

# Penerapan Metode Bagging untuk Mengurangi Data *Noise* pada Neural Network untuk Estimasi Kuat Tekan Beton

Tyas Setiyorini

*Sekolah Tinggi Manajemen Informatika dan Komputer Nusa Mandiri*  
Email: tyas\_setiyorini@yahoo.com

Romi Satria Wahono

*Fakultas Ilmu Komputer, Universitas Dian Nuswantoro*  
Email: romi@brainmatics.com

**Abstract:** Beton adalah bahan yang diolah yang terdiri dari semen, agregat kasar, agregat halus, air dan bahan tambahan lainnya. Kuat tekan beton sangat bergantung pada karakteristik dan komposisi bahan-bahan pembentuk beton. Metode neural network memiliki kinerja yang baik dalam mengatasi masalah data nonlinear, namun neural network memiliki keterbatasan dalam mengatasi data *noise* yang tinggi. Untuk menyelesaikan masalah tersebut diperlukan metode bagging untuk mengurangi data *noise* pada metode neural network. Beberapa eksperimen dilakukan untuk mendapatkan arsitektur yang optimal dan menghasilkan estimasi yang akurat. Hasil eksperimen dari delapan kombinasi parameter penelitian pada dataset *concrete compressive strength* dengan neural network didapatkan nilai rata-rata RMSE adalah 0,069 dan nilai RMSE terkecil adalah 0,057, sedangkan dengan menggunakan neural network dan bagging didapatkan nilai rata-rata RMSE adalah 0,062 dan nilai RMSE terkecil adalah 0,055. Hasil eksperimen dari delapan kombinasi parameter penelitian pada dataset *slump* dengan neural network didapatkan nilai rata-rata RMSE adalah 0,020 dan nilai RMSE terkecil adalah 0,011 sedangkan dengan neural network dan bagging didapatkan nilai rata-rata RMSE adalah 0,016 dan nilai RMSE terkecil adalah 0,010. Maka dapat disimpulkan estimasi kuat tekan beton dengan menggunakan metode bagging dan neural network lebih akurat dibanding dengan metode individual neural network.

**Keywords:** estimasi, kuat tekan beton, neural network, bagging

## 1 PENDAHULUAN

Dewasa ini kata beton sudah tidak asing lagi, baik di masyarakat umum maupun di kalangan para *engineer*. Kelebihan sifat beton dibanding bahan lain adalah: 1). Mampu memikul beban yang berat, 2). Dapat dibentuk sesuai dengan kebutuhan konstruksi 3). Tahan terhadap temperatur yang tinggi 4). Biaya pemeliharaan yang kecil (Mulyono, 2004).

Beton adalah bahan yang diperoleh dengan mencampurkan semen hidrolis (*portland cement*), agregat kasar, agregat halus, air dan bahan tambahan (Mulyono, 2004). Sebagian besar bahan pembuat beton adalah bahan lokal (kecuali semen atau bahan tambahan kimia lain), sehingga sangat menguntungkan secara ekonomi. Namun pembuatan beton akan menjadi mahal jika perencanaannya tidak memahami karakteristik bahan-bahan pembentuk beton yang harus disesuaikan dengan perilaku struktur yang akan dibuat. Dalam ilmu sipil, memprediksi sifat mekanik bahan konstruksi adalah tugas penelitian yang penting (Chou & Pham, 2013). Sifat dan karakteristik bahan pembentuk beton akan mempengaruhi mutu beton (Mulyono, 2004).

Mutu beton yang baik adalah jika beton tersebut memiliki kuat tekan tinggi (antara 20–50 Mpa, pada umur 28 hari). Dengan kata lain dapat diasumsikan bahwa mutu beton ditinjau dari kuat tekannya saja (Tjokrodinuljo, 1996). Kuat tekan beton akan berubah sesuai dengan bertambahnya umur beton tersebut dengan umur 3, 7, 14, 21, 28, 90, dan 365 hari. (PBI, 1971). Secara umum, para ahli laboratorium melakukan *mix design* dengan aturan standar tertentu yang dilakukan secara manual dengan melihat tabel dan grafik referensi dan keadaan lapangan, tetapi cara tersebut sangat tidak efisien dan tidak menjamin akurasi. Untuk menjamin tingkat akurasi dalam memprediksi kuat tekan beton sampai saat ini telah banyak penelitian yang dilakukan dengan berbagai macam metode komputasi dengan berbagai jenis dataset kuat tekan beton, dalam cabang ilmu komputer yang disebut *data mining*.

