

Prediksi *Timing Financial Distress* Pada Bank Perkreditan Rakyat di Indonesia Menggunakan *Machine Learning*

Maysas Yafi' Urrochman^{1*}, Endang Setyati², Yosi Kristian³
Departemen Informatika, Institut Sains dan Teknologi Terpadu Surabaya, Surabaya, Indonesia

*e-mail *Corresponding Author*: maysasyafi@gmail.com

Abstract

There is no system that can provide early warning of financial problems that threaten the operations of Rural Banks (BPR), so it is necessary to predict the timing of financial distress in BPRs in Indonesia using a two-stage classification and regression technique. Researchers used BPR financial report data in Indonesia for 4 years as a research sample, with a total of 150 Financial Ratio Data, consisting of 50 bankrupt financial ratio data and 100 non-bankrupt BPRs. Data analysis was carried out 2 years before being declared bankrupt. The target classification is divided into 5 classes: very healthy, healthy, moderately healthy, less healthy, distressed. The results of the study concluded: a two-stage classification and regression technique can be used to predict the timing of financial distress. This is evidenced by the results of the MLP Classifier classification with an accuracy rate of f1-score of 87%. The results of the evaluation of timing predictions using Random Forest Regression showed a mean absolute error of 1.8 months and a mean absolute percentage error of 4%.

Keywords: Rural Banks; Financial Distress; Random Forest Regression; Support Vector Machine

Abstrak

Belum ada suatu sistem yang dapat memberikan peringatan dini adanya permasalahan keuangan yang mengancam operasional Bank Perkreditan Rakyat (BPR), sehingga perlu memprediksi *timing financial distress* pada BPR di Indonesia menggunakan teknik dua tahap klasifikasi dan regresi. Peneliti menggunakan data laporan keuangan BPR di Indonesia selama 4 tahun sebagai sampel penelitian, dengan jumlah data 150 Data Rasio Keuangan, terdiri dari 50 Data rasio keuangan Pailit dan 100 BPR tidak pailit. Analisis Data dilakukan 2 tahun sebelum dinyatakan Pailit. Target klasifikasi dibagi menjadi 5 kelas: sangat sehat, sehat, cukup sehat, kurang sehat, distress. Hasil penelitian menyimpulkan: teknik dua tahap klasifikasi dan regresi dapat digunakan untuk memprediksi *timing financial distress*. Ini dibuktikan dengan hasil klasifikasi MLP *Classifier* dengan tingkat akurasi *f1-score* sebesar 87%. Hasil evaluasi prediksi *timing* menggunakan *Random Forest Regression* menunjukkan hasil *mean absolute error* sebesar 1,8 bulan dan hasil *mean absolute percentage error* sebesar 4%.

Kata Kunci: *Bank Perkreditan Rakyat; Financial Distress; Random Forest Regression; Support Vector Machine*

1. Pendahuluan

Salah satu risiko utama yang dihadapi oleh Bank Perkreditan Rakyat adalah risiko kebangkrutan atau *financial distress* [1]. *Financial distress* adalah kondisi ketika sebuah perusahaan mengalami krisis keuangan dan gagal memenuhi kewajiban debitur karena tidak memiliki dana untuk meneruskan bisnis mereka [2]. *Financial distress* merupakan risiko yang harus diwaspadai oleh lembaga keuangan, termasuk Bank Perkreditan Rakyat di Indonesia [3]. Risiko ini dapat terjadi akibat berbagai faktor, seperti penurunan kualitas aset, pengelolaan likuiditas yang buruk, perubahan kondisi ekonomi, dan lain sebagainya [4]. Oleh karena itu, penting untuk dilakukan upaya untuk memprediksi tingkat *financial distress* pada Bank Perkreditan Rakyat agar dapat diambil tindakan yang tepat untuk mengurangi risiko tersebut. Kondisi ini disertai dengan penurunan laba serta aset tetap dan biasanya terjadi menjelang

kebangkrutan [5]. Kebangkrutan merupakan situasi dimana perusahaan tidak sanggup lagi untuk menjalankan kewajibannya [6]. Terdapat indikasi awal sebelum terjadinya *financial distress*, yakni biasanya dapat diketahui lebih dini dengan melihat laporan keuangan secara cermat kemudian diolah menggunakan metode atau cara tertentu [7]. Salah satunya dengan melihat rasio keuangan yang dapat digunakan sebagai indikasi awal adanya potensi *financial distress* yang mungkin bisa berdampak terhadap kebangkrutan perusahaan [8].

