

Implementasi *Predictive Maintenance* Pada *Bearing* Dengan Menggunakan *Machine Learning* Untuk Memprediksi Temperatur

Rosyad Burhan^{1*}, Mega Bagus Herlambang², Salahuddin³

^{1,2} Jurusan Teknik Industri Institut Teknologi Indonesia

³ Jurusan Teknologi Informasi dan Komputer Politeknik Negeri Lhokseumawe

^{1*}rosyad.burhan@student.iti.ac.id (penulis korespondensi), ²mega.herlambang@iti.ac.id, ³salahuddintik@pnl.ac.id

Abstrak — PT. Integral Industrial Indonesia adalah perusahaan yang beroperasi di lingkungan industri yang kompleks di mana desain, pengoperasian, dan pemeliharaan peralatan yang optimal sangat penting. Salah satu produknya adalah sensor putaran yang dipasang pada *bearing* mesin kertas. Penelitian ini bertujuan untuk memprediksi variabel suhu pada suatu *bearing* dengan memfokuskan pada variabel yang terekam oleh sensor. PT. Integral Industrial Indonesia menerapkan sistem pemeliharaan prediktif untuk meningkatkan efisiensi *part bearing* dan memprediksi kerusakan sebelum benar-benar terjadi. Pada saat pengumpulan data, data diperoleh dari pabrik pembuat kertas PT. XYZ yang bekerja sama dengan PT. Industri Integral Indonesia. Pemrosesan data dilakukan dengan membuat algoritma *machine learning*. Model yang digunakan adalah *K-Nearest Neighbors*, *Support Vector Machine*, dan *Artificial Neural Network*. Kemudian dilakukan evaluasi model untuk ketiga model menggunakan *Mean Absolute Percentage Error* (MAPE), *Root Mean Square Error* (RMSE), dan *R-squared*. Untuk model *K-Nearest Neighbors* diperoleh hasil MAPE sebesar 4,44%, RMSE sebesar 1,9623, dan *R-squared* sebesar 0,849. Untuk model *Support Vector Machine* diperoleh hasil MAPE sebesar 7,52%, RMSE sebesar 1,8190, dan *R-squared* sebesar 0,749. Untuk model *Artificial Neural Network* diperoleh hasil MAPE sebesar 5,55%, RMSE sebesar 2,0209, dan *R-squared* sebesar 0,799. Berdasarkan evaluasi model ini, model *K-Nearest Neighbors* menjadi pilihan terbaik yang digunakan perusahaan dalam memprediksi suhu karena memiliki nilai MAPE terkecil, RMSE yang mendekati 0 dan nilai *R-Squared* yang mendekati 1. Model *K-Nearest Neighbors* kemudian digunakan untuk menentukan *feature importances* dan mencari variabel yang memiliki pengaruh terbesar terhadap variabel suhu berdasarkan nilai *feature importances* tertinggi. Didapatkan nilai *feature importances* tertinggi yaitu: *Y.rms* bernilai (1082.4209), posisi kedua *Y.peak* bernilai (1066.7731), dan posisi ketiga *Z.rms* bernilai (1023.5485). Selain itu, analisis finansial dilakukan untuk menghitung potensi penghematan biaya penerapan pemeliharaan prediktif, dengan hasil produktivitas tambahan sebesar 22,52% (78.820 ton/mesin kertas) dan laba atas investasi (ROI) sebesar 6,56%. Oleh karena itu, penerapan pemeliharaan prediktif sangat bermanfaat bagi perusahaan PT. XYZ.

Kata kunci — *Predictive Maintenance*, *Bearing*, *K-Nearest Neighbors*, *Support Vector Machine*, *Artificial Neural Network*.

