

Economic Bulletin: Joint Research Program – Issue 59

Prediksi Besar Klaim Asuransi Kesehatan Berdasarkan *Multilayer Perceptron - Particle Swarm Optimization*

Abstrak

Introduction/Main Objectives: Prediksi besar klaim yang tepat sangat penting bagi perusahaan asuransi untuk mengelola risiko dan menjaga stabilitas keuangan serta menjaga margin keuntungan perusahaan asuransi. Permasalahan prediksi besar klaim adalah tugas yang kompleks dan sulit. Metode *Machine Learning* (ML) menjanjikan solusi yang baik untuk memprediksi besar klaim dibandingkan dengan metode konvensional. Salah satu metode ML yang terkenal adalah *Artificial Neural Networks* (ANNs). ANNs menawarkan beberapa keunggulan dibandingkan metode ML lainnya, seperti *Support Vector Regression* (SVR) dan *Linear Regression* (LR). *Multilayer Perceptron* (MLP) adalah salah satu jenis ANNs yang telah digunakan untuk berbagai aplikasi dan mampu menangkap hubungan non-linier yang kompleks dalam data. Namun penelitian sebelumnya menunjukkan bahwa parameter MLP berperan penting dalam mempelajari dan menggeneralisasi data secara efektif. Pemilihan parameter MLP biasanya dilakukan dengan cara *trial and error* sehingga kinerjanya kurang optimal dan memerlukan banyak waktu serta memerlukan keahlian. Algoritma *Particle Swarm Optimization* (PSO) menawarkan banyak keuntungan untuk memilih parameter MLP terbaik. Oleh karena itu, artikel ini mengusulkan metode prediksi besar klaim asuransi Kesehatan berbasis MLP dan PSO (MLP-PSO).

Background Problems: Bagaimana memprediksi besar klaim asuransi kesehatan untuk mengoptimalkan strategi penetapan harga dan meningkatkan pengelolaan risiko.

Novelty: Keterbaruan pada penelitian ini adalah penggunaan ANNs dengan *hyperparameter tuning* untuk prediksi besar klaim.

Research Methods: Data yang digunakan bersumber dari kaggle.com. Penelitian dimulai dari pengumpulan data, studi literatur, *preprocessing* data, kontruksi algoritma dan implementasi program, pengujian program dan evaluasi hasil program.

Finding/Results: Metode prediksi besar klaim asuransi kesehatan berbasis MLP-PSO yang memiliki kemampuan prediksi yang baik dan *hyperparameter* MLP ditentukan otomatis.

Conclusions: Metode yang diusulkan menghasilkan prediksi besar klaim yang lebih akurat dibandingkan MLP tanpa optimisasi *hyperparameter* dan metode ML terkenal lainnya. Metode ini berpotensi digunakan untuk mengoptimalkan strategi penetapan harga premi, meningkatkan pengelolaan risiko, dan menjaga keberlanjutan industri asuransi.

Syaiful Anam
syaiful@ub.ac.id

Universitas Brawijaya

Indah Yanti
indah_yanti@ub.ac.id

Universitas Brawijaya

Umu Sa'daah
u.saadah@ub.ac.id

Universitas Brawijaya

Nada Serpina
nada.serpina@ifg.id

Indonesia Financial Group

Ezra Pradipta Hafidh
ezra.pradipta@ifg.id

Indonesia Financial Group

Rosi Melati
rosi.melati@ifg.id

Indonesia Financial Group

Acknowledgment: Penelitian ini merupakan hasil kerjasama program *Joint Research* yang didukung dan dibiayai oleh Indonesia Financial Group.

Pendahuluan

Asuransi kesehatan menjadi komponen utama dalam sistem layanan kesehatan secara global dan memainkan peran penting dalam memberikan perlindungan finansial serta memastikan akses terhadap layanan medis penting (Wahyu and Ramdhani, 2024). Besar klaim menjadi salah satu faktor utama penetapan harga premi. Prediksi besar klaim yang tepat sangat penting bagi perusahaan asuransi untuk mengelola risiko, menjaga stabilitas keuangan dan berdampak pada margin keuntungan perusahaan asuransi (Anam dkk., 2023). Prediksi besar klaim yang akurat memungkinkan perusahaan asuransi untuk mengoptimalkan strategi penetapan harga (Acar dkk., 2021), meningkatkan praktik manajemen risiko (Nadeb dkk., 2020) dan meningkatkan keberlanjutan keuangan (Burney dkk., 2022).

Namun, menentukan besar klaim merupakan tugas yang kompleks dan sulit. Metode *Machine Learning* (ML) menjanjikan solusi yang baik untuk memprediksi besaran klaim polis asuransi dibandingkan dengan metode analisis data konvensional karena ML memiliki banyak keunggulan seperti menangani struktur data yang kompleks dan berdimensi tinggi (Pesantez-Narvaez dkk., 2019), serta skalabilitas dan efisiensi (Qazvini, 2019). Salah satu keunggulan utama ML adalah kemampuannya memproses kumpulan data yang kompleks dan besar secara efisien, mengekstraksi wawasan berharga dari sejumlah besar informasi (Li dkk., 2022). Keuntungan lain dari ML adalah kemampuannya untuk menangkap hubungan nonlinier yang kompleks dalam data, sehingga menghasilkan akurasi prediksi yang lebih baik dibandingkan model regresi konvensional (Zhou dkk., 2021).

Metode ML telah berhasil digunakan di berbagai aplikasi, termasuk di bidang asuransi. Salah satu metode ML yang terkenal adalah *Artificial Neural Networks* (ANNs). ANNs menawarkan beberapa keunggulan dibandingkan metode ML lainnya dalam hal prediktabilitas dan performa generalisasi, seperti *Support Vector Regression* (SVR) dan *Linear Regression* (LR) (Komarica dkk., 2024; Khan dkk., 2019). ANNs menawarkan beberapa keunggulan dibandingkan metode tradisional dalam berbagai aplikasi. Berbeda dengan metode tradisional, ANNs dapat menangkap pola kompleks dan ketergantungan dalam data, sehingga cocok untuk tugas-tugas yang hubungannya rumit dan non-linier (Larasati dkk., 2019). ANNs juga memiliki kemampuan untuk belajar dari pengalaman dan beradaptasi dengan perubahan lingkungan dan pola data, sehingga meningkatkan kinerjanya seiring berjalannya waktu (Ibrahim, 2020; Mahdi dkk., 2022). ANNs juga memiliki kemampuan untuk menangani pola dan hubungan data yang rumit (Shahid dkk., 2019). ANNs juga telah digunakan secara luas untuk banyak aplikasi, seperti diagnosis klinis (Ibrahim, 2020), analisis pencitraan medis (Wei dkk., 2023), deteksi penyakit (Azeem dkk., 2023), optimalisasi sumber daya layanan

kesehatan (Qiu dkk., 2019), pengobatan yang dipersonalisasi (Amato dkk., 2013), sistem pendukung keputusan medis (Shen dkk. 2019), dan lain-lain. Salah satu jenis ANNs adalah *Multilayer Perceptron* (MLP) menawarkan banyak keunggulan yang mampu menangkap kompleks hubungan non-linier dalam data (Larasati dkk., 2019), dapat beradaptasi dengan perubahan pola data dan belajar dari pengalaman (Ibrahim dkk., 2020) dan secara efektif memperkirakan berbagai fungsi kompleks (Huuhanan & Jung, 2020). MLP dikenal dengan kinerjanya yang tinggi dalam berbagai aplikasi, termasuk tugas regresi.

Namun penelitian sebelumnya menunjukkan bahwa parameter MLP berperan penting dalam menentukan kemampuan jaringan dalam mempelajari dan menggeneralisasi data secara efektif. Pemilihan parameter MLP biasanya dilakukan dengan cara *trial and error* sehingga kinerjanya kurang optimal dan memerlukan banyak waktu. Algoritma *Particle Swarm Optimization* (PSO) dapat digunakan untuk memilih parameter MLP terbaik. PSO merupakan algoritma optimasi berbasis populasi yang unggul dalam menemukan global optima dalam ruang pencarian yang kompleks (Wang dkk., 2021). PSO dikenal karena kemampuan adaptasinya terhadap perubahan lingkungan dan lanskap permasalahan yang dinamis (Zhao dkk., 2023). PSO dapat diterapkan pada berbagai masalah optimasi dan telah berhasil digunakan di berbagai bidang karena fleksibilitas dan efektivitasnya (Jiang dkk., 2022). PSO relatif mudah diimplementasikan dan efisien secara komputasi dibandingkan dengan beberapa algoritma optimasi lainnya. Kesederhanaan dan efektivitasnya menjadikannya pilihan populer untuk berbagai masalah optimasi (Lin dkk., 2020). PSO juga telah digunakan untuk banyak aplikasi, seperti alokasi perangkat sistem transmisi AC fleksibel dalam sistem transmisi listrik (Jordehi, 2015), prediksi dinamika COVID-19 (Zrieq dkk., 2020), dan alokasi sumber daya (Gong dkk., 2012).

