

# Estimasi Tingkat Kebisingan pada Airfoil dengan Penerapan Metode Neural Network dan Bagging

Tyas Setiyorini

*Abstract— Noise on aircraft, especially unmanned aircraft becomes the problem that became the concentration of research from year to year. Noise is an unwanted noise, as it causes disruption to human comfort and health. Most of the noise on the plane comes from the propeller system of the lifter, rotor, and engine. In general, one of the parameters that affect the noise caused by the propeller is the basic geometry of the propeller-forming airfoil. Airfoil datasets have non-linear properties. The high variance in the airfoil dataset also shows high noise. Neural network method has good performance in overcoming nonlinear data problem, but neural network has weakness in overcoming high noise data. To solve the problem a bagging method is needed to reduce the high noise indicated by the high variance on the airfoil dataset. Several experiments were conducted to obtain optimal architecture and produce accurate estimates. The experimental results of the 8 combinations of research parameters on the airfoil dataset with the neural network obtained the smallest RMSE value was 2.071, while using neural network and bagging obtained the smallest RMSE value was 1.718. It can be concluded that the estimated noise level in airfoil using bagging and neural network method is more accurate than the individual neural network method.*

**Intisari—**Sebagian besar kebisingan pada pesawat berasal dari sistem propeller pengangkat, rotor, dan mesin. Secara umum, salah satu parameter yang mempengaruhi kebisingan yang disebabkan oleh propeller adalah geometri dasar pembentuk propeller yaitu airfoil. Dataset airfoil memiliki sifat non linear. Varians yang tinggi pada dataset airfoil juga menunjukkan tingginya noise. Metode neural network memiliki kinerja yang baik dalam mengatasi masalah data nonlinear, namun neural network memiliki kelemahan dalam mengatasi data noise yang tinggi. Untuk menyelesaikan masalah tersebut diperlukan metode bagging untuk mengurangi tingginya noise yang ditunjukkan dari varians yang tinggi pada dataset airfoil. Beberapa eksperimen dilakukan untuk mendapatkan arsitektur yang optimal dan menghasilkan estimasi yang akurat. Hasil eksperimen dari 8 kombinasi parameter penelitian pada dataset airfoil dengan neural network didapatkan nilai RMSE terkecil adalah 2.071, sedangkan dengan menggunakan neural network dan bagging didapatkan nilai RMSE terkecil adalah 1.718. Maka dapat disimpulkan estimasi tingkat kebisingan pada airfoil dengan menggunakan metode bagging dan neural network lebih akurat dibanding dengan metode individual neural network.

**Kata Kunci—** Estimasi, Tingkat kebisingan Airfoil, Neural Network, Bagging

Jurusan Teknik Informatika STMIK Nusa Mandiri Jakarta, Jl. Damai No. 8 Warung Jati Barat (Margasatwa) Pasar Minggu Jakarta Selatan DKI Jakarta 12540 INDONESIA (telp: 021-78839502; fax: 021-78839421; e-mail: [tyas.setiyorini@gmail.com](mailto:tyas.setiyorini@gmail.com))

## I. PENDAHULUAN

Seiring berkembangnya waktu, kebanyakan dari mesin-mesin produksi, mesin-mesin transportasi, dan segala sesuatu yang dapat meningkatkan taraf hidup manusia selalu berdampingan dengan masalah kebisingan. Kebisingan pada pesawat, khususnya pesawat tanpa awak menjadi permasalahan yang menjadi konsentrasi penelitian dari tahun ke tahun. Kebisingan adalah bunyi yang tidak dikehendaki, karena tidak sesuai dengan konteks ruang dan waktu, sehingga dapat menimbulkan gangguan terhadap kenyamanan dan kesehatan manusia. Bising merupakan suara atau bunyi yang tidak diinginkan keberadaannya [11]. Kebisingan adalah semua suara yang tidak diinginkan yang biasanya bersumber pada alat-alat proses produksi dan atau alat-alat kerja yang pada tingkat tertentu dapat menimbulkan gangguan pendengaran [13]. Sebagian besar kebisingan pada pesawat berasal dari sistem propeller pengangkat, rotor, dan mesin.