Abstract — PT Integral Industrial Indonesia is a company that operates in a complex industrial environment where optimal equipment design, operation and maintenance are critical. One of its products is a rotation sensor mounted on a paper machine bearing. This research aims to predict the temperature variables in a bearing by focusing on the variables recorded by the sensor. PT Integral Industrial Indonesia implements a predictive maintenance system to improve bearing part efficiency and predict damage before it actually occurs. At the time of data collection, data was obtained from the PT XYZ papermaking factory in collaboration with PT Integral Industrial Indonesia. Data processing is done by creating machine learning algorithms. The models used are *K-Nearest Neighbors*, *Support Vector Machine*, and *Artificial Neural Network*. Then model evaluation is carried out for the three models using *Mean Absolute Percentage Error* (MAPE), *Root Mean Square Error* (RMSE), and *R-squared*. For the *K-Nearest Neighbors* model, the MAPE result is 4.44%, RMSE is 1.9623, and *R-squared* is 0.849. For the *Support Vector Machine* model, the MAPE result is 7.52%, RMSE is 1.8190, and *R-squared* is 0.749. For the *Artificial Neural Network* model, the MAPE result is 5.55%, RMSE is 2.0209, and *R-squared* is 0.799. Based on this model evaluation, the *K-Nearest Neighbors* model is the best choice used by companies in predicting temperature because it has the smallest MAPE value, RMSE which is close to 0 and *R-Squared* value which is close to 1. The *K-Nearest Neighbors* model is then used to determine feature importances and find variables that have the greatest influence on temperature variables based on the highest feature importances value. The highest value of feature importances is obtained, namely: *Y.rms* value (1082.4209), second position *Y.peak* value (1066.7731), and third position *Z.rms* value (1023.5485). In addition, a financial analysis was conducted to calculate the potential cost savings of implementing predictive maintenance, resulting in an additional productivity of 22.52% (78,820 tons/paper machine) and a return on investment (ROI) of 6.56%. Therefore, the implementation of predictive maintenance is very beneficial for PT XYZ company.

Keywords — *Predictive Maintenance*, *Bearings*, *K-Nearest Neighbors*, *Support Vector Machine*, *Artificial Neural Networks*.

I. PENDAHULUAN

Dalam dunia industri proses pengoperasian, dan pemeliharaan aset yang optimal sangat penting untuk mengoptimalkan keberlanjutan aset atau peralatan pabrik. Pemeliharaan aset dengan *Predictive Maintenance* (pemeliharaan prediktif) menjadi pilihan tepat untuk memastikan peralatan berfungsi dengan baik dan mengurangi biaya perbaikan dan kerusakan yang tidak terduga. *Predictive Maintenance* didasarkan pada penggunaan data sensorik dan analitik tingkat lanjut untuk memprediksi potensi kerusakan peralatan sebelum benar-benar terjadi. Dalam *predictive maintenance*, sensor-sensor dipasang pada peralatan yang

diawasi dan data yang dikumpulkan secara terus-menerus. Data ini kemudian dianalisis menggunakan algoritma dan teknik *machine learning* untuk mengidentifikasi pola, tren, dan anomali yang dapat mengindikasikan kemungkinan kerusakan di masa depan.

Dalam penelitian ini akan menganalisis implementasi *predictive maintenance* pada *bearing* dengan menggunakan *machine learning* untuk memprediksi temperatur. Penelitian ini diharapkan dapat memberikan kontribusi penting dalam pengembangan teknik analisis yang lebih akurat dan dapat diandalkan untuk mendeteksi dini kerusakan pada *bearing* di berbagai lingkungan industri. Penelitian ini dilakukan dengan menggunakan teknik analisis *Machine Learning*, termasuk

model *Support Vector Machine*, *K-Nearest Neighbor*, dan *Artificial Neural Network* untuk mendeteksi variabel temperatur pada *bearing* berdasarkan putaran data yang dihasilkan selama proses produksi. Penelitian ini bertujuan untuk memberikan solusi bagi PT. Integral Industrial Indonesia dalam meningkatkan efisiensi dan mencegah kerusakan yang tidak terduga pada *bearing*.

II. METODOLOGI PENELITIAN

A. Subjek dan Objek Penelitian

Observasi subjek digunakan untuk mengetahui asal usul data yang digunakan, khususnya data putaran *bearing* yang diperoleh dari salah satu mesin kertas. Hal ini dilakukan untuk memastikan bahwa data yang digunakan relevan dan konsisten dengan tujuan penelitian. Selain itu penggunaan metode observasi objek juga penting untuk menjamin validitas dan reliabilitas data yang digunakan. Sedangkan tujuan mengamati subjek dalam penelitian ini adalah untuk mengumpulkan data-data yang diperlukan. Dengan menggunakan metode observasi objek, pengumpulan data berlangsung selama 34 hari terhitung tanggal 21 Agustus 2023 sampai dengan tanggal 24 September 2023.