Berdasarkan latar belakang yang telah dijelaskan sebelumnya, artikel ini mengusulkan metode prediksi besar klaim asuransi kesehatan berbasis MLP dan PSO (MLP-PSO). Dengan mengintegrasikan MLP dengan PSO, artikel ini memberikan beberapa kontribusi dan manfaat, yaitu:

- meningkatkan akurasi dan generalisasi performa ANNs / MLP dengan memilih *hyperparameter* MLP dengan PSO,
- mengurangi waktu untuk memilih *hyperparameter* MLP terbaik karena metode yang diusulkan memiliki kemampuan untuk memilih *hyperparameter* MLP secara otomatis, dan
- memberikan metode alternatif yang baik untuk memperkirakan besar klaim asuransi kesehatan untuk mengoptimalkan strategi penetapan harga, meningkatkan pengelolaan risiko dan meningkatkan keberlanjutan industri asuransi.

Studi Literatur

Bagian ini akan membahas penelitian terdahulu yang terkait dengan prediksi besar klaim, ANNs dan *hyperparameters tuning* dari model ML.

State of Art dari Metode Prediksi Besar Klaim

Perusahaan asuransi menghadapi tantangan di berbagai bidang. Salah satu tantangan terbesarnya adalah menemukan keseimbangan antara menutupi biaya sambil menawarkan kemungkinan premi yang terendah untuk menarik dan mempertahankan pelanggan. Perusahaan asuransi perlu mempertimbangkan teori ekonomi dalam pengambilan keputusan dalam kondisi ketidakpastian dan utilitas yang diharapkan ketika menetapkan harga premi (Goovaerts & Laeven, 2008).

Peningkatan prediktabilitas besar klaim sangat penting bagi investor dan analis keuangan dalam mengambil keputusan yang tepat mengenai alokasi aset dan manajemen risiko, yang pada akhirnya akan menghasilkan hasil investasi yang lebih baik. Prediksi besar klaim dapat membantu pemangku kepentingan mengatasi ketidakpastian pasar dan mengoptimalkan strategi investasi mereka untuk memanfaatkan peluang potensial. Prediksi besar klaim secara akurat merupakan tantangan penting bagi perusahaan asuransi, khususnya bagi spesialis keuangan dan *underwriters* (Anam, 2023). Prediksi besar klaim yang tepat diperlukan untuk menyusun anggaran keuangan tahunan perusahaan asuransi (Goundar dkk., 2020).

Salah satu pendekatan untuk memprediksi besar klaim adalah dengan memodelkan distribusi probabilitas yang mendasari besar atau jumlah klaim. Penelitian menemukan bahwa besar klaim dapat mengikuti distribusi seperti distribusi Poisson untuk jumlah klaim dan distribusi nilai ekstrim umum untuk jumlah klaim (Prabowo dkk., 2019; Selvakumar dkk., 2022). Pendekatan ini dapat dillakukan jika distribusi besar klaim diketahui, tetapi sering kali distribusi besar klaim sulit ditentukan jenisnya.

Saat ini, pendekatan terhadap prediksi besar klaim pada industri asuransi mengalami transformasi signifikan, berkat integrasi ML dan teknik pemodelan prediktif. Algoritma ML telah terbukti memberikan hasil yang akurat dalam memprediksi pengeluaran pasien yang berbiaya tinggi dan sangat dibutuhkan, sehingga perusahaan asuransi semakin beralih ke pendekatan ML untuk meningkatkan kebijakan dan pengaturan premi (Yang dkk., 2018). Salah satu keunggulan utama ML adalah kemampuannya dalam memproses hubungan nonlinier yang kompleks antar prediktor, sehingga menghasilkan prediksi yang lebih stabil dan akurat (Goto dkk. (2019). Kemampuan ini sangat bermanfaat

ketika menangani kumpulan data rumit yang mungkin berisi pola non-linier yang mungkin sulit ditangkap oleh model regresi tradisional secara efektif. Selain itu, metode ML telah menunjukkan keunggulan dalam memprediksi titik balik dan memperkirakan tren jangka panjang dibandingkan metode konvensional (Herrera dkk., 2019).

State of Art dari Metode ML dan Metode ANN

ML merupakan salah satu cabang dari *Artificial Intelligence* (AI) yang akhir-akhir ini semakin populer di bidang komputasi dan analisis data. ML mampu membuat aplikasi berperilaku cerdas (Sarker and Nowrozy., 2021). ML dalam industri 4.0 dianggap sebagai salah satu teknologi populer yang memungkinkan aplikasi belajar dari pengalaman (Sarker dkk., 2020), ini juga memungkinkan diterapkan pada industri asuransi.

Performa dan karakteristik algoritma ML serta sifat datanya akan menentukan efisiensi dan efektivitas solusi berdasarkan ML. ML menawarkan keunggulan dibandingkan metode tradisional dalam mempelajari fitur dan representasi hierarki dari kumpulan data besar dalam ruang berdimensi tinggi dan menangani kompleksitas nonlinier (Firdaus dkk., 2021; Shao dkk., 2018). Beberapa studi menunjukkan keunggulan ML dibandingkan metode tradisional (LeCun dkk., 2015; Herrera dkk., 2019; Pham dkk., 2023; Wang, 2022). Saat ini metode ML sudah banyak diterapkan dalam berbagai permasalahan yang kompleks.

Salah satu metode ML yang terkenal adalah ANNs. ANNs menawarkan beberapa keunggulan dibandingkan metode ML lainnya, menjadikannya pilihan populer dalam berbagai aplikasi. Beberapa studi menunjukkan keunggulan ANNs dibandingkan model LR. Salah satu keunggulan utamanya adalah kemampuan jaringan saraf untuk menangani hubungan nonlinier secara efektif, yang merupakan keterbatasan model LR (Sarmadian & Taghizadeh-Mehrjardi, 2014). ANNs juga memungkinkan untuk menangkap pola dan hubungan kompleks dalam data dengan lebih akurat. Fleksibilitas dalam pemodelan bentuk fungsional nonlinier ini memberi ANNs keunggulan signifikan dibandingkan LR dalam menangkap kompleksitas data dunia nyata (Zhang dkk., 2021).

Selain itu, ANNs memungkinkan jaringan tersebut mempelajari pola yang rumit dan membuat prediksi yang lebih baik dibandingkan LR (Ghanem dkk., 2022). Peningkatan fleksibilitas ini memungkinkan ANNs beradaptasi dengan beragam kumpulan data dan menangkap hubungan rumit yang mungkin tidak dapat ditangkap oleh model LR (Rahimi, 2017). Selain itu, ANNs tidak memerlukan asumsi apriori tentang hubungan antara data masukan dan keluaran, tidak seperti model regresi tradisional (Sarmadian & Taghizadeh-Mehrjardi, 2014).

ANNs dibandingkan dengan KNN cenderung berperforma lebih baik pada kumpulan data yang besar dan memiliki risiko *overfitting* yang lebih kecil

(Lerebourg, 2022). Penelitian sebelumnya juga menunjukkan bahwa tingkat akurasi yang lebih tinggi dengan model ANNs dibandingkan dengan KNN (Rahman, 2023). Penelitian sebelumnya juga memperlihatkan bahwa ANN juga lebih unggul dibandingkan dengan Naïve Bayes dalam hal akurasi (Yulhendri dkk., 2023), kefleksibelan dan keadatifan (Chen dkk., 2019), dan menangani data yang kompleks (Chen dkk., 2019). Performa dari ANNs juga lebih unggul jika dibandingkan dengan DT, dalam hal akurasi (Lee and Ham, 2022; Mirzakhani, 2022), kefleksibelan dan keadatifan (Tseng dkk., 2015), dan menangani data yang kompleks (Wu, 2009).

