



Optimization of Decision Tree Using Particle Swarm Optimization for Credit Risk of KMG Bank DKI

Optimasi Decision Tree Menggunakan *Particle Swarm Optimization* untuk Risiko Kredit KMG Bank DKI

Jwasky Budy Eswa Putry^{1*}, Ananto Tri Sasongko², Wahyu Hadikristanto³

^{1,2,3}Program Studi Teknik Informatika, Fakultas Teknik, Universitas Pelita Bangsa, Indonesia

E-Mail: ¹jwasky.312210418@ mhs.pelitabangsa.ac.id, ²ananto@pelitabangsa.ac.id,
³wahyu.hadikristanto@pelitabangsa.ac.id

Received Jun 8th 2024; Revised Jul 26th 2024; Accepted Jul 29th 2024
Corresponding Author: Jwasky Budy Eswa Putry

Abstract

In the banking world, credit risk prediction is an important aspect that determines success in credit management. This study aims to improve the accuracy of credit risk prediction for Multi-Use Credit (KMG) at Bank DKI by using the Particle Swarm Optimization (PSO) method. In this context, PSO used to optimize the search for the best combination of parameters that can enhance the performance of the credit risk prediction model. The research indicates that using PSO can significantly increase the accuracy of credit risk prediction. With PSO, the prediction accuracy reached 99.13%. Conversely, without PSO optimization, the accuracy obtained from the Decision Tree was only 97.83%. This proves that PSO can significantly improve the accuracy of credit risk prediction. Therefore, Bank DKI can make more accurate decisions in granting KMG credits, which ultimately can reduce the level of non-performing loans and increase the bank's financial stability.

Keywords: Credit Risk Prediction, Decision Tree, Multi-Use Credit, Particle Swarm Optimization

Abstrak

Pada dunia perbankan prediksi risiko kredit merupakan aspek penting yang menentukan keberhasilan dalam pengelolaan kredit. Penelitian ini bertujuan untuk meningkatkan akurasi prediksi risiko kredit Kredit Multiguna (KMG) di Bank DKI dengan menggunakan metode *Particle Swarm Optimization* (PSO). Dalam konteks ini, PSO digunakan untuk mengoptimalkan dalam menemukan kombinasi parameter terbaik yang dapat meningkatkan performa model prediksi risiko kredit. Penelitian menunjukkan bahwa penggunaan PSO ini meningkatkan akurasi prediksi risiko kredit secara signifikan. Dengan menggunakan PSO menghasilkan akurasi prediksi mencapai 99,13%. Sebaliknya, tanpa optimasi PSO, akurasi yang diperoleh dari *Decision Tree* hanya sebesar 97,83 %. Hal ini membuktikan bahwa PSO mampu meningkatkan akurasi prediksi risiko kredit secara signifikan. Dengan demikian, Bank DKI dapat mengambil keputusan yang lebih tepat dalam pemberian kredit KMG, yang pada akhirnya dapat mengurangi tingkat kredit macet dan meningkatkan stabilitas finansial bank.

Kata Kunci: *Decision Tree*, Kredit Multiguna, *Particle Swarm Optimization*, Prediksi Risiko Kredit

1. PENDAHULUAN

Pengelolaan risiko kredit artinya merupakan aspek krusial dalam operasional perbankan yg memerlukan pendekatan yg cermat dan efektif. Khususnya, dalam era dinamika pasar serta kompleksitas keuangan, risiko kredit multiguna menjadi penekanan penting bagi lembaga keuangan seperti PT Bank DKI. Menerapkan prinsip perkreditan yang sehat, lembaga perbankan juga koperasi diminta untuk bisa mengukur risiko kredit dengan baku tertentu. Hal ini sesuai menggunakan kebijakan manajemen risiko, pada Indonesia yang diatur dalam peraturan otoritas jasa keuangan No.18/POJK/03/2016 ihwal penerapan manajemen risiko bagi bank [1]. Secara historis, bank mengandalkan model penilaian risiko tradisional yang terutama berfokus pada faktor-faktor tidak aktif, mirip skor kredit, taraf pendapatan, serta riwayat pekerjaan. Meskipun contoh-contoh ini sudah mencapai tujuannya, model-model tersebut acapkali dikritik sebab ketidakmampuannya mengakomodasi sifat bergerak maju pada pasar keuangan dan interaksi kompleks antara berbagai faktor yang

mempengaruhi risiko kredit. Munculnya analisis prediktif telah mengatasi keterbatasan ini dengan memperkenalkan model yang mampu menganalisis spektrum variabel yang lebih luas, termasuk data perilaku dan transaksional, sehingga menawarkan pandangan yang lebih bernuansa dan komprehensif mengenai kelayakan kredit peminjam[2].

