

PREDIKSI KEBANGKRUTAN DENGAN METODE ANN, SVM, DAN CART PADA PERUSAHAAN PROPERTI, KONSTRUKSI, DAN INDUSTRI SEJENIS YANG TERDAFTAR DI BEI

Rafael Reinaldo Lorens¹, Doddy Prayogo² dan Januar Budiman³

¹ Mahasiswa Program Magister Teknik Sipil, Universitas Kristen Petra, Surabaya

^{2,3} Dosen Program Magister Teknik Sipil, Universitas Kristen Petra, Surabaya

¹ rafaellorens97@gmail.com, ² prayogo@peter.petra.ac.id, ³ januar@peter.petra.ac.id

ABSTRAK: Sifat ketidakpastian dalam sektor konstruksi, properti, *real estate* dan industri sejenis membuat sektor ini rentan menghadapi *financial distress*. Saat ini, pendekatan linear digunakan untuk memprediksi status finansial perusahaan, sedangkan tidak semua variabel menunjukkan korelasi linear terhadap kesehatan finansial sebuah perusahaan. Penelitian ini bertujuan untuk menemukan model prediksi paling akurat dalam memprediksi indikasi *financial distress* menggunakan kecerdasan buatan(AI). Metode AI yang digunakan adalah *artificial neural network* (ANN), *support vector machine* (SVM), dan *classification and regression tree* (CART). Metode ini digunakan untuk menganalisis tiga *dataset* rasio keuangan dari model peneliti terdahulu pada prediksi tiga dan lima tahun. Hasil terbaik dari pengolahan data dianalisis dengan *confusion matrix* untuk menentukan metode yang memiliki tingkat akurasi tertinggi. Hasil penelitian menunjukkan bahwa metode ANN memiliki tingkat akurasi paling tinggi terbanyak. *Dataset* dari peneliti Cheng et al. (2014) memiliki tingkat akurasi tertinggi pada hasil prediksi tiga tahun dengan metode CART dan lima tahun dengan menggunakan metode ANN.

Kata kunci: artificial intelligence, ANN, SVM, CART, kebangkrutan, properti

ABSTRACT: *The uncertain nature of construction, property, real estate, and similar industries makes this sector vulnerable to financial distress. Currently, linear used to predict the financial status of a company although not all variables show a linear correlation to the financial health of a company. This study aims to find the most accurate predictive model to predict indications of financial distress by using artificial intelligence (AI) – artificial neural network (ANN), support vector machine (SVM), and classification and regression tree (CART) to analyze three kinds of datasets from previous research according to their financial ratio with three and five years prediction. The best results of these data processing analyzed using the confusion matrix to determine the method that has the highest accuracy. The result shows that ANN has the highest accuracy. Cheng et al. (2014) CART method has the highest accuracy for three years prediction and ANN method for five years prediction.*

Keywords: artificial intelligence, ANN, SVM, CART, bankruptcy, property

1. PENDAHULUAN

Industri konstruksi, properti, dan *real estate* adalah suatu industri bersifat siklikal yang rentan menghadapi kondisi *financial distress*. Hal ini dikarenakan oleh sifat ketidakpastian di dalam sektor konstruksi, properti, *real estate*, dan industri sejenis. Salah satu contoh ketidakpastian dalam industri ini adalah perihal termin pembayaran. Keterlambatan pembayaran adalah hal yang umum terjadi dalam industri ini. Keterlambatan pembayaran akan tercatat sebagai piutang dan piutang tidak terbayar akan berubah menjadi beban bagi perusahaan. Akumulasi beban ini seringkali menjadi penyebab suatu perusahaan mengalami *financial distress*.

Di sisi lain, penyebab utama dari tingginya tingkat kegagalan keuangan (*financial distress*) pada perusahaan yang bergerak pada industri bisnis ini adalah kurangnya kemampuan dan pengetahuan pihak manajerial mengenai tata kelola keuangan (Cheng et al., 2014). *Financial distress* sendiri didefinisikan sebagai suatu kondisi dimana perusahaan mengalami *delisted* akibat laba bersih perusahaan dan nilai buku perusahaan bernilai negatif, maupun perusahaan telah di-*merger* (Almilia & Kristijadi, 2003).

Kondisi finansial suatu perusahaan dapat dinilai melalui laporan keuangan perusahaan tersebut. Secara umum, gambaran kinerja dan kondisi finansial suatu perusahaan dapat dilihat melalui rasio-rasio keuangan seperti *return on equity* (ROE), *return on assets* (ROA), *residual income*, *sales growth*, *cashflow*, dan *expense*. Rasio tersebut menggambarkan kondisi keuangan suatu perusahaan secara relatif dibandingkan terhadap industrinya mengacu pada sudut pandang investor (Calandro Jr, 2007).

Pada industri konstruksi, properti, dan industri sejenis yang bersifat siklikal dan dipenuhi dengan ketidakpastian, dibutuhkan suatu metode dalam rangka memahami kondisi finansial serta memprediksi status finansial dari perusahaan yang bergerak di industri tersebut. Di lain pihak, metode identifikasi kondisi finansial diperlukan oleh pihak eksternal (pemerintah, investor, industri perbankan, dsb) untuk mengidentifikasi risiko kegagalan keuangan yang berujung kebangkrutan pada suatu perusahaan. Secara praktikal, peningkatan cakupan dan tingkat kerumitan suatu pekerjaan sering kali menyebabkan dibutuhkannya kolaborasi dengan pihak eksternal. Sehingga dapat disimpulkan bahwa kerjasama antar elemen dalam pengembangan suatu proyek di dalam industri ini memegang peranan penting dalam menentukan keberhasilan suatu proyek. Mengacu pada hal ini, analisis status finansial suatu perusahaan dibutuhkan untuk dapat memberikan gambaran kondisi finansial dari mitra kerja.

Umumnya metode penelitian terdahulu menggunakan model dengan pendekatan linier dalam pengklasifikasian perusahaan yang terindikasi mengalami kebangkrutan, padahal tidak semua variabel menunjukkan korelasi linear terhadap kesehatan finansial sebuah perusahaan.

Dalam rangka menganalisis probabilitas kebangkrutan, akan dilakukan pendekatan menggunakan kecerdasan buatan dengan menggunakan beberapa metode *heuristic* di antaranya: *artificial neural network* (ANN), *support vector machine* (SVM), dan *classification and regression tree* (CART). Tanda-tanda *financial distress* suatu perusahaan dilakukan melalui pengukuran kinerja perusahaan dengan menggunakan nilai rasio finansial dari model yang ditetapkan.

2. LANDASAN TEORI

2.1 Kegagalan Finansial (*Financial Distress*)

Almilia & Kristijadi (2003) mendefinisikan kondisi *financial distress* sebagai suatu kondisi dimana perusahaan mengalami *delisted* akibat laba bersih perusahaan dan nilai buku perusahaan bernilai negatif, maupun perusahaan telah di-merger. Menurut Lau (1987), *financial distress* terindikasi dari pemberhentian tenaga kerja maupun penghilangan pembayaran dividen, sedangkan menurut Whitaker (1999), *financial distress* didefinisikan jika tahun perusahaan mengalami laba operasi bersih bernilai negatif.

2.2 Kebangkrutan

Menurut Prihadi (2011), kebangkrutan merupakan kondisi dimana perusahaan tidak mampu lagi untuk melunasi kewajibannya. Kondisi ini biasanya tidak muncul begitu saja di perusahaan, ada indikasi awal dari perusahaan tersebut yang biasanya dapat dikenali lebih dini kalau laporan keuangan dianalisis secara lebih cermat dengan suatu cara tertentu. Rasio keuangan dapat digunakan sebagai indikasi adanya kebangkrutan di perusahaan.

