



OPTIMASI HYPERPARAMETER MULTILAYER PERCEPTRON UNTUK PREDIKSI DAYA BELI MOBIL

**Muhammad Iqbal¹, Hendri Mahmud Nawawi², M Rangga Ramadhan Saelan³, Muhammad Sony
Maulana⁴, Yudhistira⁵, Ali Mustopa⁶**

^{1,6}Program Studi Teknik Informatika, Universitas Bina Sarana Informatika, ²Program Studi Informatika,
Universitas Nusa Mandiri, ³Program Studi Sains Data, Universitas Nusa Mandiri,

⁴Program Studi Sistem Informasi, Universitas Bina Sarana Informatika

⁵Program Studi Teknologi Komputer, Universitas Bina Sarana Informatika

Jl. Kramat Raya No.98, RW.9, Kwitang, Kec. Senen, Kota Jakarta Pusat, DKI Jakarta

¹iqbal.mdq@bsi.ac.id, ²hendri.hiw@nusamandiri.ac.id, ³rangga.mgg@nusamandiri.ac.id,

⁴muhammad.sony.mom@bsi.ac.id, ⁵yudhistira.yht@bsi.ac.id, ⁶alimustopa.aop@bsi.ac.id

Abstract

In deciding to buy a car, several factors are usually taken into consideration to determine the final decision. Therefore a number of supporting factors such as price, type, brand, and so on are important to note. In this research, optimization of the multilayer perceptron algorithm model is used to model the prediction of consumers' car purchasing power from public datasets sourced from Kaggle to find the most optimal model for car buying decisions. Multilayer perceptron is often applied to research complex data because it is able to analyze data well. Prediction of purchase intentions can not only reduce car dealership costs, but also affect car dealership marketing strategies in the long term. Testing using the Multilayer Perceptron (MLP) model with default configuration and hypertuning parameters was carried out by comparing two different optimization parameters, namely the Adam and RMSprop parameters. The result is an optimal evaluation of the default configuration of the Adam optimization parameter with a maximum learning rate of 0.01 with an accuracy of 89.50% and 87.50% for RMSprop optimization while testing with the hyperparameter tuning configuration with the same two optimization parameters Adam and RMSprop with a maximum learning rate value of 0.001 is obtained accuracy of 92.00% for the RMSprop parameter and 91.5% for the Adam parameter.

Keywords : *Multilayer Perceptron, Car Price, Hyperparameter Tuning*

Abstrak

Dalam memutuskan untuk membeli mobil biasanya beberapa faktor dijadikan pertimbangan untuk menentukan keputusan akhir. Maka dari itu sejumlah faktor pendukung seperti harga, type, merk, dan lain sebagainya penting untuk diperhatikan. Pada penelitian ini optimasi model algoritma multilayer perceptron digunakan untuk memodelkan prediksi daya beli mobil konsumen dari dataset publik yang bersumber dari kaggle untuk menemukan model paling optimal terhadap keputusan membeli mobil. Multilayer perceptron sering diterapkan untuk meneliti data yang kompleks karena mampu menganalisa data dengan baik. Prediksi niat beli tidak hanya dapat mengurangi biaya dealer mobil, tetapi juga mempengaruhi strategi pemasaran dealer mobil dalam jangka panjang. Pengujian menggunakan model Multilayer Perceptron (MLP) dengan konfigurasi default dan hypertuning parameter dilakukan dengan membandingkan dua parameter optimasi yang berbeda yaitu parameter Adam dan RMSprop. Hasilnya didapatkan evaluasi optimal dari konfigurasi default pada parameter optimasi Adam dengan maksimum



learning rate 0.01 dengan akurasi 89.50% dan 87,50% untuk optimasi RMSprop sedangkan pengujian dengan konfigurasi hyperparameter tuning dengan dua parameter optimasi yang sama Adam dan RMSprop dengan nilai maksimum learning rate 0,001 didapatkan akurasi sebesar 92.00% untuk parameter RMSprop dan 91,5% pada parameter Adam.