Menurut Undang-undang No.4 tahun 1998 tentang kepailitan, Bank yang berstatus pailit adalah bank yang berada pada situasi legal *bankruptcy* dimana perusahaan dinyatakan pailit secara sah oleh Pengadilan [9]. Setiap tahunnya terdapat data bahwa Bank Perkreditan Rakyat mengalami proses likuidasi ataupun selesai dilikuidasi, seperti data yang ditunjukkan pada laman <https://www.lps.go.id> 5 tahun terakhir bahwa sebanyak kurang lebih 100 Bank Perkreditan Rakyat di seluruh wilayah Indonesia [10]. Hal ini menunjukkan bahwa perlu adanya suatu system yang digunakan oleh perbankan khususnya pada Bank Perkreditan Rakyat untuk mencegah terjadinya *financial distress* yang kemungkinan berdampak terhadap keberlangsungan usaha Bank Perkreditan Rakyat. Namun sampai pada saat ini belum ada program yang digunakan untuk memprediksi *timing financial distress* perbankan khususnya di Bank Perkreditan Rakyat sebagai bentuk *early warning* adanya potensi masalah kesehatan keuangan pada Bank Perkreditan Rakyat.

Sejumlah penelitian yang berkaitan tentang prediksi *timing financial distress* telah banyak menerapkan teknik data mining untuk menemukan pengetahuan yang berguna secara otomatis berdasarkan penilaian terhadap penilaian manajemen resiko-resiko yang ada pada suatu perusahaan [11]. Dalam proses penilaian resiko sebenarnya pengetahuan dari para ahli masih dianggap sebagai tugas penting karena prediksi para ahli tergantung pada subjektivitas mereka [12].

Penelitian ini merupakan pengembangan dari penelitian Budiwati et al tahun 2021 [10] dalam penelitiannya yang berjudul *Bankruptcy Prediction Model Conventional Bank Rural Banks in Indonesia*. Data yang digunakan meliputi rasio keuangan, antara lain APYDAP, NPL, ROE, BOPO, NIM, LDR, IRR. Dengan rentang waktu pengambilan data 3 bulan, 6 bulan, 9 bulan, 12 bulan, 15 bulan, 18 bulan, 21 bulan dan 24 bulan sebelum dinyatakan pailit.

Berdasarkan penelitian sebelumnya hasil yang didapatkan cukup memuaskan, namun belum ada yang spesifik membahas mengenai prediksi *financial distress* pada Bank Perkreditan Rakyat serta dengan memanfaatkan teknik *machine learning* dua tahap klasifikasi dan regresi. Oleh karena itu, dalam penelitian ini akan membahas secara spesifik dan penekanan mengenai prediksi *timing financial distress* pada Bank Perkreditan Rakyat di Indonesia dengan memanfaatkan teknik *machine learning* dua tahap klasifikasi dan regresi serta adanya pembentukan model prediksi kepailitan. Penelitian ini memiliki kontribusi berupa tersusunnya sebuah dataset yang berisi Rasio Keuangan BPR dengan label *Financial Distress*, serta terciptanya sebuah model prediksi yang dapat membantu melakukan prediksi *financial distress* yang akan dialami Bank Perkreditan Rakyat.

2. Tinjauan Pustaka

Studi tentang finansial distress sudah dilakukan oleh Beaver [13] dan Altman, Haldeman, and Narayanan [14] dimana keduanya dikenal sebagai pioneer dalam penelitian *prediction distress analysis*, oleh karena itu penelitiannya sering dianggap sebagai penelitian dasar dari perkembangan penelitian corporate failure. Namun demikian pada kedua *pioneer* ini terdapat perbedaan dalam hal model analisis yang digunakan, pada penelitian Beaver [13] menggunakan univariate model dimana variabel yang digunakan bersifat *single variable*, sedangkan pada penelitian Altman et al. [14] mencoba memperbaiki penelitian Beaver [13] dengan menerapkan *Multiple Linier Discriminant Analysis* (MDA). Meyer and Pifer [15] dan Sinkey Jr [16] merupakan pelopor penelitian prediksi kepailitan pada perbankan dengan menggunakan rasio-rasio keuangan pada bank.

Pada tahun 2017, [17] menganalisis terkait penerapan *machine learning* untuk memprediksi kebangkrutan dengan menggunakan 8 tehnik yang meliputi *bagging*, *boosting*, *random forest* (RF), *SVM with two kernels*, *artificial neural networks*, *logistic regression* dan MDA dengan menggunakan data keuangan pada perusahaan Amerika dan Kanada dimulai dari tahun 1985 sampai dengan 2013 yang dikumpulkan dari *database NYU's Salomon Center*. Data keuangan yang meliputi likuiditas, profitabilitas, produktivitas, *leverage asset turnover*, *growth of assets*, *growth in sales*, *growth of employees*, operational margin, perubahan *return*

on equity, dan perubahan *price-to-book ratio* digunakan sebagai variabel dalam penelitian untuk memprediksi kebangkrutan, hasilnya menunjukkan bahwa model tradisional (MDA, LR, dan ANN) memiliki kapasitas prediksi yang lebih rendah yakni 52% dan 77% dibandingkan dengan machine learning models yang memiliki prediksi sebesar 71% dan 87%.

Pada tahun 2017, [18] membuat model untuk memprediksi kebangkrutan bank dengan menunjukkan hasil bahwa semua model prediksi yang dihitung telah mencapai akurasi prediksi sekitar 50% pada dataset perusahaan Slovakia. Ini diberikan terutama karena kesalahan tipe I yang tinggi dalam model *Fulmer* (62%), *Altman* (99%) dan *Springate* (78%). Di sisi lain dalam model *Zmijewski* dan *Taffler* kesalahan tipe I. dan tipe II. Kesalahan yang serupa sekitar 50%. Menurut perhitungan yang diberikan, kita dapat mengasumsikan bahwa kita belum menemukan perbedaan penting antara kemampuan model yang diuji untuk memprediksi kebangkrutan perusahaan di masa depan.

