

DISERTASI

PEMODELAN PREDIKSI KINERJA SISWA DENGAN HYBRID PARTICLE SWARM OPTIMIZATION-SUPPORT VECTOR REGRESSION (PSO-SVR) DAN GENETIC ALGORITHM-SUPPORT VECTOR REGRESSION (GA-SVR)

**Diajukan untuk memenuhi salah satu syarat memperoleh gelar
Doktor Ilmu Teknik pada Fakultas Teknik Universitas Sriwijaya**



M. RIKI APRIYADI

03043681823001

**PROGRAM STUDI DOKTOR ILMU TEKNIK
FAKULTAS TEKNIK
UNIVERSITAS SRIWIJAYA
2023**

HALAMAN PENGESAHAN

PEMODELAN PREDIKSI KINERJA SISWA DENGAN HYBRID PARTICLE SWARM OPTIMIZATION-SUPPORT VECTOR REGRESSION (PSO-SVR) DAN GENETIC ALGORITHM-SUPPORT VECTOR REGRESSION (GA-SVR)

DISERTASI

Diajukan untuk memenuhi salah satu syarat memperoleh gelar
Doktor Ilmu Teknik pada Fakultas Teknik Universitas Sriwijaya

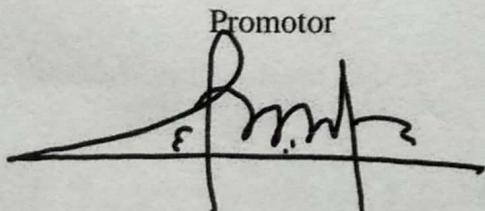
Oleh:

M. RIKI APRIYADI

03043681823001

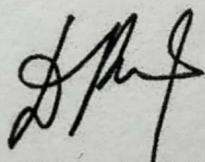
Indralaya, 2023

Promotor



Dr. Ermatita, M.Kom
NIP. 196709132006042001

Co Promotor



Dian Palupi Rini, Ph.D
NIP. 197802232006042002

Mengetahui,

Dekan Fakultas Teknik



Prof. Dr. Eng. Ir. Joni Arliansyah, MT
NIP. 196706151995121002

LEMBAR PERSETUJUAN

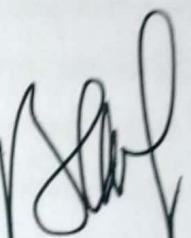
Karya Tulis Ilmiah berupa Laporan Akhir Disertasi ini dengan Judul "Pemodelan Prediksi Kinerja Siswa dengan Hybrid Particle Swarm Optimization-Support Vector Regression (PSO-SVR) dan Genetic Algorithm-Support Vector Regression (GA-SVR)" telah dipertahankan dihadapan Tim Penguji Karya Tulis Ilmiah Fakultas Teknik Universitas Sriwijaya pada tanggal 10 April 2023.

Inderalaya, 10 April 2023

Tim Penguji Karya Tulis Ilmiah berupa Disertasi.

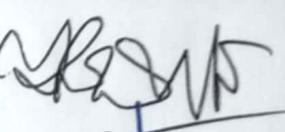
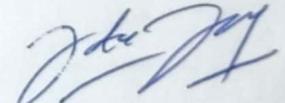
Ketua :

Dr. Bhakti Yudho S, S.T., M.T.
NIP. 197502112003121002

()

Anggota :

1. Dr. Yusuf Hartono, M.Sc.
NIP. 196411161990031002
2. Dr. Abdiansah, S.Kom., M.Cs.
NIP. 198410012009121005
3. Dr. Ade Silvia Handayani, S.T., M.T.
NIP. 197609302000032002

()
()
()

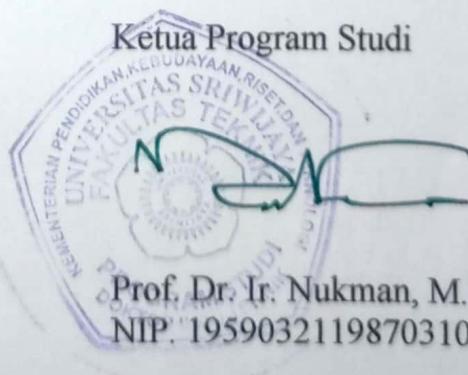
Mengetahui

Dekan Fakultas Teknik



Prof. Dr. Eng. Ir. H. Joni Arliansyah, M.T.
NIP. 196706151995121002

Ketua Program Studi



Prof. Dr. Ir. Nukman, M.T.
NIP. 195903211987031001

HALAMAN PERNYATAAN INTEGRITAS

Yang bertanda tangan di bawah ini:

Nama : M. Riki Apriyadi

NIM : 03043681823001

Judul : Pemodelan Prediksi Kinerja Siswa dengan Hybrid Particle Swarm Optimization-Support Vector Regression (PSO-SVR) dan Genetic Algorithm-Support Vector Regression (GA-SVR)

Menyatakan bahwa Laporan Akhir Disertasi saya merupakan hasil karya sendiri didampingi Promotor dan Co-Promotor dan bukan hasil penjiplakan/plagiat. Apabila ditemukan unsur penjiplakan/plagiat dalam Disertasi ini, maka saya bersedia menerima sanksi akademik dari Universitas Sriwijaya sesuai aturan yang berlaku.

Demikian, pernyataan ini saya buat dalam keadaan sadar dan tanpa ada paksaan dari siapapun.

Palembang, 14 April 2023



M. Riki Apriyadi

KATA PENGANTAR

Alhamdulillahirobbil’alamin, Puji syukur penulis panjatkan kehadirat Allah SWT, karena atas rahmat hidayah-Nya lah penulis dapat menyelesaikan disertasi yang berjudul “Pemodelan Prediksi Kinerja Siswa dengan Hybrid Particle Swarm Optimization-Support Vector Regression Genetic Algorithm (PSO-SVR) dan Genetic Algorithm-Support Vector Regression (GA-SVR)”. Shalawat dan salam semoga selalu tercurahkan kepada Rasulullah Nabi Muhammad SAW yang telah membawa cahaya Islam di alam semesta.

Penyusunan Disertasi ini merupakan salah satu syarat dalam rangka menyelesaikan pendidikan pada Program Studi Doktor Ilmu Teknik pada Fakultas Teknik Universitas Sriwijaya. Dalam penulisan disertasi ini, banyak pihak yang telah membantu dan berkontribusi, sehingga penulis ingin menyampaikan terima kasih kepada:

1. Kedua orang tua: (alm) papa Malian Sadeli, mama Lukiah Herlina; Saudara-saudara Kandung: Yuk cak, Yuk ci, Dek Mayang; Mertua: Bapak Sunarto, Ibu Sumarni; serta Istri Reny Anggraini dan Anak-anakku tersayang: Zahra dan Aisyah, yang selalu memberikan doa dan dukungan kepada penulis.
2. Prof. Dr. Ir. H. Anis Saggaff, MSCE, IPU., ASEAN. Eng selaku Rektor Universitas Sriwijaya.
3. Prof. Dr. Eng. Ir. H. Joni Arliansyah, M.T., selaku Dekan Fakultas Teknik Universitas Sriwijaya.
4. Prof. Dr. Ir. Nukman, M.T., selaku Koordinator Program Studi Ilmu Teknik Program Doktor, Fakultas Teknik, Universitas Sriwijaya.
5. Dr. Ermatita, M.Kom., selaku Promotor yang telah memberikan arahan dan bimbingan selama penyusunan disertasi ini.
6. Dian Palupi Rini, Ph.D., selaku Co-Promotor yang telah memberikan arahan dan bimbingan selama penyusunan disertasi ini.
7. (alm) Dr. Reza Firsandaya Malik, S.T., M.T selaku yang semasa hidupnya telah memberikan masukan, arahan, dan bimbingan.

Penulis menyadari dalam penyusunan disertasi ini masih terdapat kekurangan dan kekeliruan. Oleh karena itu, kritik dan saran yang bersifat membangun sangat diharapkan demi perbaikan dan perkembangan ilmu pengetahuan di masa mendatang. Semoga Disertasi ini dapat bermanfaat bagi para pembaca, peneliti, pemerhati ilmu pengetahuan, serta bagi dunia pendidikan secara luas. Akhir kata penulis mengucapkan terima kasih.

Palembang, April 2023

Penulis

RINGKASAN

PEMODELAN PREDIKSI KINERJA SISWA DENGAN HYBRID PARTICLE SWARM OPTIMIZATION-SUPPORT VECTOR REGRESSION (PSO-SVR) DAN GENETIC ALGORITHM-SUPPORT VECTOR REGRESSION (GA-SVR)

Karya Tulis Ilmiah Berupa Disertasi, 10 April 2023

M. Riki Apriyadi; dibimbing oleh Dr. Ermatita, M.Kom. dan Dian Palupi Rini, Ph.D.
Program Studi Doktor Ilmu Teknik, Fakultas Teknik, Universitas Sriwijaya.

