

# MODEL PREDIKSI *SLUMP* BETON DENGAN ARTIFICIAL NEURAL NETWORKS- BACKPROPAGATION

Stefanus Santosa, Basuki Setiyo Budi, Junaidi, Tjokro Hadi

Jurusan Teknik Sipil Politeknik Negeri Semarang  
Jln. Prof. H. Sudarto, S.H. Tembalang, Semarang 50275 Telp. (024) 7473417  
Email : jwahana\_tspolines@yahoo.com

## **Abstract**

*The design value of slump is often done manually by calculating the value of cement water factor in order to obtain the desired slump value. But these designs often unreliable. This study proposes a model prediction of concrete slump design for a variety of quality concrete with variables that are more complex than other studies. From a series of experiments with various models using Artificial Neural Network-Backpropagation (BPNN), the smallest RMSE values obtained models that can be achieved is by 0.004294661. Best Setting model parameters are Training Cycles: = 100,000, Learning Rate = 0.001, Momentum: = 0.2, Hidden Layer Size: = 10, and Number of Hidden layer: = 1.*

**Kata kunci :** *prediction, concrete slump, artificial neural network, backpropagation*

## **PENDAHULUAN**

Metode estimasi perilaku beton yang meliputi aspek-aspek pemompaan, pengecoran, pemadatan, dan tekanan lateral pada cetakan akan lebih akurat dilakukan melalui pengukuran viskositas dan kuat tekan yang menggunakan peralatan-peralatan eksperimen (experimental equipment) semacam viscometer dan rheometer. Namun peralatan tes rheologi sangat mahal untuk diterapkan di lapangan. Beberapa penelitian telah dilakukan untuk mengembangkan metode estimasi kuantitatif properti rheologi dengan pendekatan *mini slump test* (Choi, 2016).

Perancangan nilai *slump* saat ini sering dilakukan secara manual dengan memperhitungkan nilai faktor air semen sedemikian rupa agar

diperoleh nilai *slump* yang diinginkan. Namun sering terjadi desain seperti ini sulit diandalkan karena berbagai faktor yang mempengaruhi. Kandungan air yang terdapat pada agregat kasar maupun halus sangat mempengaruhi nilai faktor air semen. Walaupun kondisi agregat sudah dibuat kering permukaan (SSD) tetapi dalam kenyataan di lapangan sulit dijamin kondisi tersebut terpenuhi pada setiap bagian agregat. Selain itu proses pencampuran, pengadukan, transportasi, dan pengecoran dapat merubah nilai faktor air semen yang sudah direncanakan. Kondisi iklim dan cuaca serta perlakuan terhadap campuran beton juga sangat berpengaruh. Kelemahan lain dari cara desain *slump* manual ini setiap desain/model hanya berlaku untuk satu nilai

*slump* saja. Apabila bahan agregat dan campuran lain berbeda, maka diperlukan desain baru dan pengujian baru. Ini merupakan metode yang tidak efisien dan kurang akurat. Untuk mengatasi hal ini dapat dilakukan pemodelan baik model matematis, model statistik, model komputasi cerdas, maupun model citra dan animasi berbasis komputer.

Penelitian tentang pemodelan kelecakan beton 3D dilakukan oleh Deeb, dkk. guna mengamati perilaku beton segar. Metode simulasi perilaku beton 3D ini memberikan gambaran yang cukup guna menentukan model campuran yang tepat yang berkaitan dengan *workability* beton. Namun kendala yang dihadapi adalah adanya tuntutan akan komputasi yang tinggi dari komputer yang digunakan untuk pemodelan. (Deeb, 2014). Hal ini dapat dimengerti karena pendekatan berbasis pengolahan citra dan animasi komputer untuk pemodelan memerlukan komputer dengan unjuk kerja yang sangat tinggi.