Pada tahun 2018, [19] yang meneliti terkait dengan *Machine Learning and Statistical Techniques in Bankruptcy Prediction* menunjukkan bahwa algoritma prediksi SVM-PSO memperoleh akurasi tertinggi 95%, presisi 94,73% dan spesifisitas (95,23%) bila dibandingkan dengan analisis statistik tradisional dan algoritma pembelajaran mesin lainnya. Alat Apache *Mahout* adalah perangkat lunak sumber terbuka yang digunakan untuk penambangan data yang menyediakan implementasi algoritme pembelajaran mesin yang kuat dan dapat diskalakan yang digunakan untuk pengelompokan, klasifikasi, dan algoritme evolusioner heuristic.

Pada tahun 2019, [20] yang meneliti prediksi kebangkrutan perusahaan dengan menggunakan model machine learning menunjukkan hasil penelitian bahwa terdapat kelemahan dalam metode tradisional dalam memprediksi kebangkrutan sehingga mengambil metode SVM dan *Random Forrest* untuk membangun model prediksi. Hasilnya adalah pada saat pengujian model awal memiliki akurasi prediksi kebangkrutan yang rendah disebabkan oleh ketidakseimbangan sampel, sehingga pengambilan metode random forrest digunakan untuk meningkatkan akurasi prediksi dan menghasilkan akurasi senilai lebih dari 70%.

Teknik dua tahap klasifikasi dan regresi dapat digunakan untuk memprediksi tingkat financial distress pada Bank Perkreditan Rakyat di Indonesia dengan memanfaatkan data historis keuangan. Tahap pertama, yaitu tahap klasifikasi, digunakan untuk mengklasifikasikan Bank Perkreditan Rakyat ke dalam dua kategori, yaitu financial distress atau non-distress. Model yang digunakan dalam tahap klasifikasi dapat dilatih dengan menggunakan berbagai teknik pembelajaran mesin, seperti *Decision Tree*, *Support Vector Machine* dan lain-lain. Dalam penelitian ini menggunakan teknik *Support Vector Machine*.

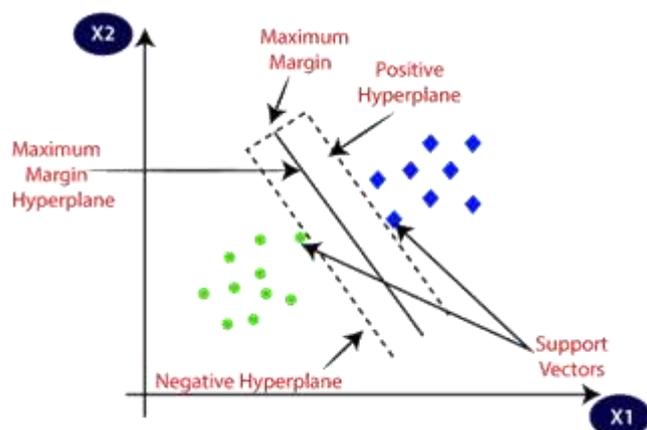
Setelah Bank Perkreditan Rakyat diklasifikasikan sebagai berpotensi mengalami financial distress atau *non-distress*, tahap kedua yaitu tahap regresi, digunakan untuk memprediksi waktu kemungkinan terjadinya financial distress pada Bank Perkreditan Rakyat yang telah diklasifikasikan berpotensi mengalami *financial distress*. Model regresi ini dapat menggunakan teknik regresi linear atau regresi logistik untuk memprediksi waktu kemungkinan terjadinya *financial distress* pada Bank Perkreditan Rakyat. Pada penelitian ini menggunakan teknik Random Forrest Regression.

3. Metodologi

1) Algoritma Support Vector Machine

Algoritma *Support Vector Machine* (SVM) adalah salah satu teknik pembelajaran mesin (*machine learning*) yang digunakan untuk mempelajari pola pada data dengan maksud memprediksi atau klasifikasi data baru. SVM digunakan untuk menyelesaikan masalah pemisahan kelas yang tidak dapat dipisahkan dengan garis linear. SVM bekerja dengan cara mencari *hyperplane* (sebuah garis, bidang atau *hyperplane*) yang dapat memisahkan data dengan sebaik-baiknya. Ide dasar SVM adalah memaksimalkan batas garis pemisah atau *hyperplane* sehingga diperoleh ukuran margin yang maksimal (*maximal margin hyperplane*). *Hyperplane* pemisah terbaik antara kedua kelas dapat ditemukan dengan mengukur *margin hyperplane* tersebut dengan mencari titik maksimalnya. *Margin* adalah jarak anatara *hyperplane* dengan pattern atau data terdekat dari masing-masing *class*. *Pattern* yang paling dekat disebut *support vector*. Usaha dalam mencari *hyperplane* ini merupakan inti dari pembelajaran SVM. *Hyperplane* terbaik diperoleh dari margin terbesar atau optimal yang memisahkan kedua kelas [21]. Margin optimal dihitung dengan memaksimalkan jarak antara *hyperplane* dan data terdekat.

