

PEMODELAN ESTIMASI BIAYA KONSEPTUAL PROYEK GEDUNG SEKOLAH DENGAN MENGGUNAKAN ARTIFICIAL NEURAL NETWORK

Oei Fuk Jin¹ dan Kevin Pratama Surya²

^{1,2}Program Studi Magister Teknik Sipil, Universitas Tarumanagara Jakarta

Email: *fukjin.untar@gmail.com, kevin.psurya@gmail.com*

Masuk: **31-09-2024**, revisi: **14-10-2024**, diterima untuk diterbitkan: **31-10-2024**

ABSTRAK

Berdasarkan data Badan Pusat Statistik, pada tahun 2015 jumlah penduduk di Provinsi DKI Jakarta adalah 10.177.900 jiwa dengan laju pertumbuhan 1,02% per tahun. Ada sekitar 14,7% berada di usia sekolah. Untuk memenuhi permintaan akan pendidikan yang berkualitas, pengurus yayasan sekolah X terus mengembangkan dan membangun sekolah-sekolah baru di Jakarta dan sekitarnya. Perencanaan pembangunan sekolah harus dilakukan dengan baik. Salah satu langkah awalnya adalah dengan melakukan studi kelayakan. Estimasi biaya konseptual merupakan hal yang penting pada tahap ini. Ada beberapa kesulitan dalam melakukan estimasi biaya pada tahap konseptual, antara lain adalah kurangnya informasi awal mengenai proyek, kurangnya data biaya proyek, data yang tidak lengkap, dan lain sebagainya. Seiring dengan kemajuan teknologi komputer, berkembanglah metode baru seperti *Artificial Neural Network* yang dapat digunakan sebagai pendekatan alternatif untuk mengestimasi biaya. Tujuan dari penelitian ini adalah untuk membuat model dengan *Artificial Neural Network* dengan mengambil 15 data proyek gedung sekolah di Jakarta. Penelitian ini menggunakan analisis faktor untuk menentukan variabel yang akan menjadi *input model*. Dengan menggunakan program *Matlab*, hasil dari penelitian ini menunjukkan bahwa pemodelan *Artificial Neural Network* yang terbaik dari penelitian ini adalah dengan arsitektur jaringan 7-5-1 dengan algoritma *backpropagation*.

Kata kunci: *Artificial Neural Network*; Estimasi Biaya; Sekolah; Konseptual; Model

ABSTRACT

According to Central Bureau of Statistics (Badan Pusat Statistik), in 2015 the population of Special Capital Region of Jakarta was 10,177,900 people with the rate of growth 1.02% per annum. Approximately, 14.7% of the population are students. In order to fulfil the demand of good quality education, the X school foundation develops and builds new schools continuously, especially in Jakarta and its suburbs. The planning of school development should be done well. One of the initial steps is to conduct a feasibility study. Conceptual cost estimation is important at this stage. There are some difficulties in estimating the cost at the conceptual stage, such as the lack of preliminary information about the project, lack of project cost data, incomplete data, et cetera. The purpose of this study is to create model using *Artificial Neural Network*. To determine the input variables, analysis factors were used. After that, the model was created by using *Matlab* software. This research was conducted by collecting 15 data of school building projects. The result of this study shows the best *Artificial Neural Network* model is network architecture 7-5-1 with *backpropagation* algorithm.

Keywords: *Artificial Neural Network*; Cost Estimation; School; Conceptual; Model

1. PENDAHULUAN

Berdasarkan data yang dikeluarkan oleh Badan Pusat Statistik tahun 2016, jumlah penduduk di provinsi DKI Jakarta adalah 10.177.900 jiwa dengan laju pertumbuhan penduduk 1,02% per tahun. Dari banyaknya jumlah penduduk provinsi DKI Jakarta, ada 1.558.584 jiwa yang berada di usia sekolah. Para pelajar ini dilayani dengan 7.060 sekolah, yang terdiri dari sekolah swasta dan sekolah negeri dari jenjang TK, SD, SMP, SMK dan SMA. Diperkirakan pada tahun 2020, jumlah pelajar di provinsi DKI Jakarta akan menjadi 1.720.803 jiwa.

Sekolah X adalah salah satu sekolah swasta di Jakarta yang memiliki 72 sekolah tersebar merata di daerah Jakarta dan sekitarnya yang sudah terdaftar pada Dinas Pendidikan dengan jumlah siswa 32.493 di tahun pelajaran 2015-2016 dan terus bertambah setiap tahun. Dalam rangka memenuhi permintaan akan pendidikan yang berkualitas, pengurus sekolah X berencana untuk mengembangkan dan membangun sekolah-sekolah baru di daerah Jabodetabek. Untuk itu diperlukan perencanaan pembangunan sekolah yang baik. Estimasi biaya proyek konstruksi pada tahap awal atau tahap konseptual mempunyai peran yang penting bagi pemilik proyek konstruksi dalam mengambil keputusan pembangunan proyek yang direncanakan (Putra dan Setyandito, 2023; Wang, et.al., 2024). Pembuatan estimasi biaya konseptual ini dibuat sebelum gambar konstruksi dibuat, spesifikasi dari material belum ditentukan, serta terbatasnya informasi mengenai detail desain. Keakuratan dari estimasi biaya konseptual ini merupakan hal yang krusial (Nia, et.al., 2023, Zhang, et.al., 2024).

