

## BAB 5

### KESIMPULAN DAN SARAN

#### 5.1 Kesimpulan

*Gradient boosting* menggabungkan beberapa model sederhana menjadi model gabungan tunggal. Ide utamanya adalah, saat model sederhana ditambahkan secara berurutan, model gabungan tersebut menjadi lebih akurat dalam memprediksi. Model sederhana ini disebut juga dengan *base-learner*. Guna meningkatkan keakuratan prediksi, *gradient boosting* melihat perbedaan antara nilai prediksi dari model  $F_{m-1}(\mathbf{x}_i)$  dan nilai dari vektor target,  $y_i$  yang diketahui, dimana hal ini disebut juga dengan *residual*,  $y_i - F_{m-1}(\mathbf{x}_i)$ . Kemudian membangun *base-learner* (pohon keputusan) yang memetakan vektor *input* ke- $i$ ,  $\mathbf{x}_i$ , ke vektor *residual*. Dengan menambahkan *residual* yang diprediksi oleh pohon keputusan ke model yang ada, model tersebut akan menghasilkan nilai prediksi yang semakin mirip dengan nilai variabel *output*.

Saat menambahkan pohon keputusan kedalam model, terdapat beberapa parameter yang perlu diinisiasi terlebih dahulu terkait dengan pembangunan pohon keputusan. Penentuan parameter tersebut tidak bergantung oleh data yang dimiliki, dengan kata lain parameter tersebut ditentukan tergantung oleh peneliti yang bersangkutan. Parameter ini biasa disebut dengan *hyper-parameter*.

Nilai-nilai *hyper-parameter* tersebut dapat ditentukan secara manual atau dengan kata lain ditentukan dengan mengubah nilai parameter satu persatu sehingga akan diperoleh beberapa model. Kemudian beberapa model tersebut akan dievaluasi dengan melihat nilai MSE yang diperoleh. Model dengan nilai MSE yang kecil merupakan model terbaik. Pemilihan nilai *hyper-parameter* secara manual membutuhkan waktu yang lama untuk memperoleh model terbaik, cara yang lebih efisien untuk memperoleh model terbaik adalah dengan melakukan *hyper-grid search*. Proses *hyper-grid search* yang dilakukan pada bab (4) menghasilkan model GBM optimal dengan nilai-nilai *hyper-parameter* sebagai berikut:  $shrinkage = 0.1$ ,  $n.trees = 840$ ,  $interaction.depth = 5$  dengan menambahkan dua *hyper-parameter* baru yaitu  $n.minobsinnode = 10$ ,  $bag.fraction = 1.00$ . MSE yang diperoleh dari model GBM ini adalah 0,0114692. Nilai MSE ini kemudian akan dibandingkan dengan nilai MSE yang diperoleh dengan menggunakan metode *decision tree*. Berdasarkan simulasi pada [1] diperoleh nilai MSE dari model *Decision Tree* sebesar 0,96993. Berdasarkan kedua nilai ini dapat disimpulkan bahwa model GBM memiliki performansi yang lebih baik dibandingkan model *Decision Tree*, karena nilai MSE dari model ini lebih kecil dibanding MSE dari model *Decision Tree*.

#### 5.2 Saran

Saran untuk kajian lebih lanjut dari skripsi ini antara lain:

1. Melakukan *hyper-grid search* untuk kombinasi nilai *hyper-parameter* yang lebih beragam.
2. Menggunakan *loss-function* lain untuk kasus regresi seperti, *mean absolute error*, *huber loss* dan *quantile loss*
3. Menggunakan algoritma *neural network* untuk memprediksi kasus *recovery rate*.



## DAFTAR REFERENSI

- [1] Kopinsky, M. (2017) Predicting group long term disability recovery and mortality rates using tree models. <https://www.soa.org/resources/experience-studies/2017/2017-glted-recovery-mortality-tree/>. 30 Juni 2020.
- [2] Natekin, A. dan Knoll, A. (2013) Gradient boosting machines, a tutorial. *Frontiers in neurorobotics*, **7**, 21.
- [3] David, M. (2004) Tutorial: The id3 decision tree algorithm. *Monash University Faculty of Information Technology*, **1**, 8.
- [4] Gupta, B., Rawat, A., Jain, A., Arora, A., dan Dhami, N. (2017) Analysis of various decision tree algorithms for classification in data mining. *International Journal of Computer Applications*, **163**, 15–19.
- [5] Nurzakiyah, A. D. (2014) **Post Pruning** pohon keputusan spasial. Skripsi. INSTITUT PERTANIAN BOGOR, Indonesia.
- [6] Marcisz, M. (2013) Practical application of coefficient of variation. *XIII Congreso International en Energia y Recursos Minerals*, **10**, 44.
- [7] James, G., Witten, D., Hastie, T., dan Tibshirani, R. (2009) *An Introduction to Statistical Learning with Applications in R*, 2nd edition. Springer, London.
- [8] Friedman, J. H. (2001) Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, **29**, 1189–1232.
- [9] Lambers, J. V. dan Sumner, A. C. (2019) *Explorations in numerical analysis*. : World Scientific.
- [10] Ridgeway, G. (2019) Generalized boosted models: A guide to the gbm package. *Update*, **1**, 2007.
- [11] Friedman, J. H. (1999) Stochastic gradient boosting. department of statistics. Technical report. Stanford University, Technical Report, San Francisco, CA.
- [12] Murphy, K. P. (2012) *Machine Learning: A Probabilistic Perspective*. The MIT Press, Cambridge.
- [13] Ridgeway, G., Southworth, M. H., dan RUnit, S. (2013) Package ‘gbm’. *Viitattu*, **10**, 40.