Dari beberapa penelitian yang telah dilakukan disimpulkan bahwa metode individual yang paling baik adalah neural network. Hubungan antara komponen dan komposisi bahan pembentuk beton dengan kuat tekan beton bersifat sangat nonlinear (Chou & Pham, 2013; Erdal, 2013). 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 (Alshihri, Azmy, & El-Bisy, 2009; Chen, Zhang, Xu, Chen, & Zhang, 2012). Neural network menjadi alat yang sangat ampuh untuk memecahkan banyak masalah teknik sipil, khususnya dalam situasi, dimana data mungkin rumit atau dalam jumlah yang cukup besar (Nazari & Pacheco Torgal, 2013). Meskipun metode neural network telah mampu membuktikan dalam menangani masalah nonlinear, neural network masih memiliki beberapa kelemahan.

Seperti banyak penelitian lainnya, prediksi kuat tekan beton menderita efek negatif yaitu *noise* dari data pelatihan, hal ini dapat mempengaruhi akurasi prediksi (Erdal, Karakurt, & Namli, 2013). *Noise* adalah data yang berisi nilai-nilai yang salah atau anomali, yang biasanya disebut juga *outlier*. Penyebab lain yang mungkin dari *noise* yang harus dicari dalam perangkat rusak adalah pengukuran data, perekaman dan transmisi. Itu adalah adanya data yang dinyatakan dalam satuan pengukuran heterogen, sehingga menyebabkan anomali dan ketidakakuratan (Vercellis, 2009). Dataset kuat tekan beton mengandung *noise* yang tinggi, hal ini dapat dilihat dari penyebaran data (*varians*) yang tidak merata atau meluas (*heterogen*). *Noise* yang tinggi pada dataset kuat tekan beton mengganggu proses estimasi, sehingga menyebabkan estimasi yang kurang akurat.

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 (Dimopoulos, Tsiros, Serelis, & Chronopoulou, 2004). 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 (Giles & Lawrence, 2001). 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.

Breiman (1996) menganggap bagging sebagai teknik pengurangan varians (*noise*) untuk metode dasar seperti decision tree atau neural network (Breiman, (1996). Bagging dikenal sangat efektif bila pengklasifikasi tidak stabil, yaitu ketika penturbung set pembelajaran dapat menyebabkan perubahan yang signifikan dalam perilaku klasifikasi, karena bagging meningkatkan kinerja generalisasi dengan cara mengurangi varians (*noise*) dengan tetap menjaga atau hanya sedikit meningkatkan bias (Breiman, 1996). Menurut Wange et al dalam Erdal et al, bagging mampu mengurangi pengaruh *noise* (Erdal et al., 2013). Modifikasi algoritma hybrid bagging, mampu menyediakan kecepatan komputasi, perbaikan tambahan dalam akurasi, dan ketahanan untuk vektor respon *noise* (Culp, Michailidis, & Johnson, 2011). Bagging sering memiliki akurasi secara signifikan besar, dan lebih kuat terhadap efek *noise* dan overfitting dari data pelatihan asli (Han, Kamber, & Pei, 2012). Bagging juga baik diterapkan untuk skema pembelajaran untuk prediksi numerik (Witten, Frank, & Hall, 2011). Bagging adalah algoritma yang tepat untuk mengurangi data *noise* pada neural network, serta baik diterapkan pada dataset kuat tekan beton yang memiliki atribut dan label yang bersifat numerik.

## 2 PENELITIAN TERKAIT

Dataset kuat tekan beton merupakan dataset yang kompleks, sangat nonlinear dan mengandung *noise* yang tinggi. Neural network adalah alat yang baik untuk model sistem nonlinear, namun masih kurang mampu mengatasi *noise*. Penelitian yang dilakukan oleh Alshihri (Alshihri et al., 2009) dalam peningkatan akurasi prediksi metode neural network untuk memprediksi kekuatan tekan beton ringan dengan dua model yang digunakan yaitu, Feed-forward Back Propagation (BP) dan Cascade Correlation (CC). Hasil disimpulkan bahwa CC mampu mengurangi *noise* pada neural network, serta menunjukkan hasil yang sedikit akurat dan mampu belajar dengan sangat cepat dibandingkan dengan prosedur backpropagation.