Support vector ialah titik data atau vektor yang paling dekat dengan *hyperplane* dan yang mempengaruhi posisi *hyperplane*. Karena vektor-vektor ini mendukung *hyperplane*, maka disebut *Support vector*.



Gambar 1. Ilustrasi dari *Support Vector Machine*

Berikut adalah ilustrasi sederhana algoritma *Support Vector Machine*:

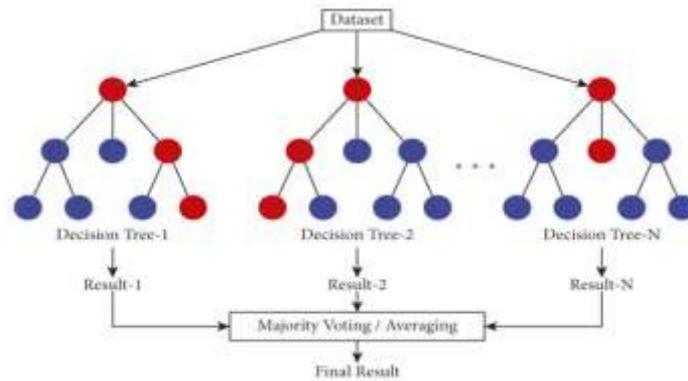
- a). Persiapan data:
Data latihan harus dipersiapkan dengan baik sebelum dimasukkan ke dalam algoritma SVM. Hal ini meliputi pemilihan fitur (*feature selection*) yang relevan, normalisasi data, dan pembagian data ke dalam kelas-kelas yang sesuai.
- b). Mencari *hyperplane*:
SVM mencari *hyperplane* terbaik yang dapat memisahkan kedua kelas dengan memaksimalkan margin, yaitu jarak terdekat antara *hyperplane* dan titik data terdekat dari kedua kelas. *Hyperplane* ini dapat berupa garis, bidang, atau *hyperplane* yang lebih kompleks.
- c). Menghitung vektor pendukung:
Setelah *hyperplane* ditemukan, SVM mencari titik data terdekat dari kedua kelas yang berada pada margin terdekat. Titik-titik ini disebut sebagai vektor pendukung (*support vector*).
- d). Penentuan model:
SVM menggunakan vektor pendukung untuk menentukan model yang dapat digunakan untuk mengklasifikasikan data baru. Model ini dapat berupa fungsi linear atau non-linear.
- e). Menguji model:
Setelah model dibuat, data baru dapat dimasukkan ke dalam model untuk diuji. Data baru ini akan diklasifikasikan ke dalam salah satu kelas berdasarkan posisinya terhadap *hyperplane* yang telah dibuat.

2) Algoritma *Random Forest Regression*

Random Forest Regression adalah algoritma *machine learning* yang digunakan untuk memprediksi nilai numerik (*continuous*) berdasarkan beberapa variabel input yang terkait. Algoritma ini menggunakan kombinasi dari beberapa *Decision Tree*, yang dibuat dengan cara acak (*random*), dengan tujuan meningkatkan akurasi prediksi dan mengurangi kemungkinan *overfitting*. Proses pembuatan *Random Forest Regression* dimulai dengan membuat beberapa *Decision Tree*, di mana setiap *Decision Tree* dibuat dengan menggunakan subset dari keseluruhan data yang tersedia. Kemudian, setiap *Decision Tree* tersebut dilatih dengan data dan target yang sesuai. Pada saat membuat *Decision Tree*, algoritma ini menggunakan teknik *Bootstrap Aggregating* (atau biasa disebut "bagging"), yang dilakukan dengan mengambil sampel acak dengan penggantian dari data yang tersedia untuk setiap *Decision Tree* yang akan dibuat.

Selanjutnya, pada setiap *Decision Tree*, dilakukan pemilihan variabel acak (*random*) untuk membangun struktur pohon keputusan. Dalam hal ini, variabel yang digunakan untuk