Pemodelan Prediksi Kinerja Siswa dengan Hybrid Particle Swarm Optimization-Support Vector Regression (PSO-SVR) dan Genetic Algorithm-Support Vector Regression (GA-SVR)

xiv + 107 halaman, 14 gambar, 24 tabel, 2 lampiran

Peningkatan kualitas pendidikan sangat berpengaruh penting dalam perkembangan suatu Negara. Mengidentifikasi data pendidikan yang representatif dan melakukan analisis prediksi kinerja siswa di suatu lembaga pendidikan sangat penting untuk membantu manajemen dalam menentukan strategi dan pengambilan keputusan dalam peningkatan kinerja siswa. Penelitian ini melakukan pemodelan terhadap kinerja siswa menggunakan Hybrid Particle Swarm Optimization-Support Vector Regression (PSO-SVR) dan Genetic Algorithm-Support Vector Regression (GA-SVR). Penelitian ini menggunakan pemodelan prediksi kinerja siswa dengan pemodelan SVR. PSO dan GA digunakan sebagai seleksi fitur untuk mengidentifikasi faktor relevan yang mempengaruhi kinerja siswa. Hasil dari seleksi fitur yang merupakan fitur terpilih kemudian dilakukan prediksi dengan SVR sehingga menghasilkan pemodelan FSPSO-SVR dan FSGA-SVR. Penelitian ini juga melakukan optimasi hyperparameter pada SVR untuk mendapatkan hyperparameter terbaik menggunakan PSO dan GA, sehingga menghasilkan pemodelan PSO-SVR (PSVR) dan GA-SVR (GSVR). Pada tahap akhir dilakukan perbandingan hasil metrik kinerja regresi yang dihasilkan dari penelitian ini maupun dari penelitian sebelumnya. Dari hasil penelitian ini, pemodelan SVR menghasilkan nilai RMSE sebesar 4.519, pemodelan FSPSO-SVR menghasilkan nilai RMSE sebesar 2.954, pemodelan FSGA-SVR menghasilkan nilai RMSE sebesar 4.447, pemodelan PSVR menghasilkan nilai RMSE sebesar 1.608, pemodelan GSVR menghasilkan nilai RMSE sebesar 1.830. Sedangkan dari penelitian sebelumnya yang dilakukan Cortez pada pemodelan SVR menghasilkan nilai RMSE sebesar 2.090. Dari perbandingan metrik kinerja regresi didapat pemodelan prediksi kinerja siswa terbaik menggunakan pemodelan PSVR dengan penurunan nilai error sebesar 64.42% dibandingkan pemodelan SVR pada penelitian ini dan penurunan nilai error sebesar 23.06% dibandingkan dengan penelitian sebelumnya.

Kata Kunci: Kinerja Siswa, Prediksi, Seleksi Fitur, Hyperparamater, Particle Swarm Optimization (PSO), Genetic Algorithm (GA), Support Vector Regression (SVR).

Situsi: 1-98 (2008-2023)

SUMMARY

STUDENT PERFORMANCE PREDICTION MODELING WITH HYBRID PARTICLE SWARM OPTIMIZATION-SUPPORT VECTOR REGRESSION (PSO-SVR) AND GENETIC ALGORITHM-SUPPORT VECTOR REGRESSION (GA-SVR)

Scientific Paper in the Form of Dissertation, 10 April 2023

M. Riki Apriyadi; supervised by Dr. Ermatita, M.Kom. and Dian Palupi Rini, Ph.D.
Doctor of Engineering Study Program, Faculty of Engineering, Sriwijaya University.

Student Performance Prediction Modeling with Hybrid Particle Swarm Optimization-Support Vector Regression (PSO-SVR) and Genetic Algorithm-Support Vector Regression (GA-SVR)

x + 107 pages, 14 pictures, 24 tables, 2 Attachment

Improving the quality of education is very important in the development of a country. Identifying representative educational data and conducting predictive analysis of student performance in an educational institution is very important to assist management in determining strategies and making decisions to improve student performance. This study modeled student performance using Hybrid Particle Swarm Optimization-Support Vector Regression (PSO-SVR) and Genetic Algorithm-Support Vector Regression (GA-SVR). This study uses predictive modeling of student performance with SVR modeling. PSO and GA are used as feature selections to identify relevant factors that influence student performance. The feature selection results, which are selected features, are then predicted with SVR to produce FSPSO-SVR and FSGA-SVR modeling. This study also performs hyperparameter optimization on SVR to obtain the best hyperparameters using PSO and GA, resulting in PSO-SVR (PSVR) and GA-SVR (GSVR) modeling. In the final stage, a comparison of the results of regression performance metrics was carried out from this study and previous studies. From the results of this study, the SVR modeling produced an RMSE value of 4.519; the FSPSO-SVR modeling produced an RMSE value of 2.954; the FSGA-SVR modeling produced an RMSE value of 4.447; the PSVR modeling resulted in an RMSE value of 1.608; the GSVR modeling had an RMSE value of 1.830. Meanwhile, from previous research conducted by Cortez on SVR modeling, the RMSE value was 2.090. The comparison of regression performance metrics found that the best student performance prediction modeling used PSVR modeling with a decrease in error values of 64.42% compared to SVR modeling in this study and a decrease in error values of 23.06% compared to previous studies.

Keywords: Student Performance, Prediction, Feature Selection, Hyperparameter, Particle Swarm Optimization (PSO), Genetic Algorithm (GA), Support Vector Regression (SVR).

Citations: 1-98 (2008-2023)

DAFTAR ISI

Halaman Pengesahan	ii
Lembar Persetujuan.....	iii
Halaman Pernyataan Integritas.....	iv
Kata Pengantar	v
Ringkasan	vii
Summary.....	viii
Daftar Isi	ix
Daftar Gambar	xii
Daftar Tabel	xiii
Daftar Lampiran.....	xiv
 BAB I. PENDAHULUAN.....	 1
1.1. Latar Belakang.....	1
1.2. Rumusan Masalah.....	6
1.3. Tujuan.....	6
1.4. Manfaat.....	6
1.5. Novelty.....	7
1.6. Batasan Masalah.....	7
1.7. Sistematika Penulisan.....	8
 BAB II. TINJAUAN PUSTAKA.....	 9
2.1. Kinerja Siswa	9
2.2. Prediksi Kinerja Siswa.....	9
2.3. Implementasi Algoritma Machine Learning untuk Prediksi Kinerja Siswa.....	11
2.4. Seleksi Fitur	24
2.5. <i>Support Vector Regression (SVR)</i>	24
2.7. <i>Particle Swarm Optimization (PSO)</i>	27
2.8. <i>Genetic Algorithm (GA)</i>	28
2.9. <i>K-Fold Cross-Validation</i>	29
2.10. Metrik Kinerja Regresi	30
2.11. Penelitian Terkait.....	31

2.12. State of The Art	38
BAB III. METODOLOGI PENELITIAN.....	40
3.1. Kerangka Kerja Penelitian.....	40
3.2. Studi Literatur	41
3.3. Pengumpulan <i>Dataset</i>	41
3.4. <i>Preprocessing Dataset</i>	44
3.5. Kerangka Kerja Seleksi Fitur.....	45
3.5.1. Kerangka Kerja Seleksi Fitur FSPSO.....	45
3.5.2. Kerangka Kerja Seleksi Fitur FSGA	46
3.6. Pemodelan Prediksi Kinerja Siswa.....	48
3.6.1. Pemodelan Prediksi Kinerja Siswa dengan Model SVR	48
3.6.2. Pemodelan Prediksi Kinerja Siswa dengan Model FSPSO-SVR..	50
3.6.3. Pemodelan Prediksi Kinerja Siswa dengan Model FSGA-SVR...	51
3.6.4. Pemodelan Prediksi Kinerja Siswa dengan Pemodelan PSVR	52
3.6.5. Pemodelan Prediksi Kinerja Siswa dengan Pemodelan GSVR	53
3.7. Perangkat yang digunakan.....	55
3.8. Rencana Pengujian	56
3.8.1. Rencana pengujian seleksi fitur pada kerangka kerja FSPSO	56
3.8.2. Rencana pengujian seleksi fitur pada kerangka kerja FSGA	57
3.8.3. Rencana pengujian pemodelan SVR	58
3.8.4. Rencana pengujian pemodelan FSPSO-SVR	58
3.8.5. Rencana pengujian pemodelan FSGA-SVR.....	59
3.8.6. Rencana pengujian prediksi kinerja siswa pemodelan PSVR.....	60
3.8.7. Rencana pengujian prediksi kinerja siswa pemodelan GSVR	61
3.9. Hasil Penelitian.....	62
BAB IV. HASIL PENELITIAN.....	63
4.1. Hasil <i>preprocessing Dataset</i>	63
4.2. Hasil fitur terpilih pada kerangka kerja seleksi fitur	65
4.2.1. Hasil fitur terpilih pada kerangka kerja seleksi fitur FSPSO	65
4.2.2. Hasil fitur terpilih pada kerangka kerja seleksi fitur FSGA.....	66
4.3. Hasil pengujian pemodelan prediksi kinerja siswa dengan SVR	69
4.4. Hasil pengujian pemodelan prediksi kinerja siswa dengan FSPSO-SVR	70
4.5. Hasil pengujian pemodelan prediksi kinerja siswa dengan FSGA-SVR.	71