Kebisingan dari sebuah propeller adalah kombinasi dari 2 sumber kebisingan, yaitu dari propeller sendiri, dan dari sumber tenaga (mesin). Propeller terdiri dari dua atau lebih bilah yang terhubung ke porosnya. Setiap bilah adalah airfoil yang bertindak seperti sayap yang berputar karena faktor-faktor aerodinamika yang mempengaruhinya. Penjelasan secara detail tentang teori bagaimana propeller bekerja sehingga menghasilkan gaya dorong sangatlah rumit dan kompleks. Hal ini dikarenakan propeller merupakan sayap yang berputar dengan perubahan bentuk airfoil yang sulit untuk dianalisa.

Mendisain propeller rendah bising merupakan sebuah kajian khusus yang sangat kompleks. Secara umum, salah satu parameter yang mempengaruhi kebisingan yang disebabkan oleh propeller adalah geometri dasar pembentuk propeller yaitu airfoil. Aspek disain yang perlu diperhatikan untuk mengurangi kebisingan yang diakibatkan oleh adanya turbulensi dan vorteks udara, yakni dengan menguji beberapa jenis airfoil yang memiliki tingkat turbulensi dan vortisitas yang rendah akan tetapi tetap memiliki unjuk kerja aerodinamis yang tinggi.

NACA (*National Advisory Committee for Aeronautics*) merupakan standar dalam perancangan suatu airfoil. Perancangan airfoil pada dasarnya bersifat khusus dan dibuat menurut selera serta sesuai dengan kebutuhan dari pesawat yang akan dibuat. Akan tetapi NACA menggunakan bentuk airfoil yang disusun secara sistematis dan rasional. Namun cara tersebut kurang efisien dan tidak menjamin akurasi.

Dalam cabang ilmu komputer yang disebut *data mining*, untuk menjamin tingkat akurasi dalam mengurangi kebisingan telah dilakukan beberapa penelitian dengan

berbagai macam metode komputasi dengan dataset airfoil., Dari beberapa penelitian yang telah dilakukan disimpulkan bahwa metode individual yang paling baik adalah neural network. Neural network berhasil diterapkan pada masalah prediksi kebisingan airfoil [12]. Output suara dari arofil telah diberi parameter dengan menggunakan aturan penskalaan kebisingan dan parameter geometrik aerfoil [12].

Neural network memiliki keunggulan dalam memprediksi hasil dikotomis atau membuat keputusan diagnostik dibandingkan dengan model linear regression, termasuk kemampuan untuk mendeteksi hubungan kompleks yang bersifat nonlinear antara faktor prediksi dan hasil prediksi [2][4]. Neural network menjadi alat yang ampuh untuk memecahkan banyak masalah, khususnya dalam situasi, dimana data mungkin rumit atau dalam jumlah yang cukup besar [17]. Neural network memiliki kemampuan untuk model yang kompleks dengan berbagai masalah nonlinier, namun kelemahan utama dari neural network adalah ketidakstabilan mereka, terutama dalam kondisi noise dan dataset yang terbatas [6]. Neural network telah sangat berhasil dalam sejumlah aplikasi pemrosesan sinyal, namun keterbatasan fundamental dan kesulitan yang melekat yaitu ketika menggunakan neural network untuk pengolahan noise yang tinggi dan sinyal ukuran sampel yang kecil [9]. Untuk mengatasi kelemahan neural network dalam mengatasi data noise yang tinggi dibutuhkan metode gabungan dengan metode lain untuk memecahkan masalah data noise agar mendapatkan prediksi yang lebih akurat dibandingkan dengan metode individual.