Kata kunci : Multilayer Perceptron, Harga Mobil, Hyperparameter Tuning

1. PENDAHULUAN

Memahami dan memprediksi permintaan perjalanan dan kepemilikan mobil merupakan hal yang menarik [1]. Prediksi harga mobil telah menjadi area penelitian yang diminati, karena membutuhkan upaya nyata dan pengetahuan dari ahli lapangan [2]. Mobil adalah salah satu alat transportasi yang paling populer yang digunakan di kehidupan sehari-hari setelah sepeda motor [3]. Pada Tahun 2015 berdasarkan hasil survei yang dilakukan oleh Gaikindo (Gabungan Industri Kendaraan Bermotor) pembelian mobil menunjukkan angka 85% untuk kategori pembelian secara kredit [4]. Hal ini menunjukkan bahwa bagi sebagian orang mobil adalah kebutuhan pokok untuk mendukung pekerjaan dan aktivitas transportasi [5].

Pada tahap proses pemilihan mobil konsumen seringkali mengalami kebingungan untuk memilih mobil seperti apa yang diperlukan untuknya. Sejumlah besar atribut yang berbeda diperiksa untuk prediksi yang andal dan akurat, maka dari itu sejumlah faktor pendukung seperti harga, type, merk, dan lain sebagainya penting untuk diperhatikan [2][5].

Banyak faktor yang mempengaruhi konsumen dalam memutuskan untuk membeli mobil [6]. Harga mobil baru di industri ditetapkan oleh produsen dengan beberapa biaya tambahan yang dikeluarkan oleh Pemerintah dalam bentuk pajak [7].

Pada makalah ini penelitian berfokus pada klasifikasi customer dalam menentukan pilihan apakah YA membeli mobil atau TIDAK. Beberapa faktor yang menjadi bahan pertimbangan customer untuk keputusan membeli mobil berdasarkan dataset yang kami dapatkan dari dataset publik yang bersumber dari kaggle.com dengan jumlah data sebanyak 1.000 data dan 5 atribut yaitu ID customer, gender, usia, penghasilan dan keputusan YA membeli mobil atau TIDAK.

Tujuan penelitian ini adalah memodelkan klasifikasi konsumen berdasarkan faktor usia, gender dan penghasilan untuk memberikan rekomendasi keputusan membeli mobil bagi konsumen yang datang ke dealer sehingga dapat memberikan masukan pada strategi pemasaran. Prediksi niat beli tidak hanya dapat mengurangi biaya dealer mobil, tetapi juga mempengaruhi strategi pemasaran dealer mobil dalam jangka panjang [8].

Prediksi tersebut kemudian dievaluasi dan dibandingkan untuk menemukan prediksi yang memberikan kinerja terbaik dengan model multilayer perceptron. *Multilayer perceptron* sering diterapkan untuk meneliti data yang kompleks karena mampu menganalisa data dengan baik [9]. Pada sistem kerjanya dalam menyelesaikan masalah multilayer perceptron meniru daya syaraf otak manusia dalam bentuk neuron-neuron [10].

Penelitian tentang prediksi harga jual mobil menghasilkan nilai 90% untuk kategori penjualan mobil bekas dengan model regresi, penelitian ini menyimpulkan sebagian besar keputusan konsumen dalam membeli mobil bekas didasarkan pada harga dan jarak tempuh [11].

Pada penelitian yang berjudul “sebuah metodologi untuk memprediksi harga mobil bekas menggunakan Random Forest” [7]. Model *Random Forest* dengan 500 Pohon Keputusan dibuat untuk melatih data. Dari hasil eksperimen didapatkan akurasi pelatihan sebesar 95,82%, dan akurasi pengujian sebesar 83,63%.

Penelitian selanjutnya dengan melakukan komparasi tiga model algoritma yaitu SVM, RF dan DNN terhadap delapan atribut diantaranya *Gender, Age, Region, City, Education, Access to Information, Family Size, Family Income* dengan menambahkan fitur jaringan berbasis Hoby dan Jaringan Berbasis Kerja terhadap keputusan membeli mobil hasilnya model DNN merupakan nilai terbaik dengan akurasi 0,84, sedangkan RF 0,67 dan SVM 0,68 [8].