4.6. Hasil pengujian pemodelan prediksi kinerja siswa dengan PSVR	72
4.7. Hasil pengujian pemodelan prediksi kinerja siswa dengan GSVR	73
4.8. Perbandingan hasil terbaik dari pengujian pada pemodelan prediksi siswa dengan pemodelan SVR, FSPSO-SVR, FSGA-SVR, PSVR, dan GSVR.....	75
BAB V. KESIMPULAN DAN SARAN	78
5.1. Kesimpulan	78
5.2. Saran.....	79
DAFTAR ISTILAH.....	81
DAFTAR PUSTAKA.....	83

DAFTAR GAMBAR

Gambar 2.1 Penggambaran ε pada SVR <i>linear</i>	25
Gambar 2.2 Siklus <i>Genetic Algorithm</i> (GA)	29
Gambar 2.3 10-Fold Cross-validation	30
Gambar 3.1 Kerangka Kerja Penelitian	40
Gambar 3.2 <i>Preprocessing Dataset</i> dengan Metode <i>Label Encoding</i>	45
Gambar 3.3 Kerangka Kerja Seleksi fitur FSPSO	46
Gambar 3.4 Kerangka Kerja Seleksi fitur FSGA	48
Gambar 3.5 Pemodelan prediksi kinerja siswa model SVR	49
Gambar 3.6 Pemodelan prediksi kinerja siswa dengan pemodelan FSPSO-SVR	50
Gambar 3.7 Pemodelan prediksi kinerja siswa dengan pemodelan FSGA-SVR	51
Gambar 3.8 Pemodelan prediksi kinerja siswa dengan pemodelan PSVR	52
Gambar 3.9 Pemodelan prediksi kinerja siswa dengan pemodelan GSVR	54
Gambar 4.1 Perbandingan hasil terbaik pemodelan prediksi kinerja siswa	76
Gambar 4.2 Perbandingan hasil terbaik pemodelan prediksi kinerja siswa dengan Penelitian sebelumnya	77

DAFTAR TABEL

Tabel 2.1 Penelitian terkait <i>Dataset</i> Prediksi Kinerja Siswa dengan Pemodelan <i>Machine Learning</i>	16
Tabel 2.2 Literatur Penelitian terkait dan <i>Research Gap</i>	32
Tabel 2.3 <i>State of the art</i> Penelitian	39
Tabel 3.1 Deskripsi Fitur <i>Dataset</i> Kinerja Siswa	42
Tabel 3.2 Perangkat Keras yang digunakan.....	55
Tabel 3.3 Perangkat Lunak yang digunakan.....	56
Tabel 3.4 Rancangan pengujian pada kerangka kerja seleksi fitur FSPSO.....	56
Tabel 3.5 Rancangan pengujian pada kerangka kerja seleksi fitur FSGA	57
Tabel 3.6 <i>Setting default hyper-parameter</i> SVR dari <i>library sklearn</i>	58
Tabel 3.7 Rancangan pengujian pemodelan prediksi kinerja siswa SVR	58
Tabel 3.8 Rancangan pengujian pemodelan prediksi kinerja siswa FSPSO-SVR	59
Tabel 3.9 Rancangan pengujian pemodelan prediksi kinerja siswa FSGA-SVR	59
Tabel 3.10 <i>Setting</i> batas bawah dan atas <i>hyper-parameter</i> SVR	60
Tabel 3.11 Rancangan pengujian pemodelan prediksi kinerja siswa PSVR	60
Tabel 3.12 Rancangan pengujian pemodelan prediksi kinerja siswa GSVR	61
Tabel 4.1 Transformasi atribut data kategorik menjadi data numerik	64
Tabel 4.2 Hasil Seleksi Fitur pada Kerangka Kerja Seleksi Fitur FSPSO	65
Tabel 4.3 Hasil Seleksi Fitur pada Kerangka Kerja Seleksi Fitur FSGA.....	64
Tabel 4.4 Hasil pengujian pemodelan prediksi kinerja siswa dengan SVR	70
Tabel 4.5 Hasil pengujian pemodelan prediksi kinerja siswa FSPSO-SVR	70
Tabel 4.6 Hasil pengujian pemodelan prediksi kinerja siswa FSGA-SVR	71
Tabel 4.7 Hasil pengujian pemodelan prediksi kinerja siswa PSVR	73
Tabel 4.8 Hasil pengujian pemodelan prediksi kinerja siswa GSVR	74
Tabel 4.9 Perbandingan hasil terbaik dari Pemodelan SVR, FSPSO-SVR, FSGA-SVR, PSVR, GSVR dan Penelitian sebelumnya	75

DAFTAR LAMPIRAN

Lampiran 1. <i>Paper</i> Seminar Karya Ilmiah Internasional	95
Lampiran 2. <i>Paper</i> Publikasi Internasional	101

BAB I

PENDAHULUAN

1.1. Latar Belakang

Kemajuan dalam bidang pendidikan merupakan tolak ukur dari kemajuan dari suatu negara. Terbukti semakin tinggi tingkat pendidikan suatu negara maka akan maju juga negera itu. Sehingga banyak negara yang berupaya untuk meningkatkan kualitas pendidikan di negaranya. Indonesia merupakan salah satu negara yang sangat peduli akan peningkatan kualitas pendidikan akan warga negaranya. Hal ini sebagaimana tercantum dalam pasal 31 ayat 1 UUD 1945 yang menyatakan bahwa “Setiap warga Negara berhak mendapat pendidikan” [1]. Akan tetapi sebagai negara berkembang, Indonesia juga mengalami permasalahan yang cukup serius dalam meningkatkan kualitas pendidikan. Salah satu upaya untuk meningkatkan kualitas pendidikan adalah dengan mengevaluasi kinerja siswa di sekolah. Kinerja siswa. Kinerja siswa merupakan salah satu indikator penting dalam menentukan tingkat keberhasilan siswa dan efektivitas dari program pembelajaran yang dijalankan oleh lembaga pendidikan [2]. Sehingga hasil dari evaluasi terhadap kinerja siswa dapat mengatasi permasalahan yang dihadapi siswa untuk meningkatkan prestasi belajarnya [3].

Perkembangan ilmu pengetahuan dan teknologi khususnya di bidang *Machine Learning* yang sangat pesat tentunya dapat dijadikan solusi bagi pengambil keputusan untuk mengatasi permasalahan diberbagai bidang seperti ekonomi, keuangan medis, teknik, dan pendidikan. Implementasi algoritma *Machine Learning* di didang pendidikan diharapkan dapat membantu pendidik dalam pengambilan keputusan yang tepat untuk meningkatkan prestasi belajar siswa [4][5]. Mengash *et al*, 2020 [6] menggunakan algoritma *Machine Learning* untuk memprediksi siswa yang berprestasi secara akademis, sedangkan Riestra *et al*, 2021 [7] dan Tomasevic *et al*, 2019 [8] menerapkan algoritma *Machine Learning* untuk mendeteksi siswa yang memiliki resiko kegagalan dalam akademis, sehingga pendidik dapat memberikan dukungan lebih awal terhadap siswa yang teridentifikasi memiliki resiko gagal [4].