Menurut Sodikov (2005) dan Zhang, et.al. (2024), permasalahan yang terjadi dalam melakukan estimasi tahap konseptual ini antara lain, kurangnya *preliminary information*, kurangnya data historis dari pekerjaan-pekerjaan sejenis sebelumnya, dan kurang pengetahuan tentang metode pendekatan estimasi biaya yang *ter-update*. Seiring dengan kemajuan teknologi komputer, berkembanglah metode baru seperti *Artificial Neural Network* yang dapat digunakan sebagai pendekatan alternatif untuk mengestimasi biaya (Al-Tawal, et.al., 2020). *Artificial Neural Network* ini telah diterapkan dalam berbagai bidang untuk memecahkan masalah dan membantu dalam pengambilan keputusan.

Berdasarkan latar belakang yang telah dikemukakan, penelitian ini membahas permodelan estimasi biaya konseptual proyek gedung sekolah dengan menggunakan *Artificial Neural Network* dengan menggunakan *software* Matlab. Menurut Cheng *et al.* (2009) dan Wang, et.al., (2024), estimasi biaya konseptual merupakan basis dari evaluasi proyek, *design engineering*, *budgeting*, biaya serta manajemen biaya, yang tidak hanya memiliki peranan penting pada studi kelayakan suatu proyek, melainkan juga merupakan hal fundamental bagi kesuksesan suatu proyek. Estimasi biaya konseptual juga merupakan salah satu dari output perencanaan biaya awal dan merupakan salah satu bagian informasi penting. *Association for the Advancement of Cost Engineering* (AACE) (2016) mengatakan pada tahapan konseptual ini dibuat dengan keterbatasan informasi pada lingkup proyek dan belum masuk ke dalam tahap desain dan *engineering*. AACE mengklasifikasikan tahap konseptual ini adalah kelas 5. Dari beberapa definisi yang telah disebutkan dari para ahli (7), maka dapat disimpulkan bahwa estimasi biaya konseptual proyek konstruksi adalah perkiraan biaya proyek yang mana belum tersedianya gambar proyek, spesifikasi proyek, dan lingkup pekerjaan yang masih belum lengkap.

Di dalam penelitiannya, Pettang *et al.* (1997) mengatakan bahwa faktor-faktor yang mempengaruhi biaya dari sebuah gedung adalah tipe rangka, luas bangunan, jumlah lantai tipikal, luas dinding, jumlah pintu, jumlah jendela, sistem mekanikal, dan kualitas dari *finishing*. Emsley *et al.* (2002) membuat model *Artificial Neural Network* untuk memprediksi biaya total konstruksi gedung di Britania Raya. Mereka mengelompokkan variabel-variabel yang mempengaruhi biaya total konstruksi gedung menjadi tiga kelompok variabel, yaitu variabel-variabel yang berhubungan dengan lokasi proyek, sistem tata udara, jenis plafon, jenis instalasi listrik, *envelope*, jumlah pintu luar, luas dinding luar, jenis lantai, tipe rangka, fungsi gedung, tinggi lantai tipikal, jumlah pintu dalam, luas dinding dalam, jenis *finishing* dinding, jumlah elevator, jumlah lantai di atas tanah, jumlah lantai di bawah tanah. Kim *et al.* (2004) melakukan penelitian mengenai estimasi biaya proyek konstruksi gedung di Korea Selatan. Hasil penelitiannya menunjukkan bahwa variabel-variabel yang mempengaruhi biaya proyek antara lain adalah luas bangunan, jumlah lantai, tipe atap, tipe pondasi, jumlah basement, dan *finishing grades*. Di Turki, Gunaydin dan Dogan (2004) meneliti model *Artificial Neural Network* untuk

mengestimasi biaya proyek konstruksi gedung untuk pemukiman. Beberapa parameter yang mempengaruhi biaya dari suatu Gedung adalah luas bangunan, jumlah lantai tipikal, luas lantai dasar, jumlah lantai tipikal, arah konsol dari gedung, sistem pondasi, tipe lantai, dan lokasi inti dari gedung. Arafa dan Alqedra (2011) melakukan penelitian mengenai estimasi biaya dari proyek konstruksi gedung dengan menggunakan *Artificial Neural Network* di Gaza, Palestina. Hasil penelitian mereka menunjukkan bahwa biaya proyek dipengaruhi beberapa variabel, antara lain adalah luas lantai dasar, luas lantai tipikal, jumlah lantai, jumlah kolom, tipe pondasi, jumlah elevator, dan jumlah ruangan.

Cirilovic *et al.* (2014) menambahkan bahwa inflasi turut berpengaruh terhadap nilai proyek, terutama untuk proyek-proyek yang berjangka panjang. Untuk itu, inflasi harus diperhitungkan dalam membuat estimasi biaya proyek. Dari hasil studi pustaka yang telah dilakukan, diambil beberapa variabel. Variabel-variabel tersebut dapat dilihat pada Tabel 1.

Tabel 1. Variabel Penelitian

Variabel	Deskripsi	Keterangan	Referensi
X1	Luas bangunan	m ²	Pettang et al. (1997), Emsley et al. (2002), Gunaydin dan Dogan (2004), Kim et al. (2004), Arafa dan Alqedra (2011)
X2	Jumlah lantai tipikal	lantai	Pettang et al. (1997), Emsley et al. (2002), Gunaydin dan Dogan (2004), Kim et al. (2004), Arafa dan Alqedra (2011)
X3	Luas dinding	m ²	Pettang et al. (1997), Emsley et al. (2002)
X4	Jumlah pintu	unit	Pettang et al. (1997), Emsley et al. (2002)
X5	Jumlah jendela	unit	Pettang et al. (1997)
X6	Kualitas dari finishing	Sederhana/ tidak sederhana/ khusus	Pettang et al. (1997), Gunaydin dan Dogan (2004), Kim et al. (2004)
X7	Jenis pondasi	Bor pile/ pancang	Emsley et al. (2002), Gunaydin dan Dogan (2004), Kim et al. (2004), Arafa dan Alqedra (2011)
X8	Jumlah elevator	unit	Emsley et al. (2002), Arafa dan Alqedra (2011)
X9	Inflasi	persen	Cirilovic et al. (2014)
Y	Biaya proyek	dalam milyar	