Pemodelan statistik dilakukan oleh Lotfy dkk. Peneliti membuat model komputasi campuran beton dengan tanah liat (Expanded Clay-Lightweight Self-Consolidating Concrete -EC LWSCC). Desain campuran beton ini dimaksudkan untuk memperoleh beton yang mampu melakukan pemadatan sendiri tanpa kompaksi atau penggetaran saat dilakukan pengecoran dengan nilai *slump* yang ditentukan. Pemodelan dilakukan menggunakan model statistik konvensional, yakni regresi. *Proposed Mix Design Model* ini

menurut peneliti memudahkan pemahaman tentang interaksi antar-berbagai parameter beton yang dirancang. (Lotfy, 2014).

Model lain yang dikembangkan Lotfy dkk. adalah desain campuran dengan unsur terak tanur tinggi (Furnice Slag- Lightweight Self-Consolidating Concrete -FS LWSCC menggunakan pendekatan regresi, *general linear model analysis of variance*, dan *backward stepwise technique* dengan hasil salah satunya adalah peningkatan solusi desain. (Lotfy, 2015).

Penelitian ini mencari model desain *slump* beton untuk berbagai kualitas beton dengan keragaman parameter yang tidak konvensional yang terbatas hanya pada beberapa parameter saja seperti dari semen, pasir, kerikil, dan air saja namun parameternya ditambah dengan unsur abu batu bara (fly ash), terak tanur tinggi (blast furnace slag), dan bahan-bahan aditif lain. Dengan demikian penelitian ini melibatkan parameter yang lebih kompleks dibandingkan dengan penelitian lain.

Dari hasil identifikasi masalah, analisis masalah, dan pemilihan pendekatan yang telah diuraikan di atas, maka penelitian ini dimaksudkan untuk menciptakan model komputasi cerdas desain campuran beton untuk prediksi *slump* beton berbasis *Artificial Neural Networks* (ANN) dengan parameter yang lebih kompleks.

Solusi yang dicapai melalui pendekatan yang digunakan dalam penelitian ini menjadi sangat penting, yang pertama untuk mereduksi

berbagai aspek pada proses desain campuran beton manual yang:

- a. tidak efisien karena harus melakukan uji coba berkali-kali,
- b. tidak efektif karena hasil desain masih berupa perkiraan
- c. biaya tinggi karena harus menyediakan bahan, peralatan, waktu, dan tenaga khusus
- d. jauh dari prinsip *Green Technology* karena bekas benda uji *slump* yang mengeras akan menjadi sampah yang sulit terurai.

Selain itu penelitian ini juga memberikan sumbangan berupa model komputasi cerdas desain campuran beton untuk prediksi *slump* beton berbasis *Artificial Neural Networks* (ANN). Sumbangan ini ditujukan bagi pengembangan ilmu khususnya ilmu komputer dan teknik sipil. Target Penelitian ini adalah terwujudnya *Proposed Slump Design Model*.

Beton merupakan material campuran yang memiliki perilaku yang sangat kompleks sehingga memunculkan beragam model yang sangat kompleks. Model komputasi diperlukan untuk memperoleh desain campuran (mix design) yang tepat sesuai dengan perilaku yang dikehendaki (concrete behaviour). Nikko berpendapat bahwa pemodelan campuran beton menggunakan komputasi cerdas sebagai pengganti pemodelan matematis dan pengujian secara destruktif, lebih akurat dan lebih ekonomis (Nikoo, 2015).

Keberagaman unsur campuran beton tidak dapat dipisahkan dengan nilai *slump*-nya. *Slump* test sangat penting dilakukan untuk menjamin

agar workability beton memenuhi syarat untuk memudahkan proses pemompaan, pengecoran, pemadatan, dan perhitungan tekanan lateral pada cetakan selain nilai kuat tekannya.

