

PREDIKSI RISIKO KETERLAMBATAN PADA PROYEK BANGUNAN TINGGI DI SURABAYA MENGGUNAKAN BERBAGAI METODE *MACHINE LEARNING*

Ambrosius Matthew Junius Reynaldo¹, Nathanael Kenneth Suryawan², dan Willy Husada^{3*}
¹²³ Program Studi Teknik Sipil, Universitas Kristen Petra, Surabaya, Indonesia

¹ matthew.junius@petra.ac.id, ² b11210011@john.petra.ac.id, ^{3*} willy.husada@petra.ac.id

ABSTRAK: Industri konstruksi merupakan kontributor utama pertumbuhan ekonomi suatu negara yang memiliki karakteristik unik karena memiliki banyak variasi bergantung pada karakteristik setiap proyek. Tingginya kompleksitas proyek menyebabkan peningkatan risiko keterlambatan proyek. Penelitian ini melakukan prediksi risiko keterlambatan pada proyek bangunan tinggi di Surabaya dengan metode *Artificial Neural Network (ANN)*, *Support Vector Machine (SVM)*, dan *Classification and Regression Tree (CART)*. Sebanyak 35 data proyek di Surabaya dihimpun melalui penyebaran kuesioner dengan 21 variabel *input* faktor risiko penyebab keterlambatan proyek dan 1 variabel *output* yaitu tingkat keterlambatan proyek. Pembuatan model prediksi dilakukan dengan transformasi data variabel *input* menjadi 3 model yaitu *probability x impact*, matriks risiko 5 zona, dan matriks risiko 3 zona. Proses evaluasi metode prediksi dilakukan dengan 7 parameter evaluasi. Hasil penelitian menunjukkan bahwa metode ANN dengan kombinasi model 2 memiliki kinerja terbaik dibandingkan dengan kedua metode prediksi lainnya yang menghasilkan tingkat akurasi 100% dalam melakukan klasifikasi tingkat keterlambatan proyek.

Kata kunci: keterlambatan proyek, prediksi risiko keterlambatan, *machine learning*

ABSTRACT: *The construction industry is a major contributor to the country's economic growth and has unique characteristics due to variations in individual project conditions. The high complexity of construction projects increases the risk of project delays. This study predicts the project delay risks in high-rise building projects in Surabaya using the Artificial Neural Network (ANN), Support Vector Machine (SVM), and Classification and Regression Tree (CART) method. A total of 35 project datasets were collected through questionnaires, including 21 input variables representing the delay risk factors and one output variable indicating the delay level. The input variables were transformed into three modeling approaches: probability x impact, a 5-zone risk matrix, and a 3-zone risk matrix. The model performance was evaluated using seven parameters. The results show that ANN method with the second model combination achieved the best performance compared to other methods, achieving 100% accuracy in classifying the level of project delays.*

Keywords: project delays, delay risk prediction, machine learning

1. PENDAHULUAN

Industri konstruksi merupakan salah satu kontributor utama dalam pembangunan infrastruktur dan pertumbuhan ekonomi suatu negara (Xue & Zhang, 2018; Santoso & Gallage, 2020). Baik pada negara berkembang maupun negara maju, industri konstruksi berperan penting dalam mewujudkan pembangunan sosial-ekonomi yang berkelanjutan dan mendukung kesejahteraan masyarakat. Berbeda dengan industri lainnya, industri konstruksi memiliki karakteristik unik yang berasal dari struktur individual masing-masing proyek, meliputi kategori proyek, ruang lingkup pekerjaan, lokasi geografis, serta komposisi dan karakteristik tenaga kerja yang terlibat (Fashina et al., 2021). Keterlambatan proyek merupakan fenomena global

yang dihadapi oleh industri konstruksi, karena tingginya kompleksitas karakteristik proyek serta adanya hubungan saling ketergantungan antar berbagai faktor risiko penyebab keterlambatan (Gondia et al., 2020; Yaseen et al., 2020; Shirazi & Toosi, 2023). Sebuah proyek konstruksi dapat dinyatakan berhasil apabila selesai tepat waktu, tepat biaya, dan mencapai target kualitas yang ditetapkan (Al-Zwainy & Hadhal, 2015). Keterlambatan proyek berdampak pada seluruh pemangku kepentingan secara berbeda, seperti terhadap pemilik dan kontraktor serta relatif kecil terhadap konsultan sehingga sering dianggap sebagai pihak yang paling minim terdampak (Aziz & Abdel-Hakam, 2016). Dampak negatif dari keterlambatan proyek dapat meliputi sengketa hukum, pembengkakan biaya dan waktu pelaksanaan proyek, penurunan produktivitas dan pendapatan, serta potensi terjadinya pemutusan kontrak kerja (Sambasivan & Soon, 2007).

Secara umum, keterlambatan proyek konstruksi dapat disebabkan oleh berbagai faktor internal dan eksternal. Penelitian Alotaibi et al. (2015) menyebutkan ada lima faktor utama yang berpengaruh terhadap keterlambatan suatu proyek konstruksi yaitu lambatnya pengambilan keputusan, perbedaan spesifikasi dan gambar, banyaknya *change order* selama proses konstruksi, keterlambatan dalam penyelesaian gambar kontraktor, dan target waktu proyek yang tidak masuk akal. Penelitian lain oleh Al Kharashi & Skitmore (2009) menyebutkan 6 kelompok utama penyebab keterlambatan proyek konstruksi yaitu faktor yang berkaitan dengan klien, kontraktor, konsultan, material, tenaga kerja, dan peralatan. Berbagai faktor penyebab keterlambatan di atas dapat digunakan untuk melakukan prediksi risiko keterlambatan pada proyek konstruksi. Dalam beberapa tahun terakhir, metode *machine learning* telah banyak digunakan dalam berbagai disiplin ilmu sebagai alat prediksi, termasuk bidang teknik sipil. *Machine learning* telah digunakan untuk memprediksi biaya konstruksi pada fase awal proyek (Castro Miranda et al., 2022; Al-Gahtani et al., 2025; Padala & Goyal, 2025), memprediksi harga properti (Hoxha, 2025; Husada et al., 2025), memprediksi kuat tekan beton (Cheng et al., 2014; Shariati et al., 2020), dan berbagai studi kasus lainnya.

Penelitian sebelumnya tentang prediksi risiko keterlambatan proyek telah dilakukan oleh Gondia et al. (2020) dengan menggunakan metode *decision tree* dan *Bayesian classification algorithm*. Hasil penelitian menunjukkan bahwa performa *naïve Bayesian* lebih baik dibandingkan dengan *decision tree*. Selanjutnya, Yaseen et al. (2020) menggunakan metode *random forest* (RF) dan *random forest* dengan optimasi *genetic algorithm* (RF-GA) untuk memprediksi risiko keterlambatan proyek. Hasil penelitian menunjukkan bahwa integrasi metode RF-GA memperoleh performa terbaik berdasarkan perhitungan akurasi, *classification error*, dan *kappa statistic*. Penelitian terbaru dilakukan oleh Sanni-Anibire et al. (2022) yang mengembangkan model *machine learning* menggunakan *k-nearest neighbor* (KNN), *artificial neural network* (ANN), *support vector machine* (SVM), dan *ensemble method*. Hasil penelitian menunjukkan bahwa metode ANN berhasil memperoleh tingkat akurasi prediksi tertinggi sebesar 93,75%. Pada penelitian ini, risiko keterlambatan proyek pada bangunan tinggi di Kota Surabaya akan diprediksi dengan menggunakan metode *machine learning*. Metode yang digunakan meliputi metode ANN, SVM, dan *classification and regression tree* (CART) dimana ketiga metode *machine learning* tersebut paling populer digunakan. Proyek bangunan tinggi dipilih karena kompleksitasnya yang tinggi sehingga rentan terhadap masalah kinerja buruk. Hasil dari model prediksi akan dievaluasi dengan melihat akurasi yang dihasilkan untuk menentukan model *machine learning* yang terbaik.

