

MODEL ESTIMASI BIAYA DENGAN *COST SIGNIFICANT MODEL* DAN *ARTIFICIAL NEURAL NETWORK* PROYEK PENINGKATAN JALAN ASPAL DI YOGYAKARTA

Yesia Tahapari, Arief Setiawan Budi Nugroho*, Latif Budi Suparma

Departemen Teknik Sipil dan Lingkungan, Universitas Gadjah Mada

Jl. Grafika Kampus No.2 Yogyakarta

*E-mail: arief_sbn@ugm.ac.id

Abstract: The need for an analytical method that may provide an accurate project cost estimation with minimal data availability becomes very necessary. Therefore, this research was conducted to determine and compare the cost estimation model based on the Cost Significant Model (CSM) and Artificial Neural Network (ANN) with two modeling approaches, ANN-1 and ANN-2. The models were developed based on 28 data of road improvement projects in Yogyakarta from the year 2010 until 2019. The analysis results show that the ANN-2 provides the best validation compared to the ANN-1 and the CSM model. The value of Mean Absolute Percentage Error (MAPE) of ANN-1 with the 3-8-1 net scheme provides a value of 12.687%, while that of ANN-2 with 10-15-1 net scheme is 8,132% and the MAPE value of the CSM model produces a value of 14.757%.

Keyword: *Cost Estimation, Cost Significant Model, Artificial Neural Network, Asphalt Road Improvement Project*

Abstrak: Kebutuhan akan suatu metode analisis yang dapat memperkirakan biaya proyek secara akurat pada ketersediaan data yang minimal menjadi sangat diperlukan. Penelitian ini dilakukan untuk mengetahui dan membandingkan model estimasi biaya berdasarkan metode *Cost Significant Model* (CSM) dan *Artificial Neural network* (ANN) dengan dua pendekatan pemodelan, ANN-1 dan ANN-2. Model dikembangkan berdasarkan 28 data proyek peningkatan jalan aspal di Yogyakarta dari tahun 2010 sampai dengan 2019. Hasil analisis menunjukkan bahwa model ANN-2 memberikan tingkat validasi terbaik dibandingkan dengan model ANN-1 ataupun model CSM. Nilai *Mean Absolute Percentage Error* (MAPE) pada model ANN-1 dengan skema jaringan 3-8-1 mendapatkan nilai sebesar 12,687% sedangkan ANN Model-2 dengan skema jaringan 10-15-1 adalah sebesar 8,132% sementara nilai MAPE Model CSM menghasilkan nilai sebesar 14,757%.

Kata Kunci: *Estimasi Biaya, Cost Significant Model, Artificial Neural Network, Proyek Peningkatan Jalan Aspal*

PENDAHULUAN

Seiring dengan kemajuan di bidang industri perdagangan dan bertambahnya kepemilikan kendaraan serta kebutuhan distribusi barang dan jasa yang tinggi menjadikan peningkatan kebutuhan akan jalan sebagai fasilitas prasarana transportasi meningkat. Proyek peningkatan jalan untuk memenuhi kebutuhan tersebut menjadi suatu keharusan yang tidak dapat dihindarkan.

Pekerjaan peningkatan jalan dalam pelaksanaannya bagaimanapun memerlukan anggaran yang tidak sedikit. Ketidaktepatan dalam perkiraan biaya dapat berakibat munculnya kendala-kendala selama pelaksanaan pekerjaan yang pada gilirannya dapat juga

memicu hasil yang kurang maksimal dan potensi kerugian hingga terhentinya proyek (Soemardi and Kusumawardani, 2010). Di sisi lain tidak jarang keterbatasan data dan informasi yang ada serta keterbatasan waktu yang tersedia menjadikan hitungan perkiraan biaya pekerjaan yang diperlukan untuk perencanaan anggaran terkendala khususnya terkait dengan hasil akurasi yang rendah.

Sama halnya dengan kemajuan bidang lain, perkembangan teknologi membawa banyak perubahan termasuk juga pada perkembangan alat bantu perangkat lunak dalam bidang *numerical analysis*. Sehubungan kebutuhan atas kecepatan waktu dan akurasi, perhitungan estimasi biaya pekerjaan yang berdasarkan pada riwayat data menjadi salah satu alternatif.

Dua metode yang paling sering digunakan adalah *Cost Significant Model* (CSM) dan *Artificial Neural Network* (ANN). Metode CSM dan ANN merupakan metode pendekatan atau peramalan yang mana keakuratan hasil analisis menjadi hal yang perlu diperhatikan.

Penelitian ini dilakukan untuk membandingkan tingkat akurasi hasil analisis estimasi biaya pekerjaan peningkatan jalan berdasarkan *Cost Significant Model* (CSM) dan *Artificial Neural Network* (ANN). Model analisis Metode CSM menggunakan pendekatan analisis regresi linear berganda sementara ANN menggunakan *multilayer feed-forward* dengan algoritma pembelajaran *backpropagation*. Tingkat akurasi model diukur berdasarkan besaran nilai MAPE (*Mean Absolute Percentage Error*).

TINJAUAN PUSTAKA

Estimasi Biaya

The American Association of Cost Engineering (AACE) mengkategorikan *cost estimate* sebagai salah satu bidang yang terdapat dalam *cost engineering* dalam penerapan prinsip-prinsip keteknikan yang mendasarkan pada pengalaman dan pertimbangan-pertimbangan *engineering* yang berhubungan dengan permasalahan perkiraan dan pengendalian biaya serta kaidah ekonomi teknik (Asiyanto, 2005). Perkiraan biaya atau estimasi biaya adalah seni memperkirakan (*the art of approximating*) jumlah biaya yang diperlukan untuk suatu kegiatan yang didasarkan atas informasi yang tersedia pada waktu tertentu (Soeharto, 1997).

Peningkatan Jalan

Berdasarkan Peraturan Menteri Pekerjaan Umum dan Perumahan Rakyat Republik Indonesia nomor 03/PRT/M/2015 tentang Penggunaan Dana Alokasi Khusus Bidang Infrastruktur halaman 27-28 menyebutkan bahwa “Peningkatan Jalan (PJ) adalah kegiatan penanganan untuk dapat meningkatkan kemampuan ruas-ruas jalan dalam kondisi tidak mantap atau kritis agar ruas jalan tersebut dalam kondisi mantap sesuai dengan umur rencana.”

Cost Significant Model

Cost model (model biaya) merupakan salah satu alternatif metode yang dapat digunakan untuk memperkirakan biaya proyek (Ashowth, 1994). Sedangkan *cost significant model* (CSM) merupakan suatu model persamaan regresi berganda dalam memperkirakan nilai biaya dari suatu proyek yang menyandarkan pada informasi biaya-biaya pekerjaan yang paling berpengaruh (*cost significant items*) terhadap biaya total proyek berdasarkan rekaman-rekaman data sebelumnya (Indrawan, 2011). *Cost significant items* (CSI) dianggap merepresentasikan proporsi besar, umumnya sebesar 80%, dari total biaya pekerjaan. Berdasarkan data CSI, perbaikan model CSM dilakukan guna memperoleh hasil perkiraan biaya pekerjaan dengan akurasi yang lebih baik (Poh and Horner, 1995).