Penelitian tentang pemodelan *slump* beton diantaranya dilakukan oleh beberapa peneliti diantaranya adalah I-Cheng Yeh yang menggunakan pemodelan berbasis *Artificial Neural Networks* (I-Cheng Yeh, 2006) dan second order regression (I-Cheng Yeh, 2007), sedangkan Ashu Jain menggunakan *Artificial Neural Networks* (Jain, 2008).. Hasil penelitian menunjukkan bahwa pendekatan berbasis *Artificial Neural Networks* lebih baik untuk memodelkan karakteristik *slump* yang kompleks dan nonlinier dengan berbagai variasi desain campuran dibandingkan pendekatan *hardcomputing* yang menggunakan statistik regresi.

Beberapa peneliti lain juga telah melakukan uji coba model komputasi *mix design* beton, baik untuk *slump* maupun kuat tekan, menggunakan *linier regression*, *multiple linier regression*, *non linier regression*, dan *Artificial Neural Networks* (ANN). Wen-Huan Chine (2010) dari penelitiannya menyimpulkan bahwa ANN-*Backpropagation* (BPNN) lebih akurat dalam memprediksi nilai *slump* pada *mix design* beton dibandingkan *multiple linier regression*.

I-Cheng Yeh,(2007) menunjukkan bahwa ANN merupakan metode pemodelan yang lebih baik dan mampu memberikan akurasi prediksi

yang lebih akurat dibandingkan *linier regression, multiple linier regression, non linier regression*. I-Cheng Yeh juga mencoba pendekatan lain untuk memodelkan desain campuran beton khususnya yang berkaitan dengan faktor air semen, yakni menggunakan *Genetic Operation Trees (GOT)*, ANN, dan Non-Linier Regression Analysis (NLRA). Hasilnya ANN lebih akurat dibanding pendekatan yang lain. (I-Cheng Yeh, 2010).

Behnam Vakhsouri dan Shami Nejadi melakukan penelitian campuran beton jenis *light-weight self-compacting concrete* dengan variabel independennya adalah *flowability* yang berkaitan dengan nilai *slump* bahwa model yang dibangun menunjukkan tidak adanya risiko segregasi dan blocking. Namun penelitian ini masih menggunakan pendekatan manual. (Vakhsouri 2016). Sonebi, dkk meneliti hal yang sama namun dengan pendekatan komputasi cerdas, yakni Support Vector Machine (Sonebi, 2016)

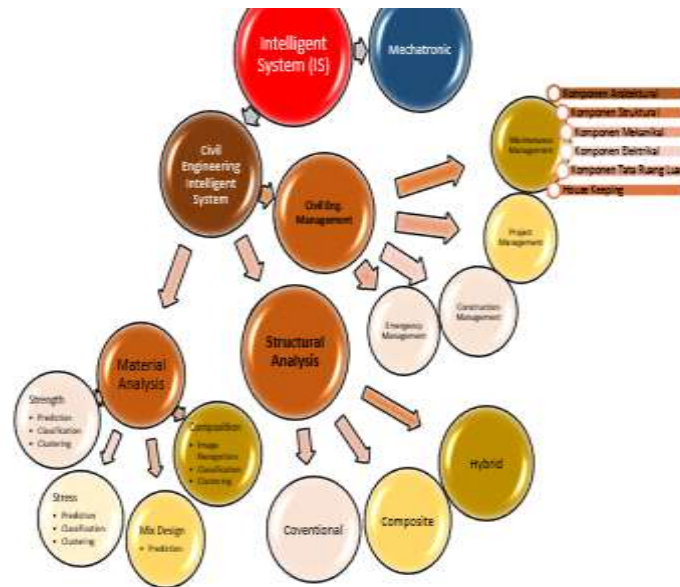
Konstelasi penelitian tentang model komputasi desain campuran beton untuk prediksi *slump* saat ini cenderung berkembang ke arah pendekatan komputasi cerdas. Pendekatan- pendekatan statistik konvensional sudah banyak ditinggalkan, walaupun masih ada.