B. Jenis Data

Jenis data yang digunakan adalah data masa lalu yang dilakukan dengan mengamati langsung pada mesin kertas. Tipe data yang berhasil diambil adalah tipe data file JSON dengan total 957 data mentah per sensor. Termasuk UID, Tanggal, Waktu, *X.peak*, *Y.peak*, *Z.peak*, *X.rms*, *Y.rms*, *Z.rms*, *Temperature*, *Battery*, dan *rss*.

C. Metode Pengumpulan Data

Data yang digunakan dalam penelitian ini adalah data masa lalu berbentuk *JSON file* berisikan frekuensi yang terjadi pada *bearing* mesin kertas. Data putaran *bearing* dikumpulkan dengan memasang sensor pada mesin yang ingin diuji kondisinya.



Gambar 1. Sensor yang terpasang pada *bearing* mesin kertas di Pabrik PT. XYZ

D. Metode Pengolahan dan Analisis Data

Pada pengolahan data peneliti menggunakan tiga model yaitu *K-Nearest Neighbors*, *Support Vector Machine*, dan *Artificial Neural Network* dengan tiga model tersebut diharapkan dapat melakukan prediksi kerusakan pada *Bearing* di mesin kertas berdasarkan variabel X terdapat beberapa variabel yaitu *X.peak*, *Y.peak*, *Z.peak*, *X.rms*, *Y.rms*, *Z.rms*, *Battery*, dan *rss*. Sehingga bisa memprediksi variabel Y yaitu Temperatur. Kemudian, menganalisis manfaat dan keuntungan yang diperoleh Perusahaan dalam penelitian ini, dari aspek finansial dengan *Potential Saving Cost*.

E. Predictive Maintenance

Konsep *Predictive Maintenance* (PdM) didasarkan pada penggunaan data sensorik dan analitik tingkat lanjut untuk memprediksi potensi kerusakan atau kegagalan peralatan sebelum benar-benar terjadi.[1] Pemeliharaan prediktif peralatan industri (PdM) dapat melihat penurunan kinerja karena dirancang untuk mencapai mendekati nol bahaya tersembunyi, kegagalan, polusi, dan mendekati nol kecelakaan di seluruh lingkungan proses manufaktur.[2]

F. Machine Learning

Machine Learning adalah studi tentang algoritma dan statistik yang digunakan untuk melakukan tugas tertentu tanpa menggunakan instruksi eksplisit, tetapi dengan mengandalkan pola dan kesimpulan.[3] Algoritma *Machine Learning* adalah sekumpulan instruksi atau prosedur matematika yang digunakan untuk menghasilkan model pembelajaran mesin.

G. K-Nearest Neighbors

K-Nearest Neighbors (K-NN) adalah model yang dipergunakan buat mengklasifikasikan objek berdasarkan data yang diperoleh. model ini memilih klasifikasi sesuai objek menggunakan jarak terdekat berasal data yang ada. Hal ini memudahkan pencarian klasifikasi atau prediksi berdasarkan variabel yang tersedia, dengan mengandalkan kedekatan antara data yang akan dievaluasi menggunakan data *training* yang ada. Metode ini bekerja dengan perkiraan bahwa data yang mempunyai fitur yang seperti cenderung mempunyai label atau kelas yang serupa. oleh karena itu, Jika data yang dievaluasi mempunyai tetangga terdekat yang mayoritasnya termasuk pada satu kelas, maka data tersebut akan diklasifikasikan ke pada kelas tersebut. [4]

H. Support Vector Machine

Support Vector Machine (SVM) merupakan model yang digunakan untuk membuat prediksi yang dapat digunakan dalam analisis dan regresi.[5] *Support Vector Machine* menggunakan prinsip *Structural Risk Minimization* (SRM), dengan tujuan menemukan *hyperline* terbaik yang memisahkan dua kelas.[6] *Hyperline* yang berada di antara atau di tengah dua kelas data adalah *hyperline* terbaik.

I. Artificial Neural Network

Artificial Neural Network (ANN) merupakan pemrosesan informasi yang terinspirasi berdasarkan sistem syaraf biologi. *Artificial Neural Network* dapat mengenali aktivitas berdasarkan data yang telah diperoleh. Data yang telah diperoleh akan dipelajari ANN sehingga memiliki kemampuan dalam memberikan sebuah keputusan terhadap data yang belum dipelajari.[5]

J. Bahasa Pemrograman R

R adalah bahasa pemrograman yang banyak digunakan dalam komputasi statistik, analisis data, dan penelitian ilmiah. Bahasa pemrograman R memiliki banyak paket, sehingga pengguna memiliki banyak pilihan di luar paket standar. Bahasa R berbasis objek dan mencakup perpustakaan. Perpustakaan ini dikembangkan oleh kolaborator bahasa R.[7] Pemrograman R biasanya digunakan oleh ahli statistik, analisis data, peneliti, dan pemasar untuk menangkap, membersihkan, menganalisis, memvisualisasikan, dan menyajikan data.