CC masih menunjukkan hasil yang sedikit akurat dan belum mampu mengurangi *noise* yang tinggi pada neural network, oleh karena itu dilakukan penelitian oleh Erdal et al (Erdal et al., 2013) dengan menggunakan metode gabungan (*ensemble*) neural network, discrete wavelet transform dan gradien boosting. Hasil penelitian menunjukkan nilai RMSE yang menurun dibanding dengan metode individual neural network.

Pendekatan model *ensemble* kembali dilakukan oleh Erdal (Erdal, 2013) dengan metode decision tree. Decision tree mudah dipengaruhi oleh data *noise*. Hasil penelitian ini menunjukkan metode *ensemble* bagging mampu mengurangi *noise* pada decision tree.

Dari permasalahan pada penelitian-penelitian di atas disimpulkan bahwa dataset kuat tekan beton merupakan data

kompleks yang bersifat nonlinear dan memiliki data *noise* yang tinggi. 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 data *noise*. Oleh karena itu pada penelitian ini diusulkan menggunakan metode *ensemble* dengan menggabungkan metode bagging untuk mengurangi *noise* pada neural network dengan kombinasi *adjustment* parameter yang berbeda-beda.

## 3 PENGUMPULAN DATA

Dalam penelitian ini dikumpulkan dua dataset yaitu dataset *concrete compressive strength* dan dataset *slump* seperti pada Tabel 1 dan Tabel 2 yang menampilkan unit, nilai minimal, maximal, mean, varians dan standard deviation dari variabel input dan variabel target (*class*). Dari model input ini menunjukkan seberapa tinggi tingkat *noise* pada dataset terlihat dari besarnya nilai varians atau perbandingan nilai standard deviation yang lebih besar dari nilai mean.

Tabel 1. Dataset Concrete Compressive Strength

Input	Unit	Min	Max	Mean	Varians	Standard Deviation
Cement	kg/m <sup>3</sup>	102,0	540,0	281,2	10911,14	104,46
Blast furnace slag	kg/m <sup>3</sup>	0,0	359,4	73,9	7436,86	86,24
Fly ash	kg/m <sup>3</sup>	0,0	200,1	54,2	4091,57	63,97
Water	kg/m <sup>3</sup>	121,8	247,0	181,6	455,62	21,35
Superplasticizer	kg/m <sup>3</sup>	0,0	32,2	6,2	35,65	5,97
Coarse aggregate	kg/m <sup>3</sup>	801,0	1145,0	972,9	6039,79	77,72
Fine aggregate	kg/m <sup>3</sup>	594,0	992,0	773,6	6421,86	80,14
Age	day	1	365	46	3986,56	63,14
Concrete compressive strength (class)	MPa	2,332	82,599	35,8	278,81	16,70

Tabel 2. Dataset Slump

Input	Unit	Min	Max	Mean	Varians	Standard Deviation
Cement	kg/m <sup>3</sup>	137,00	374,00	229,9	6161,21	78,49
Slag	kg/m <sup>3</sup>	0,00	193,00	78,0	3620,09	60,17
Fly ash	kg/m <sup>3</sup>	0,00	260,00	149,0	7225,41	85,00
Water	kg/m <sup>3</sup>	160,00	240,00	197,2	404,40	20,11
SP	kg/m <sup>3</sup>	2,00	22,00	8,6	9,76	3,12
Coarse aggregate	kg/m <sup>3</sup>	708,00	1049,90	884,0	7737,18	87,96
Fine aggregate	kg/m <sup>3</sup>	640,60	902,00	739,6	3973,27	63,03
Slump	cm	0,00	29,00	18	75,83	8,71
Flow	cm	20,00	78,00	49,6	305,65	17,48
Compressive strength (28 day) (class)	MPa	17,19	58,53	36,1	229,43	7,84

## 4. PENGOLAHAN DATA AWAL (PREPROCESSING)

Merupakan tindak lanjut dari pengumpulan data, dengan melakukan normalisasi data. Normalisasi data dilakukan sesuai fungsi aktivasi yang digunakan, dalam penelitian ini digunakan fungsi *binary sigmoid*, data harus dinormalisasikan dalam *range* 0 sampai 1, tapi akan lebih baik jika ditransformasikan ke interval yang lebih kecil, misal pada interval [0.1,0.9] (Jong Jek Siang, 2009). Maka, pada data sinoptik yang ada dilakukan *transform* data dengan interval [0.1,0.9], dengan rumus sebagai berikut:

$$x^1 = \frac{0,8(x-a)}{b-a} + 0,1 \quad (1)$$

Keterangan :  $x^1$  = nilai transform  
 x = nilai asli  
 a = nilai minimal  
 b = nilai maximal