2. KERANGKA TEORITIS

2.1. Definisi dan Jenis Keterlambatan Proyek

Keterlambatan proyek dapat didefinisikan sebagai ketidakmampuan untuk menyelesaikan sebuah proyek sesuai dengan waktu yang telah dijadwalkan. Dalam industri konstruksi, keterlambatan dapat diartikan sebagai *time overrun* yaitu penyelesaian proyek yang melampaui batas waktu yang ditetapkan dalam kontrak atau yang telah disepakati oleh para pihak terlibat untuk penyerahan proyek (Assaf & Al-Hejji, 2006). Keterlambatan proyek dikategorikan sebagai hambatan keberhasilan sebuah proyek konstruksi bahkan kegagalan (Agyekum-Mensah & Knight, 2017; Tariq & Gardezi, 2023). Dampak umum dari keterlambatan meliputi penyelesaian proyek yang terlambat, peningkatan biaya, terganggunya pelaksanaan pekerjaan, penurunan produktivitas, timbulnya sengketa, dan penghentian atau pemutusan kontrak (Abbasi et al., 2020). Menurut Nagata et al. (2018), keterlambatan proyek dapat dibagi menjadi:

- a. *Critical or Non-Critical Delay*: Keterlambatan kritis merupakan keterlambatan pekerjaan yang mempengaruhi waktu penyelesaian sebuah proyek karena terjadi pada aktivitas kritis. Sebaliknya, keterlambatan non-kritis merupakan keterlambatan pekerjaan yang tidak mempengaruhi waktu penyelesaian sebuah proyek karena terjadi pada aktivitas non-kritis.
- b. *Excusable or Non-Excusable Delay*: Keterlambatan yang terjadi di luar kendali kontraktor (*excusable delay*) meliputi pemogokan kerja, kebakaran, banjir, cuaca buruk, intervensi dari lembaga luar, perubahan oleh *owner* dan lain-lain. Sebaliknya, keterlambatan yang terjadi dalam kendali kontraktor (*non-excusable delay*) meliputi keterlambatan kinerja subkontraktor, kinerja *supplier* yang buruk, kesalahan pengerjaan oleh kontraktor atau subkontraktor, dan lain-lain.
- c. *Compensable or Non-Compensable Delay*: Keterlambatan yang dapat dikompensasi adalah penundaan yang menjadi hak kontraktor baik perpanjangan waktu penyelesaian maupun kompensasi dana terkait penundaan. Sebaliknya, keterlambatan tanpa kompensasi berarti kontraktor tidak berhak atas kompensasi dana akibat keterlambatan yang terjadi.

2.2. Penyebab Keterlambatan Proyek

Keterlambatan proyek konstruksi tidak terlepas dari faktor internal dan eksternal. Sweis et al. (2008) menyimpulkan bahwa keterlambatan dapat dibagi menjadi 3 kelompok berdasarkan pihak-pihak yang terlibat yaitu faktor masukan (*input factors*) meliputi pekerja, material, dan peralatan, faktor lingkungan internal meliputi kontraktor, pemilik, dan konsultan, serta faktor eksternal meliputi cuaca, dan peraturan pemerintah. Studi oleh Durdyev & Hosseini (2020) merangkumkan dari 149 penyebab keterlambatan menjadi 10 penyebab paling banyak terjadi meliputi kondisi cuaca, komunikasi yang buruk dan kurangnya koordinasi antar pemangku kepentingan, perencanaan yang tidak efektif, kekurangan material, masalah keuangan, keterlambatan pembayaran, kekurangan peralatan, kurangnya pengalaman/kualifikasi antar pemangku kepentingan, kekurangan tenaga kerja, dan manajemen lapangan yang buruk. Dari berbagai sumber literatur, penelitian ini menggunakan 21 variabel faktor penyebab keterlambatan proyek yang disajikan dalam Tabel 1. Faktor-faktor tersebut dikategorikan menjadi faktor masukan, faktor lingkungan internal, dan faktor eksternal.

Tabel 1. Faktor penyebab keterlambatan proyek

Faktor	Penyebab Keterlambatan	Sweis et al. (2008)	Al Kharashi & Skitmore (2009)	Alotaibi et al. (2015)	Durdyev & Hosseini (2020)
<i>Input</i> (Pekerja)	Kurangnya jumlah tenaga kerja Kurangnya tenaga kerja ahli				
<i>Input</i> (Material)	Keterlambatan pengiriman material Harga material yang fluktuatif Penggantian mutu material				
<i>Input</i> (Peralatan)	Kurangnya jumlah peralatan Banyak peralatan yang rusak				
Lingkungan Internal (Kontraktor)	Buruknya penjadwalan proyek Sistem kontrol kualitas yang kurang efektif Keterlambatan pembayaran subkontraktor Buruknya koordinasi antar bagian Kurangnya kompetensi staf yang ada di proyek				
Lingkungan Internal (Pemilik)	Banyaknya <i>change order</i> Keterlambatan persiapan lahan proyek Lambatnya pengambilan keputusan Keterlambatan pembayaran kontraktor				
Lingkungan Internal (Konsultan)	Ambiguitas dan kesalahan spesifikasi pada gambar Kurangnya koordinasi konsultan dengan pihak terkait				
Eksternal (Cuaca)	Cuaca buruk pada proyek konstruksi				
Eksternal (Peraturan pemerintah)	Hambatan dalam penerbitan izin kerja Perubahan peraturan pemerintah dan hukum				

2.3. Risiko dalam Proyek Konstruksi

Risiko dapat diartikan sebagai keadaan tak pasti yang apabila terjadi dapat menimbulkan efek positif dan negatif terhadap satu atau beberapa tujuan (Project Management Institute, 2021). Risiko juga dapat diartikan sebagai dampak dari ketidakpastian yang dimiliki oleh sebuah organisasi (Joint Australia New Zealand International Standard, 2009). Terdapat dua dimensi risiko, yaitu *probability* dan *impact* yang digunakan untuk menentukan signifikansi risiko (Hillson & Hullet, 2004). Dimensi *probability* mengukur seberapa besar kemungkinan risiko tersebut terjadi dan dimensi *impact* mengukur seberapa besar dampak yang ditimbulkan bila risiko tersebut terjadi. Gambar 1 menunjukkan matriks risiko standar yang digunakan untuk menentukan zona risiko berdasarkan faktor risiko yang teridentifikasi. Matriks berukuran 5x5 tersebut memiliki *impact* dan *probability range* dari sangat rendah hingga sangat tinggi dengan kelima zona dijelaskan sebagai berikut:

- a. Zona merah tua: Faktor risiko pada zona ini sangat tinggi sehingga perlu dihindari. Zona ini merupakan prioritas utama dan harus diberi perhatian lebih.
- b. Zona merah: Faktor risiko pada zona ini tinggi dan harus dihindari serta dimitigasi.
- c. Zona kuning: Faktor risiko pada zona kuning cukup tinggi dan harus dikendalikan.
- d. Zona hijau tua: Faktor risiko pada zona hijau tua dianggap memiliki dampak rendah tetapi harus tetap dipantau dan/atau dikendalikan.
- e. Zona hijau muda: Faktor risiko di zona ini memiliki dampak yang paling rendah, sehingga cukup dipantau atau bahkan diabaikan.

