

Penerapan Algoritma Genetika untuk Optimasi Parameter pada Support Vector Machine untuk Meningkatkan Prediksi Pemasaran Langsung

Ispandi

Sekolah Tinggi Manajemen Informatika dan Komputer Nusa Mandiri
ispandi.ipd@bsi.ac.id

Romi Satria Wahono

Faculty of Computer Science, Dian Nuswantoro University
romi@romisatriawahono.net

Abstrak: Pemasaran langsung adalah proses mengidentifikasi potensi pembeli produk tertentu dan mempromosikan produk dengan sesuai. pelaksanaan pemasaran langsung dari waktu ke waktu menghasilkan data dan informasi dalam bentuk laporan yang perlu di analisis oleh manajer dalam rangka mendukung keputusan. Namun itu adalah tugas yang sulit bagi manajer untuk menganalisis data yang kompleks yang luas. Kesulitan ini menyebabkan perkembangan teknik intelijen bisnis, yang bertujuan mengklasifikasi pengetahuan yang berguna untuk mendukung pengambilan keputusan. Algoritma support vector machine mampu mengatasi data set yang berdimensi tinggi, mengatasi masalah klasifikasi dan regresi dengan linier ataupun nonlinier kernel, yang dapat menjadi satu kemampuan algoritma untuk klasifikasi serta regresi, namun support vector machine memiliki masalah dalam pemilihan parameter yang sesuai untuk meningkatkan optimasi. Untuk mengatasi masalah tersebut diperlukan metode algoritma genetika untuk pemilihan parameter yang sesuai pada metode support vector machine. Beberapa eksperimen dilakukan untuk mendapatkan akurasi yang optimal dan metode yang di usulkan adalah penerapan algoritma untuk optimasi pada parameter pada support vector machine. Hasil penelitian menunjukkan, eksperimen dengan menggunakan metode support vector machine dan algoritma genetika yang digunakan untuk melakukan optimasi parameter C , γ dan ϵ dengan tiga jenis kernel. Kernel pertama tipe kernel dot dengan akurasi sebesar 85,59%, AUC sebesar 0,911 yang kedua tipe kernel radial dengan akurasi sebesar 98,89%, AUC sebesar 0,981 dan yang ketiga dengan tipe kernel Polynomial dengan akurasi sebesar 98,67% dan AUC sebesar 0,938. Hasil eksperimen tersebut menunjukkan pengujian data set bank menggunakan penerapan algoritma genetika pada support vector machine menunjukkan hasil yang lebih akurat dari penelitian sebelumnya untuk prediksi pemasaran langsung.

Kata Kunci: Optimasi Parameter, Pemasaran Langsung, Support Vector Machine, Algoritma Genetika.

1 PENDAHULUAN

Pemasaran langsung adalah proses mengidentifikasi potensi pembeli produk tertentu dan mempromosikan produk dengan sesuai (Wang, 2013). Pelaksanaan pemasaran langsung dari waktu ke waktu menghasilkan data dan informasi dalam bentuk laporan yang perlu di analisis oleh manajer dalam rangka mendukung keputusan. Namun, itu adalah tugas yang sulit bagi manusia untuk menganalisis data yang kompleks

yang luas (Turban, 2012). Kesulitan ini menyebabkan perkembangan teknik intelijen bisnis, yang bertujuan mengekstraksi pengetahuan yang berguna untuk mendukung pengambilan keputusan.

Pemasaran langsung adalah sistem pemasaran interaktif yang menggunakan berbagai saluran untuk menargetkan pelanggan potensial (Talla, Leus, & Spieksma, 2011). Pemasaran langsung lainnya juga menggunakan e-mail pemasaran, telemarketing, broadcast fax, dan kupon. Dalam pemasaran langsung, menggunakan catatan respon pelanggan yang tersedia saat ini, dapat memperkirakan jumlah tanggapan atau tingkat respons secara keseluruhan, dan penggunaan informasi tersebut dalam membuat keputusan manajerial.