Faktor penyebab kebangkrutan terdiri dari faktor eksternal dan faktor internal. Faktor-faktor penyebab kebangkrutan perusahaan yang berasal dari luar (eksternal) menurut Weston dan Copeland (1992) terdiri dari faktor ekonomi, sosial, dan pemerintah. Faktor-faktor yang berasal dari dalam (internal) perusahaan yang menyebabkan kebangkrutan antara lain, ketidakmampuan manajemen, desain mekanisme insentif yang buruk, dan struktur tata kelola perusahaan yang buruk (Senbet & Wang, 2012).

2.3 Penelitian yang Pernah Dilakukan

2.3.1. Prediksi Status Finansial Perusahaan dengan Metode Analisis Diskriminan (DA)

Penelitian ini dilakukan oleh Pane, Topowijono, dan Husaini (2015) dengan menggunakan metode analisis diskriminan untuk menyelidiki status finansial pada 30 sampel perusahaan jenis manufaktur dimana 10 perusahaan termasuk kategori bangkrut dan 20 perusahaan yang lain termasuk kategori tidak bangkrut. Penelitian ini dilakukan dengan menganalisis laporan keuangan untuk mendapatkan 11 variabel rasio keuangan yang ditentukan. Kemudian dilakukan uji signifikansi untuk mengetahui rasio mana saja yang secara signifikan menggambarkan status finansial (bangkrut atau tidak) suatu perusahaan.

2.3.2. Performansi Perusahaan Financial Distress dengan Metode SVM

Penelitian ini dilakukan oleh Pristiyani, Darsyah, dan Nur, (2016) dengan menggunakan dua metode, yaitu SVM dengan fungsi kernel *radial basic function* (RBF) dan *discriminant analysis* (DA) dengan variabel prediktor original dan terstandarisasi untuk mengevaluasi performa sebuah perusahaan.

Penelitian ini dilakukan dengan menganalisis 15 rasio keuangan pada perusahaan 72 yang dipilih. Kemudian dilakukan klasifikasi perusahaan yang terprediksi mengalami

financial distress dan tidak melalui metode analisis diskriminan dan SVM yang diakhiri dengan mencari rasio keuangan yang berpengaruh terhadap perusahaan yang terklasifikasi mengalami *financial distress*.

2.3.3. Prediksi Status Finansial Perusahaan Kontraktor dengan Metode AI

Penelitian ini dilakukan oleh Cheng, et al. (2014) dengan menggunakan AI berbasis SVM yang dikombinasikan dengan *least squares* (LS) untuk mengevaluasi kondisi finansial perusahaan kontraktor. Penelitian dilakukan dengan menganalisis rasio finansial perusahaan kontraktor pada 76 perusahaan kontraktor terdaftar dengan total data observasi 958 buah laporan tahunan kinerja perusahaan dengan komposisi *data training* sebesar 80% dan *data testing* sebesar 20%. Pada penelitian terdapat kondisi *imbalance data* dalam sampel, digunakan metode algoritma SMOTE untuk melakukan rekayasa sampel sehingga memberikan hasil evaluasi yang relatif lebih baik.

2.4. Metode Kecerdasan Buatan

2.4.1. Support Vector Machines (SVM)

SVM yang dikembangkan oleh Vapnik (1995) sudah banyak digunakan untuk klasifikasi, maupun prediksi. Penggunaan SVM dalam bidang teknik sipil pun juga sudah banyak dilakukan (M. Cheng, Prayogo, & Wu, 2013). SVM dapat diklasifikasikan menjadi target klasifikasi yang mempunyai 2 nilai (0 dan 1) dan target regresi yang memiliki nilai yang bersifat menerus.

2.4.2. Artificial Neural Network (ANN)

ANN merupakan suatu konsep rekayasa pengetahuan dalam bidang kecerdasan buatan yang didesain dengan mengadopsi sistem saraf manusia yang ditemukan oleh Rosenblatt (1958), di mana proses utama sistem saraf manusia berada di otak. Dalam otak manusia mengandung kurang lebih 1011 neuron dan sekitar 104 hubungan perneuron. Sebuah neuron mengandung soma (badan sel), axon (pengirim sinyal), dan dendrite (penerima sinyal). Sinapsis menghubungkan antara satu neuron dan neuron yang lain sedangkan dendrite berfungsi sebagai penerima sinyal dari neuron lain melalui sinapsis. Selain itu terdapat axon yang berfungsi meneruskan sinyal ke ujung serat yang berhubungan dengan sinapsis.

2.4.3. Classification and Regression Tree (CART)

Metode ini pertama kali diusulkan oleh Breiman, et al. (1984), dimana pada metode ini ditunjukkan bahwa *learning tree* dapat dioptimasi dengan menggunakan data set untuk memangkas pohon yang sudah jenuh dan memilih dari beberapa pohon yang masih ada. Beberapa studi sudah dilakukan menggunakan metode CART, dimana pada penelitian terdahulu tersebut tidak hanya dilakukan pada bidang teknik sipil, namun, prediksi dilakukan pada bidang kesehatan, programming matematika, dan bidang transportasi. Metode ini juga mempunyai fitur untuk mencari prediktor dan menentukan nilai ambang batas terbaik pada semua prediktor untuk mengklasifikasikan variabel target (Chou et al., 2014).

2.4.4. Metode Evaluasi AI

Dalam rangka mengukur tingkat akurasi hasil prediksi dari metode kecerdasan buatan, digunakan metode evaluasi AI *confusion matrix*. *Confusion matrix* merupakan salah satu metode yang dapat digunakan untuk mengukur kinerja suatu metode klasifikasi (Karsito & Susanti, 2019). *Confusion matrix* memberikan informasi perbandingan hasil klasifikasi seharusnya dengan hasil klasifikasi yang dilakukan oleh sistem atau permodelan. Menurut Han & Kamber (2001) dalam Fibrianda & Bhawiyuga (2018), terdapat empat istilah sebagai hasil proses klasifikasi yang dilakukan, yaitu *true positif* (TP), *true negatif* (TN), *false positif* (FP), dan *false negatif* (FN). *True positif* adalah data benar yang diprediksi benar. *True negatif* merupakan data salah yang diprediksi salah. *False positif* adalah data salah yang diprediksi benar. *False negatif* merupakan data benar yang diprediksi salah. . Tabel klasifikasi *confusion matrix* dapat terlihat pada Gambar 1.

		Predicted Class		Total
		yes	no	
Actual Class	yes	TP	FN	P
	no	FP	TN	N
Total		P'	N'	P + N

Gambar 1. Confusion matrix

2.4.5. Data Time Series

Data adalah segala fakta, angka, atau teks yang dapat diproses oleh komputer. Dimana saat ini, akumulasi perkembangan jumlah data berjalan dengan cepat dan pesat dalam format dan basis data yang berbeda. Data-data tersebut antara lain yaitu data operasional atau penjualan, seperti penjualan, inventaris, penggajian, akuntansi, dan sebagainya, data nonoprasional, seperti industri penjualan, peramalan, dan data ekonomi mikro, serta metadata yaitu data mengenai data itu sendiri, seperti desain logika basis data atau definisi kamus data. Dalam perkembangan analisis *data time series*, banyak fenomena yang menarik dan sederhana merupakan fenomena yang non-linear (hubungan antara kejadian di masa lalu dan saat ini adalah non-linear). Sehingga pemodelan data time series yang linear tidaklah cukup dan sesuai untuk menangani kasus-kasus tersebut. Sebagai konsekuensinya, model-model *time series* nonlinear telah menjadi perhatian utama para peneliti prediksi *time series* pada beberapa tahun terakhir ini. Beberapa bentuk model non-linear telah dikembangkan dan diaplikasikan pada beberapa kasus *time series*.