Di lembaga pendidikan, seorang pendidik hendaknya dapat memahami siswa dalam hal meningkatkan prestasi akademik siswa, dengan memperhatikan faktor-faktor yang dapat mempengaruhi hasil belajar siswa berupa faktor eksternal maupun internal siswa [9][10][11]. Faktor eksternal meliputi lingkungan tempat tinggal, dukungan keluarga, sedangkan faktor internal yang mempengaruhi adalah minat, bakat, motivasi belajar [12]. Waheed *et al*, 2019 [13] menunjukkan bahwa penggunaan Algoritma *Machine Learning* dapat mengenali perilaku belajar siswa, mengatasi permasalahan akademik, optimalisasi lingkungan pendidikan, serta dapat menjadi pengambilan keputusan berdasarkan data di lembaga pendidikan. Rodriguez *et al*, 2021 [14] menerapkan Algoritma *Machine Learning* untuk mengidentifikasi faktor-faktor utama yang mempengaruhi serta keterkaitan faktor-faktor tersebut dalam pencapaian keberhasilan akademik siswa. Pada penelitian yang dilakukan oleh Cortez *et al*, 2008 [15] menggunakan pengambilan data dengan dua metode, yaitu dengan metode review laporan sekolah dan metode kuesioner. Adapun variabel yang digunakan merupakan faktor-faktor eksternal maupun internal siswa. Variabel-variabel tersebut terkait dengan beberapa variabel demografis (Misalnya pendidikan orang tua, pendapatan keluarga), sosial dan emosional (misalnya konsumsi alkohol) dan sekolah (misalnya jumlah kegagalan kelas sebelumnya). Sedangkan Zhao *et al*, 2017 [16] memprediksi hasil belajar siswa dengan menggunakan faktor kebiasaan keseharian siswa yaitu kepribadian, perilaku, gaya belajar, pola tidur, olahraga dan lain-lain.

Mengidentifikasi fitur yang relevan dalam teknik *Machine Learning* diharapkan mampu meningkatkan akurasi baik pada model klasifikasi maupun prediksi [17]. Adapun identifikasi data yang representatif dapat dilakukan dengan cara pemilihan fitur (*Feature selection*) [18]. *Feature selection* merupakan teknik pemilihan fitur dengan memilih fitur-fitur yang relevan dan menghilangkan fitur-fitur yang tidak relevan dalam *Dataset* sehingga dapat meningkatkan akurasi dari pemodelan *Machine Learning* [19] [20] [21][22]. Rao *et al*, 2019 [21] menerapkan *feature selection* untuk meningkatkan akurasi dari metode *Machine Learning* yang digunakannya, yaitu dengan menggunakan pendekatan algoritma metaheuristik, yang merupakan algoritma yang digunakan untuk melakukan tugas optimasi untuk menghasilkan solusi yang optimal. Pendekatan algoritma metaheuristik dalam

feature selection yang sering digunakan untuk menghasilkan subset fitur yang optimal diantaranya adalah *Genetic Algorithm* (GA) [23], *Ant Colony Optimization* (ACO) [24], dan *Particle Swarm Optimization* (PSO) [25][26]. Implementasi PSO dan GA pada Algoritma *Machine Learning* sebagai metode *feature selection* dalam memprediksi performa akademik siswa dan ketepatan kelulusan mahasiswa menghasilkan peningkatan akurasi dibandingkan tanpa menggunakan *feature selection* [23][27][28][29]. Iqbal *et al*, 2020 [30] melakukan eksperimen dengan beberapa algoritma *Machine Learning* berbasis PSO sebagai *feature selection* untuk meningkatkan akurasi prediksi kinerja siswa. Pada penelitian lain, Farissi *et al*, [23] menggunakan GA sebagai *feature selection* pada algoritma *Decision Tree*, KNN, *Naïve Bayes* dan *Random Forest* untuk meningkatkan hasil akurasi prediksi kinerja akademik siswa.

Cortez *et al*, 2008 [15] memprediksi kinerja siswa di sekolah menengah di Portugal pada mata pelajaran Bahasa dan Matematika. Pada penelitian tersebut dilakukan komparasi akurasi prediksi klasifikasi dan regresi pada tiga pola eksperimen dengan menggunakan algoritma *Neural Network*, *Decision Tree*, *Naïve Bayes*, dan *Support Vector Machine (SVM)*. Dengan menggunakan *Dataset* yang sama dengan [15], Sari *et al*, 2017 [31], dalam penelitiannya melakukan prediksi performa akademik siswa pada pelajaran matematika menggunakan algoritma *Random Forest*, MLP, SVM, dan *Naïve Bayes* dengan menambahkan teknik seleksi fitur menggunakan Bayesian Network. Mengash *et al*, 2020 [6] melakukan prediksi prestasi belajar siswa dalam bentuk klasifikasi nilai akhir keseluruhan (*CGPA*) dengan kriteria *Excellent* (≥ 4.5), *Very Good* (3.75 to < 4.5), *Good* (2.75 to < 3.75), *Average* (2.0 to < 2.75), dan *Poor* (< 2.0). Algoritma yang digunakan adalah *ANN*, *Decision Tree*, *SVM* dan *Naïve Bayes*. Tomasevic *et al*, 2019 [8] menggunakan data prestasi masa lampau siswa untuk memprediksi nilai ujian di masa depan dalam bentuk klasifikasi (*pass/fail*) dan regresi (rentang nilai 0-100) dengan menggunakan algoritma KNN, SVM, ANN, DT, *Naïve Bayes*, dan *Logistic Regression*.

Support Vector Machine (SVM) merupakan salah satu algoritma *Machine Learning* yang sering digunakan oleh peneliti untuk memprediksi kinerja siswa [15][6][8]. Dalam penelitian yang dilakukan Charleonnan *et al*, 2016 [32], SVM memiliki akurasi yang lebih baik dibandingkan dengan algoritma KNN, *Decision*

Tree, dan *Linear Regression*. Oloruntoba *et al*, 2017 [33], membandingkan SVM dengan algoritma *Machine Learning* lainnya seperti KNN, *Decision Tree*, dan *Linear Regression* yang menghasilkan performa akurasi training sebesar 94% dan *testing* sebesar 97%, mengungguli keempat algoritma tersebut setelah melakukan pengaturan parameter pada kernel RBF dengan C=100. Sedangkan Burman *et al*, 2019 [34] membandingkan bahwa pada Algoritma SVM, kernel RBF menghasilkan akurasi yang lebih baik dibandingkan dengan kernel *Linear* dalam memprediksi kinerja siswa. SVM memiliki kemampuan untuk mengatasi permasalahan klasifikasi maupun regresi secara *linear* dan *nonlinear* [35]. Adapun bentuk pengembangan SVM untuk menangani kasus regresi dikenal dengan *Support Vector Regression* (SVR) [36]. SVR memiliki kemampuan untuk melakukan generalisasi yang baik, dapat diterapkan pada data non-*linear* dimensi tinggi , dan memiliki kompleksitas komputasi yang rendah [9]. SVR juga mampu mengatasi *overfitting* dan dapat melakukan prediksi dengan data yang tidak terlalu besar [35]. Dari kelebihan tersebut maka SVR dapat diterapkan untuk memprediksi kinerja siswa [9]. Selain itu SVR juga memiliki kelemahan yaitu pada data yang berskala besar akan membuat proses komputasi yang besar dan kesulitan dalam menentukan nilai parameter yang optimal[9][37][38].

Beberapa penelitian telah mengusulkan penggunaan pendekatan metaheuristik dalam penentuan nilai parameter yang optimal untuk Algoritma *Machine Learning*, diantaranya *Particle Swarm Optimization* (PSO) [9][39], *Artificial Bee Colony* (ABC) [40], dan *Genetic Algorithm* (GA) [9][41]. Penelitian eksperimen Harafani *et al*, 2015 [35] melakukan optimasi nilai parameter dengan algoritma genetika pada SVM pada kernel RBF, kemudian dibandingkan model regresi lainnya antara lain *Linear Regression*, k-NN, dan *Neural Network*. Hasil yang didapat SVM(RBF)-GA mendapatkan nilai RMSE terkecil yaitu sebesar 1.418, model *Linear Regression* sebesar 1.459, model k-NN sebesar 1.526, dan terakhir model *Neural Network* dengan nilai RMSE sebesar 1.559. Peningkatan akurasi dari optimasi dengan algoritma genetika pada SVM dilakukan dengan optimasi parameter C, γ , dan ϵ . Pada kernel dot didapat akurasi sebesar 85.59%, kernel radial sebesar 98.89%, dan kernel polynomial sebesar 98.67% [42]. Luo *et al*, [43] mengusulkan optimasi parameter SVR dengan Algoritma genetika,

membandingkan dengan model SVR dan *Linear Regression*. Berdasarkan hasil yang didapat, model GA-SVR menghasilkan nilai RMSE sebesar 0.017 dan R^2 sebesar 0.980, lebih baik daripada kedua model yang lain yaitu SVR dengan RMSE sebesar 0.035, R^2 sebesar 0.912, dan *Linear Regression* dengan RMSE sebesar 0.07, R^2 sebesar 0.625. Wicaksono *et al*, 2018 [41] mengimplementasikan algoritma PSO pada beberapa algoritma *Machine Learning* untuk mengoptimasi parameter. Hasil yang diperoleh yaitu waktu komputasi yang lebih cepat dibandingkan menggunakan metode pencarian grid yang mencoba semua kemungkinan kombinasi parameter. Pengurangan waktu yang dihasilkan pada percobaan menggunakan algoritma *Machine Learning* yaitu, SVM sebesar 425.06%, *Random Forest* sebesar 17%, Adaptive Boosting sebesar 651.06% dan KNN sebesar 396.72%. Dalam penerapan permasalahan optimasi, GA dapat mengatasi permasalahan *nonlinear* dengan diskontinuitas dan minimum lokal secara efisien, serta GA juga lebih efisien dalam mengoptimasi lebih dari sepuluh parameter dibandingkan PSO yang cenderung sulit untuk mendapatkan nilai optimum jika mengoptimasi lebih dari sepuluh parameter [44].