K. *Mean Absolute Percentage Error (MAPE)*

Mean Absolute Percentage Error adalah perhitungan nilai *error* dalam perhitungan statistik untuk membuktikan tingkat keakuratan suatu model dalam melakukan *forecasting* atau prediksi. Selain itu juga terdapat tabel yang digunakan untuk memudahkan dalam menginterpretasikan hasil nilai yang diperoleh pada perhitungan MAPE.[8] Berikut merupakan rumus dalam melakukan perhitungan MAPE:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{A_i - F_i}{A_i} \right| \times 100\% \quad (1)$$

Keterangan :

- n = Ukuran Data/*Sample*
- A_i = Nilai Data Aktual
- F_i = Nilai Data Peramalan atau Prediksi

Tabel 1. Range Nilai Hasil MAPE

Range MAPE	Keterangan
< 10%	Kemampuan model peramalan sangat baik
10% - 20%	Kemampuan model peramalan baik
20% - 50%	Kemampuan model peramalan layak
> 50%	Kemampuan model peramalan buruk

L. *Root Mean Square Error (RMSE)*

Root Mean Square Error adalah salah satu metode perhitungan nilai kesalahan untuk menentukan besarnya angka kesalahan pada hasil *forecasting* atau prediksi. Untuk menentukan nilai RMSE dapat dilihat berdasarkan hasil prediksi yang didapatkan, jika hasil yang didapatkan mendekati angka 0 maka hasil prediksi atau peramalan mendekati atau sesuai dengan data aktualnya.[8] Berikut merupakan rumus dalam melakukan perhitungan RMSE:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (A_i - F_i)^2}{n}} \quad (2)$$

Keterangan:

- n = Ukuran Data/*Sample*
- A_i = Nilai Data Aktual
- F_i = Nilai Data Peramalan atau Prediksi

M. *R-Squared*

R-squared merupakan nilai yang menunjukkan seberapa besar pengaruh variabel *independent* (X) terhadap variabel *dependent* (Y). Hasil yang diperoleh berbentuk nominal, berkisar antara 0 hingga 1, atau dapat diubah dalam bentuk persentase. Berikut merupakan rumus dalam melakukan perhitungan *R-Squared*:

$$R^2 = 1 - \frac{\sum_{i=1}^n (A_i - F_i)^2}{\sum_{i=1}^n (A_i - \bar{A})^2} \quad (3)$$

Keterangan:

- n = Ukuran Data/*Sample*
- A_i = Nilai Data Aktual
- F_i = Nilai Data Peramalan atau Prediksi
- \bar{A} = Rata-rata Dari Nilai Aktual

N. *Feature Importance*

Feature Importance adalah konsep penting dalam analisis data dan pembelajaran mesin. Saat membuat model pembelajaran mesin, kami sering menggunakan banyak fitur

sebagai masukan untuk membantu model memahami pola dalam data dan membuat prediksi.[9]

III. HASIL DAN PEMBAHASAN

A. Model *K-Nearest Neighbors*

Pada pengolahan data ini model yang pertama dibuat yaitu model *K-Nearest Neighbors*, data yang digunakan berdasarkan data yang sudah melalui tahapan *Pre-Processing Data* dan *Cleansing Data*. Data akan dipisah menjadi 2 variabel, yaitu variabel X (*independent*) yaitu : X.peak, X.rms, Y.peak, Y.rms, Z.peak, dan Z.rms sedangkan variabel Y (*Dependent*) yaitu Temperatur.

Langkah awal untuk membuat model ini yaitu dengan memasukkan data csv hasil *Pre-Processing* dari hasil pengumpulan data berlangsung selama 34 hari terhitung tanggal 21 Agustus 2023 sampai dengan tanggal 24 September 2023 dan membagi datanya menjadi *Training Set* sebanyak 70% dan *Test Set* sebanyak 30%. Dari jumlah data awal sebanyak 957 baris data, yang bisa digunakan 952 baris data, dan data yang masuk dalam *Training Set* sebanyak 715 baris data sedangkan yang masuk dalam *Test Set* sebanyak 237 baris data. Dilanjutkan dengan membuat model *K-Nearest Neighbors*, dengan menggunakan *tools* yang ada pada *software R Studio*, memasukkan *command* “`knn(train = training_set[X], test = test_set[X], cl = training_set[Y], k = k)`”.