Particle Swarm Optimization (PSO), algoritma yang terinspirasi dari perilaku sosial burung dan ikan, telah menunjukkan potensi yang signifikan dalam optimasi berbagai masalah kompleks, termasuk dalam sektor keuangan. PSO menawarkan solusi inovatif dengan kemampuannya untuk mengeksplorasi ruang pencarian secara efisien dan menemukan kombinasi optimal dari variabel-variabel yang mempengaruhi risiko kredit. Partikel (PSO) yang menggabungkan kekacauan dan pembatasan kecepatan dengan tujuan menghilangkan kelemahan yang diketahui yang memaksa partikel untuk terus mencari di batas ruang pencarian. Namun, karena kumpulan data kredit biasanya berdimensi tinggi, kelasnya tidak seimbang, dan ukuran sampelnya besar [3].

Berdasarkan tinjauan pustaka [3], [4], [5], telah banyak penelitian mengenai PSO dalam meningkatkan akurasi dan keterlibatannya dalam optimasi. Pada penelitian terdahulu yang berkaitan disampaikan oleh Tyas(2021), menggunakan metode algoritma *decision tree* dengan optimasi PSO karena *decision tree* dianggap sebagai algoritma yang lemah, karena algoritma *decision tree* bergantung pada pembuatan desain dari pohon tersebut. Untuk memaksimalkan hasil klasifikasi yang akan diperoleh, dengan cara meningkatkan nilai akurasi menggunakan metode PSO. Pada penelitiannya mencari nilai klasifikasi kesuburan pria dengan dataset *Fertility Dataset* yang diambil dari *UCI repository* yang menghasilkan tingkat dari nilai akurasi yang tinggi bila dikombinasikan dengan metode PSO [6].

Penelitian dari kutipan Saprudin (2017), juga menerapkan hal yang sama dengan tujuan utama dari metode klasifikasi adalah proses penemuan model (fungsi) yang menggambarkan dan membedakan kelas data, tetap dengan optimasi PSO dimana data uji yang digunakan adalah data German Credit. Hasil yang diperoleh adalah model algoritma C4.5 berbasis PSO mendapatkan hasil terbaik sebesar 70%, sedangkan model algoritma C4.5 tanpa PSO hanya 68,6%, sehingga selisih untuk nilai akurasi sebesar 1,4% [7]

Penelitian lain dalam kutipan Eka Yuni (2023), tentang komparasi Algoritma C4.5 dan C4.5 yang berbasis PSO pada kelayakan pemberian kredit Koperasi PT. Indah Kiat Pulp & Paper TBK, menghasilkan dua model hasil uji penentuan kelayakan pemberian kredit. Disampaikan juga bahwa dari hasil evaluasi nilai *confusion matrix*, *accuracy* dan grafik *AUC* meskipun keduanya sama-sama menghasilkan tingkat *accuracy*, hanya saja algoritma C4.5 berbasis PSO dapat meningkatkan keakuratan dari algoritma C4.5 sehingga informasi yang diperoleh dapat membantu karyawan yang sangat membutuhkan pinjaman [8].

Penelitian berikutnya oleh Abdul Razak (2023), menggunakan PSO sebagai alat untuk analisis kredit *scoring*. Sulitnya melakukan prediksi yang akurat dalam menentukan kelayakan penyaluran kredit pada masyarakat berpenghasilan rendah, mendasari penelitian tersebut. Namun dalam metode nya menggunakan algoritma SVM yang dioptimasi dengan PSO. Alat yang digunakan dalam penelitian ini *Ai Studio a.k.a Rapidminer* sebab sering digunakan dalam berbagai industri, termasuk bisnis, ilmu pengetahuan, keuangan, dan lainnya untuk mengambil keputusan yang didasarkan pada data dan menganalisis tren. Ini adalah salah satu alat populer di bidang analitik data dan machine learning[9].