Artificial Neural Network pertama kali digagas oleh Waffen McCulloch dan Walter Pitts pada tahun 1943, yang terinspirasi dari neuron manusia. Sistem syaraf manusia terdiri dari susunan neuron-neuron yang sangat kompleks. Begitu banyak neuron yang saling berintegrasi sehingga membentuk suatu susunan syaraf yang membentuk suatu *network* di jaringan otak. *Artificial Neural Network* meniru konsep ini. Tindakan perubahan signal syaraf bila diindikasikan hampir sama dengan perubahan nilai *weight* dalam *Artificial Neural Network* (Haykin, 1999). Jong (2005) mendefinisikan *Artificial Neural Network* adalah sistem pemroses informasi yang memiliki karakteristik mirip dengan jaringan syaraf biologi. Secara sederhana *Artificial Neural Network* merupakan sebuah alat pemodelan data statistik non-linear, yang dapat digunakan untuk memodelkan hubungan yang kompleks antara input dan output untuk

menemukan pola-pola pada data. Secara umum, ada tiga lapisan pada *Artificial Neural Network*, yaitu:

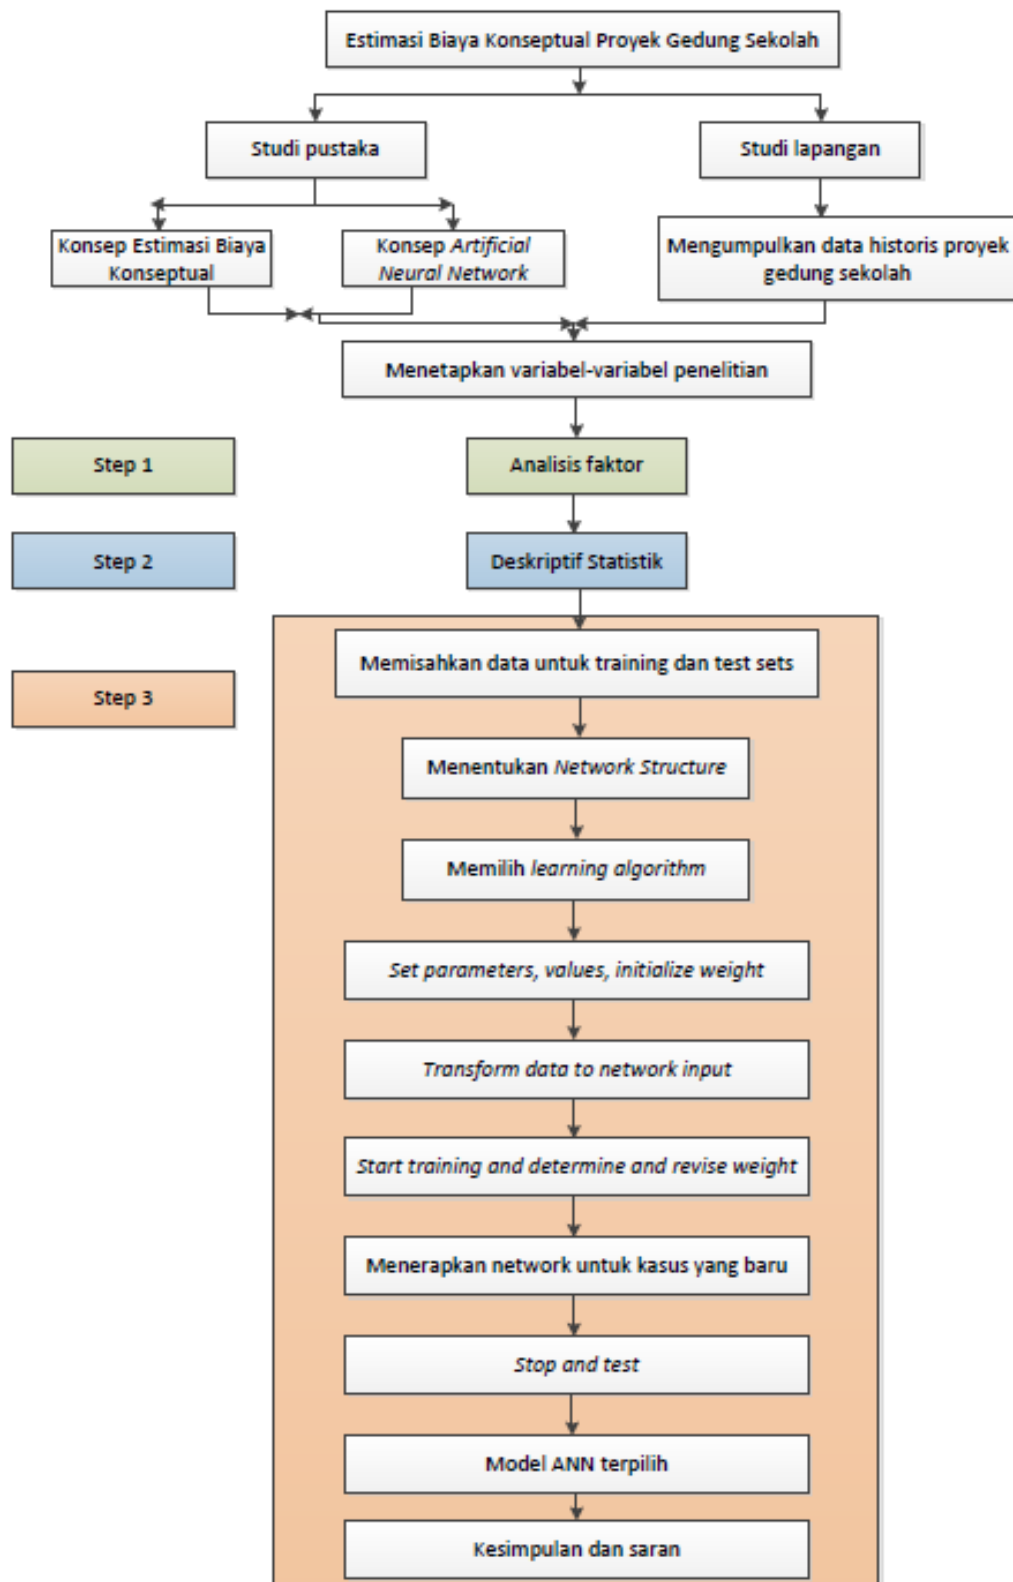
1. Lapis masukan (*input layer*) terdiri dari neuron yang menerima data masukan dari variabel X. Semua neuron pada lapis ini dapat terhubung ke neuron pada lapisan tersembunyi atau langsung ke lapisan luaran jika jaringan tidak menggunakan lapisan tersembunyi.
2. Lapisan tersembunyi (*hidden layer*) terdiri dari neuron yang menerima data dari lapisan masukan.
3. Lapisan luaran (*output layer*) terdiri dari neuron yang menerima data dari lapisan tersembunyi atau langsung dari lapisan masukan yang nilai luarannya melambungkan hasil kalkulasi dari X menjadi nilai Y.