Salah satu cara yang efektif untuk menganalisa laporan dari kampanye sebelumnya dan serupa dalam mencari tren dan pola adalah melalui intelegen bisnis dan teknik data mining, untuk membangun model dan kemudian ekstrak pengetahuan (Witten, 2011). Intelegen bisnis adalah sebuah konsep luas yang mencakup data mining yang terdiri dalam ekstraksi pengetahuan dari data mentah.

Selain itu, marketing memiliki sedikit pengetahuan tentang data mining, maka ada kebutuhan untuk mengembangkan suatu kerangka kerja yang disederhanakan untuk membantu marketing dalam memanfaatkan metode data mining untuk pemasaran langsung. Beberapa studi yang di lakukan untuk memprediksi pemasaran dengan menggunakan metode komputasi antara lain: support vector machine (SVM) (Moro & Laureano, 2012) dan multi layer perceptron (MLP) (Elsalamony & Elsayad, 2013).

Multi layer perceptron (MLP) diketahui berfungsi untuk memprediksi dan mengklasifikasi sebuah masalah yang rumit, yang memungkinkan pengakuan terhadap data yang besar (Elsalamony & Elsayad, 2013). Tetapi kinerja MLP tergantung pada parameter, bobot dan fungsi pengalihan, banyak variable dan *overfitting* (Kahrizi & Hashemi, 2014).

Support vector machine (SVM) bekerja lebih baik daripada MLP, dengan standar pembelajaran backpropagation, kinerja SVM lebih unggul, hal ini disebabkan karena kemampuan generalisasi support vector machine berdimensi tinggi dalam ruang highdimensional (Martinez, Sanchez, & Velez, 2010). Support vector machine digunakan untuk klasifikasi pola, pemetaan dalam ruang input dengan nonlinear merubah ke ruang berdimensi tinggi, di mana masalah linear klasifikasi menjadi optimal (Ren, 2012).

SVM dapat mengatasi masalah klasifikasi dan regresi dengan linier ataupun nonlinier kernel yang dapat menjadi satu kemampuan algoritma pembelajaran untuk klasifikasi (Kara,

Acar, & Kaan, 2011). Selain memiliki banyak kemampuan yang telah disebutkan diatas, metode SVM juga memiliki kelemahan pada sulitnya pemilihan parameter SVM yang optimal, keakuratan klasifikasi atau regresi ditentukan oleh sekelompok parameter yang sesuai (Xiang, 2013).

Kinerja SVM sangat tergantung pada pilihan yang memadai dari nilai-nilai parameter, termasuk misalnya, kernel dan parameter regularisasi. Pemilihan parameter SVM umumnya sebagai masalah optimasi di mana teknik pencarian digunakan untuk menemukan konfigurasi parameter yang memaksimalkan kinerja SVM (Rossi & Soares, 2012).

Ada banyak teknik optimasi yang telah digunakan untuk mengoptimasi parameter pada machine learning, seperti algoritma genetika (GA) (Ilhan & Tezel, 2013) dan particle swarm optimization (PSO) (Khoshahval, Minuchehr, & Zolfaghari, 2011).

Karena konsep sederhana, implementasi mudah, dan konvergensi cepat, particle swarm optimization (PSO) dapat diterapkan untuk berbagai aplikasi di berbagai bidang untuk memecahkan masalah optimasi (Liu, Tian, Chen, & Li, 2013). PSO, sebagai alat optimasi, yang dapat membantu menentukan parameter optimum. Tetapi PSO memiliki ketergantungan yang sensitif pada parameter yang digunakan (Yusup, Zain, Zaiton, & Hashim, 2012).

GA adalah menemukan popularitas sebagai alat desain karena fleksibilitas, intuitif dan kemampuan untuk memecahkan sangat non-linear, optimasi mixed integer masalah (Khoshahval et al., 2011). Algoritma Genetika digunakan untuk mengoptimasi parameter yang optimal dengan ruang lingkup yang besar, dengan pemilihan parameter yang tepat algoritma genetika akan lebih optimal (Wang et al., 2013). Algoritma genetika memiliki kelemahan yaitu pemilihan parameter yang salah dapat mengurangi akurasi yang dihasilkan.