Merujuk pada kemampuan PSO untuk mengoptimalkan keakuratan prediksi, penelitian ini menerapkannya pada masalah yang diangkat, yaitu tingginya tingkat kredit macet (Non-Performing Loans/ NPL) yang berdampak negatif pada stabilitas finansial bank dan kepercayaan nasabah. Dalam penelitian ini, peneliti mengintegrasikan PSO dalam proses analisis risiko Kredit Multiguna (KMG) di Bank DKI. KMG adalah salah satu jenis produk kredit di Bank DKI. Diharapkan, pendekatan ini dapat memberikan wawasan baru, meningkatkan keakuratan penilaian risiko, mengurangi NPL, dan meningkatkan kinerja finansial bank secara keseluruhan.

2. BAHAN DAN METODE

2.1. Metode Yang Digunakan

Metode analisis penelitian dilakukan dengan pengumpulan data kemudian menggunakan metode *Particle Swarm Optimization* (PSO). PSO diinisialisasi dengan populasi solusi acak, yang disebut partikel. Partikel-partikel ini bergerak di sekitar ruang pencarian dengan kecepatan yang disesuaikan secara dinamis [10]. PSO pseudocode misalkan $f : R^N \rightarrow R$ adalah fungsi objektif yang perlu disederhanakan. Kemudian, fungsi tersebut mengambil vektor dari (N) bilangan real yang menunjukkan (N) solusi kandidat dan menghasilkan bilangan real yang menunjukkan nilai dari fungsi objektif. Gradien (f) sulit dihitung atau sering tidak diketahui. Kemudian, minimum global terbaik dikejar seperti yang ditunjukkan dalam Algoritma [11].

Algoritma dasar PSO terdiri dari tiga tahap, yaitu pembangkitan posisi serta kecepatan partikel, update kecepatan, dan update posisi. Posisi x_{ki} dan kecepatan v_{ki} dari kumpulan partikel dibangkitkan secara random menggunakan batas atas x_{max} dan batas bawah x_{min} dari design variabel, seperti yang ditunjukkan pada persamaan (1) dan (2).

$$x_0^i = x_{min} + \text{rand} (x_{max} - x_{min}) \quad (1)$$

$$v_0^i = x_{min} + \text{rand} (x_{max} - x_{min}) \quad (2)$$

Langkah kedua adalah update kecepatan pada semua partikel dengan menggunakan nilai fitness posisi partikel saat ini. Dari nilai fitness dapat ditentukan partikel mana yang mempunyai nilai global terbaik pada swarm saat ini p_{kg} dan juga dapat ditentukan posisi terbaik dari setiap partikel pada semua waktu yang sekarang dan sebelumnya p_i . Perumusan update kecepatan menggunakan dua informasi tersebut untuk semua partikel pada kumpulan dengan pengaruh perpindahan yang sekarang v_{ki} untuk memberikan arah pencarian v_{k+1} untuk generasi selanjutnya.

Perumusan update kecepatan mencakup beberapa parameter random (rand), untuk mendapatkan cakupan yang baik, tiga parameter yang mempengaruhi arah pencarian, yaitu inertia factor w , self confidence c_1 , dan swarm confidence c_2 seperti yang ditunjukkan persamaan (3).

$$v_{k+1}^i = w * v_k^i + c_1 * \text{rand} * (p^i - x_k^i) + c_2 * \text{rand} * (p_k^g - x_k^i) \quad (3)$$

Langkah terakhir dari setiap iterasi adalah update posisi setiap partikel dengan vektor velocity, seperti yang ditunjukkan pada persamaan (4).

$$x_{k+1}^i = x_k^i + v_{k+1}^i \quad (4)$$


Setelah sejumlah iterasi, PSO akan menghasilkan posisi terbaik yang mungkin sebagai solusi optimal atau mendekati solusi optimal untuk masalah yang diberikan [12]. Data yang terkumpul dimasukkan ke dalam tabel *excel*. Data masih berupa text sehingga perlu dilakukan perubahan dengan menu *Text to Column* agar dapat terbaca. Proses selanjutnya adalah penggunaan *Ai Studio a.k.a Rapidminer*.

