Science and Informatics, University of Energy and Natural Resources, Sunyani, Ghana, I. K. Nti, O. Nyarko-Boateng, and J. Aning, “Performance of Machine Learning Algorithms with Different K Values in K-fold CrossValidation,” *Int. J. Inf. Technol. Comput. Sci.*, vol. 13, no. 6, pp. 61–71, Dec. 2021, doi: 10.5815/ijitcs.2021.06.05.
- [4] D. Berrar, “Cross-Validation,” in *Encyclopedia of Bioinformatics and Computational Biology*, Elsevier, 2019, pp. 542–545. doi: 10.1016/B978-0-12-809633-8.20349-X.
- [5] F. Rios-Avila, *CV_KFOLD: Stata module to implement k-fold cross-validation procedures*. econpapers.repec.org, 2022. [Online]. Available: <https://econpapers.repec.org/software/bochocode/s458798.htm>
- [6] A. Tholib, M. N. Fadli Hidayat, S. Yono, R. Wulanningrum, and E. Daniati, “Comparison of C4.5 and Naive Bayes for Predicting Student Graduation Using Machine Learning Algorithms,” *Int. J. Eng. Comput. Sci. Appl. IJECSA*, vol. 2, no. 2, pp. 65–72, Sep. 2023, doi: 10.30812/ijecsa.v2i2.3364.
- [7] Z. Lyu *et al.*, “Back-Propagation Neural Network Optimized by K-Fold Cross-Validation for Prediction of Torsional Strength of Reinforced Concrete Beam,” *Materials*, vol. 15, no. 4, p. 1477, Feb. 2022, doi: 10.3390/ma15041477.
- [8] M. K. Mayangsari, I. Syarif, and A. Barakbah, “Evaluation of Stratified K-Fold Cross Validation for Predicting Bug Severity in Game Review Classification,” *Kinet. Game Technol. Inf. Syst. Comput. Netw. Comput. Electron. Control*, Jul. 2023, doi: 10.22219/kinetik.v8i3.1740.
- [9] O. Oyedele, “Determining the optimal number of folds to use in a K-fold cross-validation: A neural network classification experiment,” *Res. Math.*, vol. 10, no. 1, p. 2201015, Dec. 2023, doi: 10.1080/27684830.2023.2201015.
- [10] J. White and S. D. Power, “k-Fold Cross-Validation Can Significantly Over-Estimate True Classification Accuracy in Common EEG-Based Passive BCI Experimental Designs: An Empirical Investigation,” *Sensors*, vol. 23, no. 13, p. 6077, Jul. 2023, doi: 10.3390/s23136077.
- [11] R. Tuntun, K. Kusrini, and K. Kusnawi, “Analisis Perbandingan Kinerja Algoritma Klasifikasi dengan Menggunakan Metode K-Fold Cross Validation,” *J. MEDIA Inform. BUDIDARMA*, vol. 6, no. 4, p. 2111, Oct. 2022, doi: 10.30865/mib.v6i4.4681.
- [12] S. Linawati, S. Nurdiani, K. Handayani, and L. Latifah, “Prediksi Prestasi Akademik Mahasiswa Menggunakan Algoritma Random Forest Dan C4.5,” *J. Khatulistiwa Inform.*, vol. 8, no. 1, Jun. 2020, doi: 10.31294/jki.v8i1.7827.
- [13] D. Selvida and P. H. Putra, “Optimization of cross-validation testing on the decision tree and k-nearest neighbor in classifying election data,” vol. 7, no. 3, 2023.
- [14] O. Chamorro-Atalaya *et al.*, “K-Fold Cross-Validation through Identification of the Opinion Classification Algorithm for the Satisfaction of University Students,” *Int. J. Online Biomed. Eng. IJOE*, vol. 19, no. 11, Aug. 2023, doi: 10.3991/ijoe.v19i11.39887.
- [15] N. Nurainun, E. Haerani, F. Syafria, and L. Oktavia, “Penerapan Algoritma Naïve Bayes Classifier Dalam Klasifikasi Status Gizi Balita dengan Pengujian K-Fold Cross Validation,” *J. Comput. Syst. Inform. JoSYC*, vol. 4, no. 3, pp. 578–586, May 2023, doi: 10.47065/josyc.v4i3.3414.