Metode algoritma genetika digunakan untuk mengoptimalkan parameter dan untuk lebih menemukan bagian parameter yang dioptimalkan (Wang et al., 2014). Namun semua komponen algoritma genetika bersifat random atau acak menghasilkan solusi yang dihasilkan berbeda-beda. Algoritma genetika di terapkan pada optimasi parameter untuk support vector machine, sehingga hasil yang diperoleh adalah pemilihan optimasi parameter yang sesuai (Zhao, Fu, Ji, Tang, & Zhou, 2011). Permasalahan yang sering dihadapi oleh algoritma Genetika adalah memperoleh solusi optimal setelah serangkaian melakukan perulangan, tetapi kejadian ini dapat dihindari dengan memilih nilai-nilai parameter yang tepat.

Dari uraian diatas, pada penelitian ini algoritma genetika akan di terapkan untuk optimasi parameter pada support vector machine.

2 PENELITIAN TERKAIT

Data set bank dalam jumlah besar yang dihasilkan setiap hari di banyak lembaga. Data set bank dapat digunakan untuk membangun dan memelihara hubungan langsung dengan pelanggan untuk menargetkan mereka secara individu untuk penawaran tertentu. Selain itu, marketing memiliki sedikit pengetahuan tentang data mining, maka ada kebutuhan untuk mengembangkan suatu kerangka kerja yang disederhanakan untuk membantu marketing dalam memanfaatkan metode data mining untuk pemasaran langsung.

Penelitian yang dilakukan (Elsalamony & Elsayad, 2013) Dalam penelitian ini menggunakan data set bank Support vector machine (SVM) bekerja lebih baik daripada Multi Layer Perceptron MLP, dengan standar pembelajaran

backpropagation, kinerja SVM lebih unggul, hal ini disebabkan karena kemampuan generalisasi support vector machine berdimensi tinggi dalam ruang highdimensional.

Metode SVM juga memiliki kelemahan pada sulitnya pemilihan parameter SVM yang optimal, keakuratan klasifikasi atau regresi ditentukan oleh sekelompok parameter yang sesuai (Moro & Laureano, 2012). Pemilihan parameter SVM umumnya sebagai masalah optimasi di mana teknik pencarian digunakan untuk menemukan konfigurasi parameter yang memaksimalkan kinerja SVM.

Karena konsep sederhana, implementasi mudah, dan konvergensi cepat, particle swarm optimization (PSO) dapat diterapkan untuk berbagai aplikasi di berbagai bidang untuk memecahkan masalah optimasi (Vieira & Mendonc, 2013). PSO sebagai alat optimasi yang dapat membantu menentukan parameter optimum, tetapi PSO memiliki ketergantungan yang sensitif pada parameter yang digunakan.

Algoritma genetika digunakan untuk mengoptimasi parameter yang optimal dengan ruang lingkup yang besar, dengan pemilihan parameter yang tepat algoritma genetika akan lebih optimal (Wang et al., 2013). Algoritma genetika memiliki kelemahan yaitu pemilihan parameter yang salah dapat mengurangi akurasi yang dihasilkan. Permasalahan yang sering dihadapi oleh algoritma genetika adalah memperoleh solusi optimal setelah serangkaian melakukan perulangan, tetapi kejadian ini dapat dihindari dengan memilih nilai-nilai parameter yang tepat.

Dari permasalahan pada penelitian-penelitian di atas disimpulkan bahwa untuk mengolah data set bank adalah sebuah masalah yang rumit karena merupakan data yang kompleks. berdasarkan analisa bahwa metode gabungan dua metode atau lebih (*ensemble*) menunjukkan hasil yang lebih baik dibanding metode individual. SVM yang mampu mengatasi masalah klasifikasi dan regresi dengan linear maupun nonlinear kernel yang dapat menjadi satu kemampuan algoritma, di mana masalah linear klasifikasi menjadi optimal, sedangkan algoritma genetika digunakan untuk mengoptimasi parameter yang optimal dengan ruang lingkup yang besar, dengan pemilihan parameter yang tepat algoritma genetika akan lebih optimal. Oleh karena itu pada penelitian ini diusulkan menggunakan metode *ensemble* dengan menggabungkan algoritma genetika untuk mengoptimasi parameter SVM dengan kombinasi kernel yang berbeda.