Aplikasi ANN dalam Estimasi Biaya

Artificial Neural Network (ANN) atau jaringan syaraf tiruan merupakan salah satu representasi otak manusia yang selalu mencoba untuk mensimulasikan proses pembelajaran. Penggunaan istilah tiruan dalam definisi tersebut sehubungan dengan pendekatan sistem jaringan syaraf yang diimplementasikan dalam suatu program komputer yang mampu menyelesaikan sejumlah proses perhitungan setelah melalui mekanisme pembelajaran (Kusumadewi, 2004).

Penggunaan ANN dalam pembuatan model persamaan untuk memprediksi atau memperkirakan biaya konstruksi sudah banyak dilakukan dengan hasil yang cukup baik. Keunggulan ANN dibanding metode model persamaan yang lain terletak pada kemampuan pembelajaran dan generalisasinya. Suatu penelitian dalam pembuatan model persamaan estimasi biaya berdasarkan data dari 41 proyek gedung yang dibangun antara tahun 1998 dan 2001 menyebutkan bahwa setelah menguji beberapa arsitektur jaringan dalam ANN, disimpulkan bahwa model estimasi biaya dengan satu lapisan tersembunyi, empat node tersembunyi, dan satu node keluaran merupakan arsitektur model ANN dengan kinerja terbaik (Setyawati et al, 2002). Sementara itu pemodelan lain untuk perkiraan biaya pekerjaan gedung rumah sakit mendapatkan struktur ANN terbaik terjadi pada konfigurasi 7-9-1 (7 *variable inputs*, 1 *hidden layer* dengan 9 *neurons* dan 1

output) dengan akurasi hasil estimasi biaya rata – rata 96.51% (Prathama et al, 2017).

Penelitian lain terkait pengembangan model ANN untuk memprediksi biaya proyek jalan raya pernah juga dilakukan. Data informasi penawaran proyek jalan raya yang dibangun oleh Departemen Transportasi New Jersey digunakan sebagai *input* dalam model. Hasil analisis menghasilkan nilai *Mean absolute percentage Error* (MAPE) sebesar 7,55% (Williams, 2002). Sementara itu model lain menggunakan data yang dikumpulkan dari 300 proyek menunjukkan bahwa dalam pemodelan nonlinear ANN memberikan hasil terbaik dengan nilai MAPE 16,6% (Emsley, 2002).

Penggunaan *cost significant item* (CSI) diintegrasikan dengan ANN untuk meningkatkan akurasi estimasi biaya *life cycle cost* (LCC) pernah juga dilakukan dengan hasil *average different error* sebesar 1,91 % (Alqahtani and Whyte, 2013).

METODE PENELITIAN

Penelitian ini mengambil 31 data sekunder berupa Rencana Anggaran Biaya (RAB) kegiatan peningkatan jalan aspal Dinas PU Provinsi Yogyakarta dan PU Kabupaten Sleman dari tahun 2010 s.d. 2019. Daftar RAB tersebut adalah hasil analisis biaya pekerjaan *engineering estimate* oleh konsultan perencana berdasarkan *Detail Engineering Design* (DED) yang dikembangkannya. Dari keseluruhan 31 data, 28 data digunakan untuk pengembangan model CSM dan ANN, sedangkan tiga data sisanya disiapkan untuk pengujian validasi hasil pemodelan.

Analisis *time value of money* dilakukan untuk melakukan penyeragaman nilai biaya pekerjaan pada proyeksi tahun anggaran yang sama. Identifikasi variabel *Cost Significant Item* (CSI) dilakukan berdasarkan 80% nilai signifikansi bobot kumulatif pekerjaan divisi dan sub-sub pekerjaan yang terdapat pada divisi.

Model persamaan CSM dilakukan berdasarkan variabel CSI hasil uji *t* parsial. Persamaan CSM diperoleh menggunakan analisis regresi linear berganda yang selanjutnya dilakukan uji asumsi klasik. Sementara itu pemodelan ANN menggunakan 2 versi data *input*. Data *input* versi pertama menggunakan variabel CSI yang sama seperti pada pemodelan CSM, sedangkan data *input* versi kedua berupa variabel CSI secara keseluruhan. Pemodelan pada kedua ANN memakai parameter pelatihan yang sama yaitu menggunakan algoritma *backpropagation*. *Backpropagation* merupakan algoritma pembelajaran yang terawasi dan biasanya digunakan oleh *preceptron* dengan banyak lapisan untuk mengubah bobot-bobot yang terhubung dengan *neuron-neuron* yang ada pada lapisan tersembunyinya (Kusumadewi, 2004). Target *output* ketiga model baik model CSM maupun kedua model ANN berupa nilai total biaya konstruksi dan akan diuji tingkat akurasi berdasarkan nilai *Mean Absolute Percentage Error* (MAPE). Alur penelitian ini selengkapnyanya disajikan pada Gambar 1.

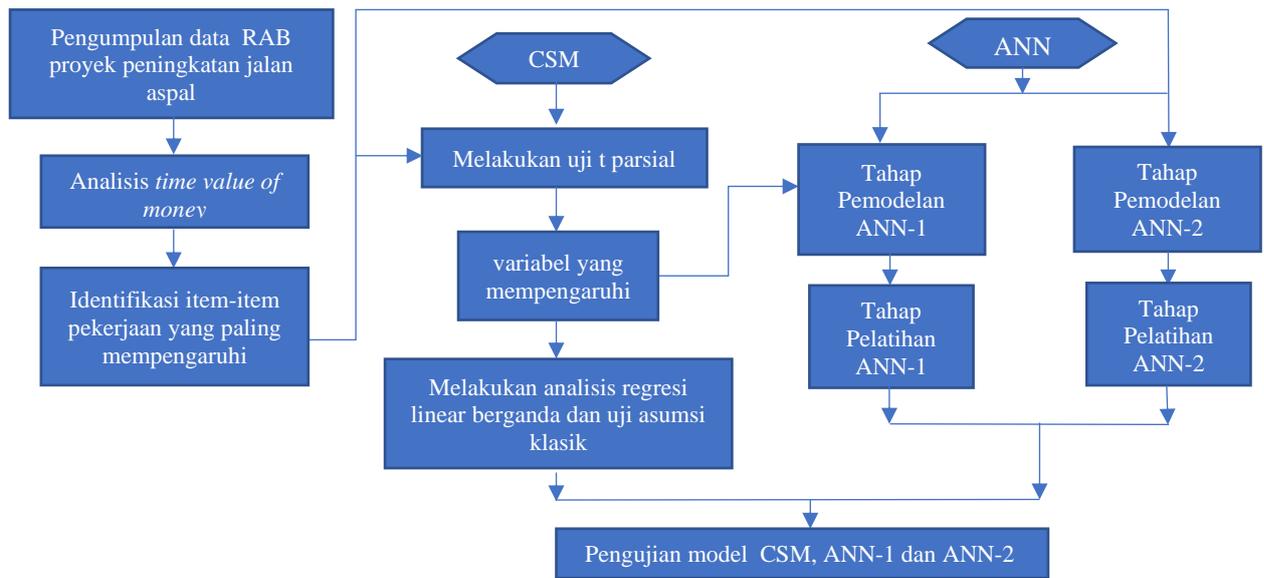
ANALISIS DAN PEMBAHASAN

Time value of money

Berdasarkan hasil pemetaan data diketahui bahwa terdapat 31 data proyek dengan tahun pelaksanaan bervariasi dari tahun 2010 sampai dengan tahun 2019. Untuk mendapatkan proyeksi biaya pekerjaan yang sama, analisis *time value of money* dilakukan dengan memproyeksikan nilai seluruh biaya proyek ke nilai biaya proyek pada tahun 2020. Nilai *interest rate* diambil berdasarkan nilai inflasi tahunan Provinsi Yogyakarta sementara faktor penyeragaman biaya (FPB) dihitung berdasarkan persamaan berikut (Muis, 1995) :

$$FPB_i = (1 + f_i) \cdot (1 + f_{\dots}) \cdot (1 + f_{n-1}) \quad (1)$$

dengan FPB_i = faktor penyeragaman biaya pada tahun pelaksanaan proyek, f_i = inflasi pada tahun pelaksanaan proyek, n = tahun pembahasan, tahun 2020 dan f_{n-1} = inflasi pada tahun 2019.