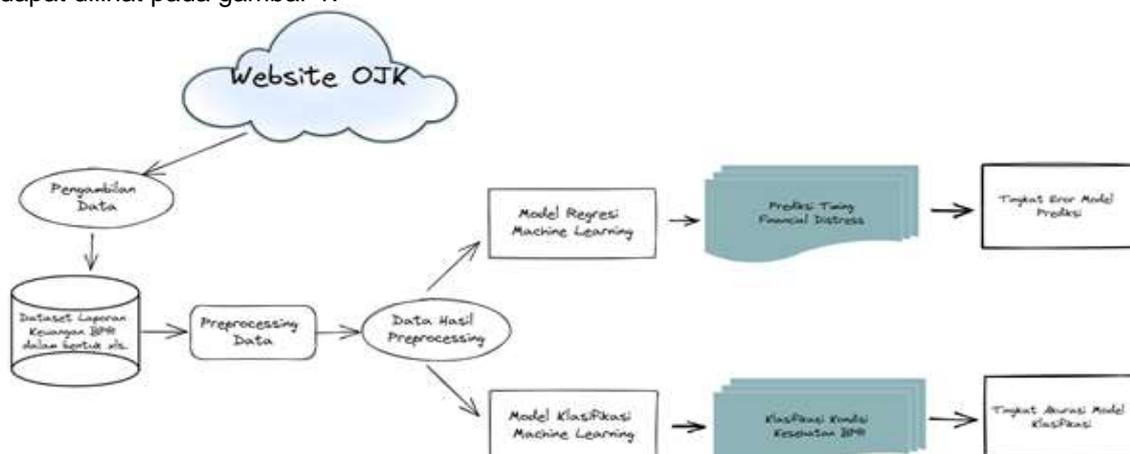
membangun pohon keputusan berbeda-beda pada setiap *Decision Tree*, sehingga setiap *Decision Tree* memiliki keunikan dan tidak saling mempengaruhi satu sama lain. Setelah pembuatan *Decision Tree* selesai, *Random Forest Regression* menggabungkan hasil prediksi dari semua *Decision Tree*, dengan cara mengambil rata-rata (*average*) dari semua nilai prediksi yang dihasilkan. Dengan cara ini, *Random Forest Regression* dapat menghasilkan prediksi yang lebih akurat dan stabil dibandingkan dengan hanya menggunakan satu *Decision Tree*. Ilustrasi dari *Random Forest Regression* dapat dilihat pada gambar di bawah ini:



Gambar 2. Ilustrasi dari *Random Forest Regression*

Gambar 2 menunjukkan bagaimana algoritma *Random Forest Regression* bekerja. Data yang tersedia dibagi menjadi sub-set yang berbeda-beda untuk setiap *Decision Tree* yang dibuat. Pada setiap *Decision Tree*, pemilihan variabel yang digunakan untuk membangun struktur pohon keputusan dilakukan secara acak. Setelah semua *Decision Tree* selesai dibuat, hasil prediksi dari semua *Decision Tree* digabungkan dengan cara mengambil rata-rata dari semua nilai prediksi yang dihasilkan. *Random Forest Regression* memiliki beberapa keunggulan, di antaranya adalah kemampuan untuk menangani masalah overfitting, mampu mengatasi data yang kompleks dan tidak terstruktur, serta dapat mengatasi kekurangan dari *Decision Tree* pada kasus-kasus yang sensitif terhadap perubahan data. Namun, *Random Forest Regression* juga memiliki kelemahan, yaitu kompleksitas model yang tinggi dan waktu komputasi yang lama dibandingkan dengan algoritma *machine learning* lainnya seperti *Linear Regression* atau *Decision Tree*.

Perancangan arsitektur penelitian prediksi *timing financial distress* pada bank perkreditan rakyat di Indonesia memanfaatkan teknik *machine learning* dua tahap klasifikasi dan regresi dapat dilihat pada gambar 1.



Gambar 3. Arsitektur Penelitian

3) Dataset

Dalam penelitian ini, peneliti menggunakan data sejumlah 150 Data Rasio Keuangan Bank Perkreditan Rakyat yang terdiri dari 50 Data rasio keuangan Bank Perkreditan Rakyat

Pailit dan 100 BPR tidak pailit. Data dapat diperoleh dari sumber seperti laporan keuangan, laporan kegiatan usaha, dan publikasi Bank Perkreditan Rakyat pada website OJK. Analisis Data dilakukan 2 tahun berturut-turut sebelum dinyatakan Pailit. Dengan pengambilan data laporan keuangan 4 triwulan setiap tahun. Data yang dibutuhkan meliputi rasio keuangan seperti rasio APYDAP, NPL, ROE, BOPO, NIM, LDR, IRR. Dalam proses pengumpulan dataset Rasio Keuangan BPR, peneliti menggunakan kriteria berikut ini:

1. Dataset harus tersedia dan dapat diakses dengan mudah untuk penggunaan yang berkelanjutan, dalam hal ini, laporan keuangan yang dipublish pada website ojk.
2. Dataset harus mencakup semua informasi yang diperlukan untuk analisis selama masa pengamatan.
3. Dataset harus konsisten dalam format dan isi data yang digunakan sehingga mudah untuk diproses dan digunakan.

Tabel 1.
Dataset Rasio Keuangan BPR yang sudah dikumpulkan.