Sementara itu, secara umum, ada tiga macam arsitektur *Artificial Neural Network* yang sering digunakan, yaitu (Haykin, 1999):

1. *Single Layer Feedforward Networks* (Lapisan Tunggal)
Jaringan dengan lapisan tunggal hanya memiliki satu lapisan dengan bobot-bobot terhubung. Jaringan ini hanya menerima *input* kemudian secara langsung akan mengolahnya menjadi *output* tanpa harus melalui *hidden layer* dan tidak berlaku sebaliknya. Dengan kata lain, ciri-ciri dari arsitektur *Artificial Neural Network* dengan lapisan tunggal adalah hanya terdiri dari satu lapisan *input* dan satu lapisan *output*, tanpa *hidden layer* dan bergerak dari lapisan *input* ke *output* (*feedforward*).
2. *Multilayer Feedforward Networks* (Lapisan Jamak)
Jaringan dengan banyak lapisan memiliki satu atau lebih lapisan yang terletak di antara lapisan *input* dan lapisan *output* (memiliki satu atau lebih *hidden layer*). Umumnya, ada lapisan bobot-bobot yang terletak antara dua lapisan yang bersebelahan. Jaringan dengan banyak lapisan ini dapat menyelesaikan permasalahan yang lebih sulit daripada lapisan dengan lapisan tunggal, tentu saja dengan pembelajaran yang lebih rumit.
3. *Recurrent Network*
Jaringan mempunyai arsitektur berbeda dimana neuron saling dihubungkan dan sekurang-kurangnya memiliki satu *feedback loop*.

2. METODE PENELITIAN

Proses penelitian dalam penelitian ini dapat digambarkan melalui alur penelitian seperti Gambar 1. berikut ini.



Gambar 1. Alur Penelitian

Pengolahan data dilakukan dalam tiga tahap. Tahap pertama adalah dengan analisis factor, yang bertujuan untuk mereduksi variabel-variabel yang tidak ada hubungan. Tahap kedua

dengan deskriptif statistic yang bertujuan untuk mengetahui apakah ada *outlier* pada data yang dikumpulkan. Tahap pertama dan kedua dilakukan dengan menggunakan *software* SPSS. Setelah itu tahap ketiga adalah membuat model *Artificial Neural Network* (ANN) dengan menggunakan *software* Matlab.

3. HASIL DAN PEMBAHASAN

Profil dari proyek yang digunakan dalam penelitian ini dapat dilihat pada Tabel 2.

Tabel 2. Profil Proyek

Proyek	Lokasi	Luas Bangunan (m ²)	Jumlah Lantai
A	Bintaro	6042,2	5
B	Bintaro	54471,1	4
C	Cipinang	4321,74	3
D	Harapan Indah	9488,61	4
E	Harapan Indah	2162	5
F	Harapan Indah	2256,4	5
G	Harapan Indah	5094,03	3
H	Harapan Indah	8545,11	3
I	Cibubur	66528,5	9
J	Pembangunan	6018,12	6
K	Pantai Indah Kapuk	6954,784	6
L	Samanhudi	3870,08	4
M	Bekasi	50000	9
N	Muara Karang	8770	5
O	Mangga Besar	1841,722	4

Hasil data proyek yang akan digunakan pada penelitian ini dapat dilihat pada Tabel 3.