Gambar 1. Tiga metode pengembangan model: CSM, ANN-1 dan ANN-2

Tabel 1. Data penelitian

No	Tahun	Jumlah proyek	Inflasi	FPB
1	2010	1	7,38%	1,50
2	2013	2	7,32%	1,29
3	2014	1	6,59%	1,20
4	2015	3	3,09%	1,13
5	2016	1	2,29%	1,09
6	2017	6	4,20%	1,07
7	2018	15	2,66%	1,03
8	2019	2	0,46%	1,01
TOTAL PROYEK		31		

Tabel 1 menunjukkan data nilai inflasi dan hasil perhitungan FPB pada masing-masing tahun anggaran. Nilai FPB selanjutnya akan dikalikan dengan biaya-biaya pada data RAB sesuai tahun pelaksanaan proyek.

Identifikasi Variabel *Cost Significant Item* (CSI)

Untuk mengetahui variabel biaya yang berpengaruh terhadap biaya total pekerjaan, analisis proporsi biaya untuk setiap divisi pekerjaan dilakukan. Biaya setiap divisi pekerjaan dari 28 proyek peningkatan jalan dikonversi terlebih dahulu berdasarkan koefisien FPB pada Tabel 1. Total biaya divisi pekerjaan terbesar yang mempengaruhi lebih dari 80% biaya proyek diperhitungkan sebagai variabel

divisi pekerjaan yang berpengaruh. Hasil pemilahan data disajikan pada Tabel 2.

Tabel 2. Analisis proporsi biaya divisi pekerjaan

No	Divisi pekerjaan	Jumlah biaya divisi (28 Proyek)	Proporsi Biaya	Kumulatif proporsi
1	Perkerasan Aspal	Rp201.627.651.293	38,86%	38,87%
2	Drainase	Rp125.746.038.601	24,24%	63,11%
3	Perkerasan Berbutir	Rp64.838.828.022	12,49%	75,61%
4	Struktur	Rp46.174.352.554	8,90%	84,51%
5	pekerjaan tanah	Rp39.267.153.605	7,57%	92,08%
6	pelebaran perkerasan dan bahu jalan	Rp21.557.286.038	4,16%	96,23%
7	pekerjaan minor	Rp14.512.516.854	2,80%	99,03%
8	umum	Rp3.535.211.620	0,68%	99,71%
9	pekerjaan pemeliharaan rutin	Rp1.353.963.440	0,26%	99,97%
10	pekerjaan harian	Rp139.538.495	0,03%	100,00%
Total Biaya Proyek		Rp518.752.540.523		

Berdasarkan hasil analisis proporsi biaya divisi pekerjaan pada Tabel 2 diketahui bahwa terdapat empat divisi pekerjaan yang berpengaruh terhadap 80% biaya proyek. Keempat divisi tersebut adalah Divisi perkerasan aspal, divisi drainase, divisi perkerasan berbutir dan divisi struktur. Selanjutnya dengan cara yang sama seperti proses pemilihan biaya divisi, sub-sub pekerjaan pada divisi-divisi tersebut yang mempengaruhi lebih dari 80% total biaya divisi diperhitungkan sebagai item biaya pekerjaan yang berpengaruh (CSI) terhadap biaya proyek.

Daftar hasil pemilahan CSI disajikan pada Tabel 3. Variabel-variabel CSI tersebut selanjutnya digunakan sebagai variabel dalam pemodelan CSM dan pemodelan ANN.

Tabel 3. *Cost significant items*

No	Variabel model	Simbol
Divisi Drainase		
1	galian untuk saluran drainase	X ₁
2	pasangan batu dengan mortar	X ₂
3	beton K250/fc 20	X ₃
4	baja tulangan untuk beton minor	X ₄
Divisi Perkerasan berbutir		
5	lapis pondasi agregat kelas A	X ₅
Divisi Perkerasan Aspal		
6	laston lapis aus (AC-WC)	X ₆
7	laston lapis antara (AC-BC)	X ₇
8	laston lapis antara perata (AC-BC(L))	X ₈
Divisi Struktur		
9	pasangan batu	X ₉
10	beton mutu fc 10	X ₁₀
Variable terikat		
11	Total biaya konstruksi	Y

Pemodelan *Cost Signifikan Model* (CSM)

Dalam analisis CSM, uji variabel CSI (X_n) yang berpengaruh terhadap total biaya konstruksi dilakukan berdasarkan uji *t* parsial dengan

bantuan aplikasi SPSS. Variable X_n yang memiliki nilai *sig* < 0,05 merupakan variable yang berpengaruh terhadap total biaya konstruksi (Y). Sebaliknya variabel dengan nilai *sig* > 0,05 merupakan variable tidak berpengaruh terhadap total biaya konstruksi (Y) dan selanjutnya diabaikan. Hasil dari uji *t* parsial menunjukkan bahwa hanya terdapat tiga variabel yang berpengaruh terhadap total biaya (Y) yaitu pekerjaan galian untuk saluran drainase (X₁), pekerjaan lapis pondasi agregat kelas A (X₅), dan pekerjaan laston lapis antara (AC-BC) (X₇) seperti yang ditunjukkan pada Tabel 4.

Tabel 4. Hasil uji *t* parsial

No	Variabel model	Simbol	Nilai Sig
1	galian untuk saluran drainase	X ₁	0.001
2	lapis pondasi agregat kelas A	X ₅	0.015
3	laston lapis antara (AC-BC)	X ₇	0.038

Berdasarkan tiga variabel pada Tabel 4 selanjutnya dilakukan analisis regresi linear berganda serta uji asumsi klasik dengan bantuan aplikasi SPSS. Hasil analisis ditampilkan pada Tabel 5 dan Tabel 6.

Tabel 5. Hasil analisis *coefficient* variabel

Model	Unstandardized Coefficients		Standardized Coefficients	<i>t</i>	Sig.	Collinearity Statistics	
	B	Std. Error	Beta			Tolerance	VIF
1 (Constant)	3.385.264,846	938.596.940		3,607	0,001		
x1	31,060	3,627	0,434	8,564	0,000	0,528	1,895
x5	3,662	0,967	0,304	3,786	0,001	0,210	4,762
x7	2,902	0,538	0,375	5,394	0,000	0,281	3,564

a. *Dependent Variable:* y

Tabel 6. *Model summary*

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	0,984 ^a	0,968	0,963	3.795.244.180	2,683

a. *Predictors:* (Constant), x7, x1, x5

b. *Dependent Variable:* y

Berdasarkan hasil *unstandardized coefficient* pada Tabel 5 diperoleh persamaan perhitungan estimasi biaya CSM sebagai berikut:

$$Y = Rp\ 3.385.264.846 + 31,060 X_1 + 3,662 X_5 + 2,902 X_7 \tag{2}$$

dengan Y = Total biaya konstruksi peningkatan jalan aspal, X₁ = Biaya pekerjaan galian untuk

saluran drainase, X₅ = Biaya pekerjaan lapis pondasi agregat kelas A dan X₇ = Biaya pekerjaan lapis antara (AC-BC).