Seperti banyak penelitian lainnya, prediksi tingkat noise menderita efek negatif yaitu noise dari data pelatihan, hal ini dapat mempengaruhi akurasi prediksi [8]. Noise adalah data yang berisi nilai-nilai yang salah atau anomali, yang biasanya disebut juga outlier [20]. Outlier atribut dapat mengakibatkan hilangnya informasi sehingga akan merusak hasil pemodelan [16][19]. Noise adalah kesalahan acak atau varians dalam variabel yang diukur dengan nilai standar deviasi [10]. Noise atau outlier yaitu nilai atribut yang mengandung penyimpangan nilai standar deviasi dari nilai mean-nya [16][19]. Penyebab lain yang mungkin dari noise yang harus dicari dalam perangkat rusak adalah pengukuran data, yang dinyatakan dalam satuan pengukuran heterogen sehingga menyebabkan anomali dan ketidakakuratan [20]. Dataset airfoil mengandung penyebaran data (variens) yang tidak merata atau meluas (heterogen). Varians yang tinggi pada dataset airfoil menunjukkan noise yang tinggi sehingga akan mengganggu proses estimasi dan menyebabkan estimasi yang kurang akurat.

Bagging sering memiliki akurasi secara signifikan besar, dan lebih kuat terhadap penyebab noise dan overfitting dari data pelatihan asli [10]. Bagging sebagai teknik pengurangan varians untuk metode dasar seperti decision tree atau neural network [3]. Bagging dikenal sangat efektif bila pengklasifikasi tidak stabil, yaitu ketika penturbing set pembelajaran dapat menyebabkan perubahan yang signifikan dalam perilaku klasifikasi, karena bagging meningkatkan kinerja generalisasi dengan cara mengurangi

variens dengan tetap menjaga atau hanya sedikit meningkatkan bias [3]. Menurut Wange et al dalam Erdal et al, bagging mampu mengurangi penyebab noise [8]. Modifikasi algoritma hybrid bagging, mampu menyediakan kecepatan komputasi, perbaikan tambahan dalam akurasi, dan ketahanan untuk vektor respon noise [5]. Bagging juga baik diterapkan untuk skema pembelajaran untuk prediksi numerik [21]. Bagging adalah algoritma yang tepat untuk mengurangi varians, serta baik diterapkan pada dataset airfoil yang memiliki atribut dan label yang bersifat numerik.

Dari permasalahan pada penelitian-penelitian di atas disimpulkan bahwa dataset airfoil merupakan data kompleks yang bersifat nonlinear. Varians yang tinggi pada dataset airfoil menunjukkan tingginya noise. Berdasarkan analisa bahwa metode gabungan dua metode atau lebih (*ensemble*) menunjukkan hasil yang lebih akurat dibanding metode individual. Neural network yang ampuh mengatasi masalah data nonlinear namun kurang mampu mengatasi data noise yang tinggi, sedangkan bagging mampu mengurangi tingginya noise yang ditunjukkan dari varians yang tinggi pada dataset airfoil. Oleh karena itu pada penelitian ini diusulkan menggunakan metode gabungan yaitu metode neural network dan bagging.

## II. KAJIAN LITERATUR

### A. Bagging

*Bagging* dikenal sangat efektif ketika pengklasifikasi tidak stabil, yaitu ketika perturbing set belajar dapat menyebabkan perubahan signifikan dalam perilaku klasifikasi, karena bagging meningkatkan kinerja generalisasi karena pengurangan varians tetap terjaga atau hanya sedikit meningkatkan bias [14]. Bagging menggabungkan pengklasifikasi yang diperoleh dari algoritma belajar yang berbeda dengan menggunakan tingkat meta-classifier tinggi untuk menggabungkan tingkat model yang lebih rendah. Hal ini didasarkan pada kenyataan bahwa pengklasifikasi yang berbeda diperoleh dari data yang sama dan algoritma belajar yang berbeda menggunakan bias yang berbeda untuk mencari ruang hipotesis (19). Pendekatan ini diharapkan bahwa model gabungan (*classifier-ensemble*) akan dapat belajar bagaimana untuk memutuskan prediksi yang diberikan oleh pengklasifikasi dasar, untuk mendapatkan akurasi yang lebih baik daripada model tunggal.