Software ini juga meliputi beragam operator yg sudah dibangun, adalah blok bangunan berasal alur kerja, yang meliputi semua tahap proses data mining, seperti pencucian data, pemilihan fitur, dan pemodelan [13]. Untuk cara kerjanya diterapkan *preprocessing* dengan cara melakukan pembersihan data dan *replace* data. Setelah *pre-processing* selesai, dilanjutkan dengan membuat modeling *Decision Tree* dan dioptimasi menggunakan *particle swarm optimization*.

Pre-processing data dilakukan dengan impor data ke dalam *Ai Studio a.k.a Rapidminer* dan lakukan pra-pemrosesan. Ini mungkin termasuk langkah-langkah seperti menghapus duplikat, mengisi nilai yang hilang, atau melakukan transformasi data. Tujuannya adalah memastikan bahwa data siap untuk dianalisis [14]. *Decision Tree* menciptakan model pelatihan yang dikembangkan untuk memprediksi nilai dari variabel target. Oleh karena itu, beberapa sistem dalam lingkungan digitalisasi menggunakan *Decision Tree* untuk membedakan antara kelas objek. Menggunakan node sebagai *Decision Tree* bertujuan untuk memilih atribut objek dan menentukan nilai alternatif untuk atribut lainnya. Fungsi daun dalam struktur pohon dijelaskan sebagai objek dengan klasifikasi yang sama [15].

2.2. Kerangka Pemikiran

Kerangka pemikiran membantu peneliti dalam merumuskan hipotesis, merancang metode penelitian, dan memandu analisis data sehingga dapat dijadikan acuan oleh peneliti. Kerangka pemikiran dapat dilihat pada gambar 1.




Gambar 1. Kerangka Pemikiran

Berikut adalah penjelasan gambar 1: Pada permasalahan yang diangkat adalah bagaimana menentukan optimasi dalam menganalisis risiko kredit pada data KMG Bank DKI. Ini mengacu pada masalah optimasi data risiko kredit untuk KMG. Optimasi risiko kredit melibatkan penilaian dan peningkatan prediksi potensi gagal bayar atau risiko finansial yang terkait dengan pemberian kredit. Kemudian peneliti menggunakan metode *Decision Tree* yang dioptimasi menggunakan PSO agar diperoleh akurasi. Langkah ini melibatkan penggunaan PSO untuk meningkatkan kinerja algoritma *Decision Tree*.

PSO digunakan di sini untuk menemukan parameter atau fitur optimal untuk *Decision Tree*, yang merupakan model *machine learning* yang populer digunakan untuk tugas klasifikasi dan regresi. Dalam kerangka pemikiran *tools AI Studio a.k.a RapidMiner* digunakan dalam proses optimasi. Alat ini berupa platform ilmu data yang menyediakan lingkungan terpadu untuk *machine learning*, persiapan data, dan analitik prediktif. *AI Studio a.k.a Rapidminer* bisa merujuk pada lingkungan pengembangan AI yang mendukung berbagai tugas *machine learning* dan optimasi. Langkah terakhir di mana hasil dari optimasi PSO disajikan. Langkah ini melibatkan analisis peningkatan kinerja dalam model *Decision Tree* setelah menerapkan metode PSO. Hasilnya biasanya mencakup metrik seperti akurasi, presisi, *recall*, skor F1, dan mungkin visualisasi dari *decision tree* serta proses optimasi PSO.

2.3. Model yang diusulkan

Model disini merujuk ke kerangka pemikiran tetapi lebih detail mengenai model penelitian biasanya digunakan untuk memeriksa teori-teori tertentu dan memperkirakan hasil atau menguji hubungan antara variabel tertentu. Berikut tahapan penelitian yang dapat dilihat dari gambar 2 dan penjelasannya.



Gambar 2. Tahapan Penelitian

2.3.1. Tahap awal

Pada tahap ini merupakan dimulainya pengumpulan data, dan diperoleh data sebanyak 1061 record. Peneliti melakukan studi kasus pada salah satu BPD yaitu Bank DKI. Pengumpulan data ini sering disebut sebagai data primer. Data primer biasanya data yang diperoleh langsung dari sumbernya atau dikumpulkan khusus untuk keperluan penelitian, baik dilakukan dengan cara observasi, wawancara, kuisioner, dan eksperimen. Pengumpulan data dilakukan pada bulan Februari 2024 di kantor Bank DKI KCP Klender.