Berdasarkan uraian diatas, maka peneliti melakukan penerapan seleksi fitur untuk mengetahui faktor-faktor yang berpengaruh terhadap kinerja siswa dengan menggunakan kerangka kerja seleksi fitur dengan PSO, *Feature Selection Particle Swarm Optimization* (FSPSO) dan seleksi fitur dengan GA, *Feature Selection Genetic Algorithm* (FSGA). Hasil dari seleksi fitur yang merupakan fitur terpilih kemudian dilakukan prediksi dengan SVR sehingga menghasilkan pemodelan FSPSO-SVR dan FSGA-SVR. Penelitian ini juga melakukan optimasi nilai *hyperparameter* pada SVR untuk mendapatkan nilai *hyperparameter* terbaik menggunakan PSO dan GA, sehingga menghasilkan pemodelan *Particle Swarm Optimization-Support Vector Regression* (PSVR) dan pemodelan *Genetic Algorithm-Support Vector Regression* (GSVR). Kemudian tingkat akurasi metrik kinerja regresi dievaluasi dengan membandingkan pemodelan prediksi kinerja siswa yang telah dihasilkan.

1.2. Rumusan Masalah

Adapun perumusan masalah pada penelitian ini adalah:

1. Bagaimana menerapkan kerangka kerja seleksi fitur FSPSO dan FSGA pada prediksi kinerja siswa?
2. Bagaimana mengembangkan pemodelan prediksi kinerja siswa dengan fitur terpilih FSPSO (FSPSO-SVR) dan FSGA (FSGA-SVR)?
3. Bagaimana mengembangkan pemodelan prediksi kinerja siswa dengan optimasi nilai *hyperparameter* pada metode SVR dengan PSO (PSVR) dan GA (GSVR)?
4. Bagaimana meningkatkan metrik kinerja regresi pemodelan prediksi kinerja siswa?

1.3. Tujuan

Tujuan dari penelitian ini adalah:

1. Menerapkan kerangka kerja seleksi fitur FSPSO dan FSGA untuk mendapatkan fitur terbaik pada prediksi kinerja siswa.
2. Mengembangkan pemodelan prediksi kinerja siswa dengan fitur terpilih FSPSO (FSPSO-SVR) dan FSGA (FSGA-SVR) untuk meningkatkan akurasi pemodelan prediksi kinerja siswa.
3. Mengembangkan pemodelan prediksi kinerja siswa dengan optimasi nilai *hyperparameter* pada metode SVR dengan PSO (PSVR) dan GA (GSVR) untuk menghasilkan pemodelan prediksi kinerja siswa yang akurat.
4. Meningkatkan metrik kinerja regresi dengan tingkat *error* yang rendah untuk pemodelan prediksi kinerja siswa.

1.4. Manfaat

Manfaat dari penelitian ini adalah:

1. Kerangka kerja seleksi fitur yang dihasilkan dapat bermanfaat bagi lembaga pendidikan terutama pendidik untuk mengetahui faktor-faktor yang mempengaruhi prestasi belajar siswa.

2. Model prediksi kinerja siswa yang dihasilkan dapat dijadikan sebagai bahan evaluasi bagi lembaga pendidikan untuk meningkatkan prestasi belajar siswa dan mengantisipasi tingkat kegagalan siswa.
3. Menghasilkan model prediksi kinerja siswa dengan tingkat *error* rendah sehingga dapat lebih akurat dalam pengambilan keputusan dalam membantu meningkatkan prestasi belajar siswa.

1.5. Novelty

Penelitian ini menghasilkan novelty sebagai berikut:

1. Pengembangan kerangka kerja seleksi fitur kinerja siswa dengan metode *Particle Swarm Optimization* (FSPSO) dan *Genetic Algorithm* (FSGA).
2. Pengembangan pemodelan prediksi kinerja siswa pada metode SVR dengan seleksi fitur FSPSO (FSPSO-SVR) dan FSGA (FSGA-SVR).
3. Pengembangan pemodelan prediksi kinerja siswa pemodelan prediksi kinerja siswa dengan optimasi nilai *hyperparameter* pada metode SVR dengan PSO (PSVR) dan GA (GSVR).

1.6. Batasan Masalah

Adapun batasan masalah pada penelitian ini adalah:

1. Pemodelan prediksi kinerja siswa dengan regresi.
2. Fitur terpilih berasal dari kerangka kerja seleksi fitur FSPSO dan FSGA.
3. Pemodelan Prediksi Kinerja Siswa menggunakan SVR.
4. Algoritma yang digunakan untuk mengoptimasi nilai *hyperparameter* SVR yaitu *Particle Swarm Optimization* (PSO) dan *Genetic Algorithm* (GA).
5. Kinerja model prediksi diukur dengan *Root Mean Square Error* (RMSE).
6. *Dataset* yang digunakan bersumber dari UCI *Machine Learning Repository*: *Student Performance* (Kinerja Siswa) pada pelajaran matematika sekolah menengah.

1.7. Sistematika Penulisan Penelitian

Sistematika Penulisan penelitian ini terdiri dari tiga bab, yaitu:

Bab-1 Merupakan Pendahuluan dari penelitian ini, yang terdiri dari Latar belakang, Rumusan Masalah, Tujuan, Novelty, Batasan Masalah dan Sistematika Penulisan.

Bab-2 Terdiri dari teori yang mendasar tentang Prediksi Kinerja Siswa, Implementasi Algoritma *Machine learning* untuk prediksi kinerja siswa, Seleksi Fitur, *Support Vector Regression* (SVR), *Genetic Algorithm* (GA), *Particle Swarm Optimization* (PSO), K-Fold Cross-Validation, Metrik Kinerja Regresi, Penelitian terkait dan *State of the art*.

Bab-3 Berisi tentang langkah kerja penelitian yang dimulai dari Kerangka Kerja Penelitian, Studi Literatur, Pengumpulan *Dataset*, *Preprocessing Dataset*, Kerangka Kerja Seleksi Fitur, Pemodelan Prediksi Kinerja Siswa, Perangkat yang digunakan, Rencana pengujian, dan Hasil penelitian.

Bab-4 Terdiri dari hasil penelitian dari pemodelan prediksi kinerja siswa yang telah dihasilkan, yaitu pemodelan SVR, FSPSO-SVR, FSGA-SVR, PSVR, GSVR dan pemodelan hasil penelitian terdahulu.

Bab-5 Terdiri dari kesimpulan dan saran.