3 METODE YANG DIUSULKAN

3.1 Algoritma Genetika

Algoritma genetika adalah suatu teknik optimasi yang didasarkan pada prinsip genetika dan seleksi alam. algoritma genetika merupakan metode pencarian yang disesuaikan dengan proses generika dari organisme biologi yang berdasar pada teori evolusi Charles Darwin (Shukla, Tiwari, & Kala, 2010). Algoritma genetika terinspirasi dari mekanisme seleksi alam, dimana individu yang lebih kuat kemungkinan akan menjadi pemenang dalam lingkungan yang kompetitif dan solusi yang optimal dapat diperoleh dan diwakilkan oleh pemenang akhir dari permainan genetika (Haupt & Haupt, 2004). Pada algoritma genetika tersedia solusi yang diterapkan pada sebuah populasi individu yang masing-masing mewakili

solusi yang mungkin. Setiap solusi yang mungkin disebut dengan kromosom.

Algoritma genetika menggunakan analogi secara langsung dari kebiasaan yang alami yaitu seleksi alam. Algoritma ini berkerja dengan sebuah populasi yang terdiri dari individu-individu, yang masing-masing individu merepresentasikan sebuah solusi yang mungkin bagi persoalan yang ada. Dalam kaitan ini, individu dilambangkan dengan dengan sebuah nilai fitness yang akan digunakan untuk mencari solusi terbaik dari persoalan yang ada.

Pada akhirnya, akan didapatkan solusi-solusi yang paling tepat bagi permasalahan yang dihadapi. Untuk menggunakan algoritma genetika, solusi permasalahan direpresentasikan sebagai khromosom (Weise, 2009). Tiga aspek yang penting untuk penggunaan algoritma genetik:

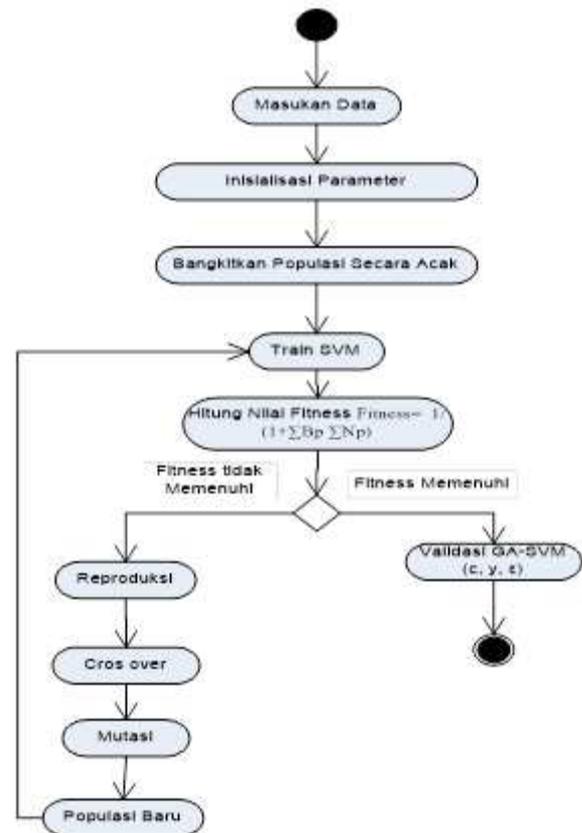
1. Defenisi fungsi fitness
2. Defenisi dan implementasi representasi genetik
3. Defenisi dan implementasi operasi genetik

3.2 Support Vector Machine

Support vector machine adalah salah satu metode klasifikasi dua kelas dan teori ini di dasarkan pada gagasan resiko struktural, support vector machine menggunakan fungsi kernel untuk memetakan data input ke ruang berdimensi tinggi dan menemukan hyper plane optimal untuk memisahkan data dua kelas (Aydin, Karakose, & Akin, 2011). Untuk mendapatkan optimal hyper plane yang memisahkan dua kelas berbeda pada ruang vector. Optimal hyper plane adalah jarak terjauh dari hyper plane kedua kelas tersebut. Pada permasalahan pemisahan secara linear, optimal hyper plane dapat memisahkan dua kelas yang berbeda dengan baik dan vector-vector yang terdekat dengan optimal hyper plane disebut support vector (Wu et al., 2007).