2.3.2. Preprocessing

Pada tahap ini data diambil dari *credit management relationship system*, dan data tersebut masih dalam bentuk text. Sedangkan pada *Ai Studio a.k.a Rapidminer* menggunakan kolom, maka diperlukan penanganan lebih lanjut yaitu mengubah data *text* dengan menggunakan menu *Text to Column* yang tersedia di dalam *Ms.Excel*. Hal ini dilakukan agar data dapat terbaca di *Ai Studio a.k.a Ai Studio a.k.a Rapidminer* nantinya. Setelah itu data di simpan kembali dalam format *.xls*. Data yang sudah dijadikan kolom pada *ms.excel* diolah dengan menggunakan *Ai Studio a.k.a Rapidminer*. Cukup dengan menarik kode proses *Retrieve* lalu diletakkan pada box *process*, untuk output dihubungkan ke *nominal cross validation*. Pada parameter *cross vlidation* diberikan nilai *10 fold cross*. Berdasarkan tinjauan pustaka dan hasil literatur yang peneliti cantumkan pada bab 2, pemilihan *10 fold cross validation* ini sengaja diberikan karena dianggap nilai 10 adalah nilai terbaik untuk mendapat kan hasil yang akurat. Pada tahap ini artinya akan dilakukan pengujian berulang sebanyak 10 kali, dan hasil hasil pengukuran adalah nilai rata-rata dari 10 kali pengujian.

2.3.3. Optimasi *Particle Swarm Optimization*

Pada tahap optimasi menggunakan *Particle Swarm Optimization* (PSO) dilakukan dengan menentukan beberapa prosedur, diantaranya :

1. Mulai menentukan aturan-aturan dan nilai-nilai.
2. Tentukan k_{max} , v_{max} , w_k , $p.c1$. dan $c2$.
3. Inisialisasi posisi dan kecepatan setiap *particle* secara acak.
4. Jika posisi dan kecepatan setiap *particle* dinilai layak maka hitung fungsi tujuan setiap *particle*, apabila tidak layak maka inisialisasikan kembali posisi dan kecepatan tiap partikel.
5. Hitung fungsi tujuan tiap partikel.
6. Perbaharui nilai fungsi dengan tujuan agar setiap partikel dan nilai *swarm* terbaik.
7. Perbaharui kecepatan setiap partikel.
8. Perbaharui posisi tiap partikel.
9. Layak atau tidak apabila tidak layak maka perbaharui kembali kecepatan dan posisi setiap partikel, apabila layak perbaharui nilai w_k
10. Kriteria penghentian tercapai, apabila tidak maka hitung kembali fungsi tujuan setiap partikel apabila terpenuhi artinya selesai.

Setiap partikel dianggap sama dan memiliki dua karakteristik yaitu posisi dan kecepatan [16].

2.3.4. Pengujian

Pada penelitian ini menggunakan metode *Decision Tree* yang dioptimasi dengan algoritma *Particle Swarm Optimization*. Kemudian menggunakan framework *Ai Studio a.k.a Rapidminer* yang selanjutnya dilakukan pengujian keakuratan dengan confusion matrix dengan persamaan[17] :

$$Accuracy = \frac{a+b}{a+b+c+d} \text{ atau } \frac{TP+TN}{TP+FP+TN+FN} \quad (5)$$

3. HASIL DAN PEMBAHASAN

3.1. Hasil Pengujian

3.1.1. Hasil dataset

Pada pengujian penelitian ini memiliki jumlah data yang diproses sebanyak 1061, dengan label berupa kredibilitas lancar, moderat, dan macet. Untuk kredibilitas lancar memiliki kategori 1, moderat kategori 2, dan macet kategori 3. Kategori moderat artinya pembayaran angsuran telah terlambat dalam kurun waktu kurang dari dan sampai 3 bulan, sedangkan yang dikategorikan macet adalah lebih dari 3 bulan. Kemudian setelah dilakukan seleksi data diperoleh data sebanyak 1059 data, terdiri dari lancar 1031 data, moderat 22 data, dan macet 24 data. Agar lebih jelas dapat dilihat pada tabel 1.

Tabel 1. Kelas Kredibilitas


Kelas Label	Dataset
Lancar	1031
Moderat	22
Macet	24
Jumlah data	1059

3.1.2. Hasil *Cleaning* dan *Remove Missing Value*

Pada hasil *Cleaning* dan *Remove Missing Value* terdapat beberapa data yang tidak terisi atau kosong sehingga perlu dilakukan pembersihan data. Dengan cara menghapus data yang kosong atau tidak terisi pada beberapa atribut dan data yang sulit diolah saat melakukan pengujian. Pembersihan data ini dilakukan untuk mendapatkan dataset yang berkualitas.