Algoritma Bagging (Brieman, 1996):

Perulangan for  $b = 1, 2, \dots, B$

1. Buat sampel bootstrap dengan penggantian secara acak dari data training  $\{(X_1, Y_1), (X_2, Y_2), \dots, (X_n, Y_n)\}$  mencocokkan dengan classifier  $C_b$  dinyalakan pada sampel yang sesuai bootstrap.
2. Output classifier akhir:

$$C(x) = B^{-1} \sum_{b=1}^B C_b(x) \quad (2)$$

Noise pada dataset mampu diatasi oleh Bagging dibanding model individu, sehingga mampu meningkatkan akurasi yang tinggi [5][10]. Algoritma seperti Neural

Network (NN) mampu meningkatkan kinerja dengan metode gabungan (ensemble) dengan bagging [14]. Noise yang tinggi mengakibatkan masalah dalam kinerja pengklasifikasian. Untuk mengatasi noise yang tinggi tersebut maka bagging akan digabungkan dengan algoritma neural network sehingga akurasi estimasi dapat ditingkatkan.

B. Neural Network

Neural network (NN) adalah satu set unit input atau output yang terhubung dimana tiap relasinya memiliki bobot [10]. NN dimaksudkan untuk mensimulasikan perilaku sistem biologi susunan syaraf manusia, yang terdiri dari sejumlah besar unit pemroses yang disebut neuron, yang beroperasi secara paralel. Neuron mempunyai relasi dengan synapse yang mengelilingi neuron-neuron lainnya. Susunan syaraf tersebut dipresentasikan dalam neural network berupa graf yang terdiri dari simpul (neuron) yang dihubungkan dengan busur, yang berkorespondensi dengan synapse [1]. Sejak tahun 1950-an [20], neural network telah digunakan untuk tujuan prediksi, bukan hanya klasifikasi tapi juga untuk regresi dengan atribut target kontinu. Algoritma backpropagation digunakan pada penelitian ini. Multilayer perceptron (MLP) disebut juga multilayer feedforward neural network merupakan algoritma yang paling luas digunakan. Penemuan algoritma backpropagation untuk MLP, merupakan metode yang sistematis untuk training sehingga bisa dilakukan dan lebih efisien.