Penelitian pada makalah ini dengan menggunakan model *multilayer perceptron* menghasilkan akurasi paling baik untuk prediksi keputusan membeli mobil dengan menggunakan konfigurasi *default* dan *hyper parameter Tuning* dan menguji dengan dua parameter yaitu optimasi Adam dan RMSprop. Hasilnya pada dua konfigurasi yang dilakukan dengan parameter Adam jauh lebih baik daripada Parameter RMSprop dengan masing-masing akurasi baik sebesar 0,87% dan 0,92%.

2. TINJAUAN PUSTAKA

Tinjauan pustaka merupakan pemilihan aspek-aspek yang terkait dengan pertanyaan penelitian dalam tinjauan teoritis, kerangka ideologis tersebut disebut hipotesis dasar yang disusun oleh peneliti berdasarkan kerangka teori dalam tinjauan pustaka sebelumnya.

2.1. Data Mining

Data mining merupakan disiplin ilmu yang mempelajari hubungan atau pola-pola tersembunyi dalam sebuah dataset yang besar berdasarkan variabel-variabel dari data inputan yang menghasilkan sebuah keputusan prediksi, klasifikasi, regresi atau clusterisasi [12].

Dalam menentukan keputusan untuk mempelajari pola tersembunyi pada dataset yang besar data mining dibutuhkan dalam menentukan prediksi atau klasifikasi pada dataset dengan tujuan mengambil suatu keputusan atau kesimpulan berdasarkan hasil pembelajaran data sebelumnya [13]. Untuk memperkirakan hasilnya, proses pada data mining dibagi menjadi dua bagian yaitu *data training* (data pelatihan) dan *data testing* (data pengujian) [14].

Variasi teknik atau model pada data mining sangat bervariasi hal ini ditentukan pada proses penemuan pengetahuan data pada database atau biasa disebut *Knowledge Discovery in Database (KDD)* [15].


2.2. Prediksi

Saat ini peramalan atau prediksi telah mencakup beberapa bidang kehidupan diantaranya ekonomi, bisnis, pendidikan, industry, keuangan dan masih banyak lainnya,

Prediksi digunakan untuk mempelajari faktor-faktor apa saja yang mempengaruhi terhadap suatu permasalahan untuk diambil sebuah hasil atau kesimpulan [16]. Prediksi dan klasifikasi menggunakan metode *machine learning* dan *deep learning* masih memberikan hasil yang beragam, terkadang hasilnya menunjukkan akurasi dan performa yang baik, namun terkadang hasilnya labil atau tidak menentu hal ini tergantung banyak faktor [17].

2.3. Multilayer Perceptron

Sebuah MLP terdiri dari beberapa lapisan, dengan setiap lapisan mengandung beberapa neuron. menunjukkan struktur MLP. Lapisan paling kanan disebut "lapisan keluaran" dan menghasilkan nilai yang ingin di aproksimasi. Lapisan perantara disebut "lapisan tersembunyi" [18]. Pengklasifikasi MLP membuat pendakian berulang yang jauh lebih kuat daripada pengklasifikasi data lain yang menyoroti kemampuannya untuk pembelajaran pola yang lebih efisien [19].



Gambar 1. Struktur Multilayer Perceptron

Setiap lapisan berisi beberapa neuron, yang terhubung ke semua neuron di lapisan yang berdekatan.

Masukan dari lapisan paling kiri ke neuron adalah nilai masukan, untuk neuron di lapisan lain, inputnya adalah output dari neuron di lapisan sebelumnya. Output dari setiap neuron dihitung menggunakan persamaan berikut:

$$a = f(b + \sum piwi) \quad (1)$$

Dimana :

pi adalah input,



w_i adalah bobot yang diterapkan pada input

b adalah bias, dan

f adalah fungsi aktivasi.

Sebuah neuron dapat menerapkan pemetaan nonlinier dari sekumpulan input ke output jika fungsi f adalah fungsi nonlinier.

