

naik sebesar 0,4 untuk semua metode pengukuran. Sedangkan, dua metode lain, *filter method* dan *embedded method*, mengalami penurunan hasil evaluasi dari sebelum dilakukan seleksi fitur.

4.2 Analisis Hasil Pengujian

Perbedaan metode dari seleksi fitur yang digunakan menghasilkan pemilihan fitur yang akan dipelajari oleh pembelajaran mesin berbeda pula. *Filter method* memilih fitur dengan membandingkan fitur mana yang memiliki tingkat korelasi paling besar dengan fitur variabel terikat atau dalam dataset berarti kolom 'event'. *Wrapper method* memilih fitur berdasarkan hasil evaluasi paling baik dengan model pembelajaran mesin yang digunakan. *Embedded method* melakukan seleksi fitur bersamaan dengan proses pembelajaran model yang dipilih. Tabel 4.2 menunjukkan fitur apa saja yang mempengaruhi seseorang melakukan *turnover* berdasarkan metode seleksi fitur yang digunakan.

Tabel 4. 2 Fitur yang diseleksi setelah seleksi fitur tiap metode

Metode Seleksi Fitur	Fitur yang Diseleksi	Jumlah Fitur
<i>Filter Method</i>	<i>Coach, independend, anxiety, industry, way</i>	5
<i>Wrapper Method</i>	<i>Stag, gender, age, industry, profession, head_gender, greywage, way, independend, anxiety</i>	10
<i>Embedded Method</i>	<i>Stag, gender, age, independend, extraversion, anxiety, way, selfcontrol</i>	8

5. Kesimpulan

Model pembelajaran mesin SVM dapat melakukan prediksi dengan cukup baik terhadap data *turnover* pegawai yang diberikan. Hasil evaluasi yang diperoleh oleh model SVM untuk dataset tanpa dilakukan seleksi fitur memiliki nilai sebesar 0,56 untuk semua metode pengukuran. Metode pengukuran yang digunakan adalah akurasi, presisi, *recall*, dan *f1-score*.

Seleksi fitur yang dilakukan terhadap dataset dapat menaikkan dan juga menurunkan hasil evaluasi yang diperoleh tergantung pada metode yang digunakan. Metode seleksi fitur yang menunjukkan hasil evaluasi yang meningkat dibandingkan hasil evaluasi tanpa seleksi fitur adalah *wrapper method* dengan nilai performa model adalah 0,60. Sedangkan dua metode lain, *filter method* dan *embedded method*, mengalami penurunan performa dengan nilai performa yang sama yaitu 0,55. Hal tersebut dapat disebabkan karena pemilihan fitur yang berbeda dari ketiga metode yang digunakan menghasilkan hasil performa yang berbeda pula.

Kekurangan pada penelitian ini adalah tidak menggali lebih jauh mengenai parameter yang dapat mempengaruhi hasil nilai evaluasi. Penggunaan parameter bawaan dari *library* yang digunakan mungkin saja dapat menghasilkan hasil yang berbeda dengan pemilihan sendiri parameter-parameter yang cocok kepada model atau disebut juga *hyperparameter tuning*. Pada penelitian ini, *hyperparameter tuning* tidak dilakukan karena untuk menghindari terlalu banyak parameter yang harus diuji.

Daftar Pustaka

- [1] A. Karmańska, "The benefits of HR analytics," *Pr. Nauk. Uniw. Ekon. we Wroclawiu*, vol. 64, no. 8, pp. 30–39, 2020, doi: 10.15611/pn.2020.8.03.
- [2] Y. Zhao, M. K. Hryniewicki, F. Cheng, B. Fu, and X. Zhu, *Employee turnover prediction with machine learning: A reliable approach*, vol. 869. Springer International Publishing, 2018.
- [3] V. Amin, J. A. Rathod, M. Kunder, and P. Patkar, "A review on employee attrition using machine learning," no. 05, pp. 1237–1241, 2021.
- [4] R. Punnoose and P. Ajit, "Prediction of Employee Turnover in Organizations using Machine Learning Algorithms," *Int. J. Adv. Res. Artif. Intell.*, vol. 5, no. 9, pp. 22–26, 2016, doi: 10.14569/ijarai.2016.050904.
- [5] S. García, J. Luengo, and F. Herrera, "Feature selection," *Intell. Syst. Ref. Libr.*, vol. 72, no. 6, pp. 163–193, 2015, doi: 10.1007/978-3-319-10247-4_7.
- [6] S. Ernawati, E. R. Yulia, Friyadie, and Samudi, "Implementation of the Naïve Bayes Algorithm with Feature Selection using Genetic Algorithm for Sentiment Review Analysis of Fashion Online Companies," *2018 6th Int. Conf. Cyber IT Serv. Manag. CITSM 2018*, no. Citsm, pp. 1–5, 2019, doi: 10.1109/CITSM.2018.8674286.
- [7] J. D. Álvarez, J. A. Matias-Guiu, M. N. Cabrera-Martín, J. L. Risco-Martín, and J. L. Ayala, "An application of machine learning with feature selection to improve diagnosis and classification of neurodegenerative disorders," *BMC Bioinformatics*, vol. 20, no. 1, pp. 1–12, 2019, doi: 10.1186/s12859-019-3027-7.
- [8] Q. R. S. Fitni and K. Ramli, "Implementation of ensemble learning and feature selection for performance