2.5. Penerapan Metode Prediksi dengan SPSS Clementine 12.0

SPSS Clementine 12.0 adalah satu kesatuan alat pengolah data yang memudahkan penggunaannya dalam membentuk suatu model prediksi untuk membantu membuat atau menentukan sebuah keputusan (IBM, 2022). Dalam mengolah data, SPSS Clementine 12.0 menggunakan konsep flow dan terdapat node untuk menaruh informasinya. Selain itu, SPSS Clementine 12.0 mempunyai tampilan yang unik dan mudah dimengerti, dengan demikian alat ini memudahkan user dalam membuat suatu model prediksi tanpa melakukan proses *programming* (SPSS, Inc., 2010)

Secara garis besar, proses komputasi dalam SPSS Clementine 12.0 meliputi: *input*, *partition*, *training*, *testing*, dan *output*. *Input* adalah posisi dimana data mentah yang telah di-*import* dan siap untuk diolah AI. *Partition* adalah proses pemisahan data menjadi data untuk training dan testing. Pemisahan data ini diperlukan karena tidak tersedianya data beton segar untuk dilakukan *testing* secara AI dan secara nyata di laboratorium. *Training* adalah proses pembelajaran dan penyesuaian parameter dari AI, dimana hasil dari proses *training* ini sendiri adalah suatu model prediksi yang merepresentasikan suatu Model. *Testing* adalah proses implementasi model prediksi pada data yang telah dipisah. Sedangkan *output* menampilkan data dan analisa hasil prediksi yang nantinya digunakan untuk dievaluasi apakah model prediksi dapat memprediksi dengan akurat atau tidak.

2.6. Rasio Keuangan

Menurut Kho dan Mariani (2017), analisis kinerja laporan keuangan diperlukan oleh manajemen perusahaan, kreditor, dan para investor. Kinerja keuangan perusahaan diukur dengan analisis rasio melalui laporan keuangan perusahaan. Analisis rasio untuk menilai kinerja keuangan perusahaan terdiri dari :

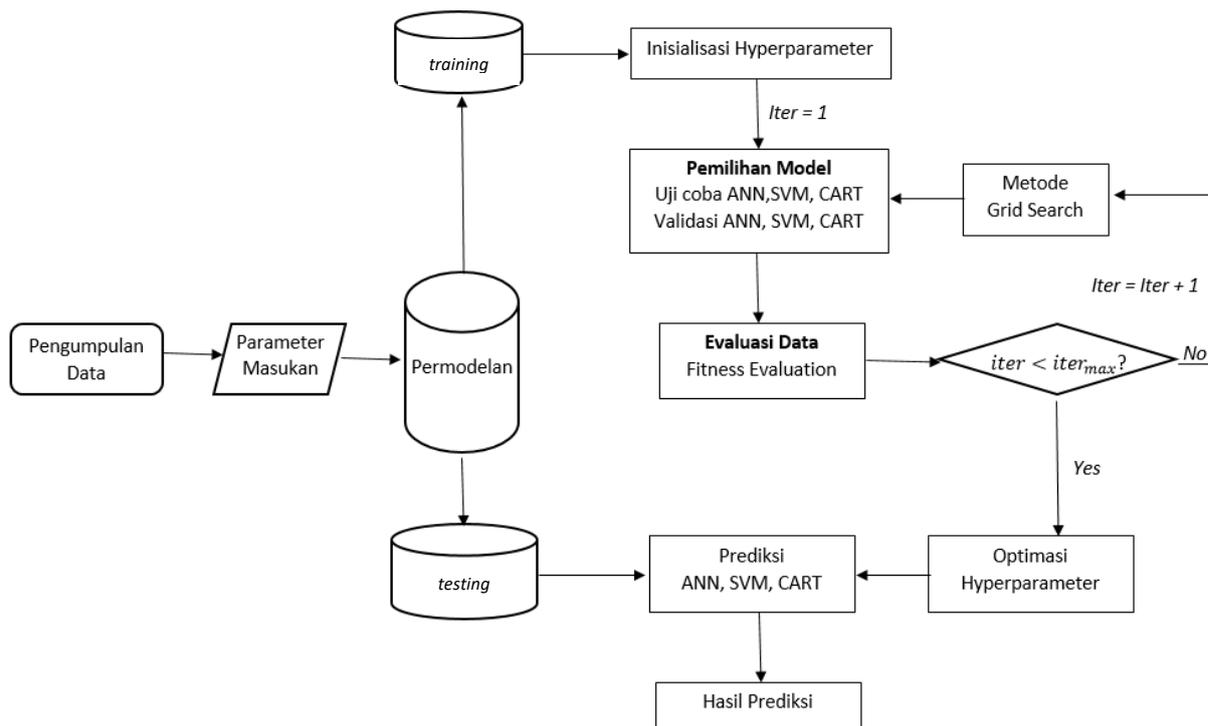
1. Rasio Likuiditas (*liquidity ratio*), yang menunjukkan kemampuan perusahaan untuk memenuhi kewajiban jangka pendek yang harus dipenuhi.
2. Rasio Solvabilitas (*leverage*), yang menunjukkan kemampuan perusahaan untuk memenuhi seluruh kewajibannya baik jangka pendek maupun jangka panjang.
3. Rasio Aktivitas (*activity ratio*), yang menunjukkan tingkat efektivitas penggunaan aset perusahaan.
4. Rasio Profitabilitas (*profitability ratio*), yang menunjukkan tingkat imbalan atau perolehan (laba) dibandingkan dengan penjualan atau aset
5. Rasio Nilai Pasar (*market value ratio*), yang menunjukkan hubungan harga saham perusahaan dengan item dalam rasio keuangan seperti nilai ekuitas, pendapatan bersih, dan sebagainya.

3. METODE PENELITIAN

Diagram alur penelitian dapat dilihat pada Gambar 2. Pengolahan data akan menggunakan alat bantu berupa SPSS Clementine dengan analisis kecerdasan buatan yang merupakan salah satu analisis dengan tujuan untuk mencari dasar *clustering* (pengelompokan) kondisi perusahaan sektor properti, konstruksi, dan industri sejenis yang terdaftar di Bursa Efek Indonesia (BEI). Berdasarkan lebih dari satu variabel yang berupa rasio-rasio keuangan. Rasio keuangan berasal dari laporan keuangan masing-masing perusahaan yang diambil dari data sepuluh tahun terakhir (2009-2019).

Tahap pertama dari penelitian ini adalah pengumpulan data. Data-data yang sudah didapatkan akan dipisahkan secara acak untuk dijadikan sampel *training* dan *testing* dengan proporsi 70:30. Dalam rangka mengolah data-data tersebut, dibutuhkan penentuan parameter awal untuk memberikan batasan kepada program. Hal ini berfungsi sebagai kontrol agar hasil analisa *machine learning* mencapai hasil yang optimal. Apabila penentuan parameter telah selesai, akan dilakukan permodelan dan analisis untuk masing-masing metode kecerdasan buatan (AI) yang telah ditentukan. Tahap ini disebut dengan tahap *Modelling*.