Output dari setiap lapisan untuk MLP yang ditunjukkan pada gambar 2 dapat dihitung dengan menggunakan persamaan berikut:

$$a^1_j = f^1(b^1_j + \sum_{i=1}^N p_i w^1_{i,j}) \quad (2)$$

$$a^2_j = f(b^2_j + \sum_{i=1}^{M^1} a^1_i w^2_{i,j}) \quad (3)$$

$$T = f^3(b^3 + \sum_{i=1}^{M^2} a^2_i w^3_{i,1}) \quad (4)$$

Superscript menunjukkan lapisan dan subscript menunjukkan neuron yang kita rujuk di dalam lapisan itu. Bobot $w_{i,j}$ dikaitkan dengan koneksi yang menunjuk dari neuron ke- i dari lapisan sebelumnya ke neuron ke- j dari lapisan yang sekarang.

Jumlah input ke MLP dilambangkan dengan N dan jumlah neuron pada lapisan tersembunyi ke- i dilambangkan dengan M_i . Saat menggunakan MLP, input akan maju melalui setiap lapisan menggunakan persamaan di atas hingga output akhir dapat dihitung.

2.4. Evaluasi

Pada tahap evaluasi untuk mendapatkan hasil pembelajaran yang dapat ditingkatkan, penelitian ini menggunakan nilai akurasi, *Loss*, *AUC* dan *Precision*.

Persamaan rumus akurasi sebagai berikut :

$$Accuracy = \frac{a+d}{total\ sample} \times 100\% \quad (5)$$

Dimana :

a adalah nilai yang prediksi benar dan hasilnya benar.

d adalah nilai yang diprediksi salah dan hasilnya memang salah [12].

Loss merupakan kebalikan dari nilai akurasi. Persamaan *Loss* adalah sebagai berikut :

$$Loss = \frac{b+c}{total\ sample} \times 100\% \quad (6)$$

Dimana :

b adalah nilai yang diprediksi benar tetapi hasilnya salah

c adalah nilai yang diprediksi salah tetapi hasilnya benar.


Hubungan a b c dan d dalam istilah *machine learning* disebut *Confusion Matrix* [20]. Jika digambarkan dalam bentuk table hubungan a b c dan d adalah seperti table 1 :

Tabel 1. Confussion Matrics

	Prediksi (Benar)	Prediksi (Salah)
Aktual (Benar)	a	b
Aktual (Salah)	c	d

3. METODOLOGI PENELITIAN

Pada metode penelitian ini secara umum alur penelitian dijelaskan pada gambar 1.



Gambar 2. Metode Penelitian

3.1. Dataset Penelitian

Dataset yang digunakan pada penelitian ini bersumber dari kaggle.com dimana jumlah sample dataset sebanyak 1.000 sample dengan 5 atribut . atribut yang digunakan diantaranya ID Konsumen, gender, usia, penghasilan dan satu atribut yang digunakan sebagai label karena bernilai binary untuk keputusan 1 (YA) membeli mobil dan 0 (TIDAK) membeli mobil.

- 1) ID : Data ini diambil dari urutan customer yang berkunjung ke dealer id customer berisi urutan angka dari 1 - 1000.
- 2) Gender: faktor kedua yang menjadi bahan pertimbangan apakah konsumen akan membeli mobil atau tidak yaitu gender



dimana isi fieldnya adalah male dan female.

- 3) Usia: Usia merupakan faktor penting dalam memutuskan membeli mobil rentang usia berdasarkan dataset antara 18 sampai dengan 63 tahun.
- 4) Penghasilan: Penghasilan merupakan faktor paling penting untuk memutuskan membeli mobil atau tidak baik secara cash ataupun kredit. Dataset yang kami teliti penghasilan bernilai konversi mata uang dollar yang diakumulasikan dalam satu tahun.
- 5) Keputusan: Nilai dari keputusan adalah 0 untuk Tidak dan 1 untuk Ya membeli mobil.