***Hyperparameter Tuning* dan Algoritma SI**

Biasanya algoritma ML mengubah masalah yang perlu diselesaikan menjadi permasalahan optimisasi dan menggunakan metode optimisasi untuk menyelesaikan masalah tersebut. Fungsi pengoptimalan dibentuk dari *hyperparameter* yang ditetapkan sebelum proses pembelajaran mempengaruhi algoritma ML dalam menyesuaikan model dengan data. *Hyperparameter* yang berbeda dari parameter model internal, seperti bobot ANNs, dapat dipelajari dari data selama fase pelatihan model. Sebelum fase pelatihan, sekumpulan nilai *hyperparameter* yang menghasilkan performa terbaik pada data ingin ditemukan dalam jangka waktu yang wajar. Proses ini disebut *hyperparameter optimization* atau *hyperparameter tuning*. *Hyperparameter tuning* memainkan peran penting dalam akurasi prediksi algoritma ML. Namun, hubungan antara performa algoritma ML dan *hyperparameter* tidak jelas sehingga tidak ada formulasi matematis untuk menentukan *hyperparameter* yang optimal. Oleh karena itu, cara mengoptimalkan *hyperparameter* menjadi isu utama dalam algoritma ML.

Secara umum ada dua jenis metode optimisasi *hyperparameter*, yaitu metode pencarian manual dan metode pencarian otomatis. Pencarian manual mencoba himpunan *hyperparameter* dengan cara coba-coba secara manual. Hal ini bergantung pada intuisi mendasar dan pengalaman pengguna dalam mengidentifikasi parameter penting yang berdampak lebih besar pada hasil dan kemudian menentukan hubungan antara parameter tertentu dan hasil akhir melalui alat visualisasi (Aarshay, 2018). Pencarian manual mengharuskan pengguna untuk memiliki latar belakang pengetahuan yang lebih profesional dan pengalaman praktis serta sulit diterapkan oleh pengguna yang bukan ahli. Selain itu, seiring bertambahnya jumlah *hyperparameter* dan rentang nilai, pengelolaannya menjadi cukup sulit karena manusia tidak pandai menangani data berdimensi tinggi dan mudah salah menafsirkan atau melewatkannya tren dan hubungan dalam *hyperparameter*.

Algoritma pencarian otomatis telah diusulkan untuk mengatasi kelemahan pencarian manual, seperti pencarian *grid* (Bergstra and Bengio, 2012) atau pencarian *hyperparameter Cartesian*. Pencarian *grid* melatih model ML dengan

setiap kombinasi kemungkinan nilai *hyperparameter* pada himpunan pelatihan dan mengevaluasi kinerja berdasarkan metrik yang telah ditentukan pada himpunan validasi silang. Meskipun metode ini mencapai penyetelan otomatis dan secara teoritis dapat memperoleh nilai optimal global dari fungsi tujuan pengoptimalan, namun efisiensi algoritma menurun dengan cepat seiring dengan jumlah *hyperparameter* yang disetel dan rentang nilai *hyperparameter* yang meningkat.

Algoritma pencarian acak telah diusulkan untuk mengatasi masalah biaya mahal dalam pencarian *grid*, yang menemukan bahwa untuk sebagian besar kumpulan data, hanya beberapa *hyperparameter* yang benar-benar penting (Bergstra and Bengio, 2012). Efisiensi keseluruhan dapat ditingkatkan dengan mengurangi pencarian ke *hyperparameter* yang tidak penting, dan akhirnya solusi perkiraan dari fungsi optimasi diperoleh. Pencarian acak dibandingkan dengan pencarian *grid* lebih efisien dalam ruang berdimensi tinggi (Bergstra dkk., 2011). Namun, pencarian acak tidak dapat diandalkan untuk melatih beberapa model yang kompleks (Bergstra and Bengio, 2012). Oleh karena itu, cara membuat algoritma penyetelan otomatis mencapai presisi tinggi dan efisiensi tinggi selalu menjadi masalah yang belum sepenuhnya terpecahkan dalam ML.

Sebagian besar pekerjaan sebelumnya dalam penyetelan *hyperparameter* cenderung hanya berfokus pada pencarian *grid* dan pencarian acak, atau perbandingan di antara keduanya. Kinerja ML dapat ditingkatkan secara signifikan menggunakan optimasi parameter. Kinerja ML ditingkat dengan menerapkan dua metode yaitu pencarian *grid* dan *Genetic Algorithm* (GA) (Syarif dkk., 2016). Berdasarkan waktu berjalan rata-rata pada kumpulan data yang berbeda, GA hampir 16 kali lebih cepat dibandingkan pencarian *grid*. Penelitian lain juga melakukan perbandingan antara pencarian *grid* dan GA (Wicaksono dkk., 2018). Hasil implementasi menunjukkan bahwa GA dapat menemukan *hyperparameter* dengan waktu komputasi lebih cepat dibandingkan pencarian *grid*.

Metode optimisasi *hyperparameter* dari model prediksi dapat dilakukan dengan menggunakan algoritma SI. Algoritma SI dapat memecahkan masalah yang kompleks dan menantang karena kemampuannya sifat dinamis. Algoritma SI menawarkan berbagai keunggulan yang menjadikannya berharga di berbagai bidang. Metode SI memiliki sedikit asumsi tentang masalah yang akan dioptimalkan serta mampu mendapatkan solusi optimal atau solusi mendekati optimal di ruang besar dengan biaya komputasi yang dapat diterima (Dubitzky dkk., 2013; Kordon, 2013). Selain itu, SI mempunyai kemampuan untuk menemukan global optimum yang efisien dari banyak lokal optimum, tidak memerlukan turunan, *robust*, mudah diterapkan (Anam dan Fitriah, 2021). Fitur ini menjadikannya sangat cocok untuk memecahkan masalah multimoda dan mengoptimalkan solusi dalam berbagai scenario. Selain itu, algoritma SI menunjukkan efek konvergensi dan keseimbangan yang kompetitif, sehingga

meningkatkan kemampuan eksplorasi dan deteksinya. Algoritma ini telah terbukti mengungguli teknik pengoptimalan lainnya dalam hal efisiensi dan efektivitas dalam aplikasi teknik. PSO merupakan algoritma SI yang unggul dalam menemukan global optima dalam ruang pencarian yang kompleks (Wang dkk., 2021).

Metodologi Penelitian

Bagian ini akan menjelaskan metodologi penelitian yang digunakan dalam penelitian ini. Tahapan tersebut antara lain adalah pencarian dan kajian pustaka, pengumpulan data, perancangan dan pengembangan algoritma, implementasi hasil rancangan algoritma pada bahasa pemrograman, pengujian program dan evaluasi hasil program, analisis hasil dan pembuatan kesimpulan. Diagram alir dari penelitian yang akan dilakukan dapat dilihat pada Gambar 1. Penjelasan dari setiap tahapan dari penelitian adalah sebagai berikut.

1. Tahap Pengumpulan Pustaka dan Kajian Pustaka

Penelitian ini dimulai dengan pengumpulan pustaka dan pengkajian pustaka atau teori. Pustaka yang dikaji antara lain adalah metode prediksi besar klaim, metode ML dan ANNs, dan *hyperparameters tuning* dan algoritma SI. Hasil dari kajian pustaka ini adalah pemahaman terhadap penelitian yang sudah dikerjakan pada bidang ini. Selain itu hasil dari kajian pustaka ini adalah pemahaman cara kerja dan karakteristik masing-masing metode serta keunggulan dan kelemahan dari masing-masing metode. Hasil kajian pustaka ini digunakan untuk pengembangan metode besar klaim yang akan dilakukan.

2. Tahap Pengumpulan Data

Data yang dikumpulkan adalah data pelanggan asuransi dan besar klaim dari pelanggan asuransi kesehatan. Data yang diambil adalah data sekunder yang berasal dari situs Kaggle.com.