3.3 Support Vector Machine dan Algoritma Genetika

Gambar 1 menggambarkan metode algoritma yang diusulkan dalam penelitian ini. Pada pengolahan data awal, inialisasi parameter kernel C , γ dan ϵ , kemudian bangkitkan populasi dari kromosom dibangkitkan secara acak. Ukuran populasi di set ke 5, selanjutnya training SVM, kemudian evaluasi fitnes. Pada tahap ini fitness dari setiap kromosom dievaluasi, setelah itu cek nilai fitness, jika kondisi terpenuhi berhenti, selain itu lakukan reproduksi. Pada tahap ini populasi baru dibuat dengan perulangan mengikuti langkah-langkah sebelum populasi baru selesai, kemudian lakukan crossover. Dengan probabilitas crossover, crossover dari induk dibuat untuk membentuk offspring's (anak). Pada cross over, kromosom dipasangkan secara random, kemudian lakukan mutasi. Setelah operasi crossover berhasil, string sebagai subyekkan untuk operasi mutasi, hal ini untuk mencegah runtuhnya seluruh solusi dari populasi menjadi local optimum dari penyelesaian masalah. Variabel dalam string yang akan bermutasi dipilih secara acak, kemudian Populasi baru terbentuk, ulangi langkah train SVM.



Gambar 1. Penggabungan Support Vector Machine dan Algoritma Genetika

4 HASIL DAN PEMBAHASAN

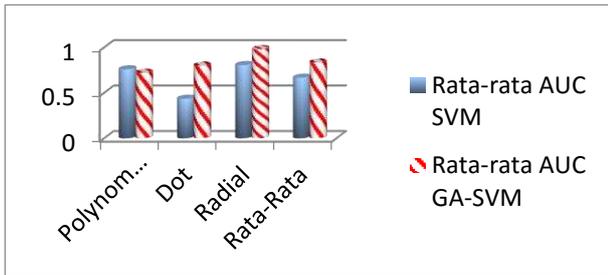
Penelitian yang dilakukan menggunakan komputer dengan spesifikasi CPU Intel Core i3 1.6GHz, RAM 2GB, dan sistem operasi Microsoft Windows 7 Professional 64-bit. Aplikasi yang digunakan adalah RapidMiner 5.2. Penelitian ini menggunakan dataset Bank. Dataset ini didapat dari UCI Machine Learning Repository.

Setelah eksperimen yang dilakukan dengan penerapan model GA-SVM dilakukan uji beda dengan membandingkan akurasi prediksi pemasaran langsung pada data testing support vector machine sebelum dan sesudah dioptimasi dengan algoritma genetika berdasarkan nilai akurasi. Pengujian penerapan algoritma genetika yang digunakan untuk melakukan optimasi parameter C , γ dan ϵ pada metode support vector machine dalam prediksi pemasaran langsung yang dilakukan dengan menggunakan tiga tipe kernel yaitu kernel dot, radial, dan polynomial.

Berdasarkan hasil eksperimen dan analisis data dalam penelitian ini, maka dapat diperoleh perbedaan rata-rata nilai AUC pada pengujian model SVM sebelum dan sesudah dilakukan optimasi parameter SVM dengan menggunakan algoritma genetika data yang digunakan pada pemasaran langsung. Perbandingan yang dihasilkan dapat memberikan informasi/gambaran tentang perbandingan rata-rata tingkat akurasi pada penerapan model tersebut. Tingkat perbandingan rata-rata nilai AUC dapat dilihat pada Tabel 2 dan Gambar 2.

Tabel 1. Perbandingan Rata-rata Nilai AUC Pada Tipe Kernel Dot, Polinomial dan Radial.