3.2. Pra Pemrosesan Data

Proses umum pengumpulan data disajikan dengan menguraikan proses dan langkah-langkah yang diperlukan untuk pengumpulan data [19]. Sebelum data di proses dengan *model multilayer perceptron* dilakukan data *preprocessing* untuk menghilangkan *noise* dan membagi data menjadi dua bagian yaitu data training dan data testing.

Data training dan data testing dibagi menjadi 80-20 % untuk menguji model.

Pada tahap *Preprocessing Dataset*, data yang *miss* dibuang dengan tujuan supaya dataset bisa diolah dengan baik tanpa ada *missing value* [21].

3.3. Pengujian Model

Pada tahap pengujian model algoritma yang diusulkan pada penelitian ini yaitu multilayer perceptron untuk menemukan pola tersembunyi dari total 1000 dataset yang diperoleh dari sumber kaggle.com pada dataset prediksi daya beli mobil [22].

Data dibagi menjadi dua yakni data *training* dan data *testing* dengan rasio 80:20, dimana 80% dijadikan sebagai data *training* dan 20% sebagai data *testing*.

3.4. Pengaturan Parameter

Pengaturan parameter digunakan untuk menguji model pada data *training* dan data

testing sehingga dihasilkan parameter paling efektif dengan nilai akurasi tertinggi dari model yang diusulkan. Setting parameter yang dibandingkan antara parameter *default* dan parameter *hyperTuning* untuk mengoptimalkan dan membandingkan nilai akurasi pada masing-masing pengaturan.

Optimasi yang diusulkan pada penelitian ini menggunakan optimisasi momentum adaptif (Adam) dan Optimasi Root-Mean-Square Propagation (RMSprop) yang berfungsi untuk meningkatkan akurasi pada model Multilayer perceptron yang dipilih pada penelitian ini.

3.5. Evaluasi

Pada tahapan evaluasi model yang diusulkan multilayer perceptron diuji dengan menggunakan *tools* python dengan menentukan *learning rate* dan *hidden layer* yang diusulkan untuk mendapatkan nilai akurasi paling tinggi berdasarkan *hyperparameter* yang diuji coba dengan melakukan optimasi pada masing-masing parameter.

Selain akurasi evaluasi yang diusulkan untuk mendapatkan model terbaik adalah dengan mendapatkan nilai AUC tertinggi dan nilai *Loss* paling rendah.

Pada tahap evaluasi juga menentukan parameter-parameter yang diusulkan untuk model prediktif pada data daya beli mobil dengan menggunakan model algoritma Multilayer Perceptron (MLP) berdasarkan hasil pengolahan dari data *training* dan data *testing*.

4. HASIL DAN PEMBAHASAN

Pada penelitian ini sumber dataset yang digunakan bersumber dari data publik kaggle.com dengan jumlah dataset sebanyak 1000 data penelitian yang terdiri dari 5 atribut [22].

Tabel 2. Dataset Penelitian

ID	Gender	Usia	Penghasilan Pertahun (\$)	Keputusan
1	Pria	32	100000	1
2	Wanita	38	63500	0
3	Pria	20	74000	0

4	Wanita	48	119000	1
..	...	...	...	...
999	Pria	60	131500	1
1000	Wanita	40	76500	1

Selanjutnya dataset dibagi menjadi dua bagian sebagai data pembelajaran (*data training*) dan data pengujian (*data testing*). Persentase perbandingan yang digunakan dengan menggunakan *split validation* data dibagi menjadi 2 bagian dengan perbandingan 80:20. Dimana 800 data dijadikan sebagai data *training* dan 200 data sebagai data *testing*.


1) Pengujian Model

Pada tahap pengujian dataset dengan menggunakan algoritma *Multilayer Perceptron* konfigurasi pertama dengan menggunakan setting *default* dari *multilayer Perceptron*. Konfigurasi default merupakan pengaturan nilai parameter bawaan yang didapatkan dari jumlah fitur. Hasil penelitian ditunjukkan pada tabel 3.