3. Tahap Pengembangan Algoritma

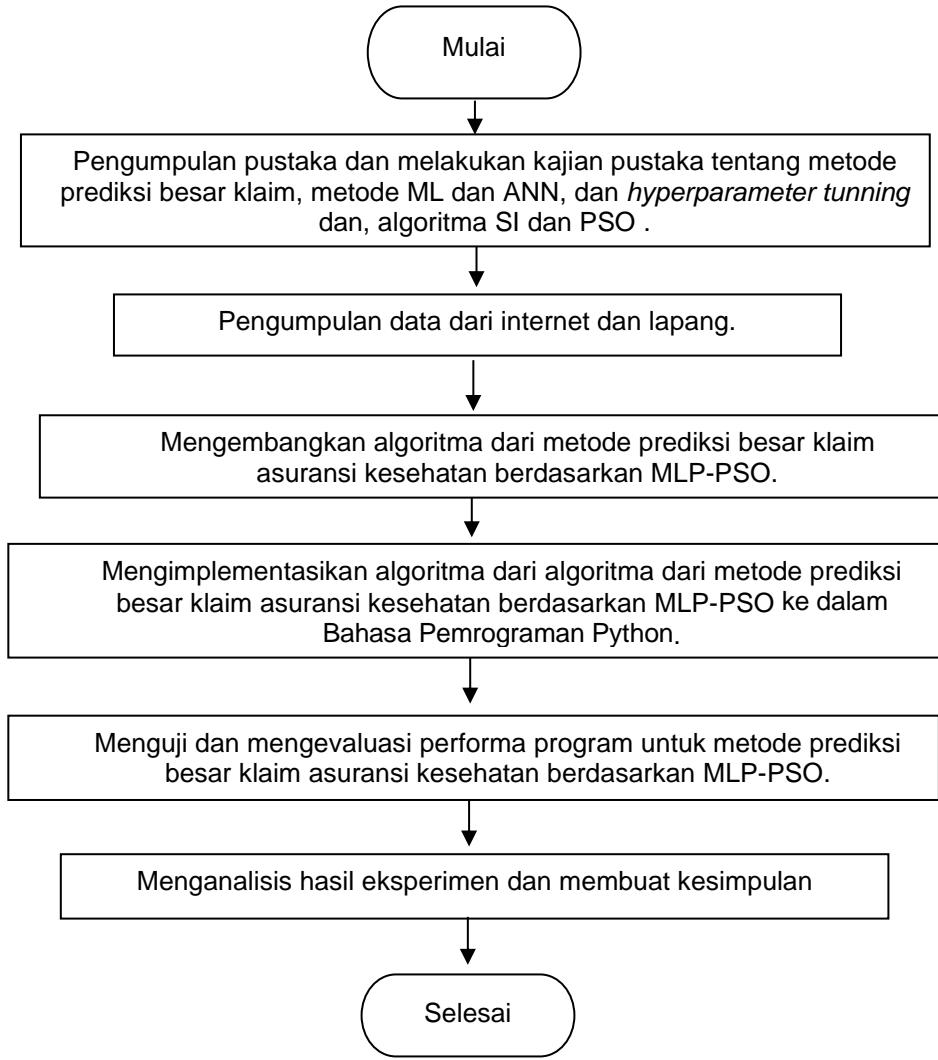
Langkah selanjutnya adalah mengembangkan algoritma dari metode prediksi besar klaim asuransi kesehatan berdasarkan MLP dengan PSO. Hasil dari tahap pengembangan algoritma adalah algoritma dari metode prediksi besar klaim asuransi kesehatan yang siap diimplementasikan ke dalam Bahasa Pemrograman.

4. Tahap Implementasi Program

Implementasi program metode prediksi besar klaim asuransi kesehatan berdasarkan MLP-PSO *hyperparameter optimization* pada tahap ini dilakukan dengan menggunakan Jupyter Notebook. Metode *preprocessing data* juga

digunakan pada tahap ini untuk memastikan data siap untuk diproses lebih lanjut. Implementasi dari metode yang diusulkan menggunakan software Python. Python dipilih karena merupakan freeware atau open source dan menyediakan banyak pustaka yang diperlukan dalam penelitian ini.

Exhibit 1. Diagram alur dari metode penelitian



5. Tahap Pengujian dan Evaluasi.

Program yang dihasilkan sebelumnya dievaluasi dan diuji dengan menggunakan dataset yang sudah didapatkan pada tahap kedua dalam proses penelitian ini. Penentuan parameter yang tepat pada metode yang diusulkan dilakukan pada tahap ini. Parameter yang dimaksud adalah parameter pada metode PSO sehingga menghasil performa yang bagus pada metode MLP. Keberhasilan program dievaluasi dengan membandingkan hasil prediksi program dengan data nyata yang sudah ada labelnya. Alat ukur keberhasilan metode yang diusulkan adalah RMSE dan MAPE.

6. Tahap Analisis Hasil dan Pembuatan Kesimpulan

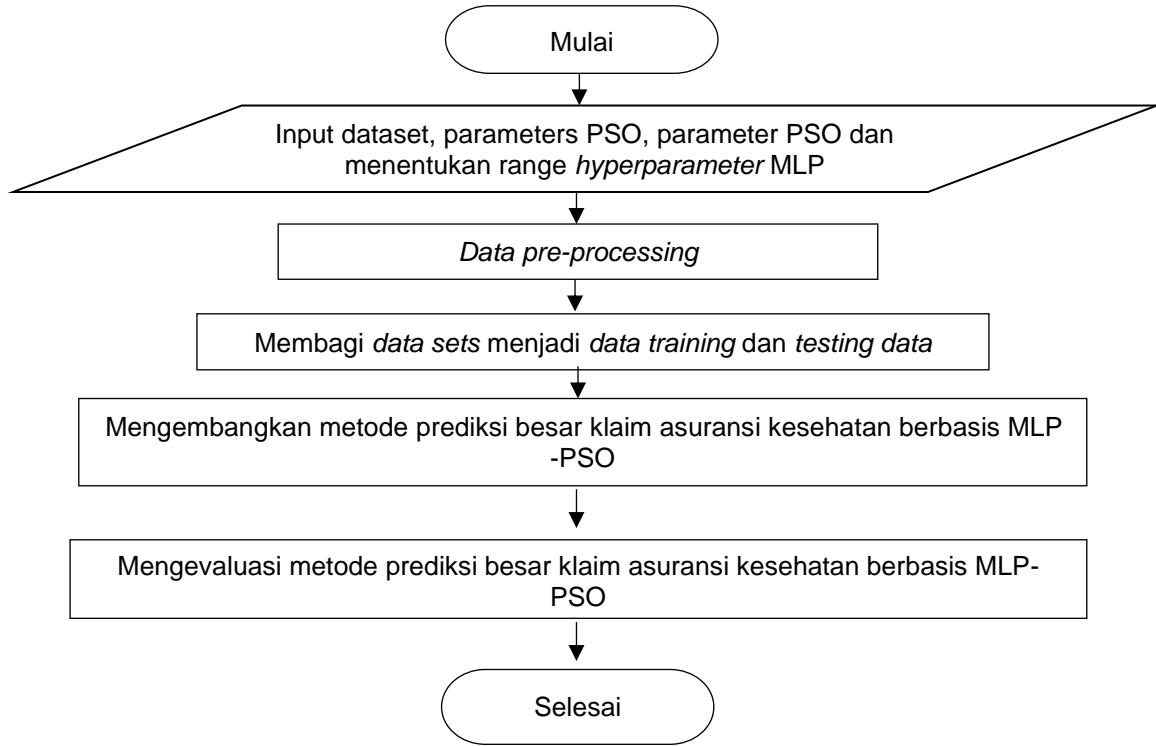
Analisis hasil dilakukan berdasarkan hasil eksperimen yang dilakukan pada tahap sebelumnya. Hasil analisis ini menjadi dasar pengambilan kesimpulan. Hasil dari tahap ini adalah kesimpulan dan saran-saran perbaikan yang dapat dikerjakan pada penelitian selanjutnya.

Hasil Penelitian dan Pembahasan

Bagian ini akan membahas metode prediksi besar klaim asuransi Kesehatan yang diusulkan yaitu meliputi input data, *data preprocessing*, pengembangan metode prediksi besar klaim asuransi kesehatan dan evaluasi dari metode yang diusulkan.

Metode yang Diusulkan

Exhibit 2. Diagram alur dari metode yang diusulkan



1. Input dataset, parameter PSO dan menentukan range hyperparameter MLP

Penelitian ini menggunakan kumpulan data klaim jumlah kesehatan (health charge) dari Kaggle.com. Jumlah dataset sebanyak 1337 data. Tabel 1 menampilkan contoh dataset besar klaim asuransi kesehatan. *Age*, *sex*, *BMI*, *children*, *smoker* dan *region* merupakan fitur dari kumpulan data besar klaim

asuransi kesehatan. Targetnya adalah biaya atau besar klaim. Penjelasan masing-masing fiturnya dapat dilihat pada Table 1.