Pemodelan yang dapat diandalkan adalah melalui pendekatan komputasi cerdas (Intelligent Computation). Pemodelan ini melibatkan komputasi- komputasi

yang mirip kemampuan manusia dalam berpikir dan memecahkan suatu masalah, yang disebut pula *softcomputing*. Oleh sebab itu peneliti saat ini *concern* pada pemecahan masalah- masalah *Civil Engineering* dengan menggunakan komputasi cerdas. Berikut ini adalah *research interest* peneliti pada bidang kajian komputasi cerdas, khususnya ranting *Civil Engineering*.

*Civil Engineering Intelligent System* yang menjadi fokus kajian peneliti adalah *Material Analysis* (Strength, Stress, Mix Design, Composition), *Structural Analysis* (Conventional, Composite, Hybrid), dan *Management* (Emergency M., Construction M., Project M., Maintenance M.). Penelitian ini fokus pada konstalasi penelitian komputasi cerdas untuk pemodelan *slump* beton.

Penelitian yang diusulkan ini melibatkan ANN seperti penelitian- penelitian sebelumnya. Namun penelitian- penelitian sebelumnya terbatas hanya pada beberapa parameter saja seperti dari semen, pasir, kerikil, air, dan fly ash (Chandwani, 2015). Apabila parameternya ditambah dengan unsur abu batu bara (fly ash), terak tanur tinggi (blast furnace slag), dan bahan- bahan aditif lain kemungkinan performanya dapat berkurang. Oleh sebab itu perlu dilakukan penelitian dengan melibatkan parameter yang lebih kompleks.



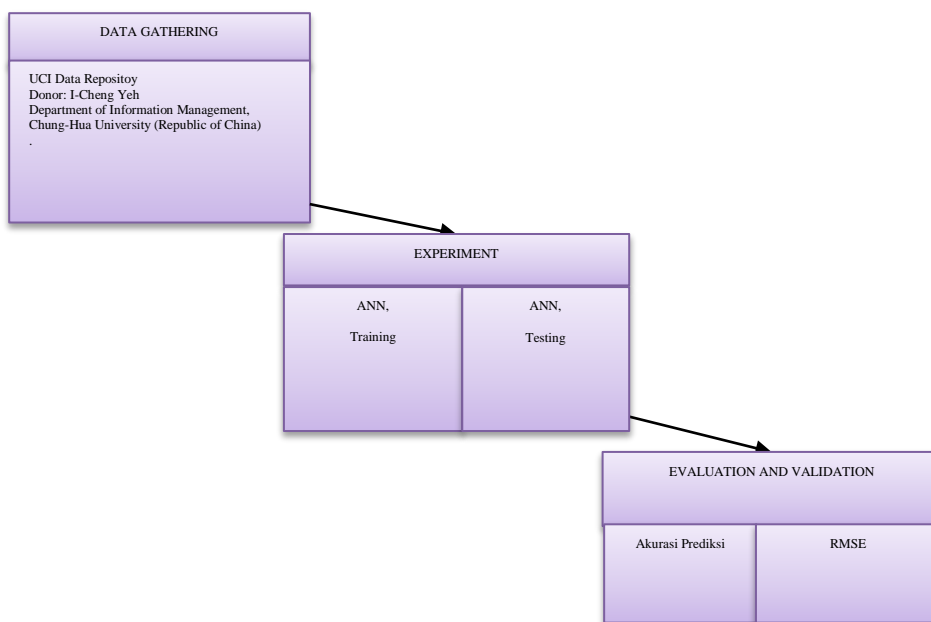
©Stefanus Santosa: *Intelligent System Research Interest- Civil Engineering*. Hak Cipta ©Dr. Drs. Stefanus Santosa., M.Kom. Bidang Kajian ini diperuntukkan bagi mahasiswa/ peneliti yang concern pada bidang kajian ini atas koordinasi Dr. Drs. Stefanus Santosa., M.Kom mulai penyusunan Proposal, Pelaksanaan, hingga Publikasi Penelitian.