Tabel 3. Konfigurasi Model (*Default*)

Optimasi	LR	Hidden Layer	Akurasi	Loss	AUC	Recall
Adam	0.1	1	89.50	28.96	95.43	92.20
RMSProp	0.1	1	87.50	32.63	93.77	90.21

Dari tabel 3 bisa disimpulkan bahwa hasil pengujian menggunakan model *MultiLayer Perceptron* (MLP) dengan membandingkan konfigurasi, optimasi dan learning rate dengan menggunakan konfigurasi model secara *default* didapatkan nilai akurasi 89,50 untuk optimasi Adam dan 87,50 untuk optimasi RMSprop dengan demikian pada konfigurasi *default* optimasi Adam jauh lebih baik daripada optimasi RMSProp. Visualisasi perbandingan dari kedua model optimasi dengan *learning rate* (LR) 0,1 dan Hidden Layer 1 diperlihatkan pada gambar 3.



Gambar 3. Grafik perbandingan nilai optimasi dengan konfigurasi *default*

2) Konfigurasi Hyper Tuning


Pengujian terhadap dataset selanjutnya dengan menggunakan *hyperparameter Tuning*. konfigurasi *Hyperparameter Tuning* merupakan pengaturan nilai parameter untuk mengidentifikasi nilai parameter yang optimal dengan nilai parameter *learning rate* (LR) maksimal 0.001. Hasilnya Pada Tabel 4.

Tabel 4. Konfigurasi *Hyperparameter Tuning*

Optimasi	LR	Hidden Layer	Akurasi	Loss	AUC	Recall
Adam	0,001	1	91.50	24.83	96.12	93.23
RMSprop	0,001	1	92.00	24.44	96.30	93.36

Dari hasil pengujian model *Multilayer Perceptron* dengan *Hyperparameter Tuning* didapatkan evaluasi optimal pada parameter optimasi Adam, *learning rate* (LR) 0.001 dengan akurasi 92.00%, Loss 24.44%, AUC 96.30% dan Precision-Recall 93.36%.

Perbandingan dengan konfigurasi *Hyperparameter Tuning* diperlihatkan pada gambar 4.




Gambar 4. Grafik perbandingan nilai optimasi dengan konfigurasi *Hyperparameter Tuning*

Pada tabel 3 dan tabel 4 hasil pengujian menggunakan model *MultiLayer Perceptron* (MLP) dengan membandingkan konfigurasi, optimasi dan learning rate. Konfigurasi *default* dan konfigurasi *Hyperparameter Tuning* untuk mengidentifikasi nilai parameter yang optimal. Pengujian dengan konfigurasi *default* dilakukan dengan perbandingan dua parameter optimasi yang berbeda yaitu parameter Adam dan RMSprop dengan nilai parameter learning rate maksimal 0.01, hasil pengujian tersebut didapatkan evaluasi optimal dari konfigurasi *default* pada parameter optimasi Adam, learning rate 0.01 dengan akurasi 89.50%, Loss 28.96%, AUC 95.43%, Precision-Recall 92.20. Sedangkan pengujian dengan konfigurasi hyperparameter tuning dengan parameter Adam dan RMSprop dengan nilai parameter learning rate dari konfigurasi hyperparameter tuning 0.001, hasil pengujian didapatkan evaluasi optimal dari konfigurasi *hyperparameter tuning* pada parameter RMSprop, learning rate 0.001 dengan akurasi 92.00%, Loss 24.44%, AUC 96.30%, Precision-Recall 93.36%.

Tabel 5. Komparasi Model Konfigurasi MLP

Config	Optimasi	Akurasi (%)	Loss	AUC	Recall
Default	Adam	89,5	28,96	95,43	92,2
	RMSProp	87,5	32,63	93,77	90,21
HT Parameter	Adam	91,5	24,83	96,12	93,23
	RMSProp	92	24,44	96,3	93,36



Gambar 5. Grafik perbandingan komparasi Model Multilayer Perceptron.

Dari perbandingan 2 konfigurasi pengaturan didapatkan parameter terpilih berdasarkan akurasi tertinggi dengan konfigurasi Hyperparameter Tuning dengan optimasi RMSprop dengan nilai 92,5% maka dari itu

model prediktif yang diusulkan dapat dilihat pada tabel 6.