Penelitian ini menggunakan PSO untuk mengoptimalkan hyperparameter MLP [21]. Parameter PSO ditentukan diawal iterasi. Jumlah partikel yang digunakan adalah 10, 20, 50 dan 100 partikel. Jumlah maksimum iterasi yang dapat digunakan adalah 50, 100, dan 500. Bobot inersia yang digunakan adalah 0,7. Sedangkan untuk parameter kognitif dan parameters sosial masing-masing adalah 1,49 dan 1,49. Hyperparameter MLP adalah kecepatan pembelajaran, ukuran lapisan tersembunyi, dan iterasi maksimum. Kisaran parameter yang digunakan masing-masing adalah [0,0001, 0,1], [5,100], [50,1000] untuk kecepatan pembelajaran, ukuran lapisan tersembunyi, dan iterasi maksimum.

Exhibit 3. Penjelasan fitur

Nama Fitur	Penjelasan
<i>Age</i>	Bertambahnya usia akan meningkatkan risiko masyarakat untuk mengajukan klaim.
<i>Sex</i>	Beberapa penyakit dipengaruhi oleh jenis kelamin. Artinya, jenis kelamin mempengaruhi risiko orang untuk mengajukan klaim.
<i>Body Mass Index (BMI)</i>	BMI dapat digunakan untuk menghitung lemak tubuh. BMI menunjukkan tingkat kesehatan seseorang.
<i>Children</i>	Variabel anak menggambarkan jumlah anak.
<i>Smoker</i>	Kebiasaan perokok mempengaruhi seseorang untuk terserang penyakit, salah satunya kanker.
<i>Region</i>	Lingkungan suatu wilayah akan mempengaruhi kesehatan masyarakatnya.

Exhibit 4. Contoh dataset besar klaim asuransi kesehatan

No	age	sex	BMI	children	smoker	region	charges
1	19	female	27.900	0	yes	southwest	16884.92400
2	18	male	33.770	1	no	southeast	1725.55230
3	28	male	33.000	3	no	southeast	4449.46200
4	33	male	22.705	0	no	northwest	21984.47061
5	32	male	28.880	0	no	northwest	3866.85520
...

2. Data Preprocessing

Pra-pemrosesan data memiliki tujuan untuk mempersiapkan data untuk diproses oleh model MLP. Pra-pemrosesan data digunakan untuk menangani nilai yang hilang. Selain, *data preprocessing* dilakukan untuk mengubah data non numerik menjadi data numerik, salah satunya dengan menggunakan *label encoder* sehingga data menjadi data baru dan sesuai dengan model yang digunakan. Penelitian ini menggunakan normalisasi *standar scaler* untuk menskalakan atribut

data agar berada dalam rentang tertentu. Normalisasi data umumnya berguna untuk algoritma pembelajaran mesin. Hal ini membuat implementasi algoritma data mining menjadi lebih mudah, efektif dan efisien.

3. *Data Splitting*

Dataset perlu dipecah menjadi dua bagian untuk membuat metode prediksi besar klaim asuransi kesehatan berbasis MLP-PSO yaitu dataset pelatihan dan pengujian. Penelitian ini menggunakan 80% data latih dan 20% data uji. Antar subkumpulan data tidak boleh tumpang tindih. Data pelatihan digunakan untuk model pelatihan, sedangkan data pengujian digunakan untuk mengevaluasi model dan mencegah *overfitting*.

4. Mengembangkan Metode Prediksi Besar Klaim Asuransi Kesehatan berbasis MLP dan PSO

Setelah tahap *pre-processing data*, langkah selanjutnya adalah membangun metode prediksi jumlah klaim asuransi kesehatan berbasis MLP dan PSO. Pseudocode metode prediksi besar klaim asuransi kesehatan berbasis MLP dan PSO dapat dilihat pada **Algoritma 1**. PSO digunakan untuk mengoptimalkan hyperparameter MLP sehingga MLP akan menghasilkan kinerja yang optimal dalam prediksi besar klaim asuransi kesehatan. Partikel PSO mewakili kandidat hyperparameter MLP terbaik. Langkah pertama menentukan jumlah iterasi maksimum (*maxiter*), bobot inersia (*w*), parameter kognitif (*c₁*), parameter sosial (*c₂*), jumlah *swarm* (*s*), batas atas dan bawah, jumlah dimensi (*n*). Karena jumlah *hyperparameter* MLP adalah 3, maka jumlah dimensinya adalah 3. Langkah selanjutnya adalah menginisialisasi posisi dan kecepatan gerombolan secara acak di domain pencarian ($x_i(0), i = 1, 2, \dots, s$) dan ($v_i(0), i = 1, 2, \dots, s$). $x_i(0)$ dinyatakan sebagai ($x_{i1}(0), x_{i2}(0), x_{i3}(0)$). $x_{i1}(0), x_{i2}(0)$, dan $x_{i3}(0)$ mewakili kecepatan pembelajaran, ukuran lapisan tersembunyi, dan iterasi maksimum dalam MLP untuk partikel dan iterasi. Selanjutnya, solusi optimal global dicari oleh partikel melalui eksplorasi dan eksloitasi ruang pencarian.

Posisi dan kecepatan partikel diperbarui dengan menghitung persamaan (1) dan persamaan (2), masing-masing.

$$v_i(t+1) = v_i(t) + c_1 R_1(t)(x_i(t) - Pbest_i(t)) + c_2 R_2(t)(x_i(t) - Gbest(t)) \quad (1)$$

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (2)$$

$R_1(t)$ dan $R_2(t)$ dihasilkan dengan menghasilkan angka acak [0,1]. $Pbest_i(t)$ mewakili posisi partikel terbaik dari setiap partikel, dan $Gbest(t)$ mendefinisikan partikel terbaik global. Fungsi fitness MLP-PSO dihitung dengan meminimalkan MAE dari MLP. Setelah kriteria penghentian terpenuhi, langkah selanjutnya adalah

menggunakan kandidat hyperparameter terbaik yang digunakan sebagai parameter MLP.

Algoritma 1

1. Input DPSO parameters and dataset (*training data, testing data*)
2. Mendefinisikan range dari MLP *hyperparameters*
3. Inisialisasi $t = 1$, posisi x , dan kecepatan v
4. Menghitung nilai fitness dari semua partikel.
5. Hitung posisi terbaik setiap partikel dan posisi populasi terbaik global.
6. While *Stopping Criteria is not meet* do
 - a. $t = t + 1$
 - b. Perbarui bobot inersia, parameter kognitif, dan parameter sosial.
 - c. Perbarui posisi dan kecepatan partikel dengan persamaan (1) dan persamaan (2).
 - d. Hitung nilai *fitness* semua partikel
 - e. Hitung posisi terbaik dan posisi populasi terbaik global
- End while
7. Menggunakan posisi terbaik global untuk pelatihan MLP.
8. Mengguunakan model MLP untuk prediksi besar klaim asuransi kesehatan.

5. Mengevaluasi model prediksi

Langkah terakhir adalah melakukan penilaian terhadap model yang telah dibuat dengan memanfaatkan *hyperparameter* yang dihasilkan oleh PSO. Metrik evaluasi yang digunakan untuk mengembangkan model adalah MAPE dan RMSE. Metrik ini digunakan untuk menentukan model regresi kinerja. Perumusan MAPE dan RMSE diwakili oleh persamaan (3) dan persamaan (4).

$$MAPE = \frac{\sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right|}{N} \quad (3)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad (4)$$

y_i mendefinisikan kebenaran data dan \hat{y}_i mewakili perkiraan data. N adalah jumlah data. Nilai MAPE yang kurang dari 10% berarti akurasi prediksinya tinggi. Nilai MAPE lebih dari 10% dan kurang dari 20% berarti prediksinya baik. Nilai MAPE lebih dari 20% dan kurang dari 50% berarti prediksi masuk akal dan Nilai MAPE lebih dari 50% berarti prediksi lemah dan tidak akurat

Hasil dan Analisis Hasil Percobaan

Di sini disajikan metode prediksi besar klaim asuransi kesehatan berbasis MLP-PSO beserta hasil percobaan dan analisis temuan percobaan. Meskipun

menggunakan parameter yang sama, MLP-PSO dapat memberikan hasil yang berbeda karena menggunakan angka acak untuk menghasilkan hasilnya. Oleh karena itu, setiap percobaan pada penelitian ini dilakukan sebanyak 25 kali. Rata-rata dan deviasi standar MAPE dan RMSE, serta waktu komputasi, digunakan untuk menilai kinerja kedua teknik tersebut.