3.1.3. Hasil *Decision Tree* model

Pada saat menempatkan operator *Decision Tree* pada *box training*, dalam dataset sudah dibuatkan role, dengan parameter *set role* berupa atribut *name* nya adalah kredibilitas sebagai *target role* adalah label. Kemudian dihubungkan ke operator *Decision Tree*, *output* dari *Decision Tree* yaitu model dihubungkan ke input *apply model* lalu dihubungkan lagi ke performance, kemudian dilakukan *play system*. Berikut gambar 3 merupakan hasil *Decision Tree* pada penelitian ini.



Gambar 3. Decision Tree Result

3.1.4. Hasil Optimalisasi Decision Tree dengan PSO



Gambar 4. Particle Swarm Optimization Result

Pada gambar 4, Metode optimasi menggunakan PSO dilakukan. Tiga output disambungkan ke result, kemudian didalam operator PSO berisi operator *set role* yang dihubungkan dengan *nominal x validation* untuk menghubungkan optimasi PSO dengan *Decision Tree*. Parameter yang diberikan sudah mengikuti aturan baku pada *Ai studio a.k.a Rapidminer*.

3.2. Pembahasan

3.2.1. Pengujian Dataset dengan Decision Tree

Hasil pengujian dari *Decision Tree* memiliki nilai akurasi 97,83%, dengan pred.lancar sebesar 1031 true lancar, 23 true moderat dan 0 true macet. Kemudian pred.moderat sebesar 0 true lancar, 0 true moderat dan 0 true macet. Selain itu pred.macet sebesar 0 true lancar, 0 true moderat dan 24 true macet.

Tabel 2. Hasil Uji Tanpa Optimasi PSO

Accuracy :	97.83%			
	True Lancar	True Moderat	True Macet	Class Precision
Pred.Lancar	1013	23	0	97.78%
Pred.Moderat	0	0	0	0.00%
Pred.Macet	0	0	24	100.00%
Class Recall	100.00%	0.00%	100.00%	

Berdasarkan tabel 2, *confusion matrix* tersebut dapat dibahas model ini memiliki performa sempurna berdasarkan data yang diuji. Precision dan Recall untuk macet semuanya menunjukkan nilai 100.00%, yang berarti model ini mampu mengklasifikasikan semua contoh dengan benar tanpa adanya kesalahan.

3.2.2. Pengujian Dataset Decision Tree dengan optimalisasi particle swarm optimization

Hasil pengujian dari model *Decision Tree* dilakukan optimasi dengan *particle swarm optimization* untuk mengetahui seberapa baik dan akurat model *Decision Tree* ini dalam melakukan analisis. Pada pengujian pertama Tingkat akurasi menunjukkan 99,13%. Ini artinya model berhasil mengukur prediksi dengan benar 99.13% dari total *instance*. Untuk class precision berarti dari semua *instance* yang diprediksi sebagai “lancer” sebesar 99,10% sedangkan pada pred moderat dan macet sebesar 100%, hal ini berarti pula benar-benar “macet” dan “moderat”.

Tabel 3. Hasil Uji Optimasi PSO

Accuracy :	99.13% +/- 1.16% (Micro Average : 99.13%)			
	True Lancar	True Moderat	True Macet	Class Precision
Pred.Lancar	986	9	0	99.10%
Pred.Moderat	0	13	0	100.00%
Pred.Macet	0	0	24	100.00%
Class Recall	100.00%	59.09%	100.00%	

Pada tabel 3, pengujian model ini bekerja sangat baik untuk kelas “lancar” dan “macet”, tetapi kurang optimal untuk kelas “moderate” karena memiliki nilai *recall* yang rendah. Dalam hal ini perlu ada perbaikan untuk meningkatkan klasifikasi pada kelas “moderate”.