Setelah tahap *modelling* dilakukan, akan dilakukan proses *training* oleh *machine learning* dilanjutkan dengan *testing* untuk masing-masing metode. Akurasi hasil testing akan diuji terhadap data riil untuk mengetahui keadaan finansial perusahaan yang dianalisis. Apabila hasil menunjukkan bahwa $iter > iter_{max}$, maka akan dilakukan optimasi parameter dengan menggunakan metode *Grid Search* untuk menghasilkan hasil *training* dan *testing* yang baru. Akurasi metode kecerdasan buatan akan dibandingkan dengan cara menganalisis nilai dari 3 (tiga) parameter evaluasi kecerdasan buatan, yaitu ANN, SVM, dan CART. Setelah ditemukan hasil *testing* dari setiap metode prediksi yang ada, nilai- nilai korelasi, *error* dan *reference index* yang sudah ada dibandingkan dalam satu tabel dengan setiap metode yang digunakan pada keempat *Model* yang sudah terkumpul. Hasil prediksi akan menggambarkan tingkat akurasi dari model-model prediksi yang ada serta metode yang digunakan.



Gambar 2. Diagram alur penelitian

3.1. Parameter Awal

Penentuan parameter diperlukan agar hasil yang didapatkan dari prediksi tetap terkontrol dan tidak abstrak. *Setting* parameter diperlukan untuk semua jenis AI yang digunakan pada penelitian kali ini (ANN, SVM, dan CART). Deskripsi parameter yang akan digunakan pada penelitian ini dapat dilihat pada Tabel 1.

Tabel 1. Penentuan parameter

Prediksi	Parameter	Setting
ANN	<i>Hidden Layer</i>	1
	<i>Learning Rate</i>	0,3
	<i>Momentum</i>	0,2
	<i>Training/time</i>	500
	<i>Validation threshold</i>	20
SVM	<i>C</i>	1,0
	<i>Kernel</i>	RBF
CART	<i>Initial Court</i>	0,0
	<i>Max Depth</i>	-1
	<i>MinNum</i>	2,0
	<i>minVarlanceProp</i>	0,001
	<i>noPruning</i>	False
	<i>numFolds</i>	3
	<i>seed</i>	1

3.2. Pengaturan Parameter

Pengaturan parameter diperlukan agar hasil yang didapatkan dari prediksi tetap terkontrol dan tidak abstrak. Selain itu, tujuan adanya pengaturan parameter ini untuk mengevaluasi pengaturan parameter metode prediksi yang dapat menghasilkan prediksi yang paling akurat. Pengaturan parameter diaplikasikan untuk 3 jenis AI yang digunakan pada penelitian ini, diantaranya: ANN, SVM, dan CART. Adapun dalam penelitian ini, digunakan dua jenis parameter, yaitu parameter standar SPSS Clementine dan parameter yang dioptimasi menggunakan metode *grid search*.

3.2.1. Pengaturan Parameter Standar

Pengaturan parameter awal yang digunakan pada penelitian ini adalah pengaturan parameter standar dari SPSS Clementine 12.0. Pengaturan parameter standar dapat dilihat pada Tabel 2. Dimana angka 1 pada akhiran nama metode prediksi menjelaskan bahwa metode tersebut berjalan dengan pengaturan parameter standar.

Tabel 2. Pengaturan parameter standar pada SPSS clementine 12.0

Metode Prediksi	Parameter	Pengaturan
ANN1	<i>Prevent Over training</i>	TRUE
	<i>Alpha</i>	0.9
	<i>Persistence</i>	200
	<i>Hidden Layer</i>	1
	<i>Number of Hidden Neuron</i>	20
SVM1	<i>Epsilon</i>	1
	<i>Kernel</i>	RBF
	<i>Regularization Parameter, C</i>	10
	<i>RBF Gamma</i>	0.1
CART1	<i>Levels Below Root</i>	5
	<i>Max Surrogates</i>	5
	<i>Change in Impurity</i>	0.0001
	<i>Impurity Measure</i>	Gini
	<i>Prune Tree</i>	TRUE

3.2.2. Pengaturan Parameter dengan Optimasi *Grid Search*

Grid search adalah metode sederhana yang dapat digunakan untuk optimasi suatu parameter. Metode ini menggabungkan 2 himpunan parameter dengan bantuan produk kartesius untuk menemukan suatu kombinasi parameter baru.

Himpunan parameter yang dioptimasi pada penelitian ini didasari oleh penelitian terdahulu yang telah dilakukan oleh Christiono (2020). Pada metode ANN, parameter yang diubah adalah *number of hidden layer* dan *number of hidden neurons*. Himpunan dari parameter tersebut adalah:

$$\textit{number of hidden layers} = \{1, 2, 3\}$$

$$\textit{number of hidden neurons} = \{8, 13, 17\}$$

Masing- masing dari parameter tersebut disusun dalam sumbu X dan Y. AI melakukan training dengan parameter yang sudah diubah sesuai titik-titik pada sumbu kartesius . Dari 1 pengaturan standar SPSS Clementine 12.0 dan 9 pengaturan menggunakan *grid search*, didapatkanlah total 10 kombinasi yang digunakan pada metode ANN.

Sedangkan untuk metode SVM, parameter yang diubah adalah nilai dari C (*regularization parameter*) dan nilai dari γ (*kernel parameter*). Himpunan dari parameter C dan γ adalah :

$$C = \{1, 10, 100\}$$

$$\gamma = \{0.01, 0.1, 1\}$$

Masing-masing dari parameter tersebut disusun dalam sumbu X dan Y. AI melakukan training dengan parameter yang sudah diubah sesuai titik-titik pada sumbu kartesius. Dari 1 pengaturan standar SPSS Clementine 12.0 dan 9 pengaturan menggunakan *grid search*, didapatkanlah total 10 kombinasi yang digunakan pada metode SVM.

Pada metode CART parameter yang diubah adalah parameter "*levels below root*". "*Levels below root*" adalah:

$$\text{Levels below root} = \{6, 7, 8\}$$

Dari 1 pengaturan standar SPSS Clementine 12.0 dan 3 pengaturan menggunakan *grid search*, didapatkanlah total 4 kombinasi yang digunakan pada metode CART.

Semua pengaturan parameter ini diaplikasikan pada keempat Model yang terkumpul, setelah itu dilakukan evaluasi model prediksi dengan parameter manakah yang punya performa paling bagus memprediksi berbagai tipe Model.

4. HASIL DAN PEMBAHASAN

4.1. Model Penelitian

Pada sub-bab ini akan dijabarkan Model yang digunakan oleh peneliti. Peneliti menggunakan data dari perusahaan sektor konstruksi, properti, dan industri sejenis yang terdaftar di Bursa Efek Indonesia dalam kurun waktu 2009 sampai dengan 2019. Penelitian ini melibatkan total 92 perusahaan dari sektor-sektor terkait. Data yang tertulis dalam penelitian ini telah dijabarkan untuk setiap tahunnya, mulai dari tahun 2009 sampai dengan tahun 2019. Pada penelitian ini, terdapat dua kelompok Model, yaitu:

1. Kelompok data yang menggunakan data tahun pertama sampai dengan tahun ketiga untuk memprediksi kondisi finansial perusahaan di tahun keempat. Maka dari 11 tahun Model penelitian, akan diperoleh 8 prediksi *financial distress* untuk setiap perusahaan tercatat. Dalam Model kelompok pertama, terdapat 736 buah Model yang terdiri atas 92 perusahaan. Model terklasifikasi menjadi data yang menyatakan kondisi *financial distress* dan 514 data yang menyatakan tidak mengalami *financial distress*.
2. Kelompok data yang menggunakan data tahun pertama sampai dengan tahun kelima untuk memprediksi kondisi finansial perusahaan di tahun keenam. Maka dari 11 tahun Model penelitian, akan diperoleh 6 prediksi *financial distress* untuk setiap perusahaan tercatat. Dalam Model kelompok kedua, terdapat 552 buah Model yang terdiri atas 92 perusahaan. Model terklasifikasi menjadi 150 data yang menyatakan kondisi *financial distress* dan 402 data yang menyatakan tidak mengalami *financial distress*.