1. Hasil *Preprocessing*

Tabel 1 menunjukkan rentang nilai yang luas untuk setiap variabel, seperti usia, jenis kelamin, BMI, banyak anak, perokok, dan wilayah. Beberapa teknik ML, seperti ANNs, KNN, memerlukan data numerik dan skala data yang sama sebagai inputnya. Pengkodean label digunakan untuk mengubah data kategorial menjadi data numerik. Data pada Tabel 1 diterapkan metode *label encoder* untuk mengubah data non numerik menjadi data numerik dan selanjutnya diterapkan metode *standard scaler* untuk menyesuaikan data agar memiliki skala yang sama, sehingga cocok untuk pemodelan dan memastikan bahwa tidak ada fitur yang mempengaruhi algoritma secara tidak proporsional karena perbedaan skala. Hal ini membantu meningkatkan performa dan konvergensi model pembelajaran mesin, khususnya model yang sensitif terhadap skala fitur. Ilustrasi dataset setelah penerapan *label encoder* dan teknik *standard scaler* ditunjukkan pada Tabel 3.

2. Analisis Kinerja Metode Prediksi Besar Klaim Asuransi Kesehatan Berbasis MLP dan PSO

Bagian ini akan membahas evaluasi kinerja metode prediksi besar klaim asuransi kesehatan berbasis MLP-PSO. Hasil evaluasi metode prediksi besar klaim asuransi kesehatan berbasis MLP-PSO ditunjukkan pada Tabel 4, 5 dan 6. Hasil eksperimen menunjukkan bahwa untuk metrik penilaian MAPE dan RMSE, metode prediksi besar klaim asuransi kesehatan berbasis MLP-PSO lebih baik daripada parameter default beberapa metode ML yang dikenal, seperti *Decision Tree Regressor* (DTR), BR, *MLPRegressor* (MLPR), *Histogram Gradient Boosting Trees Regressor* (HGBTR), LR, KNN Regresor, SVR dan *Ada Boost Regresor* (ABR). Tabel 4 menunjukkan bahwa metode MLP-PSO mampu menyelesaikan masalah *over-fitting* pada DTR, BR, HGBTR, LR, KNN Regressor, dan ABR, selain juga mampu mengatasi masalah *under fitting* pada MLPR konvensional dan SVR. Hasil terbaik dihasilkan oleh MLP-PSO Ketika banyak partikel adalah 5. Hasilnya MAPE sebesar 27.6641% dan RMSE sebesar 4574.5334. Hal ini dapat disimpulkan bahwa hasil prediksi besar klaim tersebut merupakan prediksi cukup baik. Tabel 4 juga memperlihatkan bahwa metode yang diusulkan dipengaruhi oleh banyaknya partikel, semakin banyak jumlah partikel maka akan meningkatkan kinerja metode MLP-PSO yaitu menurunkan varian dari MAPE dan RMSE.

Standar deviasi penilaian metode prediksi besar klaim asuransi kesehatan berbasis MLP-PSO disajikan pada Tabel 5. Standar deviasi MAPE cukup kecil

untuk seluruh banyak partikel. RMSE yang dihasilkan metode yang diusulkan juga kecil. Metode yang diusulkan menghasilkan nilai optimal dengan varians yang kecil, hal ini menunjukkan bahwa kinerjanya baik. Banyaknya jumlah gerombolan akan menurunkan varians MAPE dan RMSE yang dihasilkan oleh metode yang diusulkan. Seperti ditunjukkan pada Tabel 6, waktu komputasi metode yang diusulkan lebih lama dibandingkan metode keseluruhan.

Exhibit 5. Contoh dataset setelah menerapkan teknik *label encoder* dan *standard scaler*

No	age	sex	BMI	children	smoker	region	charges
1	-1.4388	-1.0105	-0.4533	-0.9086	1.9706	1.3439	16884.92400
2	-1.5100	0.9896	0.5096	-0.0788	-0.5075	0.4385	1725.55230
3	-0.7980	0.9896	0.3833	1.5809	-0.5075	0.4385	4449.46200
4	-0.4419	0.9896	-1.3055	-0.9086	-0.5075	-0.4669	21984.47061
5	-0.5131	0.9896	-0.2926	-0.9086	-0.5075	-0.4669	3866.85520
...

Exhibit 6. Perbandingan rata-rata evaluasi metrik dari metode prediksi besar klaim asuransi kesehatan berbasis MLP-PSO terhadap metode ML lainnya

Metode	MAPE		RMSE	
	Training Data	Testing Data	Training Data	Testing Data
MLP-PSO (20 partikel)	29.0521%	27.8166%	4826.5016	4532.2177
MLP-PSO (10 partikel)	28.9123%	27.7076%	4841.5925	4597.8448
MLP-PSO (5 partikel)	28.8248%	27.6641%	4828.8937	4574.5334
DTR	0.8472%	41.8840%	494.2060	6176.0128
BR	13.9226%	34.1320%	2220.8935	4793.5974
MLPR	95.5116%	94.7953%	17445.7127	17452.2717
HGBTR	21.9053%	35.0809%	2925.4943	4608.5243
LR	42.2027%	46.8883%	6105.5452	5796.2847
KNN Regressor	28.5451%	40.7538%	4488.1749	5533.3663
SVR	101.5269%	113.1255%	12568.9815	12888.9622
ABR	65.7838%	73.2604%	4979.1802	5203.3966

Exhibit 6 juga menunjukkan bahwa peningkatan banyak partikel akan meningkatkan komputasi secara signifikan, walaupun waktu komputasi dari metode yang diusulkan masih dapat diterima untuk digunakan dalam aplikasi nyata.

Gambar 3 menunjukkan perbandingan metode prediksi jumlah klaim asuransi kesehatan berbasis MLP-PSO dan data yang sebenarnya untuk 50 data pengujian. Hal ini dapat menunjukkan bahwa metode yang diusulkan mampu memprediksi besar klaim dengan baik atau mampu memprediksi tingkat kesalahan yang kecil. Hal ini juga sejalan dengan RMSE dan MAPE yang kecil seperti pada Tabel 4.

Exhibit 7. Perbandingan standar deviasi evaluasi metrik dari metode prediksi besar klaim asuransi kesehatan berbasis MLP-PSO terhadap metode ML lainnya.

Metode	MAPE		RMSE	
	Training Data	Testing Data	Training Data	Testing Data
MLP-PSO (20 partikel)	0.83368%	1.30563%	36.6855	21.7349
MLP-PSO (10 partikel)	0.7469%	1.5051%	43.6074	32.4308
MLP-PSO (5 partikel)	0.8054%	1.1765%	34.6261	41.9192
DTR	0.0000%	0.0000%	0.0000	0.0000
BR	0.8300%	2.0923%	47.6514	71.3938
MLPR	0.1904%	0.2229%	22.6071	23.3879
HGBTR	0.0000%	0.0000%	0.0000	0.0000
LR	0.0000%	0.0000%	0.0000	0.0000
KNN Regressor	0.0000%	0.0000%	0.0000	0.0000
SVR	0.0000%	0.0000%	0.0000	0.0000
ABR	7.4451%	8.1287%	175.5347	193.0786

Exhibit 8. Perbandingan rata-rata dan standar deviasi waktu komputasi prediksi besar klaim asuransi kesehatan Metode berbasis MLP-PSO terhadap metode ML lainnya.