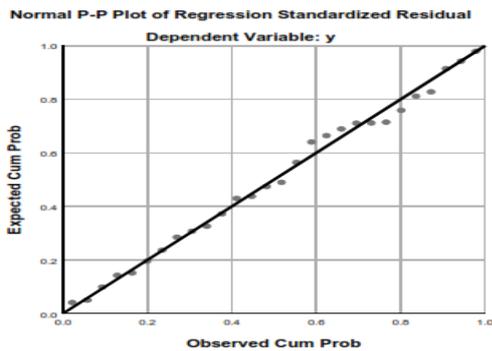
Berdasarkan hasil analisis pada Tabel 6 *Model Summary* diketahui bahwa nilai koefisien determinasi R square = 0,968 yang berarti bahwa tiga variable CSI: pekerjaan galian untuk saluran drainase (X₁), pekerjaan lapis pondasi agregat kelas A (X₅), dan pekerjaan laston lapis antara (AC-BC) (X₇), mempengaruhi 96,8% total biaya konstruksi. Sementara sisanya (100% - 96,8% = 3,2%) dipengaruhi oleh sebab-sebab lain.

Selanjutnya untuk mendapatkan model regresi yang bersifat *Best Linear Unbias Estimator* (BLUE), perlu dilakukan uji asumsi klasik. Uji asumsi klasik terdiri dari uji normalitas, uji

multikolinearitas, uji autokorelasi dan uji heteroskedastitas.

1. Uji Normalitas

Model regresi dikatakan berdistribusi normal jika *data plotting* (titik-titik) yang menggambarkan data sesungguhnya mengikuti garis diagonal (Ghozali, 2018). Hasil uji normalitas pada penelitian ini ditunjukkan pada Gambar 2.



Gambar 2. Grafik Normal P-P Plot

Grafik normal P-P Plot pada Gambar 2 menunjukkan bahwa sebaran titik-titik residual berada di sekitar garis normal yang mana dapat disimpulkan bahwa hasil persamaan regresi telah memenuhi persyaratan normalitas.

2. Uji Multikolonieritas

Cara mendeteksi ada tidaknya multikolonieritas yaitu dengan cara memperhatikan angka *Variance Inflation Factor* (VIF) dan *tolerance*. Apabila nilai *tolerance* lebih dari 0,10 dan nilai VIF kurang dari 10 maka persamaan regresi dinyatakan tidak terjadi gejala multikolonieritas (Ghozali, 2018). Berdasarkan hasil analisis nilai VIF pada Tabel 5 yang menunjukkan bahwa variabel X_1 , X_5 , dan X_7 memiliki nilai VIF kurang dari 10 dan nilai *tolerance* lebih dari 0,10 memberikan arti bahwa hasil persamaan regresi tidak terjadi gejala multikolonieritas.

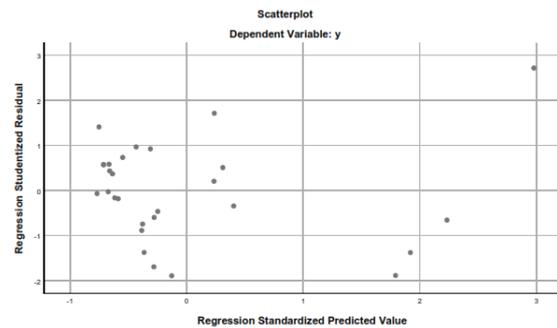
3. Uji Autokorelasi

Uji autokorelasi bertujuan untuk menguji apakah terdapat korelasi antar kesalahan pengganggu hasil analisis pada periode t dengan kesalahan hasil analisis pada periode sebelumnya ($t - 1$) dalam suatu model regresi linier. Apabila hasil uji autokorelasi mendapatkan nilai tingkat

signifikansi lebih besar dari 0,05 memberikan arti bahwa sebaran nilai residual merupakan nilai acak dan tidak memiliki ikatan korelasi (Sumantri, 2010). Berdasarkan hasil uji *Runs* diperoleh nilai signifikansi uji autokorelasi pada penelitian ini adalah sebesar 0,178 yang mana berarti bahwa tidak terjadi pengaruh autokorelasi antar nilai residual.

4. Uji Heteroskedastisitas

Deteksi terhadap heteroskedastisitas dilakukan dengan melihat ada tidaknya pola tertentu pada grafik *scatterplot* antara *studentized residual* (SRESID) dan *standardized predicted value* (ZPRED) (Ghozali, 2018). Hasil *scatterplot* pada Gambar 3 terlihat bahwa tidak ada pola yang jelas di mana titik-titik menyebar secara acak di atas dan di bawah nilai 0 pada sumbu-y. Hal ini menunjukkan bahwa tidak terjadinya gejala heteroskedastisitas dari hasil persamaan regresi.



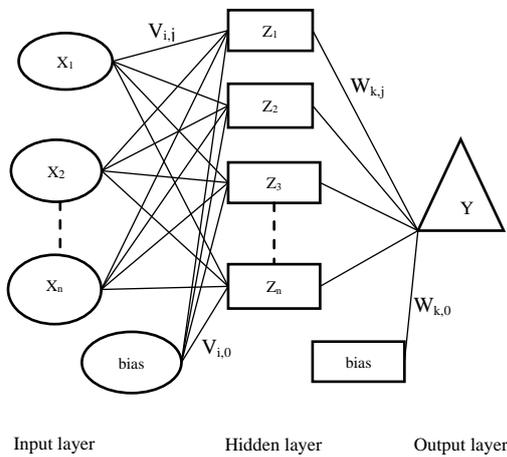
Gambar 3. Scatterplot

Pemodelan *Artificial Neural Network* (ANN)

Pemodelan merupakan bagian tahapan dari perencanaan arsitektur ANN. Tahapan ini merupakan proses untuk menentukan variabel *input*, target *ouput* dan bentuk jaringan (jumlah *neuron input layer*, jumlah *neuron hidden layer* dan jumlah *neuron output layer*). Arsitektur jaringan *backpropagation* disajikan pada Gambar 3. Jaringan ANN terdiri atas unit (*neuron*) pada *input layer* yaitu (X_1, X_2, \dots, X_n); 1 *hidden layer* dengan unit *neuron* ($Z_1, Z_2, Z_3 \dots Z_n$); serta 1 unit *neuron* pada *output layer* yaitu (Y). bobot yang menghubungkan *neuron* ($X_1, X_2, X_3 \dots X_n$) *input layer* dengan *hidden layer* ($Z_1, Z_2, Z_3 \dots Z_n$) adalah V_{ij} . Bobot yang menghubungkan *neuron hidden layer* ($Z_1, Z_2, Z_3 \dots Z_n$) dengan *output layer* (Y) adalah W_{jk} . Bobot bias yang menuju ke *neuron hidden*

layer adalah V_{i0} sedangkan bobot bias yang menghubungkan *hidden layer* dengan *output layer* adalah W_{k0} . Pada proses pelatihan jaringan dilakukan dalam rangka melakukan pengaturan bobot sehingga pada akhir pelatihan akan diperoleh bobot-bobot yang baik.