Kedua kelompok data tersebut akan dianalisis menggunakan tiga Model acuan yang digunakan sebagai input dalam melakukan prediksi kondisi finansial perusahaan, yaitu :

1. Model 1 (Pane, Topowijono, dan Husaini, 2015)
Model 1 merupakan model yang diadopsi dari penelitian yang dilakukan oleh Pane, Topowijono, dan Husaini pada tahun 2015. Model ini menggunakan 11 buah *variabel ratio* yang akan digunakan sebagai *input*. Rasio-rasio tersebut adalah: *Current Ratio*, *Quick*

Ratio, Debt to Liability Ratio, Debt to Equity Ratio, Total Asset Turnover, Inventory Turnover, Return on Asset, Return on Equity, Net Working Capital, Gross Profit Margin, dan Operating Profit Margin.

2. Model 2 (Cheng et al., 2014)

Model 2 merupakan model yang diadopsi dari penelitian yang dilakukan oleh Cheng, Hong, Limanto pada tahun 2014. Berbeda dengan penelitian terdahulu, model ini menggunakan tujuh belas dari total dua puluh buah variabel rasio sebagai *input*. Rasio-rasio tersebut adalah: *Current Ratio, Quick Ratio, Net Working Capital to Total Assets, Current Asset to Net Assets, Total Liabilities to Net Worth, Retained Earnings to Sales, Debt to Liability Ratio, Revenues to Net Working Capital, Fixed Assets to Net Worth, Sales to Net Worth, Revenues to Fixed Assets, Profits to Net Working Capital, Accounts Receivable Turnover, Accounts Payable Turnover, Return on Equity, Return on Sales, dan Earning per Share*. Adapun 3 buah variabel yang tidak digunakan adalah: *Time Interest Earned, Quality of Inventory, dan Turnover of Total Assets*. Ketiga rasio tersebut tidak digunakan dalam analisis model dikarenakan keterbatasan sumber data.

3. Model 3 (Pristiyani, Darsyah, dan Nur, 2016)

Model 3 merupakan model yang diadopsi dari penelitian yang dilakukan oleh Pristiyani, Darsyah, dan Nur pada tahun 2016. Berbeda dengan penelitian terdahulu yang menggunakan 15 buah variabel rasio, model ini menganalisis 14 buah variabel rasio sebagai input. Variabel rasio yang digunakan adalah: *Current Ratio, Quick Ratio, Debt to Equity Ratio, Debt to Asset Ratio, Debt Turnover, Total Asset Turnover, Fixed Asset Turnover, Current Asset Turnover, Inventory Turnover, Return on Asset, Return on Equity, Net Profit Margin, Gross Profit Margin, Earning per Share, dan Price to Book Values*. Sedangkan variabel rasio yang tidak digunakan dalam analisis model adalah *Debt Turnover Ratio*. Hal ini dikarenakan keterbatasan sumber data.

4.2. Data Pre-Processing

Pre proses data merupakan proses penyaringan dari data mentah menjadi data yang siap diolah. Pada penelitian ini, pre proses data dilakukan karena terdapat beberapa data yang hilang (rasio keuangan) dari sumber data, dimana *software SPSS Clementine* tidak mampu melakukan proses prediksi apabila terdapat data hilang. Hal ini mengakibatkan dibutuhkannya koreksi dari data mentah agar menjadi data siap olah. Pre proses data dilakukan dengan menghilangkan seluruh input data tahun $n-1$, $n-2$, $n-3$, dan output data tahun ke n apabila terdapat rasio keuangan yang hilang di antara data tahun $n-1$, $n-2$, dan $n-3$. n merupakan tahun prediksi kondisi finansial perusahaan. Hasil pre proses data yang digunakan dalam penelitian ini dapat dilihat pada Tabel 3. Proses ini dilakukan dengan tiga model prediksi, yaitu Model 1 mewakili data dari Pane, Topowijono, dan Husaini, 2015, Model 2 mewakili data dari Cheng et al., 2014, Model 3 mewakili data dari Pristiyani, Darsyah, dan Nur, 2016. Penjelasan mengenai ketiga data ini dapat terlihat pada landasan teori.

Tabel 3. Hasil pre proses data

Model	Total Jumlah Data Mentah		Total Jumlah Data Hilang		Jumlah Data Final	
	Pred. 3 Tahun	Pred. 5 Tahun	Pred. 3 Tahun	Pred. 5 Tahun	Pred. 3 Tahun	Pred. 5 Tahun
Model 1	736	552	508	419	228	133
Model 2	736	552	442	360	294	192
Model 3	736	552	460	374	276	178

4.3. Hasil Prediksi untuk Setiap Model

4.3.1. Model 1 (Pane, Topowijono, dan Husaini, 2015)

Hasil prediksi model 1 dapat dilihat pada Tabel 4 untuk metode ANN, Tabel 5 untuk metode SVM, dan Tabel 6 untuk metode CART. Dari hasil yang diperoleh, ANN3 memiliki performa terbaik pada prediksi data 3 tahunan dan ANN1 – ANN10 memiliki performa yang sama baiknya pada prediksi 5 tahunan karena memiliki nilai prediksi benar yang setara. Mengacu pada hasil analisis AI, seluruh metode SVM selain SVM 3 memiliki performa setara pada prediksi data 3 tahunan dan SVM8, SVM9, dan SVM10 memiliki performa terbaik pada prediksi 5 tahunan. CART1 memiliki performa terbaik pada prediksi data 3 tahunan yang ditunjukkan dengan persentase prediksi benar tertinggi dibandingkan dengan permodelan CART lainnya., sedangkan pada prediksi data 5 tahunan, semua metode CART memiliki tingkat akurasi prediksi setara.

Tabel 4. Hasil prediksi ANN untuk model 1

Model	Metode	Hasil Pred. 3 Tahunan		Hasil Pred. 5 Tahunan	
		Benar	Salah	Benar	Salah
Model 1 (ANN)	ANN1	72.06%	27.94%	78.05%	21.95%
	ANN2	72.06%	27.94%	78.05%	21.95%
	ANN3	76.47%	23.53%	78.05%	21.95%
	ANN4	72.06%	27.94%	78.05%	21.95%
	ANN5	73.53%	26.47%	78.05%	21.95%
	ANN6	75.00%	25.00%	78.05%	21.95%
	ANN7	75.00%	25.00%	78.05%	21.95%
	ANN8	75.00%	25.00%	78.05%	21.95%
	ANN9	72.06%	27.94%	78.05%	21.95%
	ANN10	73.53%	26.47%	78.05%	21.95%

Tabel 5. Hasil prediksi SVM untuk model 1

Model	Metode	Hasil Pred. 3 Tahunan		Hasil Pred. 5 Tahunan	
		Benar	Salah	Benar	Salah
Model 1 (SVM)	SVM1	72.06%	27.94%	68.29%	31.71%
	SVM2	72.06%	27.94%	75.61%	24.39%
	SVM3	70.59%	29.41%	73.17%	26.83%
	SVM4	72.06%	27.94%	73.17%	26.83%
	SVM5	72.06%	27.94%	65.85%	34.15%
	SVM6	72.06%	27.94%	68.29%	31.71%
	SVM7	72.06%	27.94%	65.85%	34.15%
	SVM8	72.06%	27.94%	78.05%	21.95%
	SVM9	72.06%	27.94%	78.05%	21.95%
	SVM10	72.06%	27.94%	78.05%	21.95%

Tabel 6. Hasil prediksi CART untuk model 1

Model	Metode	Hasil Pred. 3 Tahunan		Hasil Pred. 5 Tahunan	
		Benar	Salah	Benar	Salah
Model 1 (CART)	CART 1	70.59%	29.41%	75.61%	24.39%
	CART 2	67.65%	32.35%	75.61%	24.39%
	CART 3	67.65%	32.35%	75.61%	24.39%
	CART 4	67.65%	32.35%	75.61%	24.39%

4.3.2. Model 2 (Cheng et al., 2014)

Hasil prediksi model 2 terdapat pada Tabel 7 untuk metode ANN, Tabel 8 metode SVM, dan Tabel 9 metode CART. Hasil menunjukkan, ANN2 memiliki performa terbaik pada prediksi data 3 tahunan dan ANN4 memiliki performa terbaik pada prediksi 5 tahunan. Mengacu pada hasil analisis AI, metode SVM5 memiliki performa terbaik pada prediksi data 3 tahunan dan SVM8, SVM9, dan SVM10 memiliki performa terbaik pada prediksi 5 tahunan. Seluruh metode CART memiliki performa yang sama baiknya pada siklus data 3 tahunan dan 5 tahunan.