- improvements in anomaly-based intrusion detection systems,” *Proc. - 2020 IEEE Int. Conf. Ind. 4.0, Artif. Intell. Commun. Technol. IAICT 2020*, pp. 118–124, 2020, doi: 10.1109/IAICT50021.2020.9172014.
- [9] A. Tursunbayeva, S. Di Lauro, and C. Pagliari, “People analytics—A scoping review of conceptual boundaries and value propositions,” *Int. J. Inf. Manage.*, vol. 43, no. July, pp. 224–247, 2018, doi: 10.1016/j.ijinfomgt.2018.08.002.
- [10] T. Peeters, J. Paauwe, and K. Van De Voorde, “People analytics effectiveness: developing a framework,” *J. Organ. Eff.*, vol. 7, no. 2, pp. 203–219, 2020, doi: 10.1108/JOEPP-04-2020-0071.
- [11] J. H. Marler and J. W. Boudreau, “An evidence-based review of HR Analytics,” *Int. J. Hum. Resour. Manag.*, vol. 28, no. 1, pp. 3–26, 2017, doi: 10.1080/09585192.2016.1244699.
- [12] C. Varma and C. Chavan, “A Case of HR Analytics—to Understand Effect on Employee Turnover,” *J. Emerg. Technol. ...*, vol. 6, no. 6, pp. 781–787, 2019, [Online]. Available: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3619634.
- [13] V. S. Rangel, “A review of the literature on principal turnover,” *Rev. Educ. Res.*, vol. 88, no. 1, pp. 87–124, Feb. 2018, doi: 10.3102/0034654317743197.
- [14] Y. Zhang, “A Review of Employee Turnover Influence Factor and Countermeasure,” *J. Hum. Resour. Sustain. Stud.*, vol. 04, no. 02, pp. 85–91, 2016, doi: 10.4236/jhrss.2016.42010.
- [15] B. J. Ali and G. Anwar, “Employee Turnover Intention and Job Satisfaction,” *Int. J. Adv. Eng. Manag. Sci.*, vol. 7, no. 6, pp. 22–30, 2021, doi: 10.22161/ijaems.76.3.
- [16] I. El Naqa and M. J. Murphy, “What Is Machine Learning?,” in *Machine Learning in Radiation Oncology*, Springer International Publishing, 2015, pp. 3–11.
- [17] R. Rai, M. K. Tiwari, D. Ivanov, and A. Dolgui, “Machine learning in manufacturing and industry 4.0 applications,” *International Journal of Production Research*, vol. 59, no. 16. Taylor and Francis Ltd., pp. 4773–4778, 2021, doi: 10.1080/00207543.2021.1956675.
- [18] S. Suthaharan, *Machine Learning Models and Algorithms for Big Data Classification*, vol. 36. Boston, MA: Springer US, 2016.
- [19] D. A. Pisner and D. M. Schnyer, “Support vector machine,” in *Machine Learning: Methods and Applications to Brain Disorders*, Elsevier, 2019, pp. 101–121.
- [20] R. Gholami and N. Fakhari, “Support Vector Machine: Principles, Parameters, and Applications,” in *Handbook of Neural Computation*, Elsevier Inc., 2017, pp. 515–535.
- [21] R. Kavitha and E. Kannan, “An Efficient Framework for Heart Disease Classification using Feature Extraction and Feature Selection Technique in Data Mining.”
- [22] G. Chandrashekar and F. Sahin, “A survey on feature selection methods,” *Comput. Electr. Eng.*, vol. 40, no. 1, pp. 16–28, 2014, doi: 10.1016/j.compeleceng.2013.11.024.