Metode	Waktu Komputasi	
	Rata-rata	Standar Deviasi
MLP-PSO (20 partikel)	910.1090	515.9357
MLP-PSO (10 partikel)	426.1822	246.1065
MLP-PSO (5 partikel)	249.8548	104.0460
DTR	0.0025	0.0054
BR	0.0200	0.0070
MLPR	0.5871	0.0581
HGBTR	0.4791	0.0971
LR	0.0047	0.0153
KNN Regressor	0.0020	0.0054
SVR	0.0335	0.0109
ABR	0.0112	0.0070

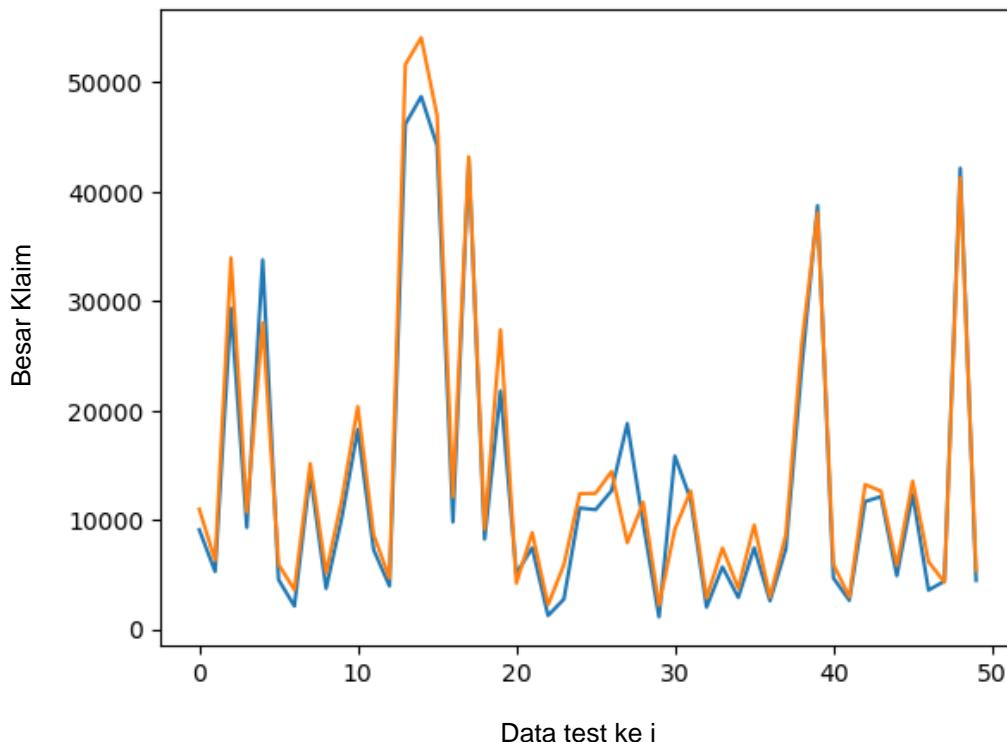


Exhibit 9. Perbandingan hasil prediksi dari metode prediksi besar klaim asuransi kesehatan berbasis MLP- PSO dan data yang sebenarnya untuk 50 data pengujian.

Kesimpulan dan Implikasi Kebijakan/Bisnis

Kesimpulan yang didapatkan dari hasil penelitian dan analisis hasil penelitian adalah metode prediksi besar klaim asuransi kesehatan berbasis MLP-PSO memberikan hasil yang lebih baik dalam hal MAPE dan RMSE jika dibandingkan dengan DTR, BR, MLPR, HGBTR, LR, KNN Regressor, SVR dan ABR. Rata-rata MAPE yang dihasilkan 27,66% dengan standar deviasi sebesar 1.1765%, ini artinya hasil prediksi sudah cukup baik. MLP-PSO dibandingkan dengan DTR, BR, MLPR, HGBTR, LR, KNN Regressor, SVR dan ABR memiliki waktu komputasi yang lebih lama, tetapi menghasilkan hasil prediksi yang jauh lebih baik sehingga waktu komputasi yang dibutuhkan sebanding dengan akurasi prediksi yang dihasilkan. Untuk setiap jumlah partikel yang lebih, metode MLP-PSO menghasilkan varians yang baik, dalam hal ini performa terbaik dihasilkan oleh MLP-PSO dengan 20 partikel. Metode yang diusulkan menawarkan metode yang baik untuk memprediksi besar klaim asuransi kesehatan dan dapat dimanfaatkan untuk mengoptimalkan strategi penetapan harga premi asuransi, meningkatkan pengelolaan risiko, dan meningkatkan keberlanjutan industri asuransi.

Daftar Pustaka

- Acar, A., Karabey, U., & Gregori, D. (2017). Incorporating heterogeneity into the prediction of total claim amount. *Hacettepe Journal of Mathematics and Statistics*, 47(4), 1–15. <https://doi.org/10.15672/hjms.2017.421>
- Amato, F., López, A. B., Peña-Méndez, E. M., Vaňhara, P., Hampl, A., & Havel, J. (2013). Artificial neural networks in medical diagnosis. *Journal of Applied Biomedicine*, 11(2), 47–58. <https://doi.org/10.2478/v10136-012-0031-x>
- Anam, S. & Z. Fitriah, 2021, “Early blight disease segmentation on tomato plant using K-means Algorithm with Swarm Intelligence-based Algorithm”, *International Journal of Mathematics and Computer Science*, vol. 16, no. 4, 1217-1228.
- Anam, S., Guci, A. N., Widhiatmoko, F., Kurniawaty, M., & Wijaya, K. A. A. (2023). Development of health insurance claim prediction method based on support vector machine and bat algorithm. *BAREKENG: Jurnal Ilmu Matematika Dan Terapan*, 17(4), 2281–2292. <https://doi.org/10.30598/barekengvol17iss4pp2281-2292>
- Anam, S., Putra, M., Fitriah, Z., Yanti, I., Hidayat, N., & Mahanani, D. M. (2023). Health claim insurance prediction using support vector machine with particle swarm optimization. *BAREKENG: Jurnal Ilmu Matematika Dan Terapan*, 17(2), 0797–0806. <https://doi.org/10.30598/barekengvol17iss2pp0797-0806>
- Azeem, M. W., Javaid, S., Khalil, R. A., Fahim, H., Althobaiti, T., Al-Sharif, N., ... & Saeed, N. (2023). Neural networks for the detection of COVID-19 and other diseases: Prospects and challenges. *Bioengineering*, 10(7), 850. <https://doi.org/10.3390/bioengineering10070850>
- Bergstra, J. & Y. Bengio, 2012, “Random search for hyper-parameter optimization,” *Journal of Machine Learning Research*, vol. 13, no. 1, 281-305.
- Bergstra, J., R. Bardenet, Y. Bengio, * B. Kégl, 2011, “Algorithms for hyper-parameter optimization,” in Proc. of the 24th Intl. Conf. on Neural Information Processing Systems, 2546-2554.
- Burney, S., Khan, L., Burney, S., & Humayoun, M. (2022). Data analysis and modeling of claim amounts of car insurance using big data: A study for Pakistan. *Asian Journal of Probability and Statistics*, 46–53. <https://doi.org/10.9734/ajpas/2022/v19i430476>
- Dubitzky, W, O. Wolkenhauer, K. H. Cho & H. Yokota, 2013, *Encyclopedia of Systems Biology*. Springer International Publishing, London. doi: 10.1007/978-1-4419-9863-7.
- Gong, Y., Zhang, M., Chung, H. S., Chen, W., Zhan, Z., Li, Y., ... & Shi, Y. (2012). An efficient resource allocation scheme using particle swarm optimization. *IEEE Transactions on Evolutionary Computation*, 16(6), 801–816. <https://doi.org/10.1109/tevc.2012.2185052>
- Goovaerts, M. J. & R. J. A. Laeven, 2008. "Actuarial risk measures for financial derivative pricing," *Insurance: Mathematics and Economics*, Elsevier, vol. 42, no.2, 540-547, April.
- Goundar, S., Prakash, S., Sadal, P., & Bhardwaj, A. (2020). Health insurance claim prediction using artificial neural networks. *International Journal of System Dynamics Applications*, 9(3), 40–57. <https://doi.org/10.4018/ijdsa.2020070103>
- Goto, T., C. Camargo, M. Faridi, R. Freishtat, & K. Hasegawa, 2019, "Machine learning-based prediction of clinical outcomes for children during emergency department triage", *JAMA Network Open*, vol. 2, no. 1, p. e186937. <https://doi.org/10.1001/jamanetworkopen.2018.6937>
- Herrera, G. P., M. Constantino, B. M. Tabak, H. Pistori, J. Su & A. Naranpanawa, 2019. "Long-term forecast of energy commodities price using machine learning", *Energy*. vol.179, 214-221. <https://doi.org/10.1016/j.energy.2019.04.077>
- Huuhtanen, T., & Jung, A. (2020). Anomaly location detection with electrical impedance tomography using multilayer perceptrons. *2020 IEEE 30th International Workshop on Machine Learning for Signal Processing (MLSP)*. <https://doi.org/10.1109/mlsp49062.2020.9231818>