Pada pemodelan ANN-1 maupun ANN-2 untuk memiliki tingkat efisiensi pemrosesan yang baik, maka system pelatihan dijalankan dan akan ditemukan model ANN dengan melakukan proses pengujian yang bersifat *trial and error*. Proses ini untuk menemukan jumlah *neuron* pada *hidden layer* yang baik pada model ANN sehingga untuk ANN-1 memakai 8 *neuron* pada *hidden layer* dan ANN-2 memakai 15 *neuron* pada *hidden layer*



Gambar 4. Jaringan Artificial Neural Network

Pada pemodelan ANN-1, variabel *input* menggunakan variabel CSI yang sama dengan variabel *input* dari persamaan CSM pada Tabel 4 yaitu pekerjaan galian untuk saluran drainase (X_1), pekerjaan lapis pondasi agregat kelas A (X_5) dan pekerjaan laston lapis antara perata (AC-BC(L)) (X_7) dengan target *output* adalah total biaya konstruksi (Y) dengan skema jaringan 3 *neuron* pada *input layer*, 8 *neuron* pada *hidden layer* dan 1 *neuron* pada *output layer*.

Berbeda dengan pemodelan ANN-1, pemodelan ANN-2 menggunakan 10 variabel *input* yang sudah diidentifikasi sebelumnya seperti yang tercantum dalam Tabel 3 yaitu pekerjaan galian untuk saluran drainase (X_1), pekerjaan pasangan batu dengan mortar (X_2), pekerjaan beton

k250/f'c 20 (X_3), pekerjaan baja tulangan minor (X_4), pekerjaan lapis pondasi agregat kelas A (X_5), pekerjaan laston lapis aus (AC-WC) (X_6), pekerjaan laston lapis antara (AC-BC) (X_7), pekerjaan laston lapis antara perata (AC-BC(L)) (X_8), pekerjaan pasangan batu (X_9) dan pekerjaan beton mutu f'c 10 (X_{10}) dengan target *output* adalah total biaya konstruksi (Y). Model ANN-2 menggunakan skema jaringan 10 *neuron* pada *input layer*, 15 *neuron* pada *hidden layer* dan 1 *neuron* pada *output layer*.

Pada tahap analisis, pemodelan ANN-1 dan ANN-2 dilakukan dengan menggunakan program komputer MATLAB. Sehubungan MATLAB tidak mengenal satuan dan hanya menerima besaran nilai angka 0 s.d. 1 sebagai data masukan dalam pemodelan ANN, untuk itu normalisasi data *input* dan target *output* menggunakan metode *Z-score* dilakukan sebelum proses entry data dalam pemodelan ANN dilaksanakan. Metode *Z-score* merupakan metode normalisasi yang berdasarkan nilai *mean* (rata-rata) dan standar deviasi dari data. Normalisasi data metode *Z-score* dilakukan dengan menggunakan persamaan berikut :

$$\text{New Data} = \frac{(\text{Data} - \text{Mean})}{\text{Std}} \quad (3)$$

dengan New Data = data normalisasi, *Data* = nilai yang akan di normalisasi, *Mean* = nilai rata-rata dari data, dan *Std* = nilai standar deviasi dari data.

Selanjutnya tahap pelatihan merupakan tahapan proses pembelajaran jaringan pada pemodelan ANN-1 dan ANN-2. Dalam proses pelatihan, kedua model ANN ini menggunakan jaringan *backpropagation*, fungsi aktivasi *logsig* (*sigmoid biner*) dan parameter pelatihan dengan jumlah *epoch* 13.000, target *error* 0,001, *learning rate* 0,1, *Inc Learning Rate* 1,2, *Dec Learning Rate* 0,6, *Epoch Show* 1000, dan *Momentum* 0,75. Hasil *training* pemodelan ANN-1 pada program MATLAB diperoleh nilai MSE 0,0051106, *epoch* mencapai *epoch* maksimum 13.000 dengan nilai $R = 0,99735$. Sementara itu hasil *training* pada pemodelan ANN-2 mendapatkan nilai MSE 0,0009972, *epoch* mencapai 1.687 dan nilai $R = 0,99948$. Bobot-bobot akhir yang didapat dari hasil pelatihan selanjutnya digunakan untuk menentukan nilai-nilai koefisien dalam

persamaan biaya konstruksi mengikuti formulasi perhitungan berikut:

$$Y_k = Mean T_k + (W_{k0} + (\sum W_{kj} \cdot f(V_{i0} + \sum V_{ij} \cdot X_i))) St. dev T_k \quad (4)$$

dengan Y_k = Biaya perkiraan konstruksi *output*, Mean T_k = Rata-rata nilai target *output*, St.dev T_k = Standar deviasi target *output*, W_{k0} = Bobot akhir bias lapisan, W_{kj} = Bobot akhir lapisan, V_{i0} = Bobot akhir bias *input*, V_{ij} = Bobot akhir *input*, X_i = Parameter *input* dan f = Fungsi transfer atau aktivasi (fungsi *sigmoid biner*) menggunakan persamaan berikut :

$$f(x) = \frac{1}{1+e^{-x}} \quad (5)$$

Pengujian Model CSM dan ANN

Untuk menguji validitas hasil persamaan pemodelan, Uji coba perhitungan perkiraan biaya proyek dilakukan menggunakan tiga data proyek yang tidak dipergunakan dalam analisis pemodelan sebelumnya. Kinerja model CSM dan ANN diukur menggunakan rumus MAPE :

$$M = \frac{\sum \left(\frac{|Actual - Forecast|}{Actual} \right) * 100\%}{n} \quad (6)$$

dengan M = *mean absolute persentage error*, *Actual* = biaya aktual, *Forecast* = biaya hasil pemodelan dan n = jumlah data pengujian.

Contoh validasi model CSM sesuai dengan Persamaan (2) untuk Proyek Balong-Degolan adalah sebagai berikut :

$$\begin{aligned} Y &= Rp3.385.264.846 + 31,060.X_1 + 3,662.X_5 + 2,902.X_7 \\ &= Rp3.385.264.846 + 31,060 \times Rp43.433.920 + 3,662 \times Rp142.457.149 + 2,902 \times Rp992.870.83 \\ &= Rp 8.137.664.146 \end{aligned}$$