Tipe Kernel	Rata-rata AUC	
	SVM	GA-SVM
Polynomial	0,7595	0,7217
Dot	0,4354	0,801
Radial	0,806	0,981
Rata-Rata	0,666966667	0,834566667



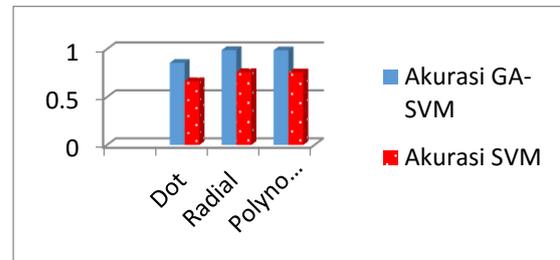
Gambar 2. Grafik Perbandingan Rata-rata Nilai AUC SVM dengan GA-SVM

Berdasarkan Tabel 1, menunjukkan bahwa pengujian penggunaan model GA-SVM pada tipe kernel dot, radial dan polinomial untuk melakukan prediksi pemasaran langsung memiliki rata-rata AUC lebih tinggi jika dibandingkan dengan model SVM, ini menunjukkan bahwa pada penggunaan tipe kernel polinomial, dot dan radial dapat meningkatkan peningkatan nilai akurasi prediksi pemasaran langsung pada model SVM setelah dilakukan optimisasi parameter dengan algoritma genetika.

Hasil eksperimen dan analisis data dalam penelitian ini, dapat diperoleh perbandingan nilai akurasi tertinggi pada pengujian model SVM sebelum dan sesudah dilakukan optimisasi parameter dengan algoritma genetika pada data testing yang diterapkan pada prediksi pemasaran langsung. Perbandingan ini dapat memberikan gambaran tentang tingkat akurasi terbaik pada penerapan model tersebut. Perbandingan terbaik pada model tersebut dapat dilihat pada Tabel 3 dan Gambar 3.

Tabel 2. Perbandingan Akurasi Terbaik antara GA-SVM Dengan SVM

Tipe Kernel	GA-SVM				SVM			
	Parameter			Akurasi	Parameter			Akurasi
	C	γ	ϵ		C	γ	ϵ	
Dot	61.628	0.1893	0.5542	85.59%	863.347	0.1754	0.5579	66.49%
Radial	92.073	0.03036	0.54485	98.89%	92.073	0.03036	0.54485	76.05%
Polynomial	31.746	0.9568	0.72688	98.67%	31.746	0.9568	0.72688	75.61%



Gambar 3. Grafik Perbandingan Terbaik Prediksi Pemasaran Langsung dengan Metode GA-SVM dan SVM

Mengacu Tabel 2, menunjukkan bahwa penerapan model SVM sebelum dilakukan optimisasi parameter nilai akurasi tertinggi terjadi pada tipe kernel dot dengan nilai $C = 863.347$, $\gamma = 0.1754$ dan $\epsilon = 0.5579$ dengan nilai akurasi sebesar 66.49%, nilai akurasi tertinggi pada tipe kernel radial terjadi pada nilai $C = 92.073$, $\gamma = 0.03036$ dan $\epsilon = 0.54485$ dengan nilai akurasi sebesar 76.05% dan nilai akurasi tertinggi pada tipe kernel Polynomial dengan $c = 31.746$, $\gamma = 0.9568$ dan $\epsilon = 0.72688$ dengan nilai akurasi sebesar 75,61%. Sedangkan penerapan SVM setelah dilakukan optimisasi parameter dengan menggunakan GA nilai akurasi tertinggi pada tipe kernel dot terjadi pada nilai $c = 61.628$, $\gamma = 0.1893$, dan $\epsilon = 0.5542$ dengan tingkat akurasi sebesar 85.59%, untuk nilai akurasi tertinggi pada tipe kernel radial terjadi pada nilai $c = 92.073$ $\gamma = 0.03036$ dan $\epsilon = 0.54485$ dengan nilai akurasi sebesar 98,89% dan untuk nilai akurasi tertinggi pada tipe kernel polinomial terjadi pada nilai $C = 31.746$ $\gamma = 0.09568$ dan $\epsilon = 0.72688$ dengan nilai akurasi sebesar 98.67%.