		<i>Risk Matrix</i>				
<i>Probability Rating</i>	5-Very High	VL,VH	L,VH	M,VH	H,VH	VH,VH
	4-High	VL,H	L,H	M,H	H,H	VH,H
	3-Moderate	VL,M	L,M	M,M	H,M	VH,M
	2-Low	VL,L	L,L	M,L	H,L	VH,L
	1-Very Low	VL,VL	L,VL	M,VL	H,VL	VH,VL
		1	2	3	4	5
		<i>Very Low</i>	<i>Low</i>	<i>Moderate</i>	<i>High</i>	<i>Very High</i>
		<i>Impact Rating</i>				

Gambar 1. *Probability-impact matrix* (Sumber: Kassem et al., 2020)

2.4. Metode Prediksi

2.4.1. Artificial Neural Network (ANN)

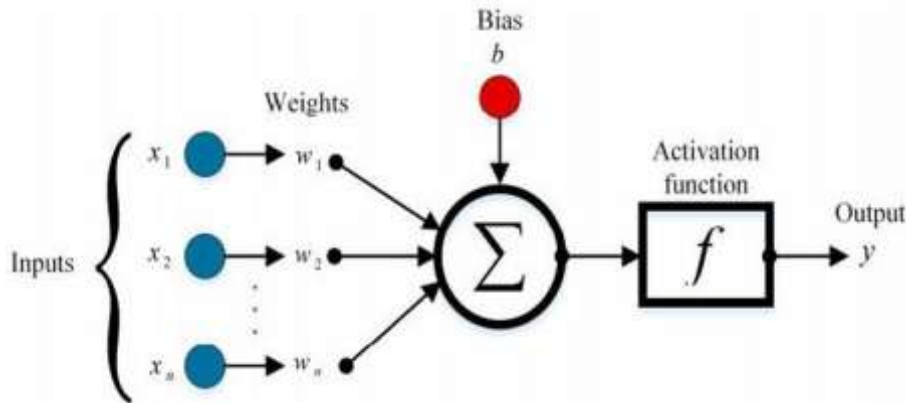
Metode *Artificial Neural Network* (ANN) dikembangkan oleh Rosenblatt pada tahun 1958 dan bekerja dengan mensimulasikan data sebagai jaringan saraf yang ada di otak untuk memproses semua informasi yang diperoleh (Wu & Feng, 2018). ANN juga sering disebut *multilayer perceptron* (MLP) yang memiliki tiga lapisan, yaitu *input layer*, *hidden layer*, dan *output layer* (Yoon et al., 2011). *Input layer* memiliki kegunaan untuk menerima semua informasi atau data yang ada dan mengirimnya ke *hidden layer* untuk diolah dengan nilai bobot. *Output layer* merupakan hasil terakhir dari perhitungan yang telah dilakukan. Ilustrasi dari metode prediksi ANN dapat dilihat pada Gambar 2. Neuron aktif yang terdapat pada *hidden layer* dapat digambarkan pada Persamaan 1 dan 2.

$$= \quad + \quad (1)$$

$$= () \quad (2)$$

di mana:

- a_j : Nilai aktivitas neuron
- w_{ij} : Pembobotan antara neuron i dan j
- x_i : Nilai *input*
- y_j : Nilai *output*
- b_j : Nilai bias untuk neuron j
- $f(\cdot)$: Fungsi transfer



Gambar 2. Ilustrasi grafis dari struktur ANN (Sumber: Ali & Abd, 2021)

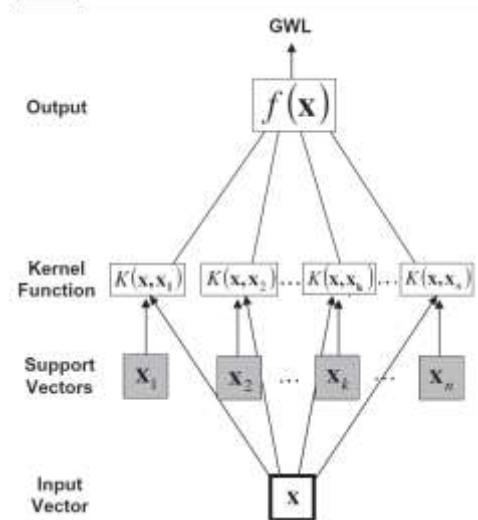
2.4.2. Support Vector Machine (SVM)

Metode *Support Vector Machine* (SVM) merupakan metode yang dikembangkan oleh Vapnik pada tahun 1995 (Vapnik, 1995). Metode ini dapat diklasifikasikan sebagai model dengan target klasifikasi biner yang memiliki dua nilai (misalnya 0 dan 1), atau sebagai model dengan target regresi yang menghasilkan nilai kontinu berupa bilangan riil (Chou et al., 2014). Vektor *input* yang mendukung struktur model dipilih melalui proses *training*, yaitu dari sekumpulan sampel berukuran n yang memenuhi $\{x_i, y_i\}_{i=1}^n$, dan selanjutnya fungsi estimasi SVM untuk regresi dapat dijelaskan dengan Persamaan 3 (Yoon et al., 2011). Alur pemodelan SVM dapat dilihat pada Gambar 3.

$$f(x) = \sum_{i=1}^n w_i x_i + b \quad (3)$$

di mana:


- x : Vektor *input* dari komponen
- y : Nilai *output*
- w : *Weight factor*
- b : Bias
- f : Fungsi transfer non-linier



Gambar 3. Ilustrasi Grafis Pemodelan SVM (Sumber: Yoon et al., 2011)

2.4.3. Classification and Regression Tree (CART)

Metode *Classification and Regression Tree* (CART) merupakan metode *machine learning* yang digunakan untuk membangun model prediksi berdasar data. Metode CART ini dapat membentuk pohon klasifikasi atau pohon regresi bergantung jenis variabel yang digunakan (Chou et al., 2014). Metode CART pertama kali diperkenalkan oleh Breiman dan menunjukkan bahwa proses pembelajaran pada pohon keputusan dapat dioptimalkan dengan menggunakan model untuk memangkas pohon yang telah jenuh dan memilih model terbaik dari pohon-pohon yang tersisa (Grajski et al., 1986). Gambar 4 menunjukkan ilustrasi dari pohon klasifikasi. Analisis metode CART menggunakan partisi rekursif yang ditunjukkan pada setiap simpul T dan mewakili sel partisi. Simpul terminal ditunjukkan pada huruf A, B, dan C yang biasa disebut dengan daun menunjukkan bahwa setelah pemisahan ini, pemisahan data selanjutnya tidak cukup untuk menjelaskan varians dalam menggambarkan hasil prediksi (Morgan, 2014).



Gambar 4. Ilustrasi Grafis dari Struktur CART (Sumber: Morgan, 2014)

Proses pemodelan metode CART meliputi tiga tahapan yaitu penentuan metode pemilah, penentuan simpul terminal, dan pemangkasan pohon. Pada tahapan penentuan metode pemilah, metode pemilah yang sering digunakan adalah indeks Gini (*Gini Index*) dan dapat dilihat pada Persamaan 4. Tahapan selanjutnya adalah proses penentuan simpul terminal, yang merupakan simpul dengan tidak adanya penurunan heterogenitas. Hal ini berarti pada simpul terminal hanya terdapat satu nilai pengamatan pada setiap simpul anak. Proses penandaan simpul terminal dilakukan berdasarkan aturan jumlah anggota kelas terbanyak sesuai Persamaan 5. Tahapan terakhir adalah pemangkasan pohon yang bertujuan untuk mencegah pembentukan pohon yang terlalu besar dan kompleks. Proses ini dilakukan berdasarkan *cost complexity pruning* sesuai dengan Persamaan 6.

$$G(\mathcal{S}) = G(\mathcal{S}_L) + G(\mathcal{S}_R) \quad (4)$$

$$G(\mathcal{S}) = G(\mathcal{S}) = \frac{G(\mathcal{S})}{G(\mathcal{S})} \quad (5)$$

$$G(\mathcal{S}) = G(\mathcal{S}) + \lambda |T| \quad (6)$$

di mana:

- $G(\mathcal{S})$: Fungsi heterogenitas indeks Gini
- $G(\mathcal{S}_L)$: Proporsi kelas pada simpul
- $G(\mathcal{S}_R)$: Proporsi kelas pada simpul
- $G(\mathcal{S})$: Jumlah pengamatan yang dilakukan di kelas pada simpul
- $G(\mathcal{S})$: Jumlah pengamatan yang dilakukan pada simpul
- $G(\mathcal{S})$: *Resubstitution* suatu pohon T pada kompleksitas
- $G(\mathcal{S})$: *Resubstitution estimate* bagi
- $G(\mathcal{S})$: *Parameter-cost complexity* dari satu simpul akhir pada pohon

2.5. Evaluasi Metode Prediksi

Pada penelitian ini, metode prediksi akan dievaluasi dengan tujuh parameter untuk mengevaluasi kinerja dari metode prediksi yang digunakan. Performa kelas diukur berdasarkan nilai *precision*, *sensitivity*, *negative predictive value*, dan *specificity*, sedangkan performa rata-rata dari model prediksi diukur berdasarkan nilai *accuracy*, *classification error*, dan *kappa statistic*. Rumusan dari parameter penilaian yang digunakan dapat dilihat pada Persamaan 7 sampai 14. Performa dari model prediksi akan terlihat melalui *confusion matrix* yang berisi informasi tentang klasifikasi aktual dan klasifikasi prediksi oleh sistem klasifikasi (Deng et al., 2016). Matriks ini terdiri dari atas dua dimensi yaitu bagian kolom yang menunjukkan *output* sesungguhnya dari masing-masing klasifikasi dan bagian baris yang menunjukkan hasil prediksi *output* dari masing-masing klasifikasi. Bentuk *confusion matrix* ditunjukkan pada Gambar 5.

- a. *Precision* digunakan untuk menunjukkan seberapa baik metode prediksi dalam memprediksi nilai *true positive*

$$= \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (7)$$

- b. *Negative predictive value* digunakan untuk menunjukkan seberapa baik metode prediksi dalam memprediksi nilai *true negative*

$$= \frac{\text{TN}}{\text{TN} + \text{FN}} \quad (8)$$

- c. *Sensitivity* digunakan untuk mengukur proporsi nilai *true positive* yang berhasil dideteksi oleh model prediksi

$$= \frac{\quad}{\quad + \quad} \tag{9}$$

d. *Specificity* digunakan untuk mengukur proporsi nilai *true negative* yang berhasil dideteksi oleh model prediksi

$$= \frac{\quad}{\quad + \quad} \tag{10}$$

e. *Accuracy* digunakan untuk melakukan perbandingan jumlah yang diprediksi benar dengan total keseluruhan prediksi yang dilakukan

$$= \frac{\quad + \quad}{\quad + \quad + \quad} \tag{11}$$

f. *Classification error* merupakan kebalikan dari akurasi yang berarti jumlah prediksi yang salah dibandingkan dengan total keseluruhan prediksi

$$= 1 - \tag{12}$$

g. *Kappa statistic* digunakan untuk mengukur konsistensi antara data aktual dengan data hasil prediksi dalam mengklasifikasikan sebuah data

$$= \frac{\quad + \quad - \quad}{1 - \quad} \tag{13}$$

$$= \left(\frac{\quad + \quad}{\quad} \right) \left(\frac{\quad + \quad}{\quad} \right) + \left(\frac{\quad + \quad}{\quad} \right) \left(\frac{\quad + \quad}{\quad} \right) \tag{14}$$

di mana:

- = Nilai positif yang benar diklasifikasi oleh metode prediksi
- = Nilai positif yang salah diklasifikasi oleh metode prediksi
- = Nilai negatif yang benar diklasifikasi oleh metode prediksi
- = Nilai negatif yang salah diklasifikasi oleh metode prediksi

		Predicted Class		
		Positive	Negative	
Actual Class	Positive	True Positive (TP)	False Negative (FN) Type II Error	Sensitivity $\frac{TP}{(TP + FN)}$
	Negative	False Positive (FP) Type I Error	True Negative (TN)	Specificity $\frac{TN}{(TN + FP)}$
		Precision $\frac{TP}{(TP + FP)}$	Negative Predictive Value $\frac{TN}{(TN + FN)}$	Accuracy $\frac{TP + TN}{(TP + TN + FP + FN)}$

Gambar 5. *Confusion matrix* (Sumber: <https://encord.com/glossary/confusion-matrix/>)

3. METODE PENELITIAN

Proses penelitian akan dimulai dengan melakukan pengumpulan data melalui penyebaran kuesioner kepada pihak-pihak yang bekerja pada proyek bangunan tinggi di Surabaya. Kategori jabatan responden yang dipilih untuk mengisi kuesioner tersebut adalah *project manager*, *site manager*, *construction manager*, *site engineer*, dan inspektur lapangan. Variabel pernyataan penyebab keterlambatan proyek pada kuesioner yang digunakan adalah sebanyak 21 variabel sesuai dengan studi literatur yang telah dilakukan dan dapat dilihat pada Tabel 2. Skala penilaian yang digunakan pada setiap variabel untuk menilai seberapa signifikan penyebab keterlambatan proyek adalah dengan menggunakan *probability* dan

impact dari setiap faktor serta dapat dilihat pada Tabel 3. Variabel hasil dari penelitian ini adalah tingkat keterlambatan yang diklasifikasikan menjadi 3 tingkat keterlambatan meliputi <50% *delay*, 50%-100% *delay*, dan >100% *delay*. Setelah semua data terkumpul, maka akan dibuat model prediksi dengan bantuan *software* SPSS Modeler 18.0 dengan membagi *dataset* terlebih dahulu menjadi 70% data untuk proses *training* dan 30% data untuk proses *testing*. Metode prediksi yang digunakan adalah metode *Artificial Neural Network* (ANN), *Support Vector Machine* (SVM), dan *Classification and Regression Tree* (CART) dengan pengaturan parameter standar. Setelah hasil prediksi diperoleh, akan dilakukan evaluasi hasil prediksi antara ketiga metode yang digunakan untuk menentukan metode prediksi dengan performa terbaik dalam melakukan prediksi keterlambatan proyek.

Tabel 2. Variabel *input* penyebab keterlambatan proyek

Variabel	Faktor Penyebab Keterlambatan
X1	Kurangnya jumlah tenaga kerja
X2	Kurangnya tenaga kerja ahli
X3	Keterlambatan pengiriman material
X4	Harga material yang fluktuatif
X5	Penggantian mutu material
X6	Kurangnya jumlah peralatan
X7	Banyaknya peralatan rusak
X8	Buruknya penjadwalan proyek
X9	Sistem kontrol kualitas yang kurang efektif
X10	Keterlambatan pembayaran untuk subkontraktor
X11	Buruknya koordinasi antar bagian
X12	Kurangnya kompetensi staf yang ada di proyek
X13	Banyaknya <i>change order</i>
X14	Keterlambatan persiapan lahan proyek
X15	Lambatnya pengambilan keputusan
X16	Keterlambatan pembayaran kepada kontraktor
X17	Ambiguitas dan kesalahan spesifikasi pada gambar
X18	Kurangnya koordinasi konsultan dengan pihak terkait
X19	Cuaca buruk pada proyek konstruksi
X20	Hambatan dalam penerbitan izin kerja
X21	Perubahan peraturan pemerintah dan hukum