NO	STATUS	MP	APYDAP	NPL	ROE	BOPO	NIM	LDR	IRRR
1	PAILIT	B-3	73,04	60,61	-106,66	274,29	4,18	116,76	140,16
		B-6	85,45	61,72	-79,51	222,73	2,40	117,43	129,68
		B-9	87,00	53,32	-50,45	273,00	3,76	110,00	119,00
		B-12	69,43	41,85	-27,39	274,05	4,40	109,22	145,00
		B-15	65,47	24,74	-15,65	255,86	5,67	113,00	165,34
		B-18	48,92	18,49	-7,00	256,89	7,89	118,00	178,98
		B-21	29,50	16,75	-5,83	243,00	5,87	129,00	193,12
		B-24	22,34	22,76	6,52	78,38	4,11	91,93	236,87
2	PAILIT	B-3	27,96	26,81	-7,01	132,50	9,51	54,29	225,51
		B-6	22,78	40,03	-4,54	238,90	5,16	106,10	242,55
		B-9	24,18	29,57	5,21	166,77	10,87	104,81	232,00
		B-12	28,78	24,62	5,78	211,95	14,20	58,61	228,67
		B-15	32,14	33,00	-12,76	120,00	18,98	67,00	198,88
		B-18	35,56	30,33	-35,89	119,68	20,67	103,69	176,34
		B-21	34,23	29,00	-32,67	146,00	24,56	87,00	163,21
		B-24	34,39	27,41	-46,19	144,74	7,30	88,12	191,39

4) Data Preprocessing

Dataset rasio keuangan Bank Perkreditan Rakyat yang sudah dikumpulkan, dilakukan pra-pemroses terlebih dahulu. Pra-pemrosesan data mencakup penghapusan data yang tidak lengkap, mengisi data yang hilang, melakukan transformasi data seperti normalisasi atau standarisasi data, dan membagi data menjadi data latih dan data uji. Dalam penelitian ini model prediksi kepailitan dikategorikan dalam variasi waktu yaitu model prediksi 3 (tiga) bulan, 6 (enam) bulan, 9 (Sembilan) bulan, 12 (dua belas) bulan, 15 (lima belas) bulan, 18 (delapan belas) bulan, 21 (dua puluh satu) bulan, 24 (dua puluh empat) bulan sebelum pailit. Pemilihan variasi waktu ini dengan pertimbangan untuk mengetahui lebih dini sinyal kepailitan yang mungkin terjadi dan rentang waktu triwulanan karena publikasi posisi laporan keuangan Bank Perkreditan Rakyat dilakukan dengan periode triwulan [22].

Tabel 2 merupakan distribusi data kondisi keuangan Bank Perkreditan Rakyat bisa dapat dilihat pada tabel 2.

Tabel 2.
Distribusi Data Kondisi Keuangan Bank Perkreditan Rakyat.

Kategori	Jumlah
Sangat Sehat	569
Sehat	131
Cukup Sehat	47
Kurang Sehat	176
Distress	127
Total	1050

Setelah dilakukan pembobotan pada masing-masing rasio keuangan, dilakukan konversi nilai pada masing-masing rasio keuangan. Kemudian dilakukan rata-rata untuk pelabelan predikat kondisi keuangan pada masing-masing triwulan tersebut. Dataset rasio keuangan BPR hasil preprocessing dapat diakses pada <https://doi.org/10.6084/m9.figshare.22558669.v1>

4. Hasil Dan Pembahasan

Hasil penelitian menunjukkan tingkat akurasi prediksi *financial distress* pada BPR di Indonesia menggunakan teknik *machine learning* ditampilkan melalui gambar 4. Pada masa pelatihan, bobot setiap *epoch* disimpan dan dipilih *f1-score* validasi yang tertinggi dan error yang terendah. Setelah itu, bobot yang sudah dipilih digunakan untuk memprediksi data pengujian. Pada gambar 4(b) menunjukkan kinerja MLP Classifier yang lebih akurat dibandingkan SVC pada gambar 4(a).

	precision	recall	f1-score	support		precision	recall	f1-score	support
CUKUP SEHAT	1.00	0.18	0.31	11	CUKUP SEHAT	0.67	0.17	0.27	12
DISTRESS	0.55	0.55	0.55	29	DISTRESS	0.70	0.80	0.75	35
KURANG SEHAT	0.65	0.77	0.70	48	KURANG SEHAT	0.72	0.78	0.75	54
SANGAT SEHAT	0.87	1.00	0.93	139	SANGAT SEHAT	0.95	0.98	0.97	172
SEHAT	1.00	0.42	0.59	36	SEHAT	0.92	0.81	0.86	42
accuracy			0.79	263	accuracy			0.87	315
macro avg	0.81	0.58	0.62	263	macro avg	0.79	0.71	0.72	315
weighted avg	0.82	0.79	0.77	263	weighted avg	0.87	0.87	0.87	315

(a) Hasil akurasi f1-score SVC

(b) Hasil akurasi f1-score MLP Classifier

Gambar 4. Hasil evaluasi model klasifikasi terhadap data validasi.

Pada gambar 4(a) menunjukkan hasil evaluasi model klasifikasi *machine learning* terhadap data validasi dengan menggunakan fitur SVC ($\gamma = \text{'auto'}$) mendapatkan tingkat akurasi *f1-score* sebesar 79%. Sedangkan pada gambar 4(b) menunjukkan hasil evaluasi klasifikasi *machine learning* dengan menggunakan fitur MLP Classifier maksimal iterasi 300, tiga lapisan tersembunyi, masing-masing dengan 200, 300, dan 100 mendapatkan tingkat akurasi sebesar 87%. Hal ini menunjukkan klasifikasi *machine learning* dengan menggunakan fitur MLP Classifier lebih efektif. Temuan tersebut sejalan dengan temuan [23] yang menemukan tingkat akurasi kinerja metode MLP Classifier sebesar 99,5% dalam kasus rekam medik.