Sementara itu validasi model ANN-1 dan ANN-2 menggunakan Persamaan (4) dengan bobot-bobot akhir yang sudah diperoleh dalam proses pelatihan. Estimasi biaya berdasarkan model ANN-1 dengan bobot akhir pada Tabel 7 dan Tabel 8 pada Proyek Balong-Degolan adalah sebagai berikut :

$$Y_k = Rp18.526.876.447 + ((Z_1, W_{[1,1]} + Z_2, W_{[1,2]} + Z_3, W_{[1,3]} + Z_4, W_{[1,4]} + Z_5, W_{[1,5]} + Z_6, W_{[1,6]} +$$

$$\begin{aligned} &Z_7, W_{[1,7]} + Z_8, W_{[1,8]} + W_{[1,0]}) \cdot \\ &Rp19.853.830.795) \\ &= Rp7.153.446.417 \end{aligned}$$

dengan :

$$\begin{aligned} Z_1 &= 1/(1+\exp^{-(X_1.V_{[1,1]} + X_5.V_{[1,2]} + X_7.V_{[1,3]} + V_{[1,0]})}) = 1,000 \\ Z_2 &= 1/(1+\exp^{-(X_1.V_{[2,1]} + X_5.V_{[2,2]} + X_7.V_{[2,3]} + V_{[2,0]})}) = 0,9988 \\ Z_3 &= 1/(1+\exp^{-(X_1.V_{[3,1]} + X_5.V_{[3,2]} + X_7.V_{[3,3]} + V_{[3,0]})}) = 0,9986 \\ Z_4 &= 1/(1+\exp^{-(X_1.V_{[4,1]} + X_5.V_{[4,2]} + X_7.V_{[4,3]} + V_{[4,0]})}) = 0,1602 \\ Z_5 &= 1/(1+\exp^{-(X_1.V_{[5,1]} + X_5.V_{[5,2]} + X_7.V_{[5,3]} + V_{[5,0]})}) = 0,7880 \\ Z_6 &= 1/(1+\exp^{-(X_1.V_{[6,1]} + X_5.V_{[6,2]} + X_7.V_{[6,3]} + V_{[6,0]})}) = 0,9006 \\ Z_7 &= 1/(1+\exp^{-(X_1.V_{[7,1]} + X_5.V_{[7,2]} + X_7.V_{[7,3]} + V_{[7,0]})}) = 0,0148 \\ Z_8 &= 1/(1+\exp^{-(X_1.V_{[8,1]} + X_5.V_{[8,2]} + X_7.V_{[8,3]} + V_{[8,0]})}) = 0,9928 \end{aligned}$$

X_1, X_5 dan X_7 merupakan nilai-nilai variabel *input* yang sudah dinormalisasi.

Hasil estimasi biaya model ANN-2 berdasarkan bobot akhir pada Tabel 9 dan Tabel 10 pada Proyek Balong-Degolan adalah sebagai berikut :

$$\begin{aligned} Y_k &= Rp18.526.876.447 + ((Z_1, W_{[1,1]} + Z_2, W_{[1,2]} + Z_3, W_{[1,3]} + Z_4, W_{[1,4]} + Z_5, W_{[1,5]} + Z_6, W_{[1,6]} + Z_7, W_{[1,7]} + Z_8, W_{[1,8]} + Z_9, W_{[1,9]} + Z_{10}, W_{[1,10]} + Z_{11}, W_{[1,11]} + Z_{12}, W_{[1,12]} + Z_{13}, W_{[1,13]} + Z_{14}, W_{[1,14]} + Z_{15}, W_{[1,15]} + W_{[1,0]}) \cdot \\ &Rp19.853.830.795) \\ &= Rp7.810.376.358 \end{aligned}$$

dengan :

$$\begin{aligned} Z_1 &= 1/(1+\exp^{-(X_1.V_{[1,1]} + X_2.V_{[1,2]} + X_3.V_{[1,3]} + X_4.V_{[1,4]} + X_5.V_{[1,5]} + X_6.V_{[1,6]} + X_7.V_{[1,7]} + X_8.V_{[1,8]} + X_9.V_{[1,9]} + X_{10}.V_{[1,10]} + V_{[1,0]})}) = 0,4258 \\ Z_2 &= 1/(1+\exp^{-(X_1.V_{[2,1]} + X_2.V_{[2,2]} + X_3.V_{[2,3]} + X_4.V_{[2,4]} + X_5.V_{[2,5]} + X_6.V_{[2,6]} + X_7.V_{[2,7]} + X_8.V_{[2,8]} + X_9.V_{[2,9]} + X_{10}.V_{[2,10]} + V_{[2,0]})}) = 0,1150 \\ Z_3 &= 1/(1+\exp^{-(X_1.V_{[3,1]} + X_2.V_{[3,2]} + X_3.V_{[3,3]} + X_4.V_{[3,4]} + X_5.V_{[3,5]} + X_6.V_{[3,6]} + X_7.V_{[3,7]} + X_8.V_{[3,8]} + X_9.V_{[3,9]} + X_{10}.V_{[3,10]} + V_{[3,0]})}) = 0,9760 \\ Z_4 &= 1/(1+\exp^{-(X_1.V_{[4,1]} + X_2.V_{[4,2]} + X_3.V_{[4,3]} + X_4.V_{[4,4]} + X_5.V_{[4,5]} + X_6.V_{[4,6]} + X_7.V_{[4,7]} + X_8.V_{[4,8]} + X_9.V_{[4,9]} + X_{10}.V_{[4,10]} + V_{[4,0]})}) = 0,0002 \end{aligned}$$

$$Z_5 = 1 / (1 + \exp^{-(X_1.V_{[5,1]} + X_2.V_{[5,2]} + X_3.V_{[5,3]} + X_4.V_{[5,4]} + X_5.V_{[5,5]} + X_6.V_{[5,6]} + X_7.V_{[5,7]} + X_8.V_{[5,8]} + X_9.V_{[5,9]} + X_{10}.V_{[5,10]} + V_{[5,0]})}) = 0,0023$$

$$Z_6 = 1 / (1 + \exp^{-(X_1.V_{[6,1]} + X_2.V_{[6,2]} + X_3.V_{[6,3]} + X_4.V_{[6,4]} + X_5.V_{[6,5]} + X_6.V_{[6,6]} + X_7.V_{[6,7]} + X_8.V_{[6,8]} + X_9.V_{[6,9]} + X_{10}.V_{[6,10]} + V_{[6,0]})}) = 0,2314$$

$$Z_7 = 1 / (1 + \exp^{-(X_1.V_{[7,1]} + X_2.V_{[7,2]} + X_3.V_{[7,3]} + X_4.V_{[7,4]} + X_5.V_{[7,5]} + X_6.V_{[7,6]} + X_7.V_{[7,7]} + X_8.V_{[7,8]} + X_9.V_{[7,9]} + X_{10}.V_{[7,10]} + V_{[7,0]})}) = 0,9302$$

$$Z_8 = 1 / (1 + \exp^{-(X_1.V_{[8,1]} + X_2.V_{[8,2]} + X_3.V_{[8,3]} + X_4.V_{[8,4]} + X_5.V_{[8,5]} + X_6.V_{[8,6]} + X_7.V_{[8,7]} + X_8.V_{[8,8]} + X_9.V_{[8,9]} + X_{10}.V_{[8,10]} + V_{[8,0]})}) = 0,7233$$

$$Z_9 = 1 / (1 + \exp^{-(X_1.V_{[9,1]} + X_2.V_{[9,2]} + X_3.V_{[9,3]} + X_4.V_{[9,4]} + X_5.V_{[9,5]} + X_6.V_{[9,6]} + X_7.V_{[9,7]} + X_8.V_{[9,8]} + X_9.V_{[9,9]} + X_{10}.V_{[9,10]} + V_{[9,0]})}) = 0,3882$$

$$Z_{10} = 1 / (1 + \exp^{-(X_1.V_{[10,1]} + X_2.V_{[10,2]} + X_3.V_{[10,3]} + X_4.V_{[10,4]} + X_5.V_{[10,5]} + X_6.V_{[10,6]} + X_7.V_{[10,7]} + X_8.V_{[10,8]} + X_9.V_{[10,9]} + X_{10}.V_{[10,10]} + V_{[10,0]})}) = 0,7879$$