DAFTAR PUSTAKA

- [1] E. Sujatmoko, “Hak Warga Negara Dalam Memperoleh Pendidikan,” *J. Konstitusi*, vol. 7, no. 1, pp. 181–212, 2010.
- [2] P. S. Suhas and S. Pandya, “Factors Influencing Students ’Academic Performance in Mathematics,” *Educ. Quest- An Int. J. Educ. Appl. Soc. Sci.*, vol. 7, no. 3, p. 291, 2016, doi: 10.5958/2230-7311.2016.00050.7.
- [3] F. Keshtkar, J. Cowart, and A. Crutcher, “Predicting Risk of Failure in Online Learning Platforms Using Machine Learning Algorithms for Modeling Students’ Academic Performance,” *33rd Int. Conf. Mach. Learn.*, vol. 48, 2018.
- [4] S. Helal *et al.*, “Predicting academic performance by considering student heterogeneity,” *Knowledge-Based Syst.*, vol. 161, pp. 134–146, 2018, doi: 10.1016/j.knosys.2018.07.042.
- [5] S. Qu, K. Li, S. Zhang, and Y. Wang, “Predicting Achievement of Students in Smart Campus,” *IEEE Access*, vol. 6, no. c, pp. 60264–60273, 2018, doi: 10.1109/ACCESS.2018.2875742.
- [6] H. A. Mengash, “Using data mining techniques to predict student performance to support decision making in university admission systems,” *IEEE Access*, vol. 8, pp. 55462–55470, 2020, doi: 10.1109/ACCESS.2020.2981905.
- [7] M. Riestra-González, M. del P. Paule-Ruiz, and F. Ortín, “Massive LMS log data analysis for the early prediction of course-agnostic student performance,” *Comput. Educ.*, vol. 163, no. 2021, pp. 104108–104128, 2021, doi: 10.1016/j.compedu.2020.104108.
- [8] N. Tomasevic, N. Gvozdenovic, and S. Vranes, “An overview and comparison of supervised data mining techniques for student exam performance prediction,” *Comput. Educ.*, vol. 143, p. 103676, 2019, doi: 10.1016/j.compedu.2019.103676.
- [9] H. Xu, “Prediction of Students’ Performance Based on the Hybrid IDA-SVR

- Model,” *Complexity*, vol. 2022, 2022, doi: 10.1155/2022/1845571.
- [10] F. Ofori, E. Maina, and R. Gitonga, “Using Machine Learning Algorithms to Predict Students’ Performance and Improve Learning Outcome: A Literature Based Review,” *J. Inf. Technol.*, vol. 4, no. 1, pp. 33–55, 2020.
 - [11] A. Khan and S. K. Ghosh, *Student performance analysis and prediction in classroom learning: A review of educational data mining studies*, vol. 26, no. 1. Education and Information Technologies, 2020.
 - [12] Y. Yuzarion, “Faktor Yang Mempengaruhi Prestasi Belajar Peserta Didik,” *Ilmu Pendidik. J. Kaji. Teor. dan Prakt. Kependidikan*, vol. 2, no. 1, pp. 107–117, 2017, doi: 10.17977/um027v2i12017p107.
 - [13] H. Waheed, S. U. Hassan, N. R. Aljohani, J. Hardman, S. Alelyani, and R. Nawaz, “Predicting academic performance of students from VLE big data using deep learning models,” *Comput. Human Behav.*, vol. 104, 2019, doi: 10.1016/j.chb.2019.106189.
 - [14] C. F. Rodríguez-Hernández, M. Musso, E. Kyndt, and E. Cascallar, “Artificial neural networks in academic performance prediction: Systematic implementation and predictor evaluation,” *Comput. Educ. Artif. Intell.*, vol. 2, no. December 2020, 2021, doi: 10.1016/j.caear.2021.100018.
 - [15] P. Cortez and A. Silva, “Using data mining to predict secondary school student performance,” *15th Eur. Concurr. Eng. Conf. 2008, ECEC 2008 - 5th Futur. Bus. Technol. Conf. FUBUTEC 2008*, vol. 2003, no. 2000, pp. 5–12, 2008.
 - [16] L. Zhao *et al.*, “Academic Performance Prediction Based on Multisource, Multifeature Behavioral Data,” *IEEE Access*, vol. 9, pp. 5453–5465, 2017, doi: 10.1109/ACCESS.2020.3002791.
 - [17] T. Transition, E. Osmanbegović, and M. Suljić, “Determining Dominant Factor For Students Performance Prediction By Using Data Mining,” vol. XVII, pp. 147–158, 2014.
 - [18] B. N. Sari, “Implementasi Teknik Seleksi Fitur Information Gain Pada Algoritma Klasifikasi Machine Learning Untuk Prediksi Performa

- Akademik Siswa,” *Semin. Nas. Teknol. Inf. dan Multimed. 2016*, no. March, pp. 55–60, 2016, [Online]. Available: <http://semnas.amikom.ac.id/document/pdf/1482.pdf>.
- [19] M. Schiezaro and H. Pedrini, “Data feature selection based on Artificial Bee Colony algorithm,” pp. 1–8, 2013.
 - [20] L. Rahman, N. A. Setiawan, and Adhistya Erna Permanasari, “Feature Selection Methods in Improving Accuracy,” no. 1, pp. 267–271, 2017.
 - [21] H. Rao *et al.*, “Feature selection based on artificial bee colony and gradient boosting decision tree,” *Appl. Soft Comput. J.*, 2018, doi: 10.1016/j.asoc.2018.10.036.
 - [22] I. Cholissodin, F. Farisuddin, and E. Santoso, “Klasifikasi Tingkat Resiko Stroke Menggunakan Improved Particle Swarm Optimization dan Support Vector Machine,” *Konf. Nas. Sist. Inf. 2016, STT Ibnu Sina*, no. February, pp. 11–13, 2017.
 - [23] A. Farissi, H. M. Dahlan, and Samsuryadi, “Genetic algorithm based feature selection for predicting student’s academic performance,” *Adv. Intell. Syst. Comput.*, vol. 1073, no. January, pp. 110–117, 2020, doi: 10.1007/978-3-030-33582-3_11.
 - [24] E. Sarac and S. A. Ozel, “An Ant Colony Optimization Based Feature Selection for Web Page Classification,” *Hindawi Publ. Corp. Sci. World J.*, no. December 2005, p. 16 pages, 2014, doi: <http://dx.doi.org/10.1155/2014/649260>.
 - [25] S. Rohaidah, A. Abu, and M. Ridzwan, “Ant colony optimization for text feature selection in sentiment analysis,” *Intell. Data Anal.*, vol. 23, pp. 133–158, 2019, doi: 10.3233/IDA-173740.
 - [26] A. Farissi, H. M. Dahlan, and S. Samsuryadi, “Genetic Algorithm Based Feature Selection With Ensemble Methods For Student Academic Performance Prediction,” *J. Phys. Conf. Ser.*, 2019, doi: 10.1088/1742-6596/1500/1/012110.
 - [27] A. Rakhman, “Prediksi Ketepatan Kelulusan Mahasiswa Menggunakan

- Metode Decision Tree Berbasis Particle Swarm Optimization (PSO)," *Smart Comp*, vol. 6, no. 1, pp. 193–197, 2017.
- [28] E. Purnamasari, D. P. Rini, and Sukemi, "Seleksi Fitur menggunakan Algoritma Particle Swarm Optimization pada Klasifikasi Kelulusan Mahasiswa dengan Metode Naive Bayes," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 4, no. 3, pp. 469–475, 2020.
 - [29] E. Purnamasari, D. P. Rini, and Sukemi, "The Combination of Naive Bayes and Particle Swarm Optimization Methods of Student ' s Graduation Prediction," *J. Ilm. Tek. Elektro Komput. dan Inform.*, vol. 5, no. 2, pp. 112–119, 2019, doi: 10.26555/jiteki.v5i2.15317.
 - [30] M. Iqbal, I. Herliawan, Ridwansyah, and W. Gata, "Implementation Of Particle Swarm Optimization Based Machine Learning Algorithm For Student Performance Prediction," *JITK (Jurnal Ilmu Pengetah. Dan Teknol. Komputer)*, vol. 6, no. 2, pp. 195–204, 2020, doi: 10.33480/jitk.v6i2.1695.IMPLEMENTATION.
 - [31] B. N. Sari, "Prediksi Performa Akademik Siswa Pada Pelajaran Matematika Menggunakan Bayesian Networks Dan Algoritma Klasifikasi Machine Learning," no. Knmpmp Ii, pp. 397–405, 2017.
 - [32] A. Charleonnan, T. Fufaung, T. Niyomwong, W. Chokchueypattanakit, S. Suwannawach, and N. Ninchawee, "Predictive analytics for chronic kidney disease using machine learning techniques," *Manag. Innov. Technol. Int. Conf.*, pp. MIT80–MIT83, 2016, doi: 10.1109/MITICON.2016.8025242.
 - [33] S. Oloruntoba and J. Akinode, "Student Academic Performance Prediction Using Support Vector Machine," *Int. J. Eng. Sci. Res. Technol.*, vol. 6, no. 12, pp. 588–598, 2017.
 - [34] I. Burman and S. Som, "Predicting Students Academic Performance Using Support Vector Machine," *Amity Int. Conf. Artif. Intell.*, pp. 756–759, 2019.
 - [35] H. Harafani, "Optimasi Parameter pada Support Vector Machine Berbasis Algoritma Genetika untuk Estimasi Kebakaran Hutan," vol. 1, no. 2, 2015.
 - [36] J. H. Fu, J. H. Chang, Y. M. Huang, and H. C. Chao, "A support vector