Hasil menunjukkan support vector machine diperoleh pada parameter $c = 31.746$ $\gamma = 0.9568$ dan $\epsilon = 0.1887$ dengan nilai akurasi sebesar 57.43% dan nilai AUC sebesar 0.7268. Sedangkan pada metode support vector machine yang dipadu dengan algoritma genetika hasil terbaik diperoleh pada parameter $c = 31.746$ $\gamma = 0.9568$ dan $\epsilon = 0.18$ dengan tingkat akurasi 98,67% dan nilai AUC sebesar 0,938.

5 KESIMPULAN

Pengujian penerapan algoritma genetika yang digunakan untuk melakukan optimisasi parameter C , γ dan ϵ pada metode support vector machine dalam prediksi pemasaran langsung yang dilakukan dengan menggunakan tiga tipe kernel yaitu kernel dot, radial, dan polinomial.

Berdasarkan hasil uji beda menunjukkan bahwa ada perbedaan yang signifikan pada nilai rata-rata AUC hasil eksperimen SVM sebelum dan sesudah dilakukan optimisasi parameter C , γ dan ϵ dengan algoritma genetika. Sehingga dapat disimpulkan bahwa penerapan model SVM yang dioptimasi parameter C , γ dan ϵ dengan algoritma genetika meningkatkan akurasi dalam prediksi pemasaran langsung. Dengan nilai masing-masing parameter $c = 92.073$ $\gamma = 0.03036$ dan $\epsilon = 0.54485$ dengan nilai akurasi sebesar 98,89%.

Berdasarkan hasil pengujian yang dilakukan untuk memecahkan masalah prediksi pemasaran langsung, dapat disimpulkan bahwa eksperimen dengan tingkat akurasi tertinggi pada metode SVM dengan tipe kernel radial sebelum dilakukan optimisasi parameter dengan nilai akurasi sebesar 76.05%. Berikutnya dilakukan penerapan algoritma genetika untuk optimisasi parameter c , γ dan ϵ dengan tipe kernel radial dengan nilai akurasi sebesar 98.89%.