Gambar 1. *Intelligent System Research Interest – Civil Engineering*

**METODE PENELITIAN**

Berdasarkan *Research Problem* yang sudah diuraikan di atas, maka untuk memperoleh solusi atas masalah

tersebut agar tujuan tercapai disusunlah strategi dan tahapan penelitian seperti berikut ini.



Gambar 2. Diagram Alir Metode Penelitian

### Pengumpulan Data

Pengumpulan data sekunder diperoleh dari UCI *Data Repository* dengan karakteristik:


- *Data Set Characteristics: Multivariate*
- *Attribute Characteristics: Real*
- *Number of Instances: 103*
- *Number of Attributes: 10*
- *Area: Computer*

Donor: I-Cheng Yeh, Department of Information Management, Chung-Hua University (Republic of China).

### Eksperimen

#### a. Pemodelan

Model dibentuk berdasarkan komponen beton yang berupa *Cement*, *Fly Ash*, *Slag*, *Water*, *SP*, *Course Aggregate*, dan *Fine Aggregate* sebagai *node* masukan, dan *Concrete Slump* sebagai keluaran hasil proses *Artificial Neural Networks*. Model dinyatakan dalam nilai parameter *Initial Population*, *Training Cycle*, *Probability Crossover*, *Probability Mutation*, *Learning Rate*, *Population*, *Hidden Neuron*, *Learning Rate Neural Networks*, dan *Momentum*. Untuk model prediksi *Artificial Neural Networks* tanpa optimasi dinyatakan dengan parameter *Iteration*, *Learning Rate*, *Momentum*, dan *Hidden Neuron*.



Gambar 3. Jaringan Syaraf Tiruan untuk Desain *Slump* Beton

#### b. Training

Untuk memperoleh model yang optimal jaringan perlu dibelajarkan (training) terlebih dahulu kemudian diuji kemampuannya dalam memprediksi nilai *slump*. Pembelajaran dilakukan dengan memberikan data yang disebut *training data* atau *training vectors*. *Training data* terdiri masukan dan keluaran yang diharapkan sedemikianrupa

sehingga diperoleh *output* yang diharapkan.

#### c. Testing

Setelah pembelajaran dilakukan oleh jaringan dengan mencoba berbagai nilai parameter *Training Cycle*, *Probability Crossover*, *Probability Mutation*, *Learning Rate*, *Population*, dan *Hidden Neuron*, maka berikutnya adalah proses pengujian untuk menguji coba model yang terbentuk.

### Evaluasi dan Validasi Hasil

Model yang terbentuk dievaluasi dengan mengukur nilai *error* yang terjadi melalui formula *RMSE*. Proses evaluasi dilakukan dengan menggunakan *cross validation*. Sehingga model yang terbentuk dapat langsung diuji dengan data yang secara acak dipisahkan dengan *10 folds cross validation*.

### HASIL DAN PEMBAHASAN

Eksperimen dalam penelitian ini menghasilkan model prediksi *slump* dengan metode *Artificial Neural Network-Backpropagation* (BPNN). Indikator yang digunakan untuk mengetahui akurasi atau kesalahan

prediksi ditunjukkan oleh besarnya nilai *Root Mean Square Error* (RMSE) di masing-masing pengujian. Eksperimen dengan *Artificial Neural Network-Backpropagation* (BPNN) dimulai dengan menetapkan *training cycle*= 100.000 sd. 1.000.000, *learning rate*= 0.001, *momentum* = 0.1, dan *hidden neuron* (hidden layer size)= 1. *Hidden layer* konstan = 1. Dari eksperimen ini diperoleh hasil RMSE terendah adalah 0.004367331 seperti yang tercantum pada tabel berikut ini. Nilai *RMSE* sebesar 0.004367331 ini diperoleh pada nilai parameter *training cycle*= 100.000, *learning rate*= 0.01, *momentum* = 0.1, dan *hidden neuron* (hidden layer size)=1.