Hal ini telah dijelaskan pada penelitian terdahulu bahwa adanya permasalahan pembagian terstruktur mengenai *imbalanced* artinya permasalahan yang acapkali timbul, yaitu nilai kinerja penjabaran membagikan nilai akurasi yg tinggi sebab jumlah kelas mayor yg banyak sekali. *Imbalanced* adalah tugas yang menantang bagi sebagian besar algoritma *machine learning* standar[18]. Hal tersebut dapat diatasi dengan *SMOTE* ,memperbaiki masalah ketidakseimbangan kelas dengan menghasilkan sampel sintetis untuk kelas minoritas [19]. Tetapi, hal itu sebenarnya memiliki kinerja klasifikasi yg sangat jelek ketika mengklasifikasikan data yang berasal dari kelas minor [20].

4. KESIMPULAN

Kesimpulan yang dapat ditarik pada pembahasan diatas diantaranya adalah optimalisasi *Particle Swarm Optimization* (PSO) pada analisis risiko data kredit multiguna di Bank DKI menghasilkan nilai akurasi sebesar 99,13 %. Sementara itu, penggunaan *Decision Tree* tanpa optimalisasi PSO hanya mencapai akurasi sebesar 97,83 %. Hal ini menunjukkan bahwa terdapat peningkatan akurasi yang signifikan dengan penggunaan PSO. Hasil penelitian ini memberikan kontribusi langsung terhadap sektor perbankan, khususnya dalam meningkatkan ketepatan prediksi risiko kredit, yang penting untuk pengambilan keputusan yang lebih baik. Pada penelitian ini juga ditemukan adanya keadaan data tidak seimbang (*Imbalance data*) yang dapat mempengaruhi nilai akurasi yang diperoleh dalam analisis data kredit. Sebagai saran dalam menangani masalah data tidak seimbang tersebut dapat dilakukan teknik *SMOTE* atau metode penyeimbang lainnya. Berdasarkan literatur juga dapat dilakukan pengujian pada dataset yang lebih besar dan beragam, untuk memastikan generalisasi hasil dan keandalannya pada berbagai jenis kredit.

UCAPAN TERIMA KASIH

Kami mengucapkan terima kasih dengan tulus kepada semua pihak yang telah memberikan dukungan dalam menuntaskan penelitian “Optimalisasi *Decision Tree* Menggunakan *Particle Swarm Optimization* (PSO) Pada Risiko Kredit KMG Bank DKI”. Bantuan, nasihat, dan dukungan Anda telah memberikan kontribusi yang sangat berharga dan tidak ternilai. Kami sangat menghargai peran serta Anda semua.

REFERENSI

- [1] K. Auliasari, M. Kertaningtyas, and D. L. Wilis Basuki, “Analisis Penentuan Resiko Kredit Menggunakan Algoritma C.5.0,” 2020. [Online]. Available: <https://doi.org/10/25047/jtit.v8i1.218>
- [2] Wilhelmina Afua Addy, Chinonye Esther Ugochukwu, Adedoyin Tolulope Oyewole, Onyeka Chrisantus Ofodile, Omotayo Bukola Adeoye, and Chinwe Chinazo Okoye, “Predictive analytics in credit risk management for banks: A comprehensive review,” *GSC Advanced Research and Reviews*, vol. 18, no. 2, pp. 434–449, Feb. 2024, doi: 10.30574/gscarr.2024.18.2.0077.
- [3] M. Y. Kurniawan and M. E. Rosadi, “Kurniawan, Rosadi-Optimasi Decision Tree Menggunakan Particle Swarm Optimiziation Pada Data Siswa Putus Sekolah,” Jun. 2017.
- [4] W. I. Rahayu, “Perbandingan Algoritma K-Means dan Naive Bayes untuk Memprediksi Prioritas Pembayaran Tagihan Rumah Sakit berdasarkan Tingkat Kepentingan pada PT Pertamina (Persero),” *Perbandingan Algoritma K-Means dan Naive Bayes untuk Memprediksi Prioritas Pembayaran Tagihan Rumah Sakit berdasarkan Tingkat Kepentingan pada PT Pertamina (Persero)*, vol. 13, pp. 1–8, Apr. 2021.
- [5] K. Anwar, A. Syukur, ; Ricardus, and A. Pramunendar, “Optimasi Artificial Neural Network Menggunakan Particle Swarm Optimization Untuk Prediksi Kredit Macet,” 2017.
- [6] T. W. Pratiwi and T. Arifin, “SISTEMASI: Jurnal Sistem Informasi Optimasi Decision Tree Menggunakan Particle Swarm Optimization untuk Klasifikasi Kesuburan pada Pria.” [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>
- [7] Saprudin, “Penerapan Particle Swarm Optimization (PSO) untuk Klasifikasi dan Analisis Kredit dengan Menggunakan Algoritma C4.5,” *Jurnal Informatika Universitas Pamulang*, vol. 2, no. No.4, pp. 1–6, Dec. 2017.
- [8] “Komparasi Algoritma Klasifikasi C4.5 Dan C4.5 Berbasis Particle Swarm Optimization 2023”.
- [9] A. R. Naufal and A. T. Suseno, “Penerapan Fitur Seleksi dan Particle Swarm Optimization pada Algoritma Support Vector Machine untuk Analisis Credit Scoring,” *Journal of Computer System and Informatics (JoSYC)*, vol. 5, no. 1, pp. 184–195, Nov. 2023, doi: 10.47065/josyc.v5i1.4409.
- [10] A. H. Al-Mter, S. Lu, Y. E. A Al-Salhi, and A. A. G Al-Hamodi, “A Particle Swarm Optimization Based on Multi Objective Functions with Uniform Design,” 2016. [Online]. Available: www.internationaljournalssrg.org