- [16] H. Azis, P. Purnawansyah, F. Fattah, and I. P. Putri, “Performa Klasifikasi K-NN dan Cross Validation Pada Data Pasien Pengidap Penyakit Jantung,” *Ilk. J. Ilm.*, vol. 12, no. 2, pp. 81–86, Aug. 2020, doi: 10.33096/ilkom.v12i2.507.81-86.
- [17] R. R. R. Arisandi, B. Warsito, and A. R. Hakim, “Aplikasi Naïve Bayes Classifier (NBC) Pada Klasifikasi Status Gizi Balita Stunting Dengan Pengujian K-Fold Cross Validation,” *J. Gaussian*, vol. 11, no. 1, pp. 130–139, May 2022, doi: 10.14710/j.gauss.v11i1.33991.
- [18] A. Desiani *et al.*, “Penerapan Metode Support Vector Machine Dalam Klasifikasi Bunga Iris,” *Indones. J. Appl. Inform.*, vol. 7, no. 1, p. 12, Apr. 2023, doi: 10.20961/ijai.v7i1.61486.
- [19] Y. N. Fuadah, I. D. Ubaidullah, N. Ibrahim, F. F. Taliningsing, N. K. Sy, and M. A. Pramuditho, “Optimasi Convolutional Neural Network dan K-Fold Cross Validation pada Sistem Klasifikasi Glaukoma,” *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 10, no. 3, p. 728, Jul. 2022, doi: 10.26760/elkomika.v10i3.728.
- [20] Agung Nugroho and Agit Amrullah, “Evaluasi Kinerja Algoritma K-Nn Menggunakan K-Fold Cross Validation Pada Data Debitur KSP Galih Manunggal,” *J. Inform. Teknol. Dan Sains Jinteks*, vol. 5, no. 2, pp. 294–300, May 2023, doi: 10.51401/jinteks.v5i2.2506.
- [21] N. Alifiah, D. Kurniasari, A. Amanto, and W. Warsono, “Prediction of COVID-19 Using the Artificial Neural Network (ANN) with K-Fold Cross-Validation,” *J. Inf. Syst. Eng. Bus. Intell.*, vol. 9, no. 1, pp. 16–27, Apr. 2023, doi: 10.20473/jisebi.9.1.16-27.
- [22] X. Zhang and C.-A. Liu, “Model averaging prediction by K -fold cross-validation,” *J. Econom.*, vol. 235, no. 1, pp. 280–301, Jul. 2023, doi: 10.1016/j.jeconom.2022.04.007.
- [23] S. N. Cahyani and G. W. Saraswati, “Implementation Of Support Vector Machine Method In Classifying School Library Books With Combination Of TF-IDF And WORD2VEC,” *J. Tek. Inform. Jutif*, vol. 4, no. 6, pp. 1555–1566, Dec. 2023, doi: 10.52436/1.jutif.2023.4.6.1536.
- [24] E. K. Nurnawati, M. Sholeh, R. Y. Ariyana, and E. Almuntaha, “Comparison Of Decision Tree And Naïve Bayes Algorithms In Classification Models To Determine Lecturer Performance Using K Fold Cross Validation,” vol. 14, no. 2, 2023.
- [25] S. A. Satriotomo, U. A. Ahmad, and P. Abadi, “Simulasi Prediksi Sintilasi Ionosfer Menggunakan Aplikasi Matlab Dengan Metode Neural Network,” vol. 2, no. 1, 2022.
- [26] S. Widodo, H. Brawijaya, and S. Samudi, “Stratified K-fold cross validation optimization on machine learning for prediction,” *Sinkron*, vol. 7, no. 4, pp. 2407–2414, Oct. 2022, doi: 10.33395/sinkron.v7i4.11792.
- [27] M. Shiddiq, F. Candra, B. Anand, and M. F. Rabin, “Neural network with k-fold cross validation for oil palm fruit ripeness prediction,” *TELKOMNIKA Telecommun. Comput. Electron. Control*, vol. 22, no. 1, p. 164, Oct. 2023, doi: 10.12928/telkomnika.v22i1.24845.
- [28] H. Hafid, “Penerapan K-Fold Cross Validation untuk Menganalisis Kinerja Algoritma K-Nearest Neighbor pada Data Kasus Covid-19 di Indonesia,” 2023.