Tabel 1. RMSE pada *Training Cycle* = 100.000 sd. 1.000.000, *Learning Rate*= 0,01, *Momentum* = 0.1, dan *Hidden Neuron* (hidden layer size)= 1

TRAINING CYCLE	LEARNING RATE	MOMENTUM	HIDDEN NEURON	RMSE
100000	0.001	0.1	1	0.004367331
200000	0.001	0.1	1	0.006616305
300000	0.001	0.1	1	0.008561682
400000	0.001	0.1	1	0.009649423
500000	0.001	0.1	1	0.010295242
600000	0.001	0.1	1	0.010695957
700000	0.001	0.1	1	0.010951599
800000	0.001	0.1	1	0.011117591
900000	0.001	0.1	1	0.011226603
1000000	0.001	0.1	1	0.011298728

Eksperimen berikutnya adalah mengubah nilai parameter *learning rate*= 0.001 sd. 0,01 sedangkan parameter yang lain konstan dengan nilai *training cycle*= 100.000,

*momentum* = 0.1, dan *hidden neuron* (hidden layer size)= 1. Hasil eksperimen ditunjukkan pada tabel berikut ini.

Tabel 2. RMSE pada *Learning Rate*= 0.001 sd. 0,01, *Training Cycle* = 100.000, *Momentum* = 0.1, dan *Hidden Neuron* (hidden layer size)= 1

TRAINING CYCLE	LEARNING RATE	MOMEN TUM	HIDDEN NEURON	RMSE
100000	<b>0.001</b>	0.1	1	0.004367331
100000	<b>0.002</b>	0.1	1	0.006616306
100000	<b>0.003</b>	0.1	1	0.008561685
100000	<b>0.004</b>	0.1	1	0.009649425
100000	<b>0.005</b>	0.1	1	0.010295245
100000	<b>0.006</b>	0.1	1	0.01069596
100000	<b>0.007</b>	0.1	1	0.010951602
100000	<b>0.008</b>	0.1	1	0.011117594
100000	<b>0.009</b>	0.1	1	0.011226607
100000	<b>0.01</b>	0.1	1	0.011298732

Dari eksperimen ini diperoleh hasil nilai RMSE terendah adalah 0.004367331. Nilai *RMSE* sebesar 0.004367331 ini diperoleh pada nilai parameter *training cycle*= 100.000, *learning rate*= 0.001, *momentum* = 0.1,

dan *hidden neuron* (hidden layer size)= 1. Walaupun angka *learning rate* dirubah dan nilai *training cycle* dibuat konstan namun nilai RMSE ini sama dengan eksperimen pertama, yakni 0.004367331.

Tabel 3. RMSE pada *Momentum* = 0.1 sd. 1.0, *Learning Rate*= 0.001, *Training Cycle* = 100.000, dan *Hidden Neuron* (hidden layer size)= 1

TRAINING CYCLE	LEARNING RATE	MOMEN TUM	HIDDEN NEURON	RMSE
100000	0.001	<b>0.1</b>	1	0.004367331
100000	0.001	<b>0.2</b>	1	0.004294824
100000	0.001	<b>0.3</b>	1	0.004560335
100000	0.001	<b>0.4</b>	1	0.005166435
100000	0.001	<b>0.5</b>	1	0.006069749
100000	0.001	<b>0.6</b>	1	0.007218082
100000	0.001	<b>0.7</b>	1	0.008561693
100000	0.001	<b>0.8</b>	1	0.010012044
100000	0.001	<b>0.9</b>	1	0.011226614
100000	0.001	<b>1</b>	1	0.045821585