III. METODE PENELITIAN

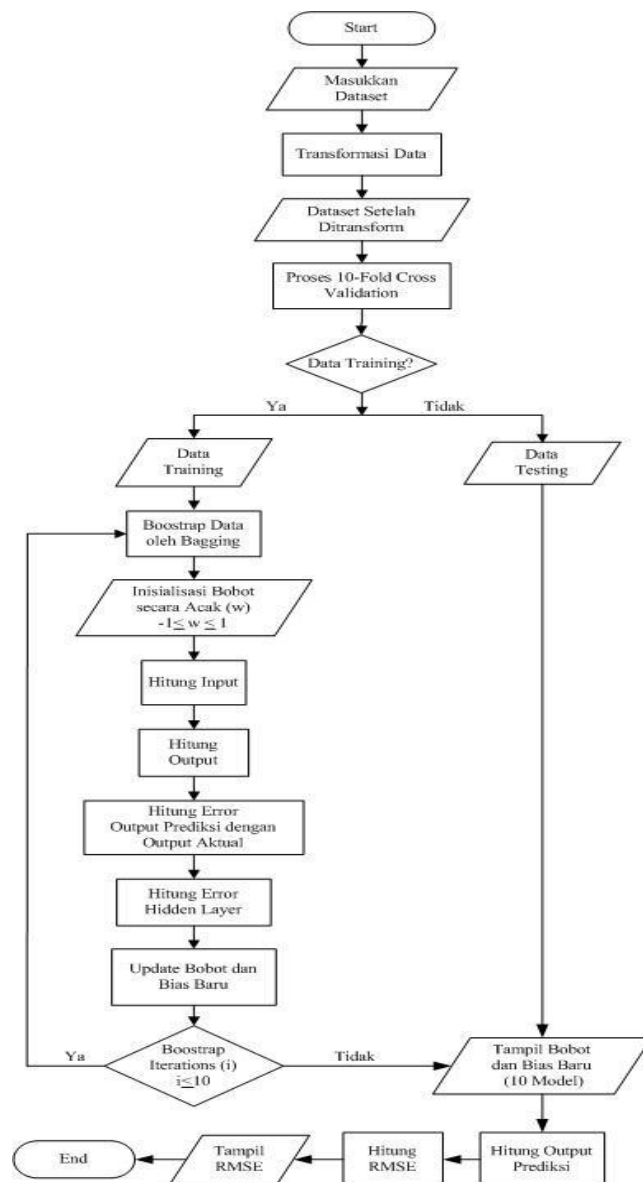
A. Pengumpulan Data

Dataset airfoil adalah dataset yang digunakan pada penelitian ini seperti pada Tabel 1 yang menunjukkan unit, mean, varians dan standard deviation dari variabel input dan variabel class. Dari model dataset pada Tabel 1 menunjukkan bahwa nilai varians yang besar atau nilai standard deviation yang lebih besar dibanding nilai mean menunjukkan tingginya noise [18] pada dataset airfoil tersebut.

TABEL 1.  
MODEL DATASET AIRFOIL

Input	Unit	Mean	Varians	Standard Deviation
Frequency	Hertz	2886.381	9938717	3152.573
Angle of attack	Degrees	6.782302	35.02424	5.918128
Chord Length	Meters	0.136548	0.00875	0.093541
Free-stream velocity	Meters per second	50.86075	242.5116	15.57278
Suction side displacement thickness	Meters	0.01114	0.000173	0.01315
Scaled sound pressure level	Decibels	124.836	47591463	6898.657

B. Metode yang Diusulkan



Gambar 1. Penggabungan Algoritma Bagging pada Neural Network

Gambar 1 menunjukkan metode bagging pada neural network adalah metode yang diusulkan dalam penelitian ini. Dataset dibagi menjadi data testing dan data training dengan 10 fold cross validation. Kemudian bagging akan membagi data training menjadi sub dataset (bootstrap) dengan 10 perulangan (iterations). Kemudian neural network akan memproses masing-masing bootstrap data. Langkah awal neural network secara acak akan memberikan inisialisasi bobot awal untuk input layer, hidden layer, dan bias. Simpul bias terdiri dari dua, yaitu pada input layer yang terhubung dengan simpul-simpul pada hidden layer, dan hidden layer yang terhubung pada output layer.

Setelah semua nilai awal ditentukan, kemudian dihitung input, output dan error. Kemudian dengan menggunakan fungsi aktivasi sigmoid untuk membangkitkan output untuk simpul. Selanjutnya dihitung nilai error output prediksi

dengan output aktual, kemudian dikembalikan lagi ke layer sebelumnya (backpropagation) untuk menghitung error pada hidden layer. Proses neural network tersebut akan terus berulang sebanyak 10 perulangan bootstrap. Setelah semua perulangan selesai semua hasil model bootstrap dihitung hingga menghasilkan 10 model. Selanjutnya dihitung output prediksi rata-rata 10 model tersebut. Kemudian dihitung Root Mean Square Error (RMSE) yaitu error rata-rata selisih antara output prediksi dengan output aktual.

#### IV. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan dataset airfoil yang didapat dari UCI Machine Learning Repository. Spesifikasi komputer yang digunakan adalah CPU Intel Core i5 1.6GHz, RAM 4 GB, dan sistem operasi Microsoft Windows 8 Professional 64-bit. Aplikasi yang digunakan adalah RapidMiner 7.