- regression-based prediction of students' school performance," *Proc. - 2012 Int. Symp. Comput. Consum. Control. IS3C 2012*, pp. 84–87, 2012, doi: 10.1109/IS3C.2012.31.
- [37] S. R. N and P. C. Deka, "Support vector machine applications in the field of hydrology : A review," *Appl. Soft Comput. J.*, vol. 19, pp. 372–386, 2014, doi: 10.1016/j.asoc.2014.02.002.
- [38] D. A. Kristiyanti, "Analisis Sentimen Review Produk Kosmetik Menggunakan Algoritma Support Vector Machine Dan Particle Swarm Optimization Sebagai," *Semin. Nas. Inov. Tren 2015 "Peluang dan Tantangan Indones. Dalam Menyikapi Afta 2015,"* pp. 134–141, 2015, [Online]. Available: http://lppm.bsi.ac.id/SNIT2015/BidangA/A22-134-141_2015-SNIT-Dinar Ajeng Kristiyanti_ALGORITMA SUPPORT VECTOR.pdf.
- [39] X. Wang, J. Wen, Y. Zhang, and Y. Wang, "Real estate price forecasting based on SVM optimized by PSO," *Optik (Stuttg.)*, vol. 125, no. 3, pp. 1439–1443, 2014, doi: 10.1016/j.ijleo.2013.09.017.
- [40] A. Kumar, G. Kabra, E. K. Mussada, M. K. Dash, and P. S. Rana, "Combined artificial bee colony algorithm and machine learning techniques for prediction of online consumer repurchase intention," *Neural Comput. Appl.*, vol. 31, pp. 877–890, 2017, doi: 10.1007/s00521-017-3047-z.
- [41] A. S. Wicaksono and A. A. Supianto, "Hyper parameter optimization using genetic algorithm on machine learning methods for online news popularity prediction," *Int. J. Adv. Comput. Sci. Appl.*, vol. 9, no. 12, pp. 263–267, 2018, doi: 10.14569/IJACSA.2018.091238.
- [42] Ispandi and R. S. Wahono, "Penerapan Algoritma Genetika untuk Optimasi Parameter pada Support Vector Machine untuk Meningkatkan Prediksi Pemasaran Langsung," *J. Intell. Syst.*, vol. 1, no. 2, pp. 115–119, 2015.
- [43] Z. Luo, M. Hasanipanah, H. Bakhshandeh Amniesh, K. Brindhadevi, and M. M. Tahir, "GA-SVR: a novel hybrid data-driven model to simulate vertical load capacity of driven piles," *Eng. Comput.*, vol. 37, no. 2, pp. 823–831, 2019, doi: 10.1007/s00366-019-00858-2.

- [44] V. Machairas, A. Tsangrassoulis, and K. Axarli, “Algorithms for optimization of building design : A review,” vol. 31, no. 1364, pp. 101–112, 2014, doi: 10.1016/j.rser.2013.11.036.
- [45] S. Ali, Z. Haider, F. Munir, H. Khan, and A. Ahmed, “Factors Contributing to the Students Academic Performance: A Case Study of Islamia University Sub-Campus,” *Am. J. Educ. Res.*, vol. 1, no. 8, pp. 283–289, 2013, doi: 10.12691/education-1-8-3.
- [46] M. F. Ayaz and M. Söylemez, “The effect of the project-based learning approach on the academic achievements of the students in science classes in Turkey: A meta-analysis study,” *Egit. ve Bilim*, vol. 40, no. 178, pp. 255–283, 2015, doi: 10.15390/EB.2015.4000.
- [47] S. K. F. Briones, R. J. R. Dagamac, J. D. David, and C. A. B. Landerio, “Factors Affecting the Students’ Scholastic Performance: A Survey Study,” *Indones. J. Educ. Res. Technol.*, vol. 2, no. 2, pp. 97–102, 2022, doi: 10.17509/ijert.v2i2.41394.
- [48] R. H. Malik and A. Rizvi, “Effect of Classroom Learning Environment on Students’ Academic Achievement in Mathematics at Secondary Level,” *Bull. Educ. Res.*, vol. 40, no. 2, pp. 207–218, 2018, [Online]. Available: <https://files.eric.ed.gov/fulltext/EJ1209817.pdf>.
- [49] M. Hussain, W. Zhu, W. Zhang, and S. M. R. Abidi, “Student Engagement Predictions in an e-Learning System and Their Impact on Student Course Assessment Scores,” *Comput. Intell. Neurosci.*, vol. 2018, 2018, doi: 10.1155/2018/6347186.
- [50] E. Alyahyan and D. Düşteğör, “Predicting academic success in higher education: literature review and best practices,” *Int. J. Educ. Technol. High. Educ.*, vol. 17, no. 1, pp. 4–5, 2020, doi: 10.1186/s41239-020-0177-7.
- [51] A. M. Shahiri, W. Husain, and N. A. Rashid, “A Review on Predicting Student’s Performance Using Data Mining Techniques,” *Procedia Comput. Sci.*, vol. 72, pp. 414–422, 2015, doi: 10.1016/j.procs.2015.12.157.
- [52] V. L. Miguéis, A. Freitas, P. J. V. Garcia, and A. Silva, “Early segmentation

- of students according to their academic performance: A predictive modelling approach,” *Decis. Support Syst.*, vol. 115, pp. 36–51, 2018, doi: 10.1016/j.dss.2018.09.001.
- [53] S. Natek and M. Zwilling, “Student data mining solution-knowledge management system related to higher education institutions,” *Expert Syst. Appl.*, vol. 41, no. 14, pp. 6400–6407, 2014, doi: 10.1016/j.eswa.2014.04.024.
 - [54] A. U. Khasanah and Harwati, “A Comparative Study to Predict Student’s Performance Using Educational Data Mining Techniques,” *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 215, no. 1, 2017, doi: 10.1088/1757-899X/215/1/012036.
 - [55] D. Buenaño-fernández, D. Gil, and S. Luján-mora, “Application of Machine Learning in Predicting Performance for Computer Engineering Students : A Case Study,” www.mdpi.com/journal/sustainability, pp. 1–18, 2019, doi: 10.3390/su11102833.
 - [56] E. B. Belachew and F. A. Gobena, “Student Performance Prediction Model using Machine Learning Approach: The Case of Wolkite University,” *Int. J. Adv. Res. Comput. Sci. Softw. Eng.*, vol. 7, no. 2, pp. 46–50, 2017, doi: 10.23956/ijarcsse/V7I2/01219.
 - [57] Elakia, Gayathri, Aarthi, and Naren J, “Application of Data Mining in Educational Database for Predicting Behavioural Patterns of the Students,” vol. 5, no. 3, pp. 4649–4652, 2014.
 - [58] M. Mayilvaganan and D. Kalpanadevi, “Comparison of classification techniques for predicting the cognitive skill of students in education environment,” *2014 IEEE Int. Conf. Comput. Intell. Comput. Res. IEEE ICCIC 2014*, pp. 113–118, 2015, doi: 10.1109/ICCIC.2014.7238346.
 - [59] C. Coffrin, L. Corrin, P. De Barba, and G. Kennedy, “Visualizing patterns of student engagement and performance in MOOCs,” pp. 83–92, 2014.
 - [60] A. Bogarín, C. Romero, R. Cerezo, and M. Sánchez-Santillán, “Clustering for improving Educational process mining,” *ACM Int. Conf. Proceeding*

- Ser.*, pp. 11–15, 2014, doi: 10.1145/2567574.2567604.
- [61] K. T. Chui, R. W. Liu, M. Zhao, and P. Ordóñez de Pablos, “Predicting Students’ Performance with School and Family Tutoring Using Generative Adversarial Network-Based Deep Support Vector Machine,” *IEEE Access*, vol. 8, pp. 86745–86752, 2020, doi: 10.1109/ACCESS.2020.2992869.
 - [62] X. Xu, J. Wang, H. Peng, and R. Wu, “Prediction of academic performance associated with internet usage behaviors using machine learning algorithms,” *Comput. Human Behav.*, vol. 98, no. January, pp. 166–173, 2019, doi: 10.1016/j.chb.2019.04.015.
 - [63] W. Chango, R. Cerezo, and C. Romero, “Multi-source and multimodal data fusion for predicting academic performance in blended learning university courses,” *Comput. Electr. Eng.*, vol. 89, no. November 2020, 2021, doi: 10.1016/j.compeleceng.2020.106908.
 - [64] D. Liu, Y. Zhang, J. Zhang, Q. Li, C. Zhang, and Y. Yin, “Multiple features fusion attention mechanism enhanced deep knowledge tracing for student performance prediction,” *IEEE Access*, vol. 8, pp. 194894–194903, 2020, doi: 10.1109/ACCESS.2020.3033200.
 - [65] A. Ariani and S. Samsuryadi, “Classification of Kidney Disease Using Genetic Modified Knna and Artificial Bee Colony Algorithm,” *Sinergi*, vol. 25, no. 2, p. 177, 2021, doi: 10.22441/sinergi.2021.2.009.
 - [66] C. Cortes and V. Vapnik, “Support-Vector Networks,” vol. 20, pp. 273–297, 1995, doi: 10.1109/64.163674.
 - [67] F. Y. Ju and W. C. Hong, “Application of seasonal SVR with chaotic gravitational search algorithm in electricity forecasting,” *Appl. Math. Model.*, vol. 37, no. 23, pp. 9643–9651, 2013, doi: 10.1016/j.apm.2013.05.016.
 - [68] V. Vapnik, S. E. Golowich, and A. Smola, “Support vector method for function approximation, regression estimation, and signal processing,” *Adv. Neural Inf. Process. Syst.*, pp. 281–287, 1997.
 - [69] B. Scholkopf and A. J. Smola, *Learning with Kernels*. 2002.