Tabel 3. Data Proyek yang Digunakan untuk Penelitian

Proyek	X1	X2	X3	X4	X5	X6	X7	X8	X9	Y
A	6042,2	5	6715,09	123	75	2	2	1	8,39	26.56
B	54471,1	4	6094,73	125	94	1	2	0	8,85	22.49
C	4321,74	3	2986,1	66	74	1	2	0	2,78	14.561
D	9488,61	4	7827,83	141	275	2	1	1	8,36	79.065
E	2162	5	1397,92	90	92	2	1	0	8,36	7.62
F	2256,4	5	1059,51	24	124	2	1	0	8,36	8.573
G	5094,03	3	2600,93	104	151	1	2	0	6,59	13.87
H	8545,11	3	1300,25	151	220	1	2	0	6,59	18.849
I	66528,5	9	34278,1	588	310	2	1	8	4,3	205.285
J	6018,12	6	6350,24	259	163	1	1	0	6,96	14.15
K	6954,784	6	5863,88	140	160	2	2	0	6,6	24.575
L	3870,08	4	4784,73	141	79	1	1	0	6,59	12.687
M	50000	9	31173,72	468	1178	2	1	4	8,36	238.69
N	8770	5	9188	196	256	2	2	1	6,96	30.35
O	1841,722	4	1085,53	39	42	2	2	1	8,36	15.754

Keterangan:

1. X1 = Luas bangunan (dalam m²)
2. X2 = Jumlah lantai tipikal (dalam lantai)
3. X3 = Luas dinding (dalam m²)
4. X4 = Jumlah pintu (dalam unit)
5. X5 = Jumlah jendela (dalam unit)
6. X6 = Kualitas dari *finishing* (1 = sederhana, 2 = tidak sederhana, 3 = khusus)
7. X7 = Jenis pondasi (1 = *bor pile*, 2= pancang)
8. X8 = Jumlah elevator (dalam unit)
9. X9 = Inflasi (dalam persen)
10. Y = biaya proyek (dalam milyar rupiah)

Ada beberapa syarat yang harus dipenuhi dalam uji analisis faktor, yaitu nilai *Kaiser-Meyer-Olkin (KMO)* yang harus lebih besar dari 0,5 dan nilai *Measure of Sampling Adequacy (MSA)* untuk tiap-tiap butir harus melebihi angka 0,5 untuk menentukan butir tersebut valid atau tidak. Apabila kedua syarat di atas telah dipenuhi, dapat dilanjutkan dengan *rotated component matrix*. Nilai KMO iterasi 1 dapat dilihat pada Tabel 4.

Tabel 4. Nilai KMO Iterasi 1
KMO and Bartlett's Test

Kaiser-Meyer-Olkin Measure of Sampling Adequacy.		,687
Approx. Chi-Square		146,132
Bartlett's Test of Sphericity	df	36
	Sig.	,000

Dilihat dari tabel di atas, didapat bahwa nilai KMO pada penelitian ini adalah 0,687 dan sudah lebih besar dari 0,5 sehingga sudah memenuhi syarat. Selanjutnya untuk nilai MSA tiap-tiap butir, dapat dilihat pada tabel 5.

Tabel 5. Hasil Penilaian *Anti-Image Matric* Iterasi 1

Variabel	Deskripsi	MSA	Validitas
X1	Luas bangunan	0,715	Valid
X2	Jumlah lantai tipikal	0,711	Valid
X3	Luas dinding	0,864	Valid
X4	Jumlah pintu	0,872	Valid
X5	Jumlah jendela	0,530	Valid
X6	Kualitas dari <i>finishing</i>	0,335	Tidak valid
X7	Jenis pondasi	0,858	Valid
X8	Jumlah elevator	0,612	Valid
X9	Inflasi	0,535	Valid

Dapat terlihat dari hasil penilaian *Anti-image matric* di atas, ada satu butir yang tidak valid, yaitu butir X6 dengan nilai MSA 0,335, oleh karena itu butir X6 akan direduksi, dan dilakukan pengecekan ulang. Faktor kualitas dari *finishing* kurang berpengaruh terhadap biaya dari proyek tersebut, dikarenakan proyek sekolah pada data yang dikumpulkan ini umumnya kualitas *finishing*nya tipikal, tidak terlalu beda jauh antara satu sekolah dengan sekolah lainnya. Sehingga kualitas dari *finishing* untuk proyek gedung sekolah tidak terlalu berpengaruh pada biaya dari proyek. Nilai KMO iterasi 2 dapat dilihat pada Tabel 6.

Tabel 6. Nilai KMO Iterasi 2
KMO and Bartlett's Test

Kaiser-Meyer-Olkin Measure of Sampling Adequacy.		,755
	Approx. Chi-Square	132,498
Bartlett's Test of Sphericity	df	28
	Sig.	,000

Dari Tabel 6. terlihat bahwa nilai KMO adalah 0,755 dan sudah lebih besar dari 0,5 sehingga sudah memenuhi syarat. Untuk nilai MSA dapat dilihat pada Tabel 7.

Tabel 7. Hasil Penilaian *Anti-Image Matric* Iterasi 2

Variabel	Deskripsi	MSA	Validitas
X1	Luas bangunan	0,746	Valid
X2	Jumlah lantai tipikal	0,919	Valid
X3	Luas dinding	0,846	Valid
X4	Jumlah pintu	0,840	Valid
X5	Jumlah jendela	0,579	Valid
X7	Jenis pondasi	0,866	Valid
X8	Jumlah elevator	0,674	Valid
X9	Inflasi	0,288	Tidak valid

Hasil penilaian *Anti-image matric* di atas, terdapat satu butir yang tidak valid, yaitu butir X9 dengan nilai MSA 0,288, oleh karena itu butir X9 akan direduksi, dan dilakukan pengecekan ulang. Faktor inflasi kurang berpengaruh terhadap biaya dari proyek tersebut, dikarenakan proyek sekolah pada data yang dikumpulkan ini umumnya inflasinya tidak berbeda jauh antara satu proyek sekolah dengan proyek sekolah lainnya. Sehingga inflasi untuk proyek gedung sekolah tidak terlalu berpengaruh pada biaya dari proyek. Nilai KMO iterasi 3 dapat dilihat pada Tabel 8.