REFERENSI

- Aydin, I., Karakose, M., & Akin, E. (2011). A multi-objective artificial immune algorithm for parameter optimization in support vector machine. *Applied Soft Computing*, 11, 120–129.
- Elsalamony, H. A., & Elsayad, A. M. (2013). Bank Direct Marketing Based on Neural Network and C5.0 Models. *International Journal of Engineering and Advanced Technology (IJEAT)*, 2(6).
- Frias-Martinez, E., Sanchez, A., & Velez, J. (2010). Support vector machines versus multi-layer perceptrons for efficient off-line signature recognition. *Engineering Applications of Artificial Intelligence*, 19(6), 693–704.
- Ilhan, I., & Tezel, G. (2013). A genetic algorithm-support vector machine method with parameter optimization for selecting the tag SNPs. *Journal of Biomedical Informatics*, 46(2), 328–40.
- Kahrizi, A., & Hashemi, H. (2014). Neuron curve as a tool for performance evaluation of MLP and RBF architecture in first break picking of seismic data. *Journal of Applied Geophysics*, 108, 159–166.
- Kara, Y., Acar, M., & Kaan, Ö. (2011). Expert Systems with Applications Predicting direction of stock price index movement using artificial neural networks and support vector machines : The sample of the Istanbul Stock Exchange. *Expert Systems With Applications*, 38(5), 5311–5319.
- Khoshahval, F., Minucheher, H., & Zolfaghari, a. (2011). Performance evaluation of PSO and GA in PWR core loading pattern optimization. *Nuclear Engineering and Design*, 241(3), 799–808.
- Liu, H., Tian, H., Chen, C., & Li, Y. (2013). Electrical Power and Energy Systems An experimental investigation of two Wavelet-MLP hybrid frameworks for wind speed prediction using GA and PSO optimization, 52, 161–173.
- Moro, S., & Laureano, R. M. S. (2012). Using Data Mining for Bank Direct Marketing: An application of the CRISP-DM methodology. *European Simulation and Modelling Conference*, (Figure 1), 117–121.
- Ren, J. (2012). ANN vs. SVM: Which one performs better in classification of MCCs in mammogram imaging. *Knowledge-Based Systems*, 26, 144–153.
- Rossi, L. D., & Soares, C. (2012). Neurocomputing Combining meta-learning and search techniques to select parameters for support vector machines. *Neurocomputing*, 75, 3–13.
- Shi, Y., Tian, Y., & Kou, G. (2011). *Optimization Based Data Mining Theory and Applications*. (xx, Ed.). Springer London.
- Shukla, A., Tiwari, R., & Kala, R. (2010). *Real Life Application of Soft Computing*. CRC Press.
- Talla, F., Leus, R. &, & Spieksma, F. C. R. (2011). Optimization models for targeted offers in direct marketing: Exact and heuristic algorithms. *European Journal of Operational Research*, 210(3), 670–683.
- Turban, E. (2012). *Information Technology for Management*. (B. L. Golub, Ed.) (8th ed.). United States of America: John Wiley & Sons, Inc.
- Vieira, S. M., & Mendonca, L. F. (2013). Modified binary PSO for feature selection using SVM applied to mortality prediction of septic patients, 13, 3494–3504.
- Wang, J. (2013). Data Mining Framework for Direct Marketing : A Case Study of Bank Marketing. *International Journal of Computer Science and Issues*, 10(2), 198–203.
- Wang, Y., Chen, X., Jiang, W., Li, L., Li, W., Yang, L., ... Li, X. (2013). Predicting human microRNA precursors based on an optimized feature subset generated by GA-SVM. *Genomics*, 98(2), 73–8.
- Wang, Y., Li, Y., Wang, Q., Lv, Y., Wang, S., Chen, X., ... Li, X. (2014). Computational identification of human long intergenic non-coding RNAs using a GA-SVM algorithm. *Gene*, 533(1), 94–9.
- Witten, I. H. (2011). *Data Mining Practical Machine Learning Tools and Techniques* (3rd ed.). USA: Elsevier.
- Wu, X., Kumar, V., Ross Quinlan, J., Ghosh, J., Yang, Q., Motoda, H., ... Steinberg, D. (2007). *Top 10 algorithms in data mining. Knowledge and Information Systems* (Vol. 14, pp. 1–37).
- Xiang, C. (2013). A Chaotic Time Series Forecasting Model Based on Parameters Simultaneous Optimization Algorithm. *Journal of Information and Computational Science*, 10(15), 4917–4930.
- Yusup, N., Zain, A. M., Zaiton, S., & Hashim, M. (2012). Procedia Engineering Overview of PSO for Optimizing Process Parameters of Machining.
- Zhao, M., Fu, C., Ji, L., Tang, K., & Zhou, M. (2011). Feature selection and parameter optimization for support vector machines: A new approach based on genetic algorithm with feature chromosomes. *Expert Systems with Applications*, 38(5), 5197–5204.

BIOGRAFI PENULIS



Ispandi. Memeroleh gelar M.Kom dari Sekolah Tinggi Manajemen Ilmu Komputer Nusa Mandiri, Jakarta. Staf pengajar di salah satu Perguruan Tinggi Swasta. Minat penelitian saat ini pada bidang data mining..



Romi Satria Wahono. Memeroleh Gelar B.Eng dan M.Eng pada bidang ilmu komputer di Saitama University, Japan, dan Ph.D pada bidang software engineering di Universiti Teknikal Malaysia Melaka. Menjadi pengajar dan peneliti di Fakultas Ilmu Komputer, Universitas Dian Nuswantoro. Merupakan pendiri dan CEO PT Brainmatics, sebuah perusahaan yang bergerak di bidang pengembangan software. Minat penelitian pada bidang software engineering dan machine learning. Profesional member dari asosiasi ilmiah ACM, PMI dan IEEE Computer Society.