Tabel 6. Model prediktif usulan

Parameter	Nilai Parameter
Input Layer	4
Hidden Layer	1
Hidden Neuron	448
Activation Input	ReLU
Activation Output	Sigmoid
Optimisation	RMSprop

5. KESIMPULAN DAN SARAN

Penelitian yang kami lakukan untuk prediksi daya beli mobil dengan melihat beberapa faktor diantaranya gender, usia dan akumulasi penghasilan selama setahun dengan menggunakan model multilayer perceptron dan dua parameter optimasi yang diusulkan Adam dan RMSprop pada pengaturan konfigurasi *default* optimasi Adam jauh lebih baik dari optimasi RMSprop dengan nilai akurasi sebesar 89,5% sedangkan pada konfigurasi *hyperparameter Tuning* optimasi RMSprop lebih baik dengan nilai akurasi sebesar 92,5%.

Saran untuk pengembangan dan penelitian selanjutnya diharapkan dapat menguji dengan optimasi lain selain daripada yang digunakan pada penelitian ini, menambahkan *novelty* pada ukuran dataset, penambahan fitur atau dengan contoh studi kasus pada pusat penjualan mobil.

6. UCAPAN TERIMA KASIH

Penulis mengucapkan terimakasih kepada LPPM Universitas Bina Sarana Informatika dan LPPM Universitas Nusa Mandiri yang telah memberikan dukungan moril kepada penulis sehingga bisa menyelesaikan penelitian ini.

DAFTAR PUSTAKA:

- [1] M. Paredes, E. Hemberg, U. M. O'Reilly, and C. Zengras, "Machine learning or discrete choice models for car ownership demand estimation and prediction?," *5th IEEE Int. Conf. Model. Technol. Intell. Transp. Syst. MT-ITS 2017 - Proc.*, pp. 780–785, 2017.
- [2] V. C. Sanap, M. M. Rangila, S. Rahi, S. Badgajar, and Y. Gupta, "Car Price