Tabel 3. Skala penilaian *probability* dan *impact*

Skala	<i>Probability</i>	<i>Impact</i>
1	<i>Very Low</i> (VL)	<i>Very Low</i> (VL)
2	<i>Low</i> (L)	<i>Low</i> (L)
3	<i>Moderate</i> (M)	<i>Moderate</i> (M)
4	<i>High</i> (H)	<i>High</i> (H)
5	<i>Very High</i> (VH)	<i>Very High</i> (VH)

4. HASIL DAN DISKUSI

4.1. Hasil Penyebaran Kuesioner

Dari hasil penyebaran kuesioner yang dilakukan pada perusahaan kontraktor dan manajemen konstruksi yang ada di Surabaya, diperoleh 35 data proyek bangunan tinggi. Data proyek

bangunan tinggi yang diperoleh adalah berupa nilai *probability* dan *impact* dari setiap faktor penyebab keterlambatan proyek seperti pada Tabel 2 yang diisi dengan skala 1-5 sesuai Tabel 3 untuk setiap proyek bangunan tinggi. Total responden yang mengisi sebanyak 19 orang berbeda, di mana setiap responden boleh mengisi lebih dari satu kuesioner data proyek bangunan tinggi berdasarkan pengalaman kerja proyeknya di masa lampau. Demografi data responden yang mengisi dan jenis perusahaannya dapat dilihat pada Tabel 4. Dari 19 orang responden, 13 orang berasal dari perusahaan kontraktor dan 6 orang berasal dari perusahaan manajemen konstruksi. Jabatan responden sebagai *project manager* sebanyak 7 orang, *site manager* sebanyak 5 orang, *construction manager* sebanyak 5 orang, *site engineer* dan inspektur lapangan masing-masing sebanyak 1 orang. Setelah dilakukan penyebaran kuesioner, diperoleh bahwa jenis klasifikasi keterlambatan proyek berkurang menjadi 2, yaitu <50% delay dan 50%-100% delay, dikarenakan tidak adanya proyek yang mengalami keterlambatan hingga dua kali durasi rencana proyek. Statistik deskriptif dari hasil penilaian *probability* dan *impact* untuk variabel *input* penyebab keterlambatan proyek disajikan dalam Tabel 5.

Tabel 4. Demografi data responden

Demografi	Kategori	Frekuensi	Persentase
Jabatan	<i>Project Manager</i>	7	36,84%
	<i>Site Manager</i>	5	26,32%
	<i>Construction Manager</i>	5	26,32%
	<i>Site Engineer</i>	1	5,26%
	Inspektur Lapangan	1	5,26%
Perusahaan	Kontraktor	13	68,42%
	Manajemen Konstruksi	6	31,58%

Tabel 5. Statistik deskriptif variabel *Input*

Variabel	Faktor Penyebab Keterlambatan	<i>Probability</i>		<i>Impact</i>	
		Rata-rata	Standar Deviasi	Rata-rata	Standar Deviasi
X1	Kurangnya jumlah tenaga kerja	3,31	1,35	4,14	0,91
X2	Kurangnya tenaga kerja ahli	2,80	1,13	3,60	1,01
X3	Keterlambatan pengiriman material	3,23	1,00	4,06	0,76
X4	Harga material yang fluktuatif	2,54	0,89	2,83	0,92
X5	Penggantian mutu material	2,60	1,09	3,20	1,02
X6	Kurangnya jumlah peralatan	2,80	1,05	3,40	0,88
X7	Banyaknya peralatan rusak	2,77	1,06	3,54	0,89
X8	Buruknya penjadwalan proyek	2,60	1,06	3,69	0,99

Variabel	Faktor Penyebab Keterlambatan	Probability		Impact	
		Rata-rata	Standar Deviasi	Rata-rata	Standar Deviasi
X9	Sistem kontrol kualitas yang kurang efektif	2,60	1,03	3,46	0,95
X10	Keterlambatan pembayaran untuk subkontraktor	3,00	1,00	3,74	0,82
X11	Buruknya koordinasi antar bagian	2,97	0,86	3,66	0,91
X12	Kurangnya kompetensi staf yang ada di proyek	2,63	1,03	3,46	0,85
X13	Banyaknya <i>change order</i>	3,49	1,31	4,23	0,94
X14	Keterlambatan persiapan lahan proyek	2,63	1,11	3,34	0,94
X15	Lambatnya pengambilan keputusan	3,49	1,01	3,89	0,87
X16	Keterlambatan pembayaran kepada kontraktor	3,23	1,09	4,03	1,01
X17	Ambiguitas dan kesalahan spesifikasi pada gambar	3,31	1,13	3,77	1,06
X18	Kurangnya koordinasi konsultan dengan pihak terkait	3,09	0,98	3,66	0,87
X19	Cuaca buruk pada proyek konstruksi	3,00	1,14	3,43	1,09
X20	Hambatan dalam penerbitan izin kerja	2,51	1,01	2,89	1,02
X21	Perubahan peraturan pemerintah dan hukum	2,29	1,15	2,89	1,18

4.2. Proses Pengolahan Data: Transformasi Kategori Risiko

Setelah memperoleh data dari hasil penyebaran kuesioner, proses selanjutnya adalah pengolahan data dengan membaginya menjadi tiga jenis model yaitu *probability x impact*, lima kategori zona matriks risiko, dan tiga kategori zona matriks risiko. Model 1, yaitu *probability x impact*, diperoleh dengan melakukan perkalian nilai *probability* dengan nilai *impact* dari setiap variabel sehingga menghasilkan nilai risiko untuk setiap variabel. Matriks risiko yang berisi hasil perkalian dari nilai *probability* dan nilai *impact* dapat dilihat pada Tabel 6. Model 2, yaitu

lima kategori warna risk matrix, diperoleh dengan meninjau nilai *probability* dan nilai *impact* untuk setiap variabel dan dicocokkan dengan matriks risiko pada Tabel 7. Kategori risiko pada model 2 dibagi menjadi lima kategori warna, yaitu *very low* (hijau muda), *low* (hijau tua), *moderate* (kuning), *high* (merah), dan *very high* (merah tua). Model 3, yaitu tiga kategori warna risk matrix, diperoleh dengan cara yang sama seperti model 2, tetapi matriks risiko untuk model 3 lebih sederhana, yaitu hanya dibagi menjadi 3 kategori warna, meliputi *low* (hijau), *moderate* (kuning), dan *high* (merah), serta dapat dilihat pada Tabel 8.

Tabel 6. Matriks risiko model 1

<i>Probability</i>	<i>Very High</i>	5	5	10	15	20	25
	<i>High</i>	4	4	8	12	16	20
	<i>Moderate</i>	3	3	6	9	12	15
	<i>Low</i>	2	2	4	6	8	10
	<i>Very Low</i>	1	1	2	3	4	5
			1	2	3	4	5
			<i>Very Low</i>	<i>Low</i>	<i>Moderate</i>	<i>High</i>	<i>Very High</i>
			<i>Impact</i>				

Tabel 7. Matriks risiko model 2

<i>Probability</i>	<i>Very High</i>	5	2	3	4	5	5
	<i>High</i>	4	2	3	4	4	5
	<i>Moderate</i>	3	2	2	3	4	4
	<i>Low</i>	2	1	2	3	3	4
	<i>Very Low</i>	1	1	1	2	3	4
			1	2	3	4	5
			<i>Very Low</i>	<i>Low</i>	<i>Moderate</i>	<i>High</i>	<i>Very High</i>
			<i>Impact</i>				

Tabel 8. Matriks risiko model 3

<i>Probability</i>	<i>Very High</i>	5	1	3	5	5	5
	<i>High</i>	4	1	3	5	5	5
	<i>Moderate</i>	3	1	1	3	5	5
	<i>Low</i>	2	1	1	3	3	5
	<i>Very Low</i>	1	1	1	1	3	5
			1	2	3	4	5
			<i>Very Low</i>	<i>Low</i>	<i>Moderate</i>	<i>High</i>	<i>Very High</i>
			<i>Impact</i>				