Tabel di atas menunjukkan eksperimen selanjutnya adalah dengan menetapkan nilai *training cycle*= 100.000, *learning rate*= 0.001 yang sudah terseleksi,

sedangkan nilai *momentum* = 0.1 sd. 1.0, dan *hidden neuron* (hidden layer size)= 1. Hasil eksperimen ini ditunjukkan pada tabel 3 di atas. Hasil

eksperimen menunjukkan bahwa nilai RMSE terendah adalah 0.004294824. Nilai *RMSE* sebesar 0.004294824 ini diperoleh pada nilai parameter *training cycle*= 100.000, *learning rate*= 0.001, *momentum* = 0.2, dan *hidden neuron* (hidden layer size)= 1. Berdasarkan ketiga tahapan eksperimen tersebut di atas diperoleh penurunan nilai RMSE yang tidak signifikan mulai dari 0.004367331, eksperimen kedua juga menghasilkan nilai 0.004367331 dan

terakhir diperoleh nilai 0.004294824. Namun demikian masih diperlukan eksperimen berikutnya untuk mengetahui jumlah neuron yang ideal pada *hidden layer*. Oleh sebab itu eksperimen berikutnya adalah menetapkan nilai *hidden neuron* yang bervariasi antara 1 sd. 10 sedangkan parameter *training cycle*= 100.000, *learning rate*= 0.001, *momentum* = 0.2. Hasil eksperimen ini ditunjukkan pada tabel berikut ini.

Tabel 4. RMSE pada *Hidden Neuron* (hidden layer size) = 1 sd. 10, *Momentum* = 0.2, *Learning Rate*= 0.001, dan *Training Cycle* = 100.000

TRAINING CYCLE	LEARNING RATE	MOMENTUM	HIDDEN NEURON	RMSE
100000	0.001	0.2	1	0.004294824
100000	0.001	0.2	2	0.004294756
100000	0.001	0.2	3	0.004294725
100000	0.001	0.2	4	0.004294708
100000	0.001	0.2	5	0.004294696
100000	0.001	0.2	6	0.004294686
100000	0.001	0.2	7	0.004294679
100000	0.001	0.2	8	0.004294672
100000	0.001	0.2	9	0.004294666
100000	0.001	0.2	10	0.004294661

Dari rangkaian eksperimen tersebut nilai RMSE terkecil yang mampu dicapai model prediksi dengan *Artificial Neural Network-Backpropagation* (BPNN) adalah sebesar 0.004294661 dengan nilai *setting* terbaik parameter model adalah sebagai berikut:

- *Training Cycles*: 100.000
- *Learning Rate*: 0.001
- *Momentum*: 0.2
- *Size Hidden Layer*: 10
- Jumlah *Hidden layer*: 1

## KESIMPULAN

Desain *slump* beton secara manual memiliki kelemahan, yakni setiap desain/ model hanya berlaku untuk satu nilai *slump* saja. Apabila bahan agregat dan campuran berbeda, maka diperlukan desain baru dan pengujian baru sehingga tidak efisien dan kurang akurat. Untuk mengatasi hal ini dapat dilakukan pemodelan berbasis komputasi cerdas. Pemodelan desain *slump* beton yang terbatas hanya pada

beberapa parameter saja seperti semen, pasir, kerikil, dan air, perlu dikembangkan agar dapat mengakomodasi perkembangan beton saat ini. Model komputasi yang dikembangkan dalam penelitian ini memiliki parameter semen, pasir, kerikil, air, abu batu bara (fly ash), dan terak tanur tinggi (blast furnace slag) dengan pendekatan komputasi cerdas *Artificial Neural Network-Backpropagation*. Beberapa peneliti lain juga telah melakukan uji coba model komputasi *mix design* beton, baik untuk *slump* maupun kuat tekan, menggunakan *linier regression*, *multiple linier regression*, *non linier regression*, dan *Artificial Neural Networks* (ANN). Wen-Huan Chine (2010) dari penelitiannya menyimpulkan bahwa ANN-*Backpropagation* (BPNN) lebih akurat dalam memprediksi nilai *slump* pada *mix design* beton dibandingkan *multiple linier regression*. Penelitian ini juga membuktikan bahwa walaupun parameter campuran atau komposisi campuran beton lebih beragam namun kehandalan ANN-*Backpropagation* (BPNN) terbukti dapat menciptakan model prediksi yang akurat pula.