Tabel 7. Hasil prediksi ANN untuk model 2

Model	Metode	Hasil Pred. 3 Tahunan		Hasil Pred. 5 Tahunan	
		Benar	Salah	Benar	Salah
Model 2 (ANN)	ANN1	78.57%	21.43%	78.69%	21.31%
	ANN2	83.33%	16.67%	73.77%	26.23%
	ANN3	80.95%	19.05%	67.21%	32.79%
	ANN4	82.14%	17.86%	80.33%	19.67%
	ANN5	76.19%	23.81%	77.05%	22.95%
	ANN6	79.76%	20.24%	68.85%	31.15%
	ANN7	79.76%	20.24%	78.69%	21.31%
	ANN8	82.14%	17.86%	75.41%	24.59%
	ANN9	82.14%	17.86%	72.31%	27.69%
	ANN10	79.76%	20.24%	77.05%	22.95%

Tabel 8. Hasil prediksi SVM untuk model 2

Model	Metode	Hasil Pred. 3 Tahunan		Hasil Pred. 5 Tahunan	
		Benar	Salah	Benar	Salah
Model 2 (SVM)	SVM1	80.95%	19.05%	75.41%	24.59%
	SVM2	82.14%	17.86%	55.74%	44.26%
	SVM3	82.14%	17.86%	55.74%	44.26%
	SVM4	82.14%	17.86%	55.74%	44.26%
	SVM5	83.33%	16.67%	55.74%	44.26%
	SVM6	80.95%	19.05%	75.41%	24.59%
	SVM7	70.24%	29.76%	73.77%	26.23%
	SVM8	78.57%	21.43%	73.77%	26.23%
	SVM9	77.38%	22.62%	73.77%	26.23%
	SVM10	77.38%	22.62%	73.77%	26.23%

Tabel 9. Hasil prediksi CART untuk model 2

Model	Metode	Hasil Pred. 3 Tahunan		Hasil Pred. 5 Tahunan	
		Benar	Salah	Benar	Salah
Model 2 (CART)	CART 1	85.71%	14.29%	77.05%	22.95%
	CART 2	85.71%	14.29%	77.05%	22.95%
	CART 3	85.71%	14.29%	77.05%	22.95%
	CART 4	85.71%	14.29%	77.05%	22.95%

4.3.3. Model 3 (Pristiyani, Darsyah, dan Nur, 2016)

Prediksi model 3 dapat dilihat pada Tabel 10 untuk metode ANN, Tabel 11 metode SVM, dan Tabel 12 metode CART. Hasil yang diperoleh, performa terbaik ANN6 dan ANN9 pada prediksi data 3 tahunan dan ANN3 dalam prediksi 5 tahunan. Metode SVM8, SVM9, dan SVM10 pada prediksi data 3 tahunan dan SVM3 pada prediksi 5 tahunan. CART1 memiliki performa terbaik pada prediksi data 3 tahunan dibandingkan dengan permodelan CART lainnya, pada prediksi data 5 tahunan, CART memiliki tingkat akurasi prediksi setara.

Tabel 10. Hasil prediksi ANN untuk model 3

Model	Metode	Hasil Pred. 3 Tahunan		Hasil Pred. 5 Tahunan	
		Benar	Salah	Benar	Salah
Model 3 (ANN)	ANN1	68.75%	31.25%	57.14%	42.86%
	ANN2	66.25%	33.75%	62.50%	37.50%
	ANN3	70.00%	30.00%	69.64%	30.36%
	ANN4	70.00%	30.00%	67.86%	32.14%
	ANN5	68.75%	31.25%	57.14%	42.86%
	ANN6	71.25%	28.75%	66.07%	33.93%
	ANN7	70.00%	30.00%	67.86%	32.14%
	ANN8	68.75%	31.25%	58.93%	41.07%
	ANN9	71.25%	28.75%	62.50%	37.50%
	ANN10	70.00%	30.00%	62.50%	37.50%

Tabel 11. Hasil prediksi SVM untuk model 3

Model	Metode	Hasil Pred. 3 Tahunan		Hasil Pred. 5 Tahunan	
		Benar	Salah	Benar	Salah
Model 3 (SVM)	SVM1	67.50%	32.50%	58.93%	41.07%
	SVM2	62.50%	37.50%	64.29%	35.71%
	SVM3	61.25%	38.75%	66.07%	33.93%
	SVM4	68.75%	31.25%	55.36%	44.64%
	SVM5	62.50%	37.50%	62.50%	37.50%
	SVM6	67.50%	32.50%	58.93%	41.07%
	SVM7	68.75%	31.25%	55.36%	44.64%
	SVM8	72.50%	27.50%	55.36%	44.64%
	SVM9	72.50%	27.50%	55.36%	44.64%
	SVM10	72.50%	27.50%	55.36%	44.64%

Tabel 12. Hasil prediksi CART untuk model 3

Model	Metode	Hasil Pred. 3 Tahunan		Hasil Pred. 5 Tahunan	
		Benar	Salah	Benar	Salah
Model 3 (CART)	CART 1	73.75%	26.25%	62.50%	37.50%
	CART 2	72.50%	27.50%	62.50%	37.50%
	CART 3	71.25%	28.75%	62.50%	37.50%
	CART 4	71.25%	28.75%	62.50%	37.50%

4.4. Studi Perbandingan Metode AI antar Model

Tabel 13. Menunjukkan hasil untuk masing-masing Model pada hasil prediksi tiga tahun. Metode terbaik untuk pengolahan data pada Model 1 adalah metode ANN. Metode ini memprediksi benar sebesar 76,47% dari keseluruhan data yang diperoleh. Sedangkan metode terbaik untuk Model 2 dan Model 3 adalah metode CART. Tingkat akurasi pengolahan data dengan metode CART pada kedua data menjadi alasan mengapa metode ini adalah metode yang terbaik pada Model 2 dan Model 3.