5 METODE YANG DIUSULKAN

5.1 Baging

Bagging adalah singkatan dari *bootstrap aggregating*, menggunakan sub-dataset (*bootstrap*) untuk menghasilkan set pelatihan L (*learning*), L melatih dasar belajar menggunakan prosedur pembelajaran yang tidak stabil, dan kemudian, selama pengujian, mengambil rata-rata (Breiman 1996). Bagging baik digunakan untuk klasifikasi dan regresi. Dalam kasus regresi, untuk menjadi lebih kuat, seseorang dapat mengambil rata-rata ketika menggabungkan prediksi. Bagging adalah (Alypadin, 2010) sebuah algoritma pembelajaran yang stabil pada perubahan kecil dalam *training* set menyebabkan perbedaan besar dalam peserta didik yang dihasilkan, yaitu algoritma belajar pada data yang memiliki varians tinggi (*noise*). Bagging mampu meningkatkan akurasi secara signifikan lebih besar dibanding model individual, dan lebih kuat terhadap efek *noise* dan *overfitting* dari data pelatihan asli. (Han et al., 2012; Culp et al., 2011).

Algoritma Bagging (Brieman, 1996):

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

1. Buat sampel *bootstrap*  $\{(X_1^*, Y_1^*), (X_2^*, Y_2^*), \dots, (X_n^*, Y_n^*)\}$  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:

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

Karya (Breiman, 1994) pada Kim & Kang melaporkan bahwa bagging dapat meningkatkan kinerja dengan penggabungan (*ensemble*) algoritma seperti Decision Tree (DT), Neural Network (NN), dan Support Vector Machine (SVM) (M. Kim & Kang, 2012).

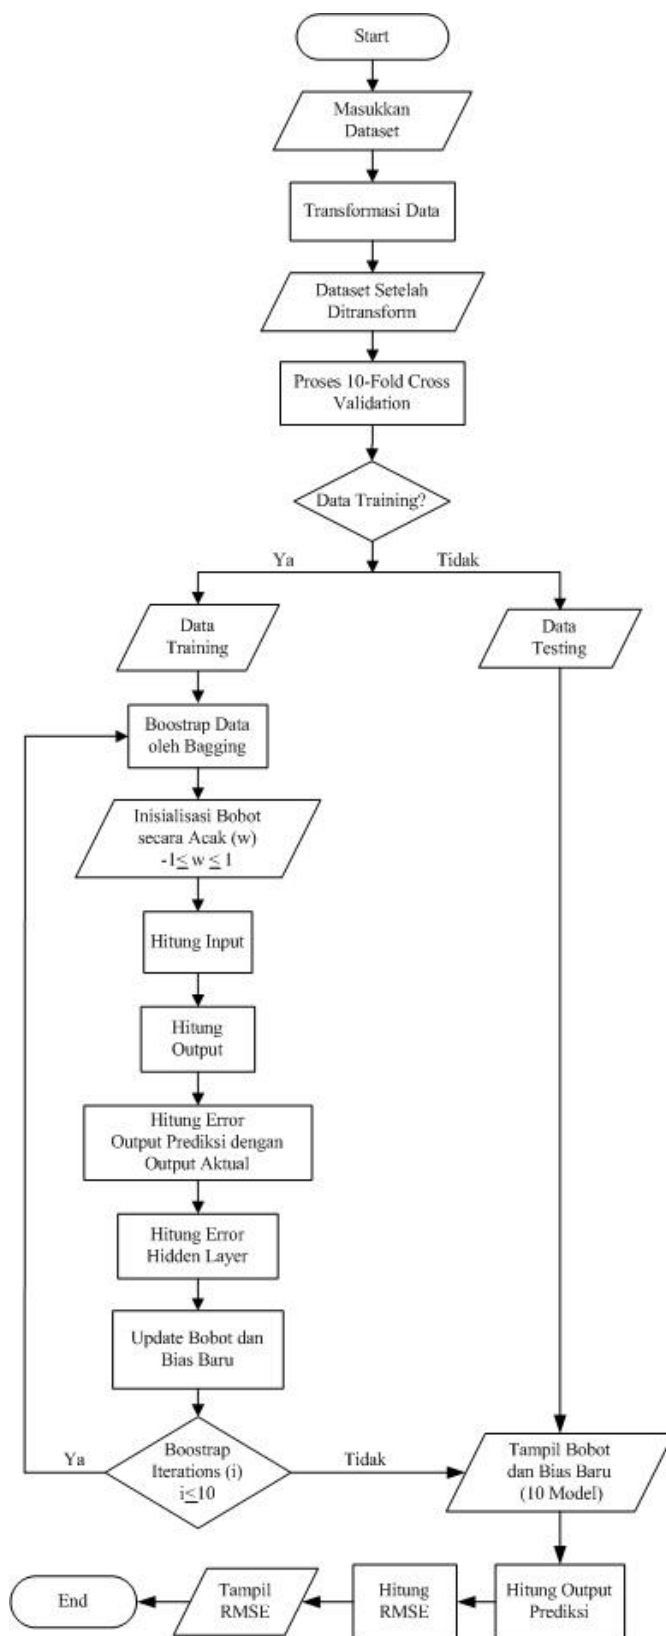
Dataset dengan *noise* yang tinggi menyebabkan kesalahan dalam generalisasi pengklasifikasian, sehingga dibutuhkan algoritma yang tepat untuk digabungkan (*ensemble*) dengan neural network agar akurasi prediksi dapat meningkat.