Setelah eksperimen yang dilakukan dengan neural network dan neural network dan bagging, kemudian dibandingkan hasil RMSE pada metode neural network dengan neural network dan bagging dari 8 eksperimen pada dataset airfoil.

Pada Tabel 2 dari 8 eksperimen dan rata-rata keseluruhan eksperimen pada dataset airfoil secara konsisten menunjukkan penurunan nilai RMSE yang signifikan antara neural network dengan neural network dan bagging.

TABEL II.  
HASIL EKSPERIMEN NEURAL NETWORK DENGAN NEURAL NETWORK DAN BAGGING

Parameter Neural Network					Parameter Bagging	RMSE	
Training Cycles	Learning Rate	Momentum	Hidden Layer 1	Hidden Layer 2	Iterations	NN	NN+Bagging
500	0.3	0.2	2	-	10	4.783	4.34
500	0.3	0.2	6	-	10	3.786	3.34
500	0.1	0.1	6	-	10	3.747	3.3
500	0.2	0.2	6	-	10	3.394	2.94
300	0.2	0.2	6	-	10	3.739	3.26
450	0.2	0.2	6	-	10	3.415	2.99
1000	0.2	0.2	12	10	10	2.060	1.70
1000	0.2	0.2	13	9	10	2.071	1.71

Penurunan nilai RMSE yang signifikan dan konsisten dari 8 eksperimen pada dataset airfoil yang ditunjukkan pada Tabel 2, menunjukkan bahwa penggunaan neural network dan bagging memiliki nilai RMSE lebih kecil dibanding dengan penggunaan neural network saja. Dari hasil pengujian tersebut menunjukkan bahwa bagging mampu mengurangi tingginya noise yang ditunjukkan dari varians yang tinggi pada dataset airfoil, sehingga menghasilkan kinerja estimasi tingkat kebisingan pada airfoil yang lebih baik dibanding dengan menggunakan metode individual neural network. Merujuk pada penelitian yang telah dilakukan sebelumnya oleh Kim & Kang dalam mengkomparasi hasil error rate neural network dengan neural network dan bagging pada 10 eksperimen yang berbeda, hasil penelitian tersebut juga menunjukkan

penurunan nilai error rate yang konsisten dan signifikan, sehingga menunjukkan bahwa metode neural network dan bagging memiliki kinerja yang lebih baik dibanding neural network saja [14].

#### V. KESIMPULAN

Hasil eksperimen dari 8 kombinasi parameter penelitian pada dataset airfoil dengan neural network didapatkan nilai RMSE terkecil adalah 2.071, sedangkan dengan menggunakan neural network dan bagging didapatkan nilai RMSE terkecil adalah 1.718.

Dari hasil eksperimen tersebut maka dapat disimpulkan bahwa bagging mampu mengurangi tingginya noise yang ditunjukkan dari varians yang tinggi pada dataset airfoil, sehingga menghasilkan kinerja estimasi tingkat kebisingan pada airfoil yang lebih baik dibanding dengan menggunakan metode neural network saja.

#### UCAPAN TERIMA KASIH

Terima kasih saya sampaikan kepada pihak-pihak yang telah mendukung dalam pembuatan *paper* ini.