Sebagai contoh, data proyek 32 dengan nilai masing-masing *probability* dan *impact* untuk setiap variabel disajikan pada Tabel 9. Pada variabel X8, nilai *probability* yang diperoleh sebesar 2 dan nilai *impact* sebesar 5. Untuk model 1, nilai risiko diperoleh dari hasil perkalian nilai *probability* dan *impact* sehingga diperoleh nilai risiko 10 yang apabila dicocokkan dengan matriks risiko berarti berada pada zona merah, yaitu *high*. Selanjutnya, untuk model 2, nilai risiko diperoleh dengan mencocokkan nilai *probability* dan *impact* terhadap matriks risiko, yaitu berada pada zona merah dengan nilai 4 yang berarti *high*. Pada model 3, nilai risiko diperoleh dengan cara yang sama dengan model 2, yaitu mencocokkan nilai *probability* dan *impact* terhadap matriks risiko yang berada pada zona merah dengan nilai 5, yang berarti *high*. Tahapan terakhir setelah dilakukan transformasi nilai *probability* dan *impact* untuk

masing-masing variabel pada setiap proyek adalah pembagian dataset menjadi 70% data *training* dan 30% data *testing*.

Tabel 9. Contoh data proyek 32

Data Proyek 32					
Variabel	Probability	Impact	Variabel	Probability	Impact
X1	4	4	X11	3	4
X2	3	3	X12	3	4
X3	3	3	X13	2	4
X4	4	4	X14	3	4
X5	4	4	X15	4	5
X6	4	4	X16	2	4
X7	4	4	X17	3	3
X8	2	5	X18	3	4
X9	3	3	X19	2	3
X10	2	5	X20	2	4
			X21	3	3

4.3. Perbandingan Hasil Prediksi Berbagai Metode *Machine Learning*

Berdasarkan hasil prediksi yang dilakukan dengan ketiga metode *machine learning* yaitu *Artificial Neural Network* (ANN), *Support Vector Machine* (SVM), dan *Classification and Regression Tree* (CART), selanjutnya dilakukan evaluasi dengan mengacu pada *confusion matrix* pada data *testing*. Dari 35 total data proyek, sebanyak 27 data digunakan sebagai data *training* dan 8 data digunakan sebagai data *testing*. Evaluasi pada data *testing* dilakukan untuk menilai kemampuan generalisasi model dalam memprediksi data yang tidak digunakan dalam proses *training*. Hasil *confusion matrix* untuk setiap metode dan model disajikan dalam Tabel 10 sampai Tabel 12.

Tabel 10. *Confusion matrix* metode ANN

Model 1				Model 2				Model 3			
Data Training	50%-100%	<50%	%	Data Training	50%-100%	<50%	%	Data Training	50%-100%	<50%	%
50%-100%	6	4	60,00	50%-100%	9	1	90,00	50%-100%	7	3	70,00
<50%	1	16	94,12	<50%	2	15	88,24	<50%	1	16	94,12
%	85,71	80,00	81,48	%	81,82	93,75	88,89	%	87,50	84,21	85,19
Data Testing	50%-100%	<50%	%	Data Testing	50%-100%	<50%	%	Data Testing	50%-100%	<50%	%
50%-100%	1	2	33,33	50%-100%	3	0	100,00	50%-100%	1	2	33,33
<50%	1	4	80,00	<50%	0	5	100,00	<50%	1	4	80,00
%	50,00	66,67	62,50	%	100,00	100,00	100,00	%	50,00	66,67	62,50

Tabel 11. *Confusion matrix* metode SVM

Model 1				Model 2				Model 3			
Data Training	50%-100%	<50%	%	Data Training	50%-100%	<50%	%	Data Training	50%-100%	<50%	%
50%-100%	9	1	90,00	50%-100%	7	3	70,00	50%-100%	8	2	80,00
<50%	1	16	94,12	<50%	1	16	94,12	<50%	1	16	94,12
%	90,00	94,12	92,59	%	87,50	84,21	85,19	%	88,89	88,89	88,89
Data Testing	50%-100%	<50%	%	Data Testing	50%-100%	<50%	%	Data Testing	50%-100%	<50%	%
50%-100%	1	2	33,33	50%-100%	2	1	66,67	50%-100%	2	1	66,67
<50%	1	4	80,00	<50%	1	4	80,00	<50%	1	4	80,00
%	50,00	66,67	62,50	%	66,67	80,00	75,00	%	66,67	80,00	75,00

Tabel 12. *Confusion matrix* metode CART

Model 1				Model 2				Model 3			
Data Training	50%-100%	<50%	%	Data Training	50%-100%	<50%	%	Data Training	50%-100%	<50%	%
50%-100%	0	10	0,00	50%-100%	0	10	0,00	50%-100%	8	2	80,00
<50%	0	17	100,00	<50%	0	17	100,00	<50%	2	15	88,24
%		62,96	62,96	%		62,96	62,96	%	80,00	88,24	85,19
Data Testing	50%-100%	<50%	%	Data Testing	50%-100%	<50%	%	Data Testing	50%-100%	<50%	%
50%-100%	0	3	0,00	50%-100%	0	3	0,00	50%-100%	1	2	33,33
<50%	0	5	100,00	<50%	0	5	100,00	<50%	1	4	80,00
%		66,67	62,50	%		62,50	62,50	%	50,00	66,67	62,50

Dari hasil tersebut dapat dilihat bahwa setiap metode prediksi memiliki model prediksi yang terbaik berdasarkan parameter *accuracy* pada data *testing*. Pada metode ANN, model 2 yang merupakan kategori risiko lima warna mampu memprediksi risiko keterlambatan proyek dengan tingkat akurasi 100%. Hal ini menunjukkan bahwa seluruh data *testing* berhasil diklasifikasikan dengan benar. Sebaliknya, model 1 dan model 3 hanya menghasilkan akurasi sebesar 62,5% yang menunjukkan masih terdapat beberapa kesalahan pada klasifikasi data *testing*. Dengan demikian, pada metode ANN dapat disimpulkan bahwa model 2 memiliki kemampuan generalisasi terbaik dibandingkan dengan model lainnya.

Selanjutnya, pada metode SVM, terdapat 2 model, yaitu model 2 dan model 3, yang berhasil memprediksi dengan tingkat akurasi 75%. Kedua model ini menunjukkan kemampuan prediksi yang cukup baik dan hasil yang relatif konsisten dalam membedakan kategori keterlambatan proyek. Sementara itu, model 1 hanya menghasilkan akurasi sebesar 62,5% yang menunjukkan performa lebih rendah dibandingkan dengan dua model lainnya. Oleh karena itu, pada metode SVM dapat disimpulkan bahwa model 2 dan model 3 merupakan model yang paling optimal.

Sebaliknya, pada metode CART hanya model 3 yang berhasil memprediksi dengan tingkat akurasi 62,5%. Pada tahap *training*, metode CART mengalami kegagalan pembentukan cabang pohon klasifikasi di model 1 dan model 2, yang menyebabkan tidak adanya aturan klasifikasi yang valid sehingga dikategorikan sebagai model yang gagal dalam memberikan

prediksi memadai. Dengan demikian, pada metode CART hanya model 3 yang dapat digunakan untuk evaluasi prediksi.

Apabila dibandingkan secara keseluruhan berdasarkan hasil pengujian data *testing*, maka metode ANN menunjukkan performa terbaik, khususnya pada Model 2 yang berhasil mencapai akurasi prediksi 100%. Metode SVM berada pada posisi kedua dengan akurasi maksimum 75%, sedangkan metode CART menunjukkan performa paling rendah dengan akurasi maksimum 62,5%. Hasil ini menunjukkan bahwa pendekatan berbasis jaringan saraf pada metode ANN mampu menangkap pola hubungan dalam data risiko keterlambatan proyek dengan lebih baik dibandingkan dengan metode berbasis *margin classifier* maupun pohon keputusan.