5.2 Neural Network

Neural Network (NN) atau biasa juga disebut Jaringan Saraf Tiruan (JST) merupakan upaya untuk meniru fungsi otak manusia. Otak manusia diyakini terdiri dari jutaan unit pengolahan kecil yang bekerja secara paralel, yang disebut neuron. Neuron saling terhubung satu sama lain melalui koneksi neuron. Setiap individu neuron mengambil input dari satu set neuron. Hal ini kemudian memproses input tersebut dan melewati output untuk satu set neuron. Output dikumpulkan oleh neuron lain untuk diproses lebih lanjut (Shukla, Tiwari, & Kala, 2010).

Pada penelitian ini menggunakan algoritma backpropagation. Algoritma backpropagation bekerja melalui proses secara iteratif menggunakan data *training*, membandingkan nilai prediksi dari jaringan dengan setiap data yang terdapat pada data *training* (Han et al., 2012).

5.3 Neural Network dan Bagging



Gambar 1. Penggabungan Algoritma Bagging dan Neural Network

Gambar 1 menggambarkan metode yang diusulkan dalam penelitian ini yaitu metode bagging pada neural network. Pada pengolahan dataset awal, dataset ditransformasi ke dalam range 0 sampai 1. Kemudian dataset dibagi dengan metode 10-fold cross validation yaitu dibagi menjadi data *testing* dan data *training*. Kemudian data *training* dibagi lagi oleh bagging

menjadi sub dataset (*bootstrap*) sebanyak 10 perulangan (*iterations*). Masing-masing *bootstrap* data kemudian diproses dengan metode neural network. Langkah awal neural network yaitu memberikan inisialisasi bobot awal untuk *input layer*, *hidden layer*, dan bias secara acak. 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 dinisialisasi, kemudian dihitung *input*, *output* dan *error*. Selanjutnya membangkitkan *output* untuk simpul menggunakan fungsi aktivasi *sigmoid*. Selanjutnya dihitung nilai *error output* prediksi dengan *output* aktual, selanjutnya dibalik ke layer sebelumnya (*backpropagation*) untuk menghitung *error* pada *hidden layer*. Proses neural network tersebut akan terus berulang sebanyak 10 perulangan *bootstrap*. Setelah perulangan selesai semua hasil model *bootstrap* dihitung hingga menghasilkan 10 model. Selanjutnya dihitung output prediksi rata-rata 10 model tersebut. Kemudian dihitung *error* rata-rata selisih antara *output* prediksi dengan *output* aktual yaitu *Root Mean Square Error* (RMSE).

6 HASIL DAN PEMBAHASAN


Penelitian yang dilakukan menggunakan komputer dengan spesifikasi CPU Intel Core i5 1.6GHz, RAM 8GB, dan sistem operasi Microsoft Windows 7 Professional 64-bit. Aplikasi yang digunakan adalah RapidMiner 5.2. Penelitian ini menggunakan dua dataset yaitu dataset *concrete compressive strength* dataset *slump*. Dataset ini didapat dari UCI Machine Learning Repository.