Tabel 13. Hasil perbandingan model prediksi 3 tahun

Model	Model Prediksi	True Positif	True Negatif	False Negatif	False Positif	BENAR	RANK
1	ANN	48	4	1	15	76.47%	1
	SVM	48	1	1	18	72.06%	2
	CART	42	6	13	7	70.59%	3
2	ANN	60	10	6	8	83.33%	2
	SVM	60	10	6	8	83.33%	2
	CART	62	10	4	8	85.71%	1
3	ANN	48	9	10	13	71.25%	3
	SVM	56	2	2	20	72.50%	2
	CART	48	11	10	11	73.75%	1

Dari hasil yang ditunjukkan dapat terlihat bahwa hasil akurasi terbaik untuk hasil prediksi tiga tahunan adalah dengan menggunakan metode CART. Hal ini dibuktikan dengan tingkat akurasi CART yang paling tinggi pada dua dari tiga Model. Meskipun model CART memiliki akurasi tinggi, model prediksi CART pada setiap Model tidak konsisten. Dapat terlihat pada Model 1 metode terbaik adalah dengan metode ANN. Model 2 dan Model 3 memiliki metode terbaik adalah model prediksi CART. Melalui hasil yang diperoleh, dapat disimpulkan bahwa setiap metode memerlukan pengaturan parameter yang tepat untuk memperoleh hasil akurasi yang paling akurat. Hal ini berkaitan dengan setiap pengaturan parameter yang tidak selalu memberikan hasil yang optimal untuk setiap Model.

Tabel 14. Menunjukkan hasil untuk setiap Model pada hasil prediksi 5 tahun. Melalui tabel kita dapat melihat bahwa metode terbaik untuk Model 1 Model 2, Model 3 adalah metode ANN.

Tabel 14. Hasil perbandingan model prediksi 5 tahun

Model	Model Prediksi	True Positif	True Negatif	False Negatif	False Positif	BENAR	RANK
1	ANN	32	0	0	9	78.05%	1
	SVM	32	0	0	9	78.05%	1
	CART	27	4	5	5	75.61%	2
2	ANN	44	5	2	10	80.33%	1
	SVM	43	3	3	12	75.41%	3
	CART	41	6	5	9	77.05%	2
3	ANN	32	7	0	17	69.64%	1
	SVM	22	15	10	9	66.07%	2
	CART	26	9	6	15	62.50%	3

Tingkat akurasi ANN yang paling tinggi pada tiga dari tiga Model. Dalam hasil yang diperoleh pada prediksi lima tahun, dapat terlihat bahwa metode ANN memiliki prediksi yang konsisten pada setiap Model. Hal ini dapat terlihat dari data yang ditunjukkan pada Model 1, 2, dan 3 yang menunjukkan bahwa hasil terbaik didapatkan dari metode ANN.

Jika Tabel 13. untuk hasil prediksi tiga tahun dan Tabel 14. untuk hasil prediksi lima tahun dibandingkan maka akan diketahui metode terbaik untuk masing-masing Model. Pada Model 1 dapat terlihat bahwa menggunakan metode ANN dengan data lima tahun akan menghasilkan tingkat akurasi 1,58% lebih tinggi dari data tiga tahun. Sementara itu, metode terbaik untuk Model 2 adalah metode CART dengan data tiga tahun. Tingkat akurasi yang diperoleh adalah 85,71%. Metode terbaik untuk Model 3 adalah metode CART dengan data (tiga tahun. Metode ini memiliki tingkat akurasi sebesar 73,75%.

Pada Tabel 15. dapat dilihat indikator rasio keuangan pada masing-masing Model. Dapat dilihat bahwa Model 2 dari Cheng,et.al (2014) memiliki jenis rasio keuangan terbanyak yang membuat Model 2 memiliki tingkat akurasi tertinggi dibandingkan dengan Model yang lainnya. Dimana akurasi prediksi data pada tiga tahun mampu mencapai rasio 85,71% dengan metode CART sedangkan pada lima tahun mencapai rasio 80,33% dengan metode ANN. Model 2 memiliki tingkat akurasi tertinggi dikarenakan memiliki data variabel ratio terbanyak, yaitu tujuh belas data. Sedangkan Model 1 hanya memiliki sebelas variabel ratio dan Model 3 memiliki empat belas variabel ratio. Selain itu, data pada Model 2 diambil pada industri konstruksi Taiwan yang cenderung lebih stabil dari industri konstruksi di Indonesia. Sehingga

memiliki data penyajian yang lebih lengkap dan mencerminkan dunia industri konstruksi. Industri konstruksi memiliki sifat stokastik dan banyak ketidakpastian yang menyebabkan sulitnya memprediksi nilai *revenue* dalam satu periode waktu. Hal ini menyebabkan jumlah data yang diambil tidak mempengaruhi tingkat akurasi data seperti yang terlihat pada hasil penelitian yang menunjukkan bahwa tingkat akurasi data tiga tahun lebih tinggi dari data lima tahun. Hal ini disebabkan juga oleh kedekatan waktu pengambilan data dengan keadaan dilakukannya penelitian.

Tabel 15. Rasio keuangan yang digunakan pada model

Jenis Rasio	Pane, Topowijono, Husaini (2015)	Cheng, et.al. (2014)	Pristiyani, Darsyah, Nur (2016)
Liquidity Ratio			
<i>Current ratio</i>	v	v	v
<i>Quick ratio</i>	v	v	v
Solvability Ratio			
<i>Net working capital to total assets</i>		v	
<i>Current asset to net assets</i>		v	
<i>Total liabilities to net worth</i>		v	
<i>Retained earnings to sales</i>		v	
<i>Debt to liability ratio</i>	v	v	
<i>Debt to equity ratio</i>	v		v
<i>Debt to asset ratio</i>			v
<i>Times interest earned</i>		v	
<i>Revenues to net working capital</i>		v	
<i>Fixed assets to net worth</i>		v	
<i>Sales to net worth</i>		v	
<i>Revenues to fixed assets</i>		v	
<i>Profits to net working capital</i>		v	
Activity Ratio			
<i>Accounts recievable turnover</i>		v	
<i>Accounts payable turnover</i>		v	
<i>Debt turnover</i>			v
<i>Total asset turnover</i>	v		v
<i>Fixed asset turnover</i>			v
<i>Current asset turnover</i>			v
<i>Inventory turnover</i>	v		v
<i>Quality of inventory</i>		v	
<i>Turnover of total assets</i>		v	
Profitability Ratio			
<i>Return on asset</i>	v		v
<i>Return on equity</i>	v	v	v
<i>Return on sales</i>		v	
<i>Net Working capital</i>	v		

Tabel 15. Rasio keuangan yang digunakan pada model (Lanjutan)

Jenis Rasio	Pane, Topowijono, Husaini (2015)	Cheng, et.al. (2014)	Pristiyani, Darsyah, Nur (2016)
<i>Net Profit Margin</i>			v
<i>Gross Profit Margin</i>	v		v
<i>Operating Profit Margin</i>	v		
Market Value Ratio			
<i>Earning per share</i>		v	v
<i>Price to book values</i>			v

5. KESIMPULAN DAN SARAN

Penelitian menunjukkan bahwa hasil prediksi terbaik pada data tiga tahun adalah Model 2 dengan metode CART sebesar 85,71% dan data lima tahun oleh Model 2 dengan metode ANN sebesar 80,33%. Metode ANN memiliki tingkat akurasi tertinggi terbanyak dibandingkan dengan metode prediksi lainnya. Metode CART memiliki tingkat akurasi tertinggi yaitu sebesar 85,71%. Model 2 dari Cheng et al. (2014) memiliki tingkat akurasi tertinggi dibandingkan dengan prediksi lainnya. Hasil prediksi tiga tahun memiliki tingkat akurasi sebesar 85,71% dengan metode CART. Hasil prediksi lima tahun memiliki tingkat akurasi sebesar 80,33% dengan metode ANN. Tingkat akurasi tertinggi untuk Model 1 diperoleh dengan metode ANN lima tahun. Tingkat akurasi tertinggi untuk Model 2 diperoleh dengan metode CART tiga tahun. Tingkat akurasi tertinggi untuk Model 3 diperoleh dengan metode CART tiga tahun.