Pada hasil evaluasi model *regresi Random Forest Regression* terhadap data validasi dengan menggunakan fitur *mean absolute error* mendapatkan hasil *error* sebesar 1,83 bulan dan dengan menggunakan fitur *mean absolute percentage error* menunjukkan hasil sebesar 4%.

5. Simpulan

Berdasarkan hasil penelitian terhadap penerapan data mining klasifikasi menggunakan *Support Vector Machine* pada dataset rasio keuangan Bank Perkreditan Rakyat dalam memprediksi *timing financial distress* didapatkan sebuah hasil bahwa nilai akurasi terhadap prediksi klasifikasi kondisi kesehatan Bank Perkreditan Rakyat dengan fitur SVC ($\gamma = \text{'auto'}$) adalah sebesar 79% sedangkan klasifikasi kondisi kesehatan Bank Perkreditan Rakyat dengan fitur MLP Classifier dengan maksimal iterasi 300, tiga lapisan tersembunyi, masing-masing dengan 200, 300, dan 100 menunjukkan hasil akurasi sebesar 83%. Hal ini menunjukkan bahwa model klasifikasi memanfaatkan teknik *Machine Learning* dengan fitur MLP Classifier lebih efektif dibandingkan dengan menggunakan fitur SVC.

Pada hasil prediksi regresi *timing financial distress* menggunakan teknik *Random Forest Regression* menunjukkan hasil evaluasi model menggunakan *mean absolute error* sebesar 1,83% sedangkan menggunakan *mean absolute percentage error* mendapatkan nilai 0,03%. Berdasarkan hasil prediksi, dapat disimpulkan bahwa model yang digunakan dalam penelitian ini cukup akurat dalam memprediksi *financial distress* pada Bank Perkreditan Rakyat di Indonesia. Kesimpulan pada penelitian ini adalah pemanfaatan teknik *machine learning* dua tahap klasifikasi dan regresi menggunakan teknik *machine learning* dalam memprediksi *timing financial distress* dinilai baik. Hal ini dapat dilihat dari tingkat akurasi yang cukup tinggi yang dan tingkat *error* yang kecil yang dihasilkan oleh model tersebut. Tetapi hal ini perlu ditinjau ulang dari sudut pandang kompleksitas dan jumlah datasetnya.

Prediksi *timing financial distress* pada Bank Perkreditan Rakyat dapat membantu pihak terkait, seperti regulator, investor, dan manajemen Bank Perkreditan Rakyat, dalam mengambil tindakan pencegahan atau penyelesaian masalah keuangan sebelum terlambat. Metode dua tahap klasifikasi dan regresi yang digunakan dalam penelitian ini dapat diaplikasikan pada Bank Perkreditan Rakyat maupun lembaga keuangan lainnya untuk memprediksi kemungkinan financial distress dan memperkirakan waktu terjadinya masalah keuangan tersebut.

Peneliti telah membahas penggunaan serta perhitungan akurasi prediksi timing financial distress pada bank perkreditan rakyat di Indonesia memanfaatkan teknik machine learning dua tahap klasifikasi dan regresi menggunakan teknik *Machine Learning*. Pada penelitian selanjutnya diharapkan dapat dibandingkan dengan memanfaatkan metode klasifikasi dan regresi lainnya seperti metode *naïve Bayes*, *K-Nearest Neighbor* serta jumlah data yang lebih kompleks. Sehingga dengan menggunakan banyak metode dapat mengetahui kelebihan dan kekurangan masing-masing metode.