Setelah eksperimen yang dilakukan dengan neural network dan neural network dan bagging, kemudian dikomparasi hasil RMSE pada metode neural network dengan neural network dan bagging dari 8 eksperimen pada dataset *concrete compressive strength* dan dataset *slump*.

Pada Tabel 3 dan Gambar 2 dari 8 eksperimen dan rata-rata keseluruhan eksperimen pada dataset *concrete compressive strength* secara konsisten menunjukkan penurunan nilai RMSE yang signifikan antara neural network dengan neural network dan bagging.

Tabel 3. Hasil Eksperimen Neural Network dengan Neural Network dan Bagging (Dataset *Concrete Compressive Strength*)

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	0,087	0,072
500	0,3	0,2	6	-	10	0,077	0,067
500	0,1	0,1	6	-	10	0,063	0,058
500	0,1	0,2	6	-	10	0,063	0,058
300	0,1	0,2	6	-	10	0,064	0,060
450	0,3	0,2	6	-	10	0,077	0,067
1000	0,1	0,2	12	10	10	0,060	0,055
1000	0,1	0,2	13	9	10	0,057	0,052
<b>Rata-rata</b>						<b>0,069</b>	<b>0,062</b>



Gambar 2. Grafik Perbedaan Metode Neural Network dengan Neural Network dan Bagging (Dataset *Concrete Compressive Strength*)

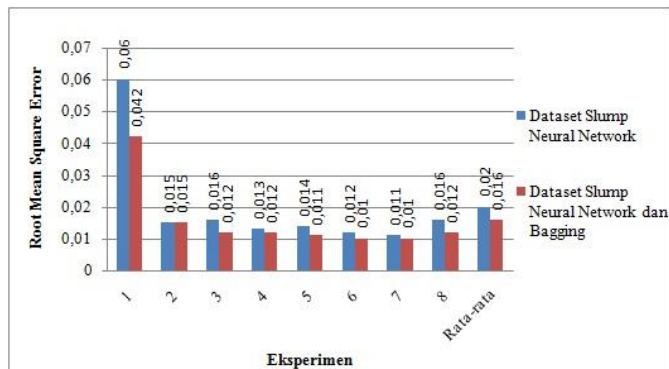
Pada Tabel 4 dan Gambar 3 dari delapan eksperimen dan rata-rata keseluruhan eksperimen pada dataset *slump* juga secara konsisten menunjukkan penurunan nilai RMSE antara neural network dengan neural network dan bagging.

Penurunan nilai RMSE yang signifikan dan konsisten dari enam belas eksperimen pada dataset *concrete compressive strength* yang ditunjukkan pada Tabel 3 dan Gambar 2 serta dataset *slump* yang ditunjukkan pada Tabel 4 dan Gambar 3, 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 data *noise* pada neural network, sehingga menghasilkan kinerja atau tingkat akurasi estimasi kuat tekan beton yang lebih baik dibanding dengan menggunakan metode individual neural network. Merujuk pada penelitian yang telah dilakukan sebelumnya oleh (Kim & Kang, 2010) 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.

Tabel 4. Hasil Eksperimen Neural Network dengan Neural Network dan Bagging (Dataset *Slump*)

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	0,060	0,042
500	0,1	0,5	6	-	10	0,015	0,015
1000	0,3	0,2	6	-	10	0,016	0,012
1000	0,1	0,5	6	-	10	0,013	0,012
3000	0,3	0,2	6	-	10	0,014	0,011
3000	0,1	0,5	6	-	10	0,012	0,010
3000	0,1	0,5	14	-	20	0,011	0,010
3000	0,1	0,5	14	1	10	0,016	0,012
<b>Rata-rata</b>						<b>0,020</b>	<b>0,016</b>





Gambar 3. Grafik Perbedaan Metode Neural Network dengan Neural Network dan Bagging (Dataset Slump)

Setelah diuji distribusi data dengan menggunakan SPSS, hasil uji distribusi data hasil eksperimen neural network dengan neural network dan bagging pada dataset *concrete compressive strength* seperti pada Tabel 5 dan hasil uji distribusi data hasil eksperimen neural network dengan neural network dan bagging pada dataset *slump* seperti pada Tabel 6 menunjukkan bahwa nilai signifikansi ( $Asymp.Sig > 0.05$ ) maka data tersebut adalah berdistribusi normal.

