

BAB 5

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berikut merupakan kesimpulan dari skripsi ini, yaitu :

1. Berdasarkan analisis penggunaan metode *Neural Network* untuk memprediksi tingkat pemulihan, diperoleh bahwa model *Neural Network* yang paling baik dalam memodelkan tingkat pemulihan pada data adalah *Neural Network* dengan 3 *hidden* neuron dan `threshold = 0,05`.
2. Berdasarkan MSE dari ketiga metode, metode GBM merupakan metode yang paling baik dalam memodelkan data GLTD, sedangkan *Neural Network* merupakan metode yang paling baik kedua dalam memodelkan data GLTD, dan Pohon Keputusan merupakan metode yang paling buruk dalam memodelkan data GLTD dari antara ketiga metode.

5.2 Saran

Berikut merupakan saran yang dapat digunakan untuk mengembangkan skripsi ini, yaitu :

1. Menambahkan banyak *hidden* neuron pada model *Neural Network* dengan memperhatikan aturan dalam menentukan banyaknya *hidden* neuron pada *hidden layer*.
2. Mencari variabel bebas yang paling memengaruhi hasil prediksi tingkat pemulihan dengan menggunakan *Neural Network* dan merancang model berdasarkan variabel-variabel bebas tersebut.
3. Menggunakan metode lain untuk memodelkan tingkat pemulihan pada data, contohnya metode *Random Forest* atau *Bayesian Addition Regression Trees*.

DAFTAR REFERENSI

- [1] Hadley, J. (2007) Insurance coverage, medical care use, and short-term health changes following an unintentional injury or the onset of a chronic condition. *Journal of the American Medical Association*, **297**, 1073–1084.
- [2] Molnar, C. (2019) Interpretable machine learning. a guide for making black box models explainable. <https://christophm.github.io/interpretable-ml-book/>. Desember 2021.
- [3] Salah, M., Altalla, K., Salah, A., dan Abu-Naser, S. S. (2018) Predicting medical expenses using artificial neural network. *International Journal of Engineering and Information Systems*, **2**, 11–17.
- [4] Kopinsky, M. (2017) Predicting group long term disability recovery and mortality rates using tree models. Society of Actuaries.
- [5] Petre, E. G. (2009) A decision tree for weather prediction. *Universitatea Petrol-Gaze din Ploiesti*, **61**, 77–82.
- [6] Mercyana, A. (2020) Pemodelan tingkat pemulihan asuransi grup cacat jangka panjang menggunakan gradient boosting machine (gbm). Skripsi. Universitas Katolik Parahyangan, Indonesia.
- [7] Zhang, Y. dan Haghani, A. (2015) A gradient boosting method to improve travel time prediction. *Transportation Research Part C: Emerging Technologies*, **58**, 308–324.
- [8] Russell, S. J. dan Norvig, P. (2003) *Artificial Intelligence: A Modern Approach*, 2nd edition. Prentice Hall, USA.
- [9] Rokach, L. dan Maimon, O. (2014) *Data Mining with Decision Trees*, 2nd edition. World Scientific, Singapore.
- [10] Ambarsari, E. W. dan Herlinda (2020) Pythagoras tree applied for determined instagram usage habit decision. *SinkrOn : Jurnal dan Penelitian Teknik Informatika*, **4**, 56–61.
- [11] Wang Xiaohu, W. L. dan Nianfeng, L. (2012) An application of decision tree based on id3. *Physics Procedia*, **25**, 1017–1021.
- [12] Friedman, J. H. (2001) Greedy function approximation: a gradient boosting machine. *Annals of Statistics*, **29**, 1189–1232.
- [13] Heaton, J. (2011) *Introduction to the Math of Neural Networks*, 1st edition. Heaton Research, Inc, USA.
- [14] Heaton, J. (2005) *Introduction to Neural Network with Java*, 1st edition. Heaton Research, Inc, USA.
- [15] Nielsen, M. (2015) *Neural Networks and Deep Learning*. Determination Press, San Francisco.
- [16] Günther, F. dan Fritsch, S. (2010) neuralnet: Training of neural networks. *The R Journal*, **2**, 30–38.