Daftar Referensi

- [1] F. Rustandi, "Pengaruh Rgec (Risk Profile, Corporate Governance, Earnings, Capital) Terhadap Financial Distress Bank Perkreditan Rakyat Di Yogyakarta Periode 2015-2017," Universitas Islam Indonesia, 2020.
- [2] M. R. Hutaaruk, M. Mansyur, M. Rinaldi, and Y. R. Situru, "Financial Distress Pada Perusahaan Yang Terdaftar Di Bursa Efek Indonesia," *JPS (Jurnal Perbankan Syariah)*, vol. 2, no. 2, pp. 237-246, 2021.
- [3] R. Muflihah, "Analisis Financial Distress Bank Perkreditan Rakyat Syariah (BPRS) di Indonesia Periode 2019-2020," *La Zhulma| Jurnal Ekonomi dan Bisnis Islam*, vol. 1, no. 1, pp. 17-26, 2022.
- [4] I. P. Sari, A. Susbiyani, and A. A. Syahfrudin, "Analisis Faktor-Faktor Yang Mempengaruhi Kondisi Financial Distress Pada Perusahaan Yang Terdapat Di Bei Tahun 2016-2018 (Studi Empiris pada Perusahaan Manufaktur Sub Sektor yang Terdaftar di Bursa Efek Indonesia)," *Jurnal Ilmiah Akuntansi dan Humanika*, vol. 9, no. 2, pp. 1-12, 2019.
- [5] F. M. Sutra and R. G. Mais, "Faktor-Faktor yang Mempengaruhi Financial Distress dengan Pendekatan Altman Z-Score pada Perusahaan Pertambangan yang Terdaftar di Bursa Efek Indonesia Tahun 2015-2017," *Jurnal Akuntansi Dan Manajemen*, vol. 16, no. 1, pp. 34-72, 2019.
- [6] D. Diana, "Analisis Prediksi Kebangkrutan Menggunakan Model Altman Z-Score Pada Perusahaan Manufaktur Yang Terdaftar Di Bursa Efek Indonesia," Prodi Akuntansi, 2021.
- [7] I. Asfali, "Pengaruh Profitabilitas, Likuiditas, Leverage, Aktivitas, Pertumbuhann Penjualan Terhadap Financial Distress Perusahaan Kimia," *Jurnal Ekonomi Dan Manajemen*, vol. 20, no. 2, pp. 56-66, 2019.
- [8] A. Evayanti, "Faktor-Faktor Yang Mempengaruhi Financial Distress Dengan Menggunakan Metode Altman Z-Score Pada Perusahaan Manufaktur," UIN KH. Achmad Siddiq Jember, 2022.
- [9] H. Budiwati, "Analisis Rasio Keuangan Camel Terhadap Prediksi Kepailitan Pada Bank Umum Swasta Nasional Di Indonesia Periode 2004–2007," *WIGA: Jurnal Penelitian Ilmu Ekonomi*, vol. 1, no. 2, pp. 50-63, 2011.
- [10] H. Budiwati, I. Fadah, H. Sukarno, and E. S. Utami, "Bankruptcy Prediction Model Conventional Bank Rural Banks in Indonesia," *PalArch's Journal of Archaeology of Egypt/Egyptology*, vol. 18, no. 4, pp. 3790-3802, 2021.
- [11] E. L. Putri, "Prediksi financial distress dengan analisis risk, good corporate governance, earnings Capital, dan size pada Bank Umum Swasta Nasional Devisa," *MBR (Management and Business Review)*, vol. 2, no. 2, pp. 93-105, 2018.
- [12] Z. Achmat, "Theory of planned behavior, masihkah relevan," *Jurnal Universitas Sumatera Utara*, vol. 23, no. 2, pp. 1-20, 2010.
- [13] W. H. Beaver, "Financial ratios as predictors of failure," *Journal of accounting research*, vol. 4, pp. 71-111, 1966.
- [14] E. I. Altman, R. G. Haldeman, and P. Narayanan, "ZETATM analysis A new model to identify bankruptcy risk of corporations," *Journal of banking & finance*, vol. 1, no. 1, pp. 29-54, 1977.
- [15] P. A. Meyer and H. W. Pifer, "Prediction of bank failures," *The journal of finance*, vol. 25, no. 4, pp. 853-868, 1970.

-
- [16] J. F. Sinkey Jr, "A multivariate statistical analysis of the characteristics of problem banks," *The Journal of Finance*, vol. 30, no. 1, pp. 21-36, 1975.
- [17] F. Barboza, H. Kimura, and E. Altman, "Machine learning models and bankruptcy prediction," *Expert Systems with Applications*, vol. 83, pp. 405-417, 2017.
- [18] M. Kovacova and J. Kliestikova, "Modelling bankruptcy prediction models in Slovak companies," in *SHS Web of Conferences*, 2017, p. 01013.
- [19] S. S. Devi and Y. Radhika, "A survey on machine learning and statistical techniques in bankruptcy prediction," *International Journal of Machine Learning and Computing*, vol. 8, no. 2, pp. 133-139, 2018.
- [20] H. Chang, "The application of machine learning models in company bankruptcy prediction," in *Proceedings of the 2019 3rd International Conference on Software and e-Business*, 2019, pp. 199-203.
- [21] M. H. N. Yahya and M. H. Nasution, "Penggunaan Algoritma Support Vector Machine (SVM) Untuk Penentuan Kelayakan Pemberian Kredit Koperasi Serba Usaha 'Daruzzakah Zakah'Desa Rensing Kecamatan Sakra Lombok Timur Nusa Tenggara Barat," *Infotek J. Inform. dan Teknol*, vol. 3, no. 1, pp. 32-41, 2020.
- [22] H. budiwati Soekirno, "Earnings dan Liquidity sebagai Prediktor Kepailitan Bank Perkreditan Rakyat di Indonesia," *Jurnal Manajemen dan Keuangan*, vol. 9, no. 2, pp. 248-264, 2020.
- [23] G. Al Qarana, & S. Sfenrianto, "Analisis Faktor Sosial-Ekonomi Pada Data Rekam Medik Pasien TB Menggunakan Teknologi MLP Classifier-ANN Dalam Kasus Kegagalan Pengobatan." *Journals of Ners Community*, vol. 13, no. 4, pp. 422-428, 2022.