Berdasarkan *command* KNN tersebut Temperatur sebagai variabel Y yang akan diprediksi dengan variabel X pada data yang digunakan yaitu : X.peak, X.rms, Y.peak, Y.rms, Z.peak, dan Z.rms. Model KNN yang telah dibuat akan menghasilkan prediksi dengan memasukkan data baru yaitu *Test Set* dengan menggunakan “*predict()*”. Kemudian, dilakukan evaluasi model *K-Nearest Neighbors* yang telah dibuat dengan *Mean Absolute Percentage Error (MAPE)*, *Root Mean Square Error (RMSE)*, dan *R-Squared*. Berikut hasil prediksi Temperatur dengan menggunakan *Test Set* sebanyak 237 baris data menghasilkan model *K-Nearest Neighbors*:

Tabel 2. Hasil Prediksi Temperatur Dengan Model *K-Nearest Neighbors*

Temperatur	Prediksi
72.89	65.37
74.72	62.25
68.99	71.53
69.41	69.38
73.52	71.67
60.52	61.96
65.29	70.43
71.62	65.85
72.91	64.9
70.92	74.84
....
72.24	74.85
65.38	62.81
64.60	68.7
55.12	55.01
59.06	69.08
66.37	68.06
62.52	62.84
61	63.72
60.24	67.38
61.97	64.38

Berdasarkan hasil tabel diatas (Tabel 2) dapat diketahui bahwa hasil prediksi model KNN mendapatkan nilai yang tidak jauh berbeda dengan data aktual Temperatur, sehingga untuk sementara dapat diasumsikan model ini cukup baik. Tidak

cukup hanya melihat hasil akhir prediksi yang didapatkan tetapi perlu adanya evaluasi model untuk memastikan secara akurat hasil model yang didapatkan dengan MAPE, RMSE dan *R-Squared*.

B. Model Support Vector Machine

Pada pengolahan data model yang kedua adalah model *Support Vector Machine*, data yang digunakan berdasarkan data yang sudah melalui tahapan *Pre-Processing Data* dan *Cleansing Data*. Data akan dipisah menjadi 2 variabel, yaitu variabel X (*independent*) yaitu : *battery* dan rssi sedangkan variabel Y (*Dependent*) yaitu Temperatur.

Langkah awal untuk membuat model ini yaitu dengan memasukkan data csv hasil *Pre-Processing* dari hasil pengumpulan data berlangsung selama 34 hari terhitung tanggal 21 Agustus 2023 sampai dengan tanggal 24 September 2023 dan membagi datanya menjadi *Training Set* sebanyak 70% dan *Test Set* sebanyak 30%. Dari jumlah data awal sebanyak 957 baris data, yang bisa digunakan 952 baris data, dan data yang masuk dalam *Training Set* sebanyak 715 baris data sedangkan yang masuk dalam *Test Set* sebanyak 237 baris data. Dilanjutkan dengan membuat model *Support Vector Machine*, dengan menggunakan *tools* yang ada pada *software R Studio*, memasukkan *command* “*svm(temp ~., data = training_set, method = “svm”, trControl = ctrl, tuneGrid = hyperparams)*”.

Berdasarkan *command SVM* tersebut Temperatur sebagai variabel Y yang akan diprediksi dengan variabel X pada data yang digunakan yaitu : *battery* dan rssi. Model SVM yang telah dibuat akan menghasilkan prediksi dengan memasukkan data baru yaitu *Test Set* dengan menggunakan “*predict()*”. Kemudian, dilakukan evaluasi model *Support Vector Machine* yang telah dibuat dengan *Mean Absolute Percentage Error* (MAPE), *Root Mean Square Error* (RMSE), dan *R-Squared*. Berikut hasil prediksi Temperatur dengan menggunakan *Test Set* sebanyak 237 baris data menggunakan model *Support Vector Machine*:

Tabel 3. Hasil Prediksi Temperatur Dengan Model *Support Vector Machine*

Temperatur	Prediksi
65.87	66.82
62.25	68.92
72.89	69.04
74.72	66.97
68.99	68.81
64.58	66.84
73.52	67.92
73.38	66.86
65.29	68.81
71.62	66.85
....
73.76	67.50
72.91	67.63
72.24	68.47
60.52	67.66
64.60	66.85
65.38	68.06
55.12	65.59
59.06	65.74
69.65	64.87
66.37	64.64

Berdasarkan hasil tabel diatas (Tabel 3) dapat diketahui bahwa hasil prediksi model SVM mendapatkan nilai yang tidak jauh berbeda dengan data aktual Temperatur, sehingga untuk sementara dapat diasumsikan model ini cukup baik. Tidak cukup hanya melihat hasil akhir prediksi yang didapatkan tetapi perlu adanya evaluasi model untuk memastikan secara akurat hasil model yang didapatkan dengan MAPE, RMSE dan *R-Squared*.

C. Model Artificial Neural Network

Pada pengolahan data model yang ketiga adalah model *Artificial Neural Network*, data yang digunakan berdasarkan data yang sudah melalui tahapan *Pre-Processing Data* dan *Cleansing Data*. Data akan dipisah menjadi 2 variabel, yaitu variabel X (*independent*) yaitu : X.peak, X.rms, Y.peak, Y.rms, Z.peak, Z.rms, *battery* dan rssi sedangkan variabel Y (*Dependent*) yaitu Temperatur.

Langkah awal untuk membuat model ini yaitu dengan memasukkan data csv hasil *Pre-Processing* dari hasil pengumpulan data berlangsung selama 34 hari terhitung tanggal 21 Agustus 2023 sampai dengan tanggal 24 September 2023 dan membagi datanya menjadi *Training Set* sebanyak 70% dan *Test Set* sebanyak 30%. Dari jumlah data awal sebanyak 957 baris data, yang bisa digunakan 952 baris data, dan data yang masuk dalam *Training Set* sebanyak 715 baris data sedangkan yang masuk dalam *Test Set* sebanyak 237 baris data. Dilanjutkan dengan membuat model *Artificial Neural Network*, dengan menggunakan *tools* yang ada pada *software R Studio*, memasukkan *command* “*neuralnet(temp ~., data = training_set, hidden = 2, linier.output = TRUE)*”.

Berdasarkan *command ANN* tersebut Temperatur sebagai variabel Y yang akan diprediksi dengan variabel X pada data yang digunakan yaitu : X.peak, X.rms, Y.peak, Y.rms, Z.peak, Z.rms, *battery* dan rssi, dengan *hidden layer* yang digunakan sebanyak 2. Model ANN yang telah dibuat akan menghasilkan prediksi dengan memasukkan data baru yaitu *Test Set* dengan menggunakan “*predict()*”. Kemudian, dilakukan evaluasi model *Artificial Neural Network* yang telah dibuat dengan *Mean Absolute Percentage Error* (MAPE), *Root Mean Square Error* (RMSE), dan *R-Squared*. Berikut hasil prediksi Temperatur dengan menggunakan *Test Set* sebanyak 237 baris data menggunakan model *Artificial Neural Network*:

Tabel 4. Hasil Prediksi Temperatur Dengan Model *Artificial Neural Network*

Temperatur	Prediksi
72.89	67.23
74.72	67.23
68.99	67.23
69.41	67.23
73.52	67.23
60.52	67.23
65.29	67.23
71.62	67.23
72.91	67.23
70.92	67.23
....
72.24	67.23
65.38	67.23
64.60	67.23
55.12	67.23
59.06	67.23
66.37	67.23
62.52	67.23
61	67.23
60.24	67.23
61.97	67.23

Berdasarkan hasil tabel diatas (Tabel 4) dapat diketahui bahwa hasil prediksi model ANN mendapatkan nilai yang tidak jauh berbeda dengan data aktual Temperatur, sehingga untuk sementara dapat diasumsikan model ini cukup baik. Tidak cukup hanya melihat hasil akhir prediksi yang didapatkan tetapi perlu adanya evaluasi model untuk memastikan secara akurat hasil model yang didapatkan dengan MAPE, RMSE dan *R-Squared*.

D. Hasil Perhitungan Mean Absolute Percentage Error (MAPE)

Perhitungan *Mean Absolute Percentage Error* dilakukan untuk mengukur tingkat akurasi prediksi berdasarkan model-model *machine learning* yang telah dibuat. Dalam menentukan tingkat akurasi prediksi dari hasil model yang telah dibuat, dapat menggunakan tabel *Range* Nilai Hasil MAPE sebagai referensi mengartikan tingkat prediksi yang didapatkan.