Tabel 8. Nilai KMO Iterasi 3
KMO and Bartlett's Test

Kaiser-Meyer-Olkin Measure of Sampling Adequacy.		,781
	Approx. Chi-Square	129,649
Bartlett's Test of Sphericity	df	21
	Sig.	,000

Tabel 8. memperlihatkan nilai KMO sebesar 0,781 dan sudah lebih besar dari 0,5 sehingga sudah memenuhi syarat. Selanjutnya untuk nilai MSA dapat dilihat pada Tabel 9.

Tabel 9. Hasil Penilaian *Anti-Image Matric* Iterasi 3

Variabel	Deskripsi	MSA	Validitas
X1	Luas bangunan	0,779	Valid
X2	Jumlah lantai tipikal	0,920	Valid
X3	Luas dinding	0,834	Valid
X4	Jumlah pintu	0,812	Valid
X5	Jumlah jendela	0,623	Valid
X7	Jenis pondasi	0,843	Valid
X8	Jumlah elevator	0,696	Valid

Terlihat bahwa semua butir valid dengan nilai KMO berada di atas 0,5, maka variabel-variabel itu dapat diproses lebih lanjut dengan *descriptive statistic* dan permodelan *Artificial Neural Network*. Langkah selanjutnya adalah dengan mencari *outlier* pada data yang didapatkan. Data untuk *multivariate* dapat dilihat dari nilai *leverage* atau nilai probabilitas mahalanobis. Jika nilai probabilitas mahalanobis kurang dari 0,001 maka data tersebut adalah *outlier*. Nilai probabilitas mahalanobis dapat dilihat pada tabel 10.

Tabel 10. Nilai Probabilitas Mahalanobis

Proyek	Nilai Mahalanobis	Probabilitas Mahalanobis	Keterangan
A	12,97421	0,07274	Bukan <i>outlier</i>
B	12,40383	0,08804	Bukan <i>outlier</i>
C	9,53148	0,21671	Bukan <i>outlier</i>
D	9,09878	0,24564	Bukan <i>outlier</i>
E	7,43215	0,38531	Bukan <i>outlier</i>
F	6,99985	0,42890	Bukan <i>outlier</i>
G	6,93099	0,43610	Bukan <i>outlier</i>
H	5,64845	0,58134	Bukan <i>outlier</i>
I	5,02978	0,65633	Bukan <i>outlier</i>
J	4,50196	0,72048	Bukan <i>outlier</i>
K	4,45042	0,72668	Bukan <i>outlier</i>
L	3,75249	0,80780	Bukan <i>outlier</i>
M	3,42978	0,84261	Bukan <i>outlier</i>
N	3,37319	0,84847	Bukan <i>outlier</i>
O	2,44264	0,93135	Bukan <i>outlier</i>

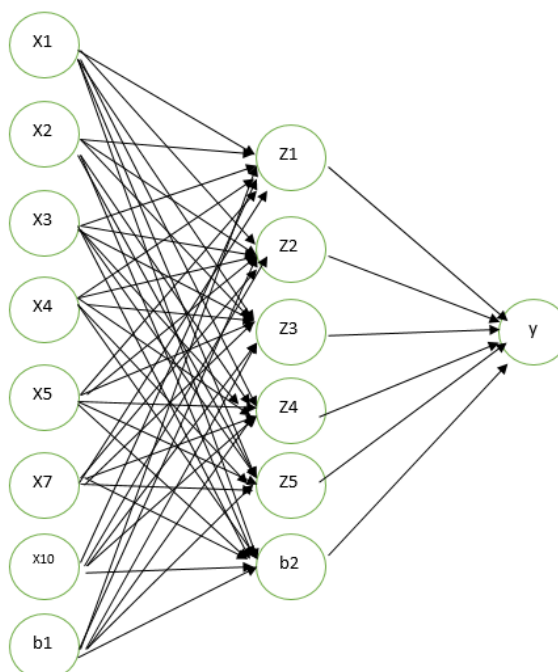
Dari Tabel 10 dapat dilihat bahwa tidak ada *outlier* pada data yang didapatkan. Data yang diperoleh ini diproses lebih lanjut untuk dibuatkan permodelan *Artificial Neural Network*. Untuk membuat permodelan *Artificial Neural Network*, langkah yang dilakukan adalah menormalisasi data. Data normalisasi *input* dan *output* pelatihan *Artificial Neural Network* dapat dilihat pada Tabel 11.