- [70] A. J. Smola and B. Scholkopf, “A tutorial on support vector regression,” *Stat. Comput.*, vol. 14, pp. 199–222, 2004, doi: 10.1210/me.10.7.813.
- [71] J. Kennedy and R. Eberhart, “Particle Swarm Optimization,” *Stud. Comput. Intell.*, vol. 927, pp. 5–13, 1995, doi: 10.1007/978-3-030-61111-8_2.
- [72] T. Qin, S. Zeng, and J. Guo, “Robust prognostics for state of health estimation of lithium-ion batteries based on an improved PSO-SVR model,” *Microelectron. Reliab.*, vol. 55, no. 9–10, pp. 1280–1284, 2015, doi: 10.1016/j.microrel.2015.06.133.
- [73] D. Bratton and J. Kennedy, “Defining a standard for particle swarm optimization,” *Proc. 2007 IEEE Swarm Intell. Symp. SIS 2007*, no. Sis, pp. 120–127, 2007, doi: 10.1109/SIS.2007.368035.
- [74] S. Rukhaiyar, M. N. Alam, and N. K. Samadhiya, “A PSO-ANN hybrid model for predicting factor of safety of slope,” *Int. J. Geotech. Eng.*, vol. 12, no. 6, pp. 556–566, 2018, doi: 10.1080/19386362.2017.1305652.
- [75] T. Salameh, P. P. Kumar, E. T. Sayed, M. A. Abdelkareem, H. Rezk, and A. G. Olabi, “Fuzzy modeling and particle swarm optimization of Al₂O₃/SiO₂ nanofluid,” *Int. J. Thermofluids*, vol. 10, 2021, doi: 10.1016/j.ijft.2021.100084.
- [76] B. Santosa and P. Willy, *Metoda metaheuristik: konsep dan implementasi*. Surabaya: Guna Widya, 2011.
- [77] I. Kusmarna, L. K. Wardhani, and M. Safrizal, “Aplikasi Penjadwalan Mata Kuliah Menggunakan Algoritma Particle Swarm Optimization (Pso),” *J. Tek. Inform.*, vol. 8, no. 2, pp. 1–8, 2015, doi: 10.15408/jti.v8i2.2441.
- [78] S. Karkheiran, A. Kabiri-Samani, M. Zekri, and H. M. Azamathulla, “Scour at bridge piers in uniform and armored beds under steady and unsteady flow conditions using ANN-APSO and ANN-GA algorithms,” *ISH J. Hydraul. Eng.*, vol. 00, no. 00, pp. 1–9, 2019, doi: 10.1080/09715010.2019.1617796.
- [79] M. Mitchell, *Introduction to genetic algorithms*. 1996.
- [80] X. Yang, “Nature-Inspired Optimization Algorithms,” *Elsevier*, pp. 77–87, 2014, doi: 10.1007/SpringerReference_72296.

- [81] Holland J.H., “Genetic Algorithms and Adaptation,” *NATO Conf. Ser. (II Syst. Sci.)*, vol. 16, pp. 317–333, 1984.
- [82] F. Gorunescu, *Data Mining : Concepts, Models and Techniques*, INTELLIGEN. Springer, 2011.
- [83] B. K. Khotimah, M. Miswanto, and H. Suprajitno, “Optimization of feature selection using genetic algorithm in naïve Bayes classification for incomplete data,” *Int. J. Intell. Eng. Syst.*, vol. 13, no. 1, pp. 334–343, 2020, doi: 10.22266/ijies2020.0229.31.
- [84] D. Zhang, W. Liu, A. Wang, and Q. Deng, “Parameter Optimization for Support Vector Regression Based on Genetic Algorithm with Simplex Crossover Operator,” *J. Inf. Comput. Sci.*, 2011, [Online]. Available: https://www.researchgate.net/publication/266051142_Parameter_Optimization_for_Support_Vector_Regression_Based_on_Genetic_Algorithm_with_Simplex_Crossover_Operator.
- [85] F. Moslehi and A. Haeri, “A novel hybrid wrapper–filter approach based on genetic algorithm, particle swarm optimization for feature subset selection,” *J. Ambient Intell. Humaniz. Comput.*, vol. 11, no. 3, pp. 1105–1127, 2020, doi: 10.1007/s12652-019-01364-5.
- [86] Y. C. Hsieh, P. J. Lee, and P. S. You, “Immune-based evolutionary algorithm for determining the optimal sequence of multiple disinfection operations,” *Sci. Iran.*, vol. 26, no. 2 C, pp. 959–974, 2019, doi: 10.24200/sci.2018.20324.
- [87] D. E. Goldberg, *Genetic Algorithms in Search, Optimization & Machine Learning*. 1989.
- [88] C. Bergmeir, M. Costantini, and J. M. Benítez, “On the usefulness of cross-validation for directional forecast evaluation,” *Comput. Stat. Data Anal.*, vol. 76, no. 2009, pp. 132–143, 2014, doi: 10.1016/j.csda.2014.02.001.
- [89] B. Santosa and A. Umam, *Data Mining dan Big Data Analytics : Teori dan Implementasi Menggunakan Python dan Apache Spark*. Penebar Media Pustaka, 2018.
- [90] A. O. Balogun *et al.*, “Impact of feature selection methods on the predictive

- performance of software defect prediction models: An extensive empirical study,” *Symmetry (Basel)*., vol. 12, no. 7, 2020, doi: 10.3390/sym12071147.
- [91] I. H. Witten, E. Frank, and M. A. Hall, *Data Mining : Practical Machine Learning Tools and Techniques*. 2011.
 - [92] D. Conway and J. M. White, *Machine Learning for Hackers*. 2012.
 - [93] B. Alfaresi, T. Barlian, F. Ardianto, and M. Hurairah, “Path loss propagation evaluation and modelling based ECC-Model in Lowland Area on 1800 MHz,” *J. Robot. Control*, vol. 1, no. 5, pp. 167–171, 2020, doi: 10.18196/jrc.1534.
 - [94] C. S. Wahyu Widayati, “Komparasi Beberapa Metode Estimasi Kesalahan Pengukuran,” *J. Penelit. dan Eval. Pendidik.*, vol. 13, no. 2, pp. 182–197, 2013, doi: 10.21831/pep.v13i2.1409.
 - [95] Z. Ruiz-Chavez, J. Salvador-Meneses, and J. Garcia-Rodriguez, “Machine Learning Methods Based Preprocessing to Improve Categorical Data Classification,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 11314 LNCS, no. December, pp. 297–304, 2018, doi: 10.1007/978-3-030-03493-1_32.
 - [96] C. Hsu, C. Chang, and C. Lin, “A Practical Guide to Support Vector Classification,” vol. 1, no. 1, pp. 1–16, 2016, [Online]. Available: <http://www.csie.ntu.edu.tw/~cjlin%0AInitial>.
 - [97] D. P. Apriyadi, M Riki; Ermatita, Ermatita; Rini, “Implementation of Feature Selection Based on Particle Swarm Optimization and Genetic Algorithm on Support Vector Regression Algorithm to Predict Student Performance,” *Int. Conf. Informatics, Multimedia, Cyber Inf. Syst.*, pp. 395–400, 2022.
 - [98] D. P. Apriyadi, M Riki; Ermatita, Ermatita; Rini and D. P. Rini, “Hyperparameter Optimization of Support Vector Regression Algorithm using Metaheuristic Algorithm for Student Performance Prediction,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 14, no. 2, pp. 144–150, 2023.