#### REFERENSI

- [1] Alpaydin, Ethem. (2010). Introduction to Machine Learning. London: The MIT Press
- [2] Alshihri, M. M., Azmy, A. M., & El-Bisy, M. S. (2009). Neural networks for predicting compressive strength of structural light weight concrete. *Construction and Building Materials*, 23(6), 2214–2219.
- [3] Breiman, L. (1996). Bagging predictors. *Machine Learning*, 26(2), 123–140.
- [4] Chen, H., Zhang, J., Xu, Y., Chen, B., & Zhang, K. (2012). Performance comparison of artificial neural network and logistic regression model for differentiating lung nodules on CT scans. *Expert Systems with Applications*, 39(13), 11503–11509.
- [5] Culp, M., Michailidis, G., & Johnson, K. (2011). On Adaptive Regularization Methods in Boosting. *Journal of Computational and Graphical Statistics*, 20(4), 937–955.
- [6] Dimopoulos, L. F., Tsiros, L. X., Serelis, K., & Chronopoulou, A. (2004). Combining Neural Network Models to Predict Spatial Patterns of Airborne Pollutant Accumulation in Soils around an Industrial Point Emission Source. *Journal of the Air & Waste Management Association*, 54(12), 1506–1515.
- [7] Erdal, H. I. (2013). Two-level and hybrid ensembles of decision trees for high performance concrete compressive strength prediction. *Engineering Applications of Artificial Intelligence*, 26(7), 1689–1697.
- [8] Erdal, H. I., Karakurt, O., & Namli, E. (2013). High performance concrete compressive strength forecasting using ensemble models based on discrete wavelet transform. *Engineering Applications of Artificial Intelligence*, 26(4), 1246–1254.
- [9] Giles, C. L. E. E., & Lawrence, S. (2001). Noisy Time Series Prediction using Recurrent Neural Networks and Grammatical Inference, 161–183.
- [10] Han, J., Kamber, M., & Pei, J. (2012). Data Mining



- Concepts and Techniques. San Fransisco: Morgan Kauffman.
- [11] Harris, C. M. (1957). Handbook of Noise Control, Sydney: McGraw-Hill Book Company.
- [12] K. Lau, R. López, and E. Oñate, "INTERNATIONAL CENTER FOR NUMERICAL METHODS IN ENGINEERING A Neural Networks Approach to Aerofoil Noise Prediction A Neural Networks Approach to Aerofoil Noise Prediction," 2009.
- [13] Kepmenaker No. Kep-51/Men/1999
- [14] Kim, M., & Kang, D. (2012). Expert Systems with Applications Classifiers selection in ensembles using genetic algorithms for bankruptcy prediction. Expert Systems With Applications, 39(10), 9308–9314.
- [15] Kim, M.-J., & Kang, D.-K. (2010). Ensemble with neural networks for bankruptcy prediction. Expert Systems with Applications, 37(4), 3373–3379.
- [16] Maimon, Oded&Rokach, Lior. (2010). Data Mining and Knowledge Discovey Handbook. New York: Springer
- [17] Nazari, A., & Pacheco Torgal, F. (2013). Predicting compressive strength of different geopolymers by artificial neural networks. Ceramics International, 39(3), 2247–2257.
- [18] T. Setiyorini, "Penerapan Metode Bagging untuk Mengurangi Data Noise pada Neural Network untuk Estimasi Kuat Tekan Beton," vol. 1, no. 1, pp. 37–42, 2015.
- [19] Twala, B. (2010). Multiple classifier application to credit risk assessment. Expert Systems with Applications, 37(4), 3326–3336.
- [20] Vercellis, Carlo (2009). Business Intelligent: Data Mining and Optimization for Decision Making. Southern Gate, Chichester, West Sussex: John Willey & Sons, Ltd.
- [21] Witten, I. H., Frank, E., & Hall, M. A. (2011). Data Mining: Practical Machine Learning and Tools. Burlington: Morgan Kaufmann Publisher.



Tyas Setiyorini. Batang, 12 Oktober 1986. Menempuh pendidikan S1 Sistem Informasi di STMIK Swadharma, Jakarta, S2 Magister Sistem Informasi di STMIK Nusa Mandiri Jakarta. Saat ini menjadi dosen di STMIK Nusa Mandiri Jakarta. *Paper* yang pernah dipublikasikan berjudul "Penerapan Metode Bagging untuk Mengurangi Data *Noise* pada Neural Network untuk Estimasi Kuat Tekan Beton", dan "Penerapan Information Gain

pada K-Nearest Neighbor untuk Klasifikasi Tingkat Kognitif Soal pada Taksonomi Bloom".