- [11] A. G. Gad, "Particle Swarm Optimization Algorithm and Its Applications: A Systematic Review," *Archives of Computational Methods in Engineering*, vol. 29, no. 5, pp. 2531–2561, Aug. 2022, doi: 10.1007/s11831-021-09694-4.
- [12] A. R. Naufal and A. T. Suseno, "Penerapan Fitur Seleksi dan Particle Swarm Optimization pada Algoritma Support Vector Machine untuk Analisis Credit Scoring," *Journal of Computer System and Informatics (JoSYC)*, vol. 5, no. 1, pp. 184–195, Nov. 2023, doi: 10.47065/josyc.v5i1.4409.
- [13] M. Saputra and J. Saragih, "Instal: Jurnal Komputer Implementation of the K-Means Clustering Algorithm in Grouping Students Based on Learning Style Using Rapidminer", doi: 10.54209/jurnalkomputer.v15i02.141.
- [14] N. Sirait, S. Yeremia Situmeang, W. Zaluku, and W. Matias Panjaitan, "Data Visualization Using The Rapid Miner Application To Evaluate Sales Patterns," *Jurnal INFOKUM*, vol. 11, no. No.4, pp. 1–11, 2023, [Online]. Available: <http://infor.seaninstitute.org/index.php/infokum/index>
- [15] M. Shahrizan *et al.*, "The Application of Decision Tree Classification Algorithm on Decision-Making for Upstream Business," 2023. [Online]. Available: www.ijacsa.thesai.org
- [16] M. Y. Kurniawan and M. E. Rosadi, "Kurniawan, Rosadi-Optimasi Decision Tree Menggunakan Particle Swarm Optimiziation Pada Data Siswa Putus Sekolah," 2017.
- [17] J. Zainal, A. Pagar, A. No, G. Meneng, and B. Lampung, "Seminar Nasional Teknologi dan Bisnis 2018 IIB DARMAJAYA Bandar Lampung," 2018.
- [18] A. S. Hussein, T. Li, C. W. Yohannese, and K. Bashir, "A-SMOTE: A new preprocessing approach for highly imbalanced datasets by improving SMOTE," *International Journal of Computational Intelligence Systems*, vol. 12, no. 2, pp. 1412–1422, 2019, doi: 10.2991/ijcis.d.191114.002.
- [19] B. Nemade, V. Bharadi, S. S. Alegavi, and B. Marakarkandy, "International Journal of INTELLIGENT SYSTEMS AND APPLICATIONS IN ENGINEERING A Comprehensive Review: SMOTE-Based Oversampling Methods for Imbalanced Classification Techniques, Evaluation, and Result Comparisons." [Online]. Available: www.ijisae.org
- [20] A. Y. Triyanto and R. Kusumaningrum, "Implementasi Teknik Sampling untuk Mengatasi Imbalanced Data pada Penentuan Status Gizi Balita dengan Menggunakan Learning Vector Quantization Implementation of Sampling Techniques for Solving Imbalanced Data Problem in Determination of Toddler Nutritional Status using Learning Vector Quantization," vol. 19, pp. 39–50, 2017.