$$Z_{11} = 1 / (1 + \exp^{-(X_1.V_{[11,1]} + X_2.V_{[11,2]} + X_3.V_{[11,3]} + X_4.V_{[11,4]} + X_5.V_{[11,5]} + X_6.V_{[11,6]} + X_7.V_{[11,7]} + X_8.V_{[11,8]} + X_9.V_{[11,9]} + X_{10}.V_{[11,10]} + V_{[11,0]})}) = 0,4636$$

$$Z_{12} = 1 / (1 + \exp^{-(X_1.V_{[12,1]} + X_2.V_{[12,2]} + X_3.V_{[12,3]} + X_4.V_{[12,4]} + X_5.V_{[12,5]} + X_6.V_{[12,6]} + X_7.V_{[12,7]} + X_8.V_{[12,8]} + X_9.V_{[12,9]} + X_{10}.V_{[12,10]} + V_{[12,0]})}) = 0,0456$$

$$Z_{13} = 1 / (1 + \exp^{-(X_1.V_{[13,1]} + X_2.V_{[13,2]} + X_3.V_{[13,3]} + X_4.V_{[13,4]} + X_5.V_{[13,5]} + X_6.V_{[13,6]} + X_7.V_{[13,7]} + X_8.V_{[13,8]} + X_9.V_{[13,9]} + X_{10}.V_{[13,10]} + V_{[13,0]})}) = 0,8103$$

$$Z_{14} = 1 / (1 + \exp^{-(X_1.V_{[14,1]} + X_2.V_{[14,2]} + X_3.V_{[14,3]} + X_4.V_{[14,4]} + X_5.V_{[14,5]} + X_6.V_{[14,6]} + X_7.V_{[14,7]} + X_8.V_{[14,8]} + X_9.V_{[14,9]} + X_{10}.V_{[14,10]} + V_{[14,0]})}) = 0,6427$$

$$Z_{15} = 1 / (1 + \exp^{-(X_1.V_{[15,1]} + X_2.V_{[15,2]} + X_3.V_{[15,3]} + X_4.V_{[15,4]} + X_5.V_{[15,5]} + X_6.V_{[15,6]} + X_7.V_{[15,7]} + X_8.V_{[15,8]} + X_9.V_{[15,9]} + X_{10}.V_{[15,10]} + V_{[15,0]})}) = 0,9991$$

X₁ s.d X₁₀ merupakan nilai variabel input yang sudah dinormalisasi. Hasil validasi model terhadap tiga proyek data peningkatan jalan ditunjukkan pada Tabel 11.

Tabel 7. Bobot-bobot akhir input pemodelan ANN-1

	0	1	2	3
V ₁	11,92	-1,36	-1,83	-2,09
V ₂	6,09	-1,95	1,72	-1,51
V ₃	5,68	-1,14	0,96	-2,59
V ₄	-0,77	2,52	-0,30	-1,83
V ₅	1,64	2,23	-2,20	0,54
V ₆	0,90	-0,27	-3,03	1,75
V ₇	-1,20	3,03	1,36	1,65
V ₈	4,80	0,48	-1,92	2,28

0 : bobot akhir bias input
1 s.d. 3 : bobot akhir input

Tabel 8. Bobot-bobot akhir lapisan tersembunyi pemodelan ANN-1

	0	1	2	3	4	5	6	7	8
W ₁	0,15	-1,14	1,41	-0,51	-0,49	1,17	-1,33	1,51	-0,15

0 : bobot akhir bias lapisan tersembunyi (*hidden layer*)
1 s.d. 8 : bobot akhir lapisan tersembunyi (*hidden layer*)

Tabel 9. Bobot-bobot akhir input pemodelan ANN-2

	0	1	2	3	4	5	6	7	8	9	10
V ₁	-1,44	0,56	-0,58	0,48	-0,04	0,51	-0,34	-0,95	0,16	-1,00	-0,75
V ₂	-1,68	0,33	0,04	-1,17	-0,29	-0,35	-0,21	-0,52	-0,50	1,21	0,16
V ₃	3,31	-0,43	0,65	-0,41	0,41	0,40	-0,22	0,44	0,27	-1,12	0,16
V ₄	-6,31	0,88	0,30	-0,98	0,50	0,70	0,40	0,96	0,17	0,86	0,11
V ₅	-4,95	0,22	0,50	-0,76	0,46	0,82	0,00	0,97	0,33	0,68	-0,63

V₆	-0,32	-0,50	0,15	0,75	-0,41	1,09	-0,12	-0,58	-0,15	0,82	0,67
V₇	2,13	-0,43	-0,73	0,43	0,33	0,11	0,68	0,11	-0,90	-1,10	0,25
V₈	1,37	0,58	0,81	-0,64	0,26	-0,73	0,52	0,11	-0,77	-0,38	-0,24
V₉	-0,30	0,65	0,62	0,82	-0,51	-0,61	0,17	-0,76	0,89	-0,44	-0,09
V₁₀	2,08	0,65	0,26	-1,01	-0,65	-0,61	0,55	-0,56	-0,58	0,62	-0,11
V₁₁	-0,50	-0,40	0,37	-0,02	0,07	0,98	-0,21	-0,58	0,89	-0,13	-0,98
V₁₂	-1,13	0,82	0,22	-0,13	0,81	-0,11	1,01	1,12	0,29	0,68	-0,64
V₁₃	1,74	0,66	-0,14	0,43	-0,37	0,55	0,44	-0,43	1,13	-0,76	-0,76
V₁₄	-1,02	-0,18	0,51	0,56	0,04	-0,70	-0,28	-0,05	-1,12	-0,70	-1,07
V₁₅	6,72	0,52	-0,49	-0,77	-0,59	0,87	0,12	-0,73	-0,11	-0,92	-0,54
0	: bobot akhir bias input										
1 s.d. 10	: bobot akhir input										

Tabel 10. Bobot-bobot akhir lapisan tersembunyi pemodelan ANN-2

	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
W₁	-0,36	0,24	-0,66	0,31	1,91	1,01	0,26	0,03	0,49	-0,27	-0,23	0,30	1,05	-0,17	-0,40	-0,46
0	: bobot akhir bias lapisan tersembunyi (<i>hidden layer</i>)															
1 s.d. 15	: bobot akhir lapisan tersembunyi (<i>hidden layer</i>)															

Tabel 11. Analisis MAPE model CSM dan ANN

No	Nama Proyek	Biaya Aktual	CSM		ANN-1		ANN-2	
			Estimasi biaya	Nilai error	Estimasi biaya	Nilai error	Estimasi biaya	Nilai error
1	Balong - Degolan	Rp8.575.652.744	Rp8.137.664.146	5,11%	Rp7.153.446.417	16,58%	Rp7.810.376.358	8,924%
2	Karangpakis - Grogolan	Rp9.114.582.578	Rp10.057.140.237	-10,34%	Rp7.249.377.312	20,46%	Rp7.776.857.222	14,677%
3	Sampakan - Singosaren	Rp6.841.151.604	Rp8.813.009.025	-28,82%	Rp6.930.825.798	-1,31%	Rp6.895.470.644	-0,794%
MAPE				14,76%		12,78%		8,132%

Pembahasan

Hasil analisis terhadap tiga data proyek peningkatan jalan aspal yang digunakan dalam validasi model menunjukkan bahwa secara umum model ANN menghasilkan nilai akurasi yang lebih baik dibandingkan dengan model CSM. Namun demikian, ditinjau dari ketiga model, model ANN-2 yang menggunakan variabel CSI berupa item-item pekerjaan paling berpengaruh dalam menentukan 80% biaya proyek mempunyai akurasi MAPE terkecil yaitu 8,132% dibandingkan model CSM dan model ANN-1 yang menggunakan variabel CSI berupa item-item pekerjaan berdasarkan hasil uji t-parsial.