- Ibrahim, S. (2020). Performance evaluation of multi-layer perceptron (MLP) and radial basis function (RBF): COVID-19 spread and death contributing factors. *International Journal of Advanced Trends in Computer Science and Engineering*, 9(1.4), 625–631. <https://doi.org/10.30534/ijatcse/2020/8791.42020>
- Jiang, L., Liu, K., & Wu, L. (2022). Particle swarm optimization gray wolf fusion algorithm for solving the optimal solution of function. *Journal of Physics: Conference Series*, 2216(1), 012066. <https://doi.org/10.1088/1742-6596/2216/1/012066>
- Jordehi, A. R. (2015). Particle swarm optimisation (PSO) for allocation of FACTS devices in electric transmission systems: A review. *Renewable and Sustainable Energy Reviews*, 52, 1260–1267. <https://doi.org/10.1016/j.rser.2015.08.007>
- Khan, M. J. U. R., & Awasthi, A. (2019). Machine learning model development for predicting road transport GHG emissions in Canada. *WSB Journal of Business and Finance*, 53(2), 55–72. <https://doi.org/10.2478/wsbjbf-2019-0022>
- Komarica, J., Glavić, D., & Kaplanović, S. (2024). Comparative analysis of the predictive performance of an ANN and logistic regression for the acceptability of eco-mobility using the Belgrade data set. *Data*, 9(5), 73. <https://doi.org/10.3390/data9050073>
- Kordon, A. K., 2010. Swarm Intelligence: The Benefits of Swarms. In: Applying Computational Intelligence. Springer, Berlin. https://doi.org/10.1007/978-3-540-69913-2_6
- Larasati, A., Dwiaستutik, A., Ramadhanti, D., & Mahardika, A. (2018). The effect of kurtosis on the accuracy of artificial neural network predictive model. *MATEC Web of Conferences*, 204, 02018. <https://doi.org/10.1051/matecconf/201820402018>
- Lin, M., Wang, Z., Wang, F., & Chen, D. (2020). Improved simplified particle swarm optimization based on piecewise nonlinear acceleration coefficients and mean differential mutation strategy. *IEEE Access*. <https://doi.org/10.1109/access.2020.2994984>
- Mahdi, Q. A., Shyshatskyi, A., Symonenko, O., Protas, N., Trotsko, O., Kyvliuk, V., ... & Holenkovska, T. (2022). Development of a method for training artificial neural networks for intelligent decision support systems. *Eastern-European Journal of Enterprise Technologies*, 1(9(115)), 35–44. <https://doi.org/10.15587/1729-4061.2022.251637>
- Nadeb, H., Torabi, H., & Dolati, A. (2020). Stochastic comparisons of the largest claim amounts from two sets of interdependent heterogeneous portfolios. *Mathematical Inequalities & Applications*, 35–56. <https://doi.org/10.7153/mia-2020-23-03>
- Pesantez-Narvaez, J., Guillén, M., & Alcañiz, M. (2019). Predicting motor insurance claims using telematics data—XGBoost versus logistic regression. *Risks*, 7(2), 70. <https://doi.org/10.3390/risks7020070>
- Prabowo, A., Mamat, M., & Taufiq, A. A. (2019). Pricing of premium for automobile insurance using Bayesian method. *International Journal of Recent Technology and Engineering (IJRTE)*, 8(3), 6226–6229. <https://doi.org/10.35940/ijrte.c5740.098319>
- Sarker, I. H., A. S. M. Kayes, S. Badsha, H. Alqahtani, P. Watters, & A. Ng, 2020, “Cybersecurity data science: an overview from machine learning perspective,” *Journal of Big Data*, vol. 7, no. 1, pp. 41–29.
- Sarker, I. H. & R. Furhad Nowrozy, “Ai-driven cybersecurity: an overview, security intelligence modeling and research directions,” *SN Computer Science*, vol. 2, no. 3, p. 173, 2021.
- Selvakumar, V., Satpathi, D. K., Kumar, P., & Haragopal, V. V. (2022). Modeling of motor insurance extreme claims through appropriate statistical distributions. *Studies of Applied Economics*, 40(S1). <https://doi.org/10.25115/eea.v40is1.5685>
- Syarif, I., A. Prugel-Bennett & G. Wills, G., 2016, “SVM parameter optimization using grid search and genetic algorithm to improve classification performance”, *Telecommun. Comput. Electron. Control*, vol. 14, 1502. [CrossRef]
- Tseng, W., W. Chiang, S. Liu, J. Roan, & C. Lin, 2015, "The application of data mining techniques to oral cancer prognosis", *Journal of Medical Systems*, vol. 39, no. 5. <https://doi.org/10.1007/s10916-015-0241-3>
- Wang, X., Fu, X., Dong, J., & Jiang, J. (2021). Dynamic modified chaotic particle swarm optimization for radar signal sorting. *IEEE Access*, 9, 88452–88466. <https://doi.org/10.1109/access.2021.3091005>

Wang, S., M. Li & S. B. Ng, 2022, "Research on infant health diagnosis and intelligence development based on machine learning and health information statistics. Frontiers in Public Health. vol. 10, 846598. <https://doi.org/10.3389/fpubh.2022.846598>

Wicaksono, A.S. & A.F Supianto, 2018, "Hyperparameter optimization using Genetic Algorithm on machine learning methods for online news popularity prediction", Int. J. Adv. Comput. Sci. Appl., vol. 9, 263–267. [CrossRef]

Wu, C., 2009, "Quantifying high-resolution impervious surfaces using spectral mixture analysis", International Journal of Remote Sensing, vol. 30, no. 11, 2915–2932. <https://doi.org/10.1080/01431160802558634>

Yang, C., C. Delcher, E. Shenkman, & S. Ranka, 2018, "Machine learning approaches for predicting high cost high need patient expenditures in health care", BioMedical Engineering OnLine, vol. 17, no. S1. <https://doi.org/10.1186/s12938-018-0568-3>

Zhou, C., Hu, J., Wang, Y., Ji, M., Tong, J., Yang, J., ... & Xia, H. (2021). A machine learning-based predictor for the identification of the recurrence of patients with gastric cancer after operation. Scientific Reports, 11(1). <https://doi.org/10.1038/s41598-021-81188-6>

Zrieq, R., Kamel, S., Boubaker, S., Al-Shammary, A. A., Algahtani, F. D., & Alshammari, F. (2020). Generalized Richards model for predicting COVID-19 dynamics in Saudi Arabia based on particle swarm optimization algorithm. AIMS Public Health, 7(4), 828–843. <https://doi.org/10.3934/publichealth.2020064>

PT. Bahana Pembinaan Usaha Indonesia (Persero)

Gedung Graha CIMB Niaga, 18th Floor

Jl. Jendral Sudirman Kav. 58

RT.5/RW.3, Senayan, Kebayoran Baru

Kota Jakarta Selatan, DKI Jakarta 12190



(+62) 021 2505080



Indonesia Financial Group



PT. Bahana Pembinaan Usaha Indonesia – Persero



@indonesianfinancialgroup



@ifg_id

Indonesia Financial Group (IFG)

Indonesia Financial Group (IFG) adalah BUMN Holding Perasuransian dan Penjaminan yang beranggotakan PT Asuransi Kerugian Jasa Raharja, PT Jaminan Kredit Indonesia (Jamkrindo), PT Asuransi Kredit Indonesia (Askrindo), PT Jasa Asuransi Indonesia (Jasindo), PT Bahana Sekuritas, PT Bahana TCW Investment Management, PT Bahana Artha Ventura, PT Bahana Kapital Investa, PT Graha Niaga Tata Utama, dan PT Asuransi Jiwa IFG. IFG merupakan holding yang dibentuk untuk berperan dalam pembangunan nasional melalui pengembangan industri keuangan lengkap dan inovatif melalui layanan investasi, perasuransian dan penjaminan. IFG berkomitmen menghadirkan perubahan di bidang keuangan khususnya asuransi, investasi, dan penjaminan yang akuntabel, prudent, dan transparan dengan tata kelola perusahaan yang baik dan penuh integritas. Semangat kolaboratif dengan tata kelola perusahaan yang transparan menjadi landasan IFG dalam bergerak untuk menjadi penyedia jasa asuransi, penjaminan, investasi yang terdepan, terpercaya, dan terintegrasi. IFG adalah masa depan industri keuangan di Indonesia. Saatnya maju bersama IFG sebagai motor penggerak ekosistem yang inklusif dan berkelanjutan.

Indonesia Financial Group (IFG) Progress

The Indonesia Financial Group (IFG) Progress adalah sebuah *Think Tank* terkemuka yang didirikan oleh Indonesia Financial Group sebagai sumber penghasil pemikiran-pemikiran progresif untuk pemangku kebijakan, akademisi, maupun pelaku industri dalam memajukan industri jasa keuangan.