Tabel 11. Data Normalisasi *Input* dan *Output* Pelatihan *Artificial Neural Network*

Proyek	X1	X2	X3	X4	X5	X7	X9	Y
A	-0,87013	-0,3333	-0,65945	-0,6489	-0,9419	1	-0,75	-0,8361

B	-0,88853	-0,6667	-0,69684	-0,64184	-0,90845	1	-1	-0,8713
C	-0,92332	-1	-0,88401	-0,8511	-0,94366	1	-1	-0,9399
D	-0,7636	-0,6667	-0,5925	-0,58511	-0,5898	-1	-0,75	-0,3816
E	-0,99010	-0,3333	-0,97963	-0,76596	-0,91197	-1	-1	-1
F	-0,98718	-0,3333	-1	-1	-0,85563	-1	-1	-0,99175
G	-0,89944	-1	-0,9072	-0,71631	-0,8081	1	-1	-0,9459
H	-0,79274	-1	-0,98551	-0,54965	-0,6866	1	-1	-0,9028
I	1	1	1	1	-0,52817	-1	1	0,71087
J	-0,87087	0	-0,6815	-0,16667	-0,78697	-1	-1	-0,9435
K	-0,84191	0	-0,71074	-0,58865	-0,7923	1	-1	-0,85325
L	-0,9373	-0,6667	-0,7757	-0,58511	-0,9349	-1	-1	-0,9561
M	0,48897	1	0,81301	0,5745	1	-1	0	1
N	-0,78579	-0,3333	-0,51061	-0,3901	-0,6232	1	-0,75	-0,8033
O	-1	-0,6667	-0,9984	-0,94681	-1	1	-0,75	-0,9296

Data dipisahkan menjadi dua bagian, yaitu untuk dilakukan pelatihan dan pengujian. Data yang digunakan untuk pelatihan sebanyak 12 data, yaitu data C, D, E, F, G, H, I, J, K, L, M, N. Data yang digunakan untuk pengujian sebanyak 3 data, yaitu data A, B, O. Setelah data dipisahkan dan dinormalisasi, barulah data dimasukkan ke *Matlab* untuk dibuatkan model *Artificial Neural Network*. Dari model tersebut diperoleh nilai MSE dan MMRE untuk setiap permodelan, dengan memilih *range* persentase *error* sesuai ketentuan AACE, yaitu yang rendah berada -20% sampai dengan -50% sedangkan yang tinggi berada para +30% sampai +100%, dan memiliki MMRE data tes terkecil. Model *Artificial Neural Network* yang dibuat ini menggunakan 7 variabel, yaitu X1, X2, X3, X4, X5, X7, dan X10. Model arsitektur yang digunakan adalah dengan menggunakan 1 *hidden layer*. Arsitektur jaringan 7-5-1, 1 hidden layer dengan 5 neuron, yaitu dengan MSE sebesar 0,0098 dan MMRE sebesar -0,0002 atau -0,02%. Gambar model arsitektur jaringan 7-5-1 dapat dilihat pada Gambar 2.



Gambar 2. Model Arsitektur Jaringan 7-5-1

Setelah dilakukan pelatihan, didapat bobot (*weight*) akhir dari *input layer* ke *hidden layer* (v_{ij}) (Tabel 12) dan bobot dari *hidden layer* ke *output layer* (w_{ij}) (Tabel 13).

Tabel 12. Bobot dari *Input Layer* ke *Hidden Layer* Model Arsitektur Jaringan 7-5-1

	Z1	Z2	Z3	Z4	Z5
X1	0,60414	-0,3236	-0,5516	-0,4589	-0,2062
X2	-0,5407	1,4562	1,1611	0,17359	-1,3214
X3	-0,6675	-0,4156	0,79171	-1,4655	0,19453
X4	-0,7354	0,30398	0,56713	0,10195	0,50524
X5	-0,0159	-0,4891	0,6032	-0,9993	1,6095
X7	-0,4729	-0,3873	0,3048	0,4858	-1,9325
X10	0,89376	0,9231	-0,2980	-0,2902	0,51682
b1	-1,2006	-0,8545	1,932	-1,221	1,6219

Tabel 13. Bobot dari *Hidden Layer* ke *Output Layer* untuk Model Arsitektur Jaringan 7-5-1

	Y
Z1	-1,9892
Z2	0,83501
Z3	0,1652
Z4	-0,7399
Z5	-1,0391
b2	0,94777

Sedangkan hasil dari model *Artificial Neural Network* dapat dilihat pada Tabel 14.

Tabel 14. Hasil Model *Artificial Neural Network*

Arsitektur	Proyek	Aktual	ANN	MSE	MMRE	MSE Total	MMRE Total
------------	--------	--------	-----	-----	------	-----------	------------

7-1-1	A	-0,836	-0,8091	0,0007	0,0324	0,009	0,091
	B	-0,871	-0,8030	0,00466	0,0783		
	O	-0,930	-0,7786	0,02279	0,1624		
7-2-1	A	-0,836	-0,7901	0,0021	0,0549	0,007	0,0851
	B	-0,871	-0,8031	0,00384	0,0711		
	O	-0,930	-0,8093	0,01448	0,1294		
7-3-1	A	-0,836	-0,8763	0,0016	0,0481	0,0018	-0,002
	B	-0,871	-0,9321	0,00370	-0,0698		
	O	-0,930	-0,9150	0,00021	0,0157		
7-4-1	A	-0,836	-0,9637	0,0163	0,1527	0,009	0,0003
	B	-0,871	-0,9663	0,00902	-0,109		
	O	-0,930	-0,9695	0,00159	-0,0429		
7-5-1	A	-0,836	-0,9687	0,0176	0,1587	0,0098	-0,0002
	B	-0,871	-0,9714	0,01003	-0,115		
	O	-0,930	-0,9708	0,001694	-0,0429		
7-9-1	A	-0,836	-0,760	0,0058	0,09072	0,0067	0,0513
	B	-0,871	-0,919	0,0023	-0,0550		
	O	-0,930	-0,820	0,0121	0,1181		

4. KESIMPULAN

Adapun dari hasil studi ini, dapat disimpulkan beberapa hal, yaitu:

1. Permodelan *Artificial Neural Network* yang terbaik dari penelitian ini adalah dengan arsitektur jaringan 7-5-1 dengan menggunakan algoritma *backpropagation*.
2. Estimasi biaya proyek gedung sekolah dipengaruhi oleh beberapa variabel antara lain adalah luas bangunan, jumlah lantai tipikal, luas dinding, jumlah pintu, jumlah jendela, jenis pondasi, dan jumlah elevator.
3. *Artificial Neural Network* dapat digunakan sebagai salah satu pedoman untuk perencanaan proyek gedung sekolah berikutnya dengan konsep yang sama (sekolah X) dan untuk lokasi yang sama (daerah Jabodetabek).
4. *Artificial Neural Network* dapat digunakan untuk mengestimasi biaya konseptual suatu proyek.