Selain melakukan evaluasi dengan lima parameter evaluasi yang ada pada *confusion matrix*, terdapat dua parameter evaluasi lain yang digunakan, yaitu *classification error* dan *kappa statistic*. Hasil perhitungan untuk *classification error* dan *Kappa statistic* pada data *testing* disajikan dalam Tabel 13. Kedua indikator tersebut digunakan secara bersamaan untuk menilai kualitas model klasifikasi, yaitu *classification error* untuk menunjukkan proporsi kesalahan prediksi, sedangkan *kappa statistic* digunakan untuk mengukur tingkat kesepakatan antara data hasil prediksi dengan data aktual setelah memperhitungkan kemungkinan kesepakatan terjadi secara acak. Berdasarkan Tabel 13, dapat dilihat bahwa metode ANN pada model 2 memberikan performa terbaik dibandingkan dengan metode lainnya, yaitu menghasilkan *classification error* sebesar 0% dan nilai *kappa statistic* sebesar 1,00. Hal ini menunjukkan bahwa seluruh data berhasil diklasifikasikan dengan benar dan tingkat kesepakatan antara data hasil prediksi oleh model prediksi dan data aktual berada pada kategori *perfect agreement*, yang berarti struktur pembelajaran dari metode ANN model 2 mampu menangkap hubungan dalam dataset secara optimal sehingga tidak terjadi kesalahan klasifikasi. Sebaliknya, pada metode ANN model 1 dan model 3, nilai *classification error* sebesar 37,5% dan nilai *kappa statistic* sebesar 0,14 yang menunjukkan tingkat kesepakatan rendah serta mengindikasikan bahwa konfigurasi model belum mampu mempelajari pola dataset secara efektif.

Tabel 13. Hasil perhitungan *Classification Error* dan *Kappa Statistic*

Metode Prediksi	Model Prediksi	<i>Classification Error (%)</i>	<i>Kappa Statistic</i>
ANN	Model 1	37,50	0,14
	Model 2	0,00	1,00
	Model 3	37,50	0,14
SVM	Model 1	37,50	0,14
	Model 2	25,00	0,47
	Model 3	25,00	0,47
CART	Model 1	37,50	0,00
	Model 2	37,50	0,00
	Model 3	37,50	0,14

Pada metode SVM, performa terbaik diperoleh pada model 2 dan model 3 dengan *classification error* sebesar 25% dan nilai *kappa statistic* sebesar 0,47. Nilai ini menunjukkan tingkat kesepakatan pada *moderate agreement*, yang berarti metode SVM memiliki kemampuan klasifikasi yang cukup baik meskipun menghasilkan sejumlah kesalahan

prediksi. Sementara itu, SVM model 1 menunjukkan performa yang lebih rendah dengan *classification error* sebesar 37,5% dan nilai *kappa statistic* sebesar 0,14 yang menandakan bahwa model tersebut memiliki kemampuan prediksi yang relatif lemah. Berbeda dengan dua metode sebelumnya, metode CART secara umum menunjukkan performa yang lebih rendah. Pada metode CART model 1 dan model 2, nilai *classification error* sebesar 37,5% dan nilai *kappa statistic* sebesar 0,00, yang menunjukkan bahwa kesepakatan antara data hasil prediksi dan data aktual tidak lebih baik dibandingkan dengan kesepakatan secara acak. Hal ini mengindikasikan bahwa struktur pohon keputusan yang dihasilkan pada metode CART belum mampu memisahkan kelas data secara efektif. Sementara itu, CART Model 3 menunjukkan sedikit peningkatan dengan nilai *kappa statistic* sebesar 0,14, meskipun nilai *classification error* tetap berada pada 37,5%.

Berdasarkan keseluruhan hasil evaluasi tersebut, dapat disimpulkan bahwa metode terbaik dalam memprediksi risiko keterlambatan proyek adalah metode ANN karena mampu menghasilkan model prediksi dengan tingkat kesalahan klasifikasi yang paling rendah dan nilai *kappa statistic* tertinggi. Secara khusus, model terbaik adalah ANN Model 2, yang menunjukkan performa paling optimal dengan *classification error* 0,00% dan *kappa statistic* 1,00. Sementara itu, metode SVM dapat dianggap sebagai alternatif yang cukup baik dengan tingkat kesepakatan moderat, sedangkan metode CART menunjukkan performa paling rendah dalam penelitian ini karena memiliki tingkat kesalahan klasifikasi yang tinggi serta nilai *kappa statistic* yang rendah.

5. KESIMPULAN

Penelitian ini dilakukan untuk memprediksi risiko keterlambatan pada proyek bangunan gedung tinggi di Surabaya dengan menggunakan tiga metode *machine learning*, yaitu *Artificial Neural Network* (ANN), *Support Vector Machine* (SVM), dan *Classification and Regression Tree* (CART). Dari hasil evaluasi ketiga metode prediksi tersebut, metode ANN menunjukkan kinerja prediksi yang paling akurat dengan tingkat akurasi 100% dan nilai *kappa statistic* 1,00, yang mengindikasikan bahwa keseluruhan data *testing* berhasil diklasifikasikan dengan benar. Metode yang menempati urutan kedua sebagai alternatif terbaik setelah ANN adalah metode SVM, dan metode CART menempati urutan terakhir karena tingkat kesalahan prediksi yang tinggi serta nilai *kappa statistic* yang rendah.

REFERENSI

- Abbasi, O., Noorzai, E., Gharouni Jafari, K., & Golabchi, M. (2020). Exploring the causes of delays in construction industry using a Cause-and-Effect Diagram: Case study for Iran. *Journal of Architectural Engineering*, 26(3), 05020008. [https://doi.org/10.1061/\(ASCE\)AE.1943-5568.0000431](https://doi.org/10.1061/(ASCE)AE.1943-5568.0000431)
- Agyekum-Mensah, G., & Knight, A. D. (2017). The professionals' perspective on the causes of project delay in the construction industry. *Engineering, Construction and Architectural Management*, 24(5), 828–841. <https://doi.org/10.1108/ECAM-03-2016-0085>
- Al-Gahtani, K. S., Alsugair, A. M., Alsanabani, N. M., Alabduljabbar, A. A., & Almohsen, A. S. (2025). ANN prediction model of final construction cost at an early stage. *Journal of*

Asian Architecture and Building Engineering, 24(2), 775–799.
<https://doi.org/10.1080/13467581.2023.2294883>