Terdapat beberapa faktor penyebab yang menyebabkan Model 2 dari Cheng et al. (2014) memiliki tingkat akurasi tertinggi. Faktor yang pertama dikarenakan Model 2 memiliki data variabel ratio terbanyak dibandingkan dengan dua Model lainnya, yaitu sebanyak tujuh belas data. Faktor kedua adalah Data yang diambil pada Model 2 berasal dari industri konstruksi di Taiwan. Industri konstruksi di Taiwan cenderung lebih stabil dibandingkan di Indonesia. Hal ini menyebabkan data penyajian lebih lengkap dan mencerminkan dunia industri konstruksi. Faktor yang terakhir, Tingkat akurasi data tiga tahun lebih tinggi dari data lima tahun disebabkan oleh kedekatan waktu pengambilan data dengan kegiatan penelitian. Namun, hal ini tidak menjamin bahwa data tiga tahun pasti lebih baik dari lima tahun dan sebaliknya. Hal ini dikarenakan, sifat stokastik dan banyaknya ketidakpastian yang menyebabkan sulitnya memprediksi nilai *revenue* dalam satu periode waktu.

Setelah melakukan penelitian ini berikut merupakan beberapa saran yang dapat dipakai sebagai bahan pertimbangan untuk penelitian selanjutnya :

1. Penelitian dengan metode SVM, CART, dan ANN kedepannya diharapkan dapat melakukan optimasi menggunakan metode yang lebih *advance* dalam melakukan *turning parameter*. Hal ini bertujuan untuk menentukan parameter AI yang memiliki pengaruh paling signifikan dalam memprediksi kebangkrutan pada perusahaan properti, konstruksi dan industri sejenis yang terdaftar di BEI.

2. Peneliti kedepannya diharapkan dapat melakukan proses optimasi untuk menentukan variabel rasio yang paling berpengaruh dalam memprediksi kebangkrutan pada perusahaan properti, konstruksi dan industri sejenis yang terdaftar di BEI.

6. DAFTAR REFERENSI

- Almilia, L., S. & Kristijadi (2003). "Analisis Rasio Keuangan untuk Memprediksi Kondisi Financial Distress Perusahaan Manufaktur yang Terdaftar di Bursa Efek Jakarta." *Jurnal Akuntansi & Auditing Indonesia*, 2.
- Breiman, L., Friedman, J., Stone, C. J., & A., O. R. (1984). *Classification and Regression Trees*. Chapman & Hall/CRC.
- Calandro, J. (2007). "Considering the Utility of Altman's Z-Score as a Strategic Assessment and Performance Management Tool." *Strategy & Leadership*, 35 (5), 37-43.
- Cheng, M. -Y., Hoang, N. D., Limanto, L., & Wu, Y.-W. (2014). "A Novel Hybrid Intelligent Approach for Contract Default Status Prediction." *Journal of Knowledge-Based Systems*, 71, 314-321.
- Cheng, M.-Y., Prayogo, D., & Wu, Y.-W. (2013). "Novel Genetic Algorithm-Based Evolutionary Support Vector Machine for Optimizing High-Performance Concrete Mixture." *Journal of Computing in Civil Engineering*, 28(4).
- Christiono, Nico. (2020). *Perbandingan Kinerja Metode Artificial Intelligence dalam Memprediksi Kuat Tekan Beton*. (Unpublished master's thesis). Universitas Kristen Petra.
- Chou, J. S., Tsai, C. F., Pham, A. D., & Lu, Y. H. (2014). "Machine Learning in Concrete Strength Simulations: Multi-Nation Data Analytics." *Journal of Construction and Building Materials*, 73, 771–780.
- Chou, J.S., Tsai, C.F., Pham, A.D., & Taharawa, I.A. (2011). "Optimizing the Prediction Accuracy of Concrete Compressive Strength based on a Comparison of Data-Mining Techniques." *Journal of Computing in Civil Engineering*, 25(3), 242-253.
- Creswell, J. W. (2014). *Research Design 4th Edition: Qualitative, Quantitative, and Mixed Methods Approaches*. SAGE Publications, Inc.
- Fibrianda, Mercury F., & Bhawiyuga, Adhitya. (2018). "Analisis Perbandingan Akurasi Deteksi Serangan pada Jaringan Komputer dengan Metode Naïve Bayes dan Support Vector Machine (SVM)." *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 2(9), 3112-3123.
- Han, J. & Kamber, M. (2001). *Data Mining: Concepts and Techniques Tutorial*. Morgan Kaufman Publisher.
- J. Chou, C. Chiu, M. Farfoura, I. A.-T. (2011). "Optimizing the Prediction Accuracy of Concrete Compressive Strength Based on a Comparison of Data-Mining Techniques." *Journal of Computing in Civil Engineering*, 30(4), 1–11.
- Karsito, & Susanti, Santi. (2019). "Klasifikasi Kelayakan Peserta Pengajuan Kredit Rumah dengan Algoritma Naïve Bayes di Perumahan Azzura Residencia." *Jurnal Teknologi Pelita Bangsa*, 9(3), 43-48.
- Kho, S. H., & Mariani, F. I. (2017). *Financial Management Canvas*. Elex Media Komputindo.
- Lau, A. H. (1987). "A Five State Financial Distress Prediction Model." *Journal of Accounting Research*, 25, 127-138.

- Pane, R. A., Topowijono, & Husaini, A. (2015). "Analisis Diskriminan untuk Memprediksi Kebangkrutan Perusahaan." *Jurnal Administrasi Bisnis*, 27.
- Prihadi, T. (2011). *Analisis Laporan Keuangan Teori dan Aplikasi*. Penerbit PPM.
- Pristiyani, Darsyah, M. Y., & Nur, I. M. (2016). "Performansi Perusahaan Finansial Distress dengan Metode Support Vector Machine." *Statistika*, 4.
- Ramadhani, A. S. & Lukviarman, N. (2009). "Perbandingan Analisis Prediksi Menggunakan Model Altman Pertama, Altman Revisi, dan Altman Modifikasi dengan Ukuran dan Umur Perusahaan sebagai Variabel Penjelas (Studi pada Perusahaan Manufaktur yang Terdaftar di Bursa Efek Indonesia)." *Jurnal Siasat Bisnis*, 13(1), 15-28.
- Roman Timoofoev. (2004). *Classification and Regression Trees (CART) Theory and Applications*. Humboldt University.
- Rosenblatt, F. (1958). "The Perceptron: a Probabilistic Model for Information Storage and Organization in The Brain." *Psychological Review*, 65(6), 386–408.
- Senbet, L. W., & Wang, T. Y. (2012). *Corporate Financial Distress and Bankruptcy: a Survey*. Now Publishers.
- SPSS, Inc., U. (2010). *IBM SPSS Modeler 18.0 User's Guide*.
- SPSS Clementine. (n.d.). *IBM*.
- Sugiyono. (2014). *Metode Penelitian Pendidikan Pendekatan Kualitatif, Kuantitatif, dan R&D*. Alfabeta.
- Sugiyono. (2017). *Metode Penelitian Bisnis*. Alfabeta.
- Van Horne, J. C., & Wachowicz, J. M. (2008). *Fundamental of Financial Management*. 13th edition. Pearson.
- Vapnik, V. (1995). *The Nature of Statistical Learning Theory*. Springer-Verlag New York, Inc.
- Weston, J. F., & Copeland, T. E. (1992). *Manajemen Keuangan*. Erlangga.
- Whitaker, B., Richard. (1999). "The Early Stages of Financial Distress." *Journal of Economics and Finance*, 23(2), 123-133.
- IBM. (2022, July 7). *Why IBM SPSS software?*. <https://www.ibm.com/analytics/spss-statistics-software>