Tabel 5. Hasil Uji Distribusi Data Hasil Eksperimen Neural Network dengan Neural Network dan Bagging pada Dataset *Concrete Compressive Strength*

One-Sample Kolmogorov-Smirnov Test			
		X1	X2
N		8	8
Normal Parameters	Mean	.06850	.06150
	Std. Deviation	.010502	.006374
Most Extreme Differences	Absolute	.291	.218
	Positive	.291	.218
	Negative	-.166	-.182
Kolmogorov-Smirnov Z		.823	.618
Asymp. Sig. (2-tailed)		.508	.840

Tabel 6. Hasil Uji Distribusi Data Hasil Eksperimen Neural Network dengan Neural Network dan Bagging pada Dataset *Slump*

One-Sample Kolmogorov-Smirnov Test			
		X1	X2
N		8	8
Normal Parameters	Mean	.01963	.01550
	Std. Deviation	.016414	.010823
Most Extreme Differences	Absolute	.462	.393
	Positive	.462	.393
	Negative	-.300	-.306
Kolmogorov-Smirnov Z		1.308	1.113
Asymp. Sig. (2-tailed)		.065	.168

Untuk menjamin evaluasi hipotesis penelitian ini, dibutuhkan pengujian dengan metode statistik untuk menguji hubungan antara penggunaan metode neural network dengan neural network dan bagging, apakah terdapat hubungan di antara keduanya. Dikarenakan data hasil eksperimen berdistribusi normal maka pengujian hipotesis menggunakan metode t-Test (Dem, 2006). Metode ini termasuk yang paling umum dalam metode statistik tradisional, yaitu t-Test (Maimon, 2010). Ada atau tidaknya perbedaan antara dua model membutuhkan pengujian, salah satunya dengan uji t-Test (Larose, 2007), dengan melihat nilai P. Jika nilai  $P < 0,05$  maka menunjukkan hipotesis nol ditolak atau disebut hipotesis alternatif (Sumanto, 2014). Hipotesis nol menyatakan tidak ada pengaruh atau perbedaan antara dua buah variabel, sedangkan

hipotesis alternatif menyatakan adanya pengaruh atau perbedaan antara dua buah variabel (Sumanto, 2014).

Pada Tabel 7 menampilkan t-Test untuk hasil RMSE pada dataset *concrete compressive strength* menunjukkan hipotesis nol ditolak (hipotesis alternatif) yaitu dengan nilai  $P < 0,05$  yaitu 0,0004. Pada Tabel 8 t-Test untuk hasil RMSE pada dataset *slump*, juga menunjukkan hipotesis nol ditolak (hipotesis alternatif) yaitu dengan nilai  $P < 0,05$  yaitu 0,0259.

Hasil t-Test dengan hipotesis nol ditolak (hipotesis alternatif) tersebut menunjukkan bahwa antara penggunaan metode neural network dengan neural network dan bagging menunjukkan adanya pengaruh atau perbedaan yang signifikan. Neural network dan bagging menghasilkan kinerja atau tingkat akurasi yang lebih baik dibanding dengan menggunakan metode neural network saja. Hal tersebut seperti dikatakan pada penelitian Kim & Kang (Kim & Kang, 2010) bagging secara konsisten menunjukkan mampu meningkatkan akurasi prediksi pada neural network, hal ini berarti bahwa dua metode gabungan (*ensemble*) bagging dan neural network yang diusulkan dapat menjadi alat yang efektif untuk meningkatkan kinerja neural network.

Tabel 7. *Paired Two-tailed t-Test* dengan Metode Neural Network dan Bagging (Dataset *Concrete Compressive Strength*)

	Variable 1	Variable 2
Mean	0,0685	0,0615
Variance	9,6 E-05	0,00003525
Observations	9	9
Pearson Correlation	0,99231096	
Hypothesized Mean Difference	0	
df	8	
t Stat	5,25	
<b>P(T&lt;=t) one-tail</b>	<b>0,00038692</b>	
t Critical one-tail	1,85954803	
P(T<=t) two-tail	0,00077383	
t Critical two-tail	2,30600413	

Tabel 8. *Paired Two-tailed t-Test* dengan Metode Neural Network dan Bagging (Dataset *Slump*)