- Ali, M. H., & Abd, A. M. (2021). Using of an Artificial Neural Networks with Particle Swarm Optimization (ANN-PSO) model in prediction of cost and delay in construction projects. *Diyala Journal of Engineering Sciences*, 14(3), 78–93.
<https://doi.org/10.24237/djes.2021.14307>
- Al Kharashi, A., & Skitmore, M. (2009). Causes of delays in Saudi Arabian public sector construction projects. *Construction Management and Economics*, 27(1), 3–23.
<https://doi.org/10.1080/01446190802541457>
- Alotaibi, N., Sutrisna, M., & Chong, H.-Y. (2015). Managing critical factors causing delays in public construction projects in Kingdom of Saudi Arabia. *Proceedings of the 2015 (6th) International Conference on Engineering, Project, and Production Management*, 109–119. <https://doi.org/10.32738/CEPPM.201509.0013>
- Al-Zwainy, F. M. S., & Hadhal, N. T. (2015). Investigation and evaluation of the cost estimation methods of Iraqi communication projects. *International Journal of Engineering and Management Research*, 5(5), 362–369.
- Assaf, S. A., & Al-Hejji, S. (2006). Causes of delay in large construction projects. *International Journal of Project Management*, 24(4), 349–357.
<https://doi.org/10.1016/j.ijproman.2005.11.010>
- Aziz, R. F., & Abdel-Hakam, A. A. (2016). Exploring delay causes of road construction projects in Egypt. *Alexandria Engineering Journal*, 55(2), 1515–1539.
<https://doi.org/10.1016/j.aej.2016.03.006>
- Castro Miranda, S. L., Del Rey Castillo, E., Gonzalez, V., & Adafin, J. (2022). Predictive analytics for early-stage construction costs estimation. *Buildings*, 12(7), 1043.
<https://doi.org/10.3390/buildings12071043>
- Cheng, M.-Y., Firdausi, P. M., & Prayogo, D. (2014). High-performance concrete compressive strength prediction using Genetic Weighted Pyramid Operation Tree (GW POT). *Engineering Applications of Artificial Intelligence*, 29, 104–113.
<https://doi.org/10.1016/j.engappai.2013.11.014>
- Chou, J.-S., Tsai, C.-F., Pham, A.-D., & Lu, Y.-H. (2014). Machine learning in concrete strength simulations: Multi-nation data analytics. *Construction and Building Materials*, 73, 771–780. <https://doi.org/10.1016/j.conbuildmat.2014.09.054>
- Deng, X., Liu, Q., Deng, Y., & Mahadevan, S. (2016). An improved method to construct basic probability assignment based on the confusion matrix for classification problem. *Information Sciences*, 340–341, 250–261. <https://doi.org/10.1016/j.ins.2016.01.033>
- Durdyev, S., & Hosseini, M. R. (2020). Causes of delays on construction projects: A comprehensive list. *International Journal of Managing Projects in Business*, 13(1), 20–46. <https://doi.org/10.1108/IJMPB-09-2018-0178>

- Fashina, A. A., Omar, M. A., Sheikh, A. A., & Fakunle, F. F. (2021). Exploring the significant factors that influence delays in construction projects in Hargeisa. *Heliyon*, 7(4), e06826. <https://doi.org/10.1016/j.heliyon.2021.e06826>
- Gondia, A., Siam, A., El-Dakhakhni, W., & Nassar, A. H. (2020). Machine learning algorithms for construction projects delay risk prediction. *Journal of Construction Engineering and Management*, 146(1), 04019085. [https://doi.org/10.1061/\(ASCE\)CO.1943-7862.0001736](https://doi.org/10.1061/(ASCE)CO.1943-7862.0001736)
- Grajski, K. A., Breiman, L., Di Prisco, G. V., & Freeman, W. J. (1986). Classification of EEG spatial patterns with a tree-structured methodology: CART. *IEEE Transactions on Biomedical Engineering*, BME-33(12), 1076–1086. <https://doi.org/10.1109/TBME.1986.325684>
- Hillson, D., & Hullet, D. (2004). Assessing risk probability: Alternative approaches. *PMI Global Congress Proceedings*.
- Hoxha, V. (2025). Comparative analysis of machine learning models in predicting housing prices: A case study of Prishtina's real estate market. *International Journal of Housing Markets and Analysis*, 18(3), 694–711. <https://doi.org/10.1108/IJHMA-09-2023-0120>
- Husada, W., Reynaldo, A. M. J., Hogianto, J. F., & Putri, C. A. (2025). Comparative study on Artificial Intelligence methods in housing price prediction. *Journal of Civil Engineering*, 40(2), 170–177.
- Joint Australia New Zealand International Standard. (2009). *Risk management—Principles and guidelines* (3rd ed.).
- Kassem, M. A., Khoiry, M. A., & Hamzah, N. (2020). Using probability impact matrix (PIM) in analyzing risk factors affecting the success of oil and gas construction projects in Yemen. *International Journal of Energy Sector Management*, 14(3), 527–546. <https://doi.org/10.1108/IJESM-03-2019-0011>
- Morgan, J. (2014). *Classification and Regression Tree analysis* [Technical Report]. Boston University.
- Nagata, M. F., Manginelli, W. A., & Lowe, S. (2018). *Construction Delays* (Third Edition). Butterworth-Heinemann. <https://doi.org/10.1016/C2015-0-00387-2>
- Padala, S. P. S., & Goyal, A. (2025). Early stage cost prediction model for Indian building construction projects using Artificial Neural Networks. *Journal of Financial Management of Property and Construction*, 30(3), 377–397. <https://doi.org/10.1108/JFMPC-12-2023-0085>
- Project Management Institute. (2021). *A guide to the project management body of knowledge* (7th ed.). Project Management Institute.
- Sambasivan, M., & Soon, Y. W. (2007). Causes and effects of delays in Malaysian construction industry. *International Journal of Project Management*, 25(5), 517–526. <https://doi.org/10.1016/j.ijproman.2006.11.007>

- Sanni-Anibire, M. O., Zin, R. M., & Olatunji, S. O. (2022). Machine learning model for delay risk assessment in tall building projects. *International Journal of Construction Management*, 22(11), 2134–2143. <https://doi.org/10.1080/15623599.2020.1768326>
- Santoso, D. S., & Gallage, P. G. M. P. (2020). Critical factors affecting the performance of large construction projects in developing countries: A case study of Sri Lanka. *Journal of Engineering, Design and Technology*, 18(3), 531–556. <https://doi.org/10.1108/JEDT-05-2019-0130>
- Shariati, M., Mafipour, M. S., & Mehrabi, P. (2020). Prediction of concrete strength in presence of furnace slag and fly ash using hybrid ANN-GA (Artificial Neural Network-Genetic Algorithm). *Smart Structures and Systems, An International Journal*, 25(2), 183–195.
- Shirazi, D. H., & Toosi, H. (2023). Deep Multilayer Perceptron Neural Network for the prediction of Iranian dam project delay risks. *Journal of Construction Engineering and Management*, 149(4), 04023011. <https://doi.org/10.1061/JCEMD4.COENG-12367>
- Sweis, G., Sweis, R., Abu Hammad, A., & Shboul, A. (2008). Delays in construction projects: The case of Jordan. *International Journal of Project Management*, 26(6), 665–674. <https://doi.org/10.1016/j.ijproman.2007.09.009>
- Tariq, J., & Gardezi, S. S. S. (2023). Study the delays and conflicts for construction projects and their mutual relationship: A review. *Ain Shams Engineering Journal*, 14(1), 101815. <https://doi.org/10.1016/j.asej.2022.101815>
- Vapnik, V. (1995). *The nature of statistical learning theory* (2nd ed.). Springer.
- Wu, Y., & Feng, J. (2018). Development and application of Artificial Neural Network. *Wireless Personal Communications*, 102(2), 1645–1656. <https://doi.org/10.1007/s11277-017-5224-x>
- Xue, H., & Zhang, S. J. (2018). Relationships between engineering construction standards and economic growth in the construction industry: The case of China's construction industry. *KSCE Journal of Civil Engineering*, 22(5), 1606–1613. <https://doi.org/10.1007/s12205-017-1990-y>
- Yaseen, Z. M., Ali, Z. H., Salih, S. Q., & Al-Ansari, N. (2020). Prediction of risk delay in construction projects using a hybrid artificial intelligence model. *Sustainability*, 12(4), 1514. <https://doi.org/10.3390/su12041514>
- Yoon, H., Jun, S.-C., Hyun, Y., Bae, G.-O., & Lee, K.-K. (2011). A comparative study of Artificial Neural Networks and Support Vector Machines for predicting groundwater levels in a coastal aquifer. *Journal of Hydrology*, 396(1–2), 128–138. <https://doi.org/10.1016/j.jhydrol.2010.11.002>