- Prediction using Linear Regression Technique of Machine Learning," *Int. J. Innov. Res. Sci. Eng. Technol.*, vol. 11, no. 4, pp. 3462–3465, 2022.
- [3] I. Romli, E. Pusnawati, and A. Siswandi, "Penentuan Tingkat Penjualan Mobil Di Indonesia," *Pros. Semin. Nas. Teknol. dan Sains*, vol. x, no. x, 2019.
- [4] I. F. Tarigan, D. Hartama, and I. S. Saragih, "Penerapan Data Mining Pada Prediksi Kelayakan Pemohon Kredit Mobil Dengan K-Medoids Clustering," *KLIK Kaji. Ilm. Inform. ...*, vol. 1, no. 4, pp. 170–179, 2021.
- [5] D. Safitri, H. K. Siradjudin, and Rosihan, "Sistem Pendukung Keputusan Pembelian Mobil Baru Dengan Menggunakan Metode Multi Attribute Utility Theory (Maut)," *J. Ilm. Ilk. - Ilmu Komput. Inform.*, vol. 4, no. 2, pp. 85–92, 2021.
- [6] M. Mahodim, Y. Fajriah, and ..., "Pengaruh Harga dan Citra Merek Terhadap Keputusan Pembelian Mobil Merek Expander," *J. Mirai ...*, vol. 5, no. 2, pp. 652–663, 2021.
- [7] N. Pal, P. Arora, P. Kohli, D. Sundararaman, and S. S. Palakurthy, "How Much is my car worth? A methodology for predicting used cars' prices using random forest," *Adv. Intell. Syst. Comput.*, vol. 886, pp. 413–422, 2019.
- [8] H. Yin, Y. Wang, Q. Li, W. Xu, Y. Yu, and T. Zhang, "A network-enhanced prediction method for automobile purchase classification using deep learning," *Proc. 22nd Pacific Asia Conf. Inf. Syst. - Oppor. Challenges Digit. Soc. Are We Ready?, PACIS 2018*, 2018.
- [9] A. N. Liyantoko, I. Candradewi, and A. Harjoko, "Klasifikasi Sel Darah Putih dan Sel Limfoblas Menggunakan Metode Multilayer Perceptron Backpropagation," *IJEIS (Indonesian J. Electron. Instrum. Syst.*, vol. 9, no. 2, p. 173, 2019.
- [10] A. Pujiyanto, K. Kusriani, and A. Sunyoto, "Perancangan Sistem Pendukung Keputusan Untuk Prediksi Penerima Beasiswa Menggunakan Metode Neural Network Backpropagation," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 5, no. 2, p. 157, 2018.
- [11] M. Asghar, K. Mehmood, S. Yasin, and Z. M. Khan, "Used Cars Price Prediction using Machine Learning with Optimal Features," *Pakistan J. Eng. Technol.*, vol. 4, no. 2, pp. 113–119, 2021.
- [12] H. M. Nawawi, S. Rahayu, J. J. Purnama, and S. I. Komputer, "Algoritma c4.5 untuk memprediksi pengambilan keputusan memilih deposito berjangka," *J. Techno Nuesa Mandiri*, vol. 16, no. 1, pp. 65–72, 2019.
- [13] Erlin Elisa, Y. Mardiansyah, and R. Fauzi, "Pola Pembelian Konsumen Terhadap Product UMKM Martista Ikhsan Dengan Algoritma Naive Bayes," *J. Manaj. Inform. Sist. Inf.*, vol. 5, no. 2, pp. 159–167, 2022.
- [14] M. Riyyan, H. Firdaus, J. H. Ronggo Waluyo, T. Timur, and J. Barat, "PERBANDINGAN ALGORITME NAÏVE BAYES DAN KNN TERHADAP DATA PENERIMAAN BEASISWA (Studi Kasus Lembaga Beasiswa Baznas Jabar)," *J. Inform. Rekayasa Elektron.*, vol. 5, no. 1, pp. 1–10, 2022.
- [15] A. Muzakir and R. A. Wulandari, "Model Data Mining sebagai Prediksi Penyakit Hipertensi Kehamilan dengan Teknik Decision Tree," *Sci. J. Informatics*, vol. 3, no. 1, pp. 19–26, 2016.
- [16] S. Selvin, R. Vinayakumar, E. A. Gopalakrishnan, V. K. Menon, and K. P. Soman, "Stock price prediction using LSTM, RNN and CNN-sliding window model," *2017 Int. Conf. Adv. Comput. Commun. Informatics, ICACCI 2017*, vol. 2017-Janua, pp. 1643–1647, 2017.
- [17] H. Harumy, M. Zarlis, M. S. Lydia, and S. Effendi, "Pengembangan model protis neural network untuk prediksi dan klasifikasi data timeseries dan image," *Pros. Semin. Nas. Ris. Dan Inf. Sci. (*, vol. 4, pp. 1–7, 2022.
- [18] T. Ding, T. Readshaw, S. Rigopoulos, and W. P. Jones, "Machine learning tabulation of thermochemistry in turbulent combustion: An approach based on hybrid flamelet/random data and multiple multilayer perceptrons," *Combust. Flame*, vol. 231, p. 111493, 2021.
- [19] R. Sharma, M. Kim, and A. Gupta, "Motor imagery classification in brain-machine interface with machine learning



- algorithms: Classical approach to multi-layer perceptron model," *Biomed. Signal Process. Control*, vol. 71, no. PA, p. 103101, 2022.
- [20] D. Visa Sofia, "Confusion Matrix-based Feature Selection Sofia Visa," *Proc. Twenty-second Midwest Artif. Intell. Cogn. Sci. Conf.*, vol. 710, no. January, p. 8, 2018.
- [21] C. Wungkana, M. Aror, G. Arther Sandag, J. Arnold Mononutu, A. Bawah, and K. Airmadidi, "Model Prediksi Penderita HCC Menggunakan Algoritma Random Forest," *J. Sist. Inf.*, vol. 10, no. 1, pp. 1–6, 2022.
- [22] G. SANTELLO, *Cars - Purchase Decision Dataset*, vol. Kaggle Rep.