Untuk penelitian lebih lanjut, dapat disarankan:

Pada penelitian estimasi biaya konseptual lebih lanjut, dapat membandingkan hasil dari metode *Artificial Neural Network* dengan metode *Fuzzy*, *Genetic Algorithm*, atau metode lainnya.

5. REFERENCES

- Al-Tawal D.R., Arafah M. and Sweis G.J. (2021). *A Model Utilizing the Artificial Neural Network in Cost Estimation of Construction Projects in Jordan*. Engineering Construction and Architectural Management Vol. 28 No. 9, pp. 2466-2488. <https://doi.org/10.1108/ECAM-06-2020-0402>
- Arafa, M. and Alqedra, M. (2011). *Early Stage Cost Estimation of Buildings Construction Projects using Artificial Neural Networks*. Journal of Artificial Intelligence 4.
- Association for the Advancement of Cost Engineering. (2012). *AACE International Recommended Practice No. 56S-08, Cost Estimate Classification System-as Applied for*

- the Building and General Construction Industries, TCM Framework: 7.3-Cost Estimating and Budgeting*. Morgantown: AACE International.
- Badan Pusat Statistik (2016). *Profil Penduduk Indonesia Hasil Supas 2015*. Badan Pusat Statistik.
- Cheng, M.Y., Hsing, C.T., and Hsieh, W.S. (2009). *Web-based Conceptual Cost Estimates for Construction Projects Using Evolutionary Fuzzy Neural Inference Model*. *Automation in Construction*, Vol. 18.
- Cirilovic, J., Vajdic, N., Mladenovic, G., and Queiroz, C. (2014). *Developing Cost Estimation Models for Road Rehabilitation and Reconstruction: Case Study of Projects in Europe and Central Asia*. *Journal of Construction Engineering & Management*, ASCE 140.
- Emsley, M.W., Lowe, D.J., Duff, A.R., Harding A., and Hickson, A. (2002). *Data Modelling and The Application of a Neural Network Approach to the Prediction of Total Construction Cost*. *Journal of Construction Management and Economics*, Vol. 20.
- Gunaydin, M.H. and Dogan, S.Z. (2004). *A Neural Network Approach for Early Cost Estimation of Structural Systems of Buildings*. *Int. J. Project Manage.*, 22: 595-602.
- Jong, J.S. (2005). *Jaringan Syaraf Tiruan & Pemrogramannya Menggunakan Matlab*. Yogyakarta: Andi Offset. 2005.
- Kim, G.H., Yoon, J.E., An, S.H., Cho, H.H., and Kang, Kl. (2004). *Neural Network Model Incorporating a Genetic Algorithm in Estimating Construction Costs*. *Journal of Building and Environment*, Vol. 39.
- Nia S. B., Taheri M., and Jamalpour R. (2023). *Achieving Realistic Cost Estimates in Building Construction Projects: A Reliability Assessment of Pre-Construction Stage Cost Estimates*. *International Journal of Construction Engineering and Management*, Vol. 12, No. 3, pp. 81-90.
- Oei, F. J., Tampubolon, S. P., & Finella, C. (2023). *Tinjauan Produktivitas Pekerja Pada Dua Proyek Serta Faktor Yang Mempengaruhinya*. *Jurnal Rekayasa Teknik Sipil Dan Lingkungan-CENTECH*, 4(1), 15-24.
- Pettang, C. Mbumbia, L. and Foudjet, A. (1997). *Estimating Building Materials Cost in Urban Housing Construction Projects, based on Matrix Calculation*. *Construct. Build. Mater.*
- Pemerintah Republik Indonesia. *Peraturan Menteri Pekerjaan Umum Nomor 45/PRT/M/2007 Tentang Pedoman Teknis Pembangunan Bangunan Gedung Negara*.
- Putra A. B. dan Setyandito O. (2023). *Analysis of Construction Cost Estimation Ministry Regulation Year 2016 and Year 2022 for Construction Projects*. *Jurnal Sains Teknologi dan Industri*, Vol. 20, No. 2, pp. 611-622.
- Sodikov, Jamshid. (2005). *Cost Estimation of Highway Projects in Developing Countries: Artificial Neural Network Approach*. *Journal of the Eastern Asia Society. Transport Stud.* 6.
- Wang, R., Salleh H., Abdul-Samad Z., Radzuan N.F.M., and Kok C.W. (2024). *Fundamentals of Developing Conceptual Cost Estimation Models Using Machine Learning Techniques: Selection and Measurement of Building Attributes*. *Planning Malaysia: Journal of the Malaysian Institute of Planners*, Vol. 22, No. 3, pp. 242-256.
- Zhang J., Yuan , J., Mahmoudi A., Ji W., and Fang Q. (2024). *A Data-Driven Framework for Conceptual Cost Estimation of Infrastructure Projects Using XGBoost and Bayesian Optimization*. *Journal of Asian Architecture and Building Engineering*, January. <https://doi.org/10.1080/13467581.2023.2294871>