	Variable 1	Variable 2
Mean	0,019625	0,0155
Variance	0,000235734	0,0001025
Observations	9	9
Pearson Correlation	0,993526309	
Hypothesized Mean Difference	0	
df	8	
t Stat	2,283872233	
<b>P(T&lt;=t) one-tail</b>	<b>0,025878775</b>	
t Critical one-tail	1,859548033	
P(T<=t) two-tail	0,05175755	
t Critical two-tail	2,306004133	

## 7 KESIMPULAN

Hasil eksperimen dari delapan kombinasi parameter penelitian pada dataset *concrete compressive strength* dengan neural network didapatkan nilai rata-rata RMSE adalah 0,069 dan nilai RMSE terkecil adalah 0,057, sedangkan dengan menggunakan neural network dan bagging didapatkan nilai rata-rata RMSE adalah 0,062 dan nilai RMSE terkecil adalah 0,055. Hasil eksperimen dari delapan kombinasi parameter penelitian pada dataset *slump* dengan neural network didapatkan nilai rata-rata RMSE adalah 0,020 dan nilai RMSE terkecil adalah 0,011 sedangkan dengan neural network dan bagging didapatkan nilai rata-rata RMSE adalah 0,016 dan nilai RMSE terkecil adalah 0,010.

Dari hasil pengujian di atas maka dapat disimpulkan bahwa bagging mampu mengurangi data *noise* pada neural network, sehingga menghasilkan kinerja atau tingkat akurasi estimasi kuat tekan beton yang lebih baik dibanding dengan menggunakan metode individual neural network.

## REFERENSI

- 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.
- Breiman, L. (1996). Bagging predictors. *Machine Learning*, 26(2), 123–140.
- 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.
- Chou, J.-S., & Pham, A.-D. (2013). Enhanced artificial intelligence for ensemble approach to predicting high performance concrete compressive strength. *Construction and Building Materials*, 49, 554–563.
- Culp, M., Michailidis, G., & Johnson, K. (2011). On Adaptive Regularization Methods in Boosting. *Journal of Computational and Graphical Statistics*, 20(4), 937–955.
- Dem, J. (2006). Statistical Comparisons of Classifiers over Multiple Data Sets, 7, 1-30
- 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.
- 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.
- 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.
- Han, J., Kamber, M., & Pei, J. (2012). *Data Mining Concepts and Techniques*. San Fransisco: Morgan Kauffman.
- Jong Jek Siang. (2009). *Jaringan Syaraf Tiruan & Pemrogramannya Menggunakan MATLAB*. Yogyakarta : Andi Yogyakarta.
- 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.
- Kim, M.-J., & Kang, D.-K. (2010). Ensemble with neural networks for bankruptcy prediction. *Expert Systems with Applications*, 37(4), 3373–3379.
- Larose, D. T. (2007). *Data Mining Methods and Model*. New Jersey: John Willey & Sons, Inc.
- Maimon, Oded&Rokach, Lior. (2010). *Data Mining and Knowledge Discovey Handbook*. New York: Springer
- Mulyono, Tri. (2004). *Teknologi Beton*. Yogyakarta: Andi Publishing.
- Nazari, A., & Pacheco Torgal, F. (2013). Predicting compressive strength of different geopolymers by artificial neural networks. *Ceramics International*, 39(3), 2247–2257.
- Shukla, A., Tiwari, R., & Kala, R. (2010). *Real Life Applications of Soft Computing*. New York: CRC Press.
- Sumanto. (2014). *Statistika Deskriptif*. Yogyakarta: Center of Academic Publishing Service.
- Tjokrodinuljo, Kardiyono. (1996). *Teknologi Beton*. Yogyakarta: Nafiri.
- Vercellis, Carlo (2009). *Business Intelligent: Data Mining and Optimization for Decision Making*. Southern Gate, Chichester, West Sussex: John Willey & Sons, Ltd.

Witten, I. H., Frank, E., & Hall, M. A. (2011). *Data Mining: Practical Machine Learning and Tools*. Burlington: Morgan Kaufmann Publisher.

## BIOGRAFI PENULIS



**Tyas Setiyorini.** Menempuh pendidikan S1 Sistem Informasi di STMIK Swadharma, Jakarta, S2 Magister Sistem Informasi di STMIK Nusa Mandiri Jakarta. Saat ini menjadi dosen di Akademi Bina Sarana Informatika. Minat penelitian saat ini adalah data mining.



**Romi Satria Wahono.** Memperoleh 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.