Selain itu, berdasarkan hasil pelatihan untuk pemodelan ANN-1 skema jaringan 3 *neuron input layer* – 8 *neuron hidden layer* – 1 *neuron output layer* dan ANN-2 skema jaringan 10 *neuron input layer* – 15 *neuron hidden layer* – 1 *neuron output layer* dengan parameter yang sama diketahui bahwa pelatihan ANN-2

memerlukan iterasi lebih sedikit untuk mencapai nilai optimum dalam proses pelatihan.

Berdasarkan hasil tersebut dapat diketahui bahwa untuk mendapatkan hasil pemodelan dengan tingkat akurasi yang paling baik, dalam pengembangan model ANN, penggunaan variabel CSI berupa item-item pekerjaan paling berpengaruh dalam menentukan 80% biaya lebih direkomendasikan dibanding penggunaan variable CSI hasil uji t-parsial yang umum digunakan dalam pemodelan CSM. Bahkan ANN tersebut memberikan hasil jauh lebih baik dibandingkan dengan penelitian serupa terkait penggunaan ANN dalam pemodelan estimasi biaya konseptual konstruksi jalan layang yang menggunakan skema jaringan 5 *neuron input layer* - 10 *neuron hidden layer* - 1 *neuron output layer* yang mana hanya menghasilkan akurasi MMRE 28% (Giwangkoro et al, 2013).

KESIMPULAN

Secara umum metode ANN memiliki tingkat akurasi lebih baik dibandingkan dengan metode CSM. Hasil analisis validasi terhadap ketiga model diperoleh nilai MAPE untuk model CSM adalah 14,76%, sedangkan model ANN-1 sebesar 12,79% dan model ANN-2 sebesar 8,132%.

Model ANN-2 yang menggunakan variabel CSI berupa item-item pekerjaan paling berpengaruh dalam menentukan 80% biaya proyek sebagai model persamaan dalam memperkirakan biaya proyek konstruksi khususnya biaya peningkatan jalan aspal dapat menjadi alternatif solusi untuk memecahkan permasalahan terkait kecepatan estimasi anggaran. ANN-2 menjanjikan tingkat akurasi yang baik dengan nilai penyimpangan di bawah 10%. Sementara itu penggunaan model CSM yang menggunakan variabel CSI hasil uji *t* parsial kurang direkomendasikan selain sehubungan dengan nilai penyimpangannya yang relatif besar, di atas 10%, persyaratan tahapan pengujiannya juga lebih banyak dan lebih kompleks.

DAFTAR PUSTAKA

- Ashwoth, A. (1994). *Perencanaan Biaya Bangunan*. Gramedia Pustaka Utama, Jakarta.
- Asiyanto, (2005). *Construction Project Cost Management*. PT. Pradnya Paramita, Jakarta.
- Alqahtani, A. and Whyte, A. (2013). "Artificial neural networks incorporating cost significant items towards enhancing estimation for (life-cycle) costing of construction projects", *Australasian Journal of Construction Economics and Building*, 13 (3) 51-64
- Biemo, W. S. dan Reni, G. K. (2010). "Studi Praktek Estimasi Biaya Tidak Langsung Pada Proyek Konstruksi", *Konferensi Nasional Teknik Sipil 4 2010*
- Emsley, M. W., Lowe, D. J., Roy, D. A., Harding, A., and Hickson, A. (2002). "Data modelling and the application of a neural network approach to the prediction of total construction cost". *Constr. Manage.Econ.*, 20(6), 465–472.
- Ganjar, G., Yusuf, L., dan Wisnu, I. (2012). "Estimasi Biaya Konseptual Konstruksi Bangunan Jalan Layang (flyover) Dengan Menggunakan Metode Jaringan Saraf Tiruan (Artificial Neural Network)", *Jurnal FT UI*, Depok.
- Ghozali, I. (2018). *Aplikasi Analisis Multivariate dengan Program IBM SPSS 25*. Badan Penerbit Universitas Diponegoro, Semarang.
- Gede, S. I. (2011). "Estimasi Biaya Pemeliharaan Jalan Dengan Cost Significant Model, Studi Kasus di Kabupaten Jembrana Bali".
- Inas, W. (2017). *Tesis Pemodelan Biaya Struktur Atas Jembatan Tipe I-Grider Berdasarkan Detail Engineering Design (DED) (studi kasus : 13 jembatan di daerah Yogyakarta)*. Magister Teknik Sarana dan Prasarana dan Bahan Bangunan, Departemen Teknik Sipil UGM. Yogyakarta.
- Kusumadewi, S. (2004). *Membangun Jaringan Syaraf Tiruan (Menggunakan MATLAB & Excel Link)*. Graha Ilmu, Yogyakarta.
- Kementerian P.U. (2015). *Peraturan menteri pekerjaan umum dan perumahan rakyat nomor 03/PRT/M/2015 tentang petunjuk teknis penggunaan dana alokasi khusus bidang infrastruktur*, Jakarta.
- Muis, A. R. (1995). *Tesis Estimasi Awal Biaya Pelaksanaan Konstruksi Jembatan*. Institut Teknologi Bandung, Bandung.
- Poh, P. S. H., and Horner, R. M. W. (1995). "Cost-Significant Modelling-Its Potential For Use In South-East Asia" : *Paper in Engineering, Construction and Architectural Management*. 85.
- Prathama, A. Y., Aminullah A., dan Saputra A., (2017), "Pendekatan ANN (Artificial Neural Network) Untuk Penentuan Presentase Bobot Pekerjaan Dan Estimasi Nilai Pekerjaan Struktur Pada Rumah Sakit Pratama", *Jurnal Tekno Sains Vol 7*, Yogyakarta.
- Soeharto, I. (1997). *Manajemen Proyek Dari Konseptual Sampai Operasional*. Erlangga, Jakarta.
- Sumantri, A. (2010). *Tugas Kuliah Laporan Praktikum Statistika Dasar*. Universitas Brawijaya, Malang.
- Setyawati, B. R., Sahirman, S., and Creese, R. C. (2002). "Neural networksfor cost estimation." *Proc., 2002 AACE International Transactions, EST.13, American Association of Cost Engineers (AACE) International, Morgantown, WV*.

- Welman, (2009). *Tesis Evaluasi Bid Price Proyek Pembangunan Jembatan Di Lingkungan Kabupaten Rokan Hulu Berdasarkan Cost Significant Model*. Magister Teknik Sarana dan Prasarana dan Bahan Bangunan, Departemen Teknik Sipil UGM. Yogyakarta.
- Williams, T. P. (2002). "Predicting completed project cost using bidding data". *Constr. Manage. Econ.*, 20(3), 225–235.