#### UCAPAN TERIMA KASIH

Kegiatan penelitian ini dilakukan dengan menggunakan dana Penelitian Swadana dari DIPA Politeknik Negeri Semarang Tahun 2016. Penulis mengucapkan terima kasih kepada kepala P3M Politeknik Negeri Semarang atas bantuan dana dan segala arahannya sehingga penelitian ini dapat terlaksana dengan baik.

#### DAFTAR PUSTAKA

- Chandwani, Vinay, Vinay Agrawal, Ravindra Nagar, 2015, Modeling Slump Of Ready Mix Concrete Using Genetic Algorithms Assisted Training of Artificial Neural Networks, Expert Systems with Applications 42 (2015) 885–893, Elsevier.
- Choi, Myoung Sung, Jung Soo Lee, Keum Seong Ryu, Kyung-Taek Koh, Seung Hee Kwon, 2016, Estimation of Rheological Properties of UHPC Using Mini Slump Test, Construction and Building Materials 106 (2 Januari 2016), p.632-639, Elsevier.
- Deeb, R, Kulasegaram, S, Karihaloo, B.L., 2014, 3D Modelling of the Flow of Self-Compacting Concrete with or without steel fibres. Part I: Slump Flow Test, Comp. Part. Mech (2014) I p. 373-389, Springer International Publishing Swotzerland.
- I-Cheng Yeh, 2006, Exploring Concrete Slump Model Using Artificial Neural Networks, Journal of Computing in Civil Engineering © ASCE / May/June 2006 p.217-221
- I-Cheng Yeh, 2007, Modeling Slump Flow of Concrete Using Second-Order Regressions and Artificial Neural Networks, Cement & Concrete Composites 29 (2007) p.474–480, Elsevier.

- I-Cheng Yeh, Che-Hui Lien, Chien-Hua Peng, Li-Chuan Lien, 2010, Modeling Concrete Strength Using Genetic Operation Trees, Proceedings of the Ninth International Conference on Machine Learning and Cybernetics, Qingdao, 11-14 July 2010, IEEE.
- Jain, Ashu, Sanjeev Kumar Jha and Sudhir Misra, 2008, Modeling and Analysis of Concrete Slump Using ANN, p 628-633 / Journal of Materials in Civil Engineering © Asce / September 2008.
- Lotfy, Abdurrahmaan, Khandaker M.A. Hossain, Mohamed Lachemi, 2014, Application Of Statistical Models In Proportioning Lightweight Self-Consolidating Concrete With Expanded Clay Aggregates, Construction and Building Materials 65 (2014) 450–469, Elsevier.
- Lotfy, Abdurrahmaan, Khandaker M.A. Hossain, Mohamed Lachemi, 2015, Statistical Models for The Development of Optimized Furnace Slag Lightweight Aggregate Self-Consolidating Concrete, Cement & Concrete Composites 55 (2015) 169–185, Elsevier.
- Nikoo, Mehdi, Farshid Torabian Moghadam, and Aukasz Sadowski, 2015, Prediction of Concrete Compressive Strength by Evolutionary Artificial Neural Networks, Advances in Materials Science and Engineering Volume 2015, Article ID 849126, 8 pages, Hindawi Publishing Corporation.
- Sonebi, Mohammed, Abdulkadir Cevik, Steffen Grunewald, Joost Walraven, 2016, Modelling the Fresh Properties of Self-Compacting Concrete Using Support Vector Machine Approach, Construction and Building Materials 106 (2016), p.55-64, Elsevier.
- Vakhshouri, B, Nejadi, S, 2016, Mix Design of Light-Weight self compacting concrete, Case Study in Construction Materials 4 (2016) p.1-14, Elsevier.
- Wen-Huan Chine, Li Chen, Hsun-Hsin Hsu, Tai-Seng Wang, 2010, Modeling Slump of Concrete Using the Artificial Neural Networks, International Conference on Artificial Intelligence and Computational Intelligence p.236-239, IEEE Computer Society