Tabel 5. Nilai Hasil Perhitungan MAPE

Model	Hasil MAPE	Kategori
<i>K-Nearest Neighbors</i>	4,44%	Prediksi Sangat Baik
<i>Support Vector Machine</i>	7,52%	Prediksi Sangat Baik
<i>Artificial Neural Network</i>	5,44%	Prediksi Sangat Baik

Berdasarkan tabel 5 diatas menunjukan bahwa didapatkan hasil MAPE ketiga model yaitu: *K-Nearest Neighbors* bernilai MAPE (4,44%), *Support Vector Machine* bernilai MAPE (7,52%), dan *Artificial Neural Network* bernilai MAPE (5,44%), mendapatkan hasil prediksi sangat baik karena memiliki nilai *Range* MAPE kurang dari sepuluh persen (< 10%).

E. Hasil Perhitungan Root Mean Square Error (RMSE)

Perhitungan *Root Mean Square Error* dilakukan untuk mengetahui besarnya nilai kesalahan yang terjadi pada hasil prediksi yang didapatkan, jika hasil *Root Mean Square Error* semakin mendekati 0 (nol), maka hasil prediksi sudah mendekati hasil aktualnya. Berikut merupakan nilai hasil

perhitungan RMSE di *software* R Studio pada masing-masing model yang telah dibuat:

Tabel 6. Nilai Hasil Perhitungan RMSE

Model	Hasil RMSE
<i>K-Nearest Neighbors</i>	1,9623
<i>Support Vector Machine</i>	1,8190
<i>Artificial Neural Network</i>	2,0209

Berdasarkan tabel 6 diatas bahwa model *K-Nearest Neighbors* memiliki hasil RMSE (1,9623) yang bernilai jauh dari 0 (nol) sehingga prediksi yang dihasilkan kurang baik. Sedangkan model *Support Vector Machine* bernilai RMSE (1,8190) dan *Artificial Neural Network* bernilai RMSE (2,0209) mendapatkan nilai hasil RMSE yang mendekati 0 (nol) sehingga prediksi yang dihasilkan baik mendekati nilai aktualnya.

F. Hasil Perhitungan R-Squared

Perhitungan *R-Squared* dilakukan untuk mengetahui seberapa besar pengaruh variabel *independent* (X) terhadap variabel *dependent* (Y). Hasil didapatkan berupa nilai bilangan dari 0 (nol) hingga 1 (satu), jika hasil yang didapatkan mendekati nilai 1 (satu) maka dapat disimpulkan terdapat pengaruh yang kuat antara variabel *independent* (X) terhadap variabel *dependent* (Y).

Tabel 7. Nilai Hasil Perhitungan R-Squared

Model	Hasil R-Squared
<i>K-Nearest Neighbors</i>	0,849
<i>Support Vector Machine</i>	0,749
<i>Artificial Neural Network</i>	0,799

Berdasarkan tabel 7 diatas didapatkan model *K-Nearest Neighbors* bernilai *R-Squared* (0,849), *Support Vector Machine* bernilai *R-Squared* (0,749) dan *Artificial Neural Network* bernilai *R-Squared* (0,799) memiliki pengaruh yang kuat karena bernilai *R-Squared* yang positif. Sedangkan, dari ketiga model tersebut yang terbaik adalah model model *K-Nearest Neighbors* bernilai *R-Squared* (0,849) karena memiliki nilai bilangan positif dan mendekati 1 sehingga bisa disimpulkan variabel X terhadap variabel Y memiliki pengaruh yang kuat pada model ini.

G. Perbandingan Hasil MAPE, RMSE, dan R-Squared

Untuk memudahkan dalam menentukan model yang terbaik diantara 3 (tiga) model yang telah dibuat, maka dilakukan perbandingan antara perhitungan MAPE, RMSE dan *R-Squared*, didapatkan hasil seperti berikut:

Tabel 8. Nilai Hasil Perhitungan MAPE, RMSE, dan R-Squared

Model	Hasil MAPE	Hasil RMSE	Hasil R-Squared
<i>K-Nearest Neighbors</i>	4,44%	1,9623	0,849
<i>Support Vector Machine</i>	7,52%	1,8190	0,749
<i>Artificial Neural Network</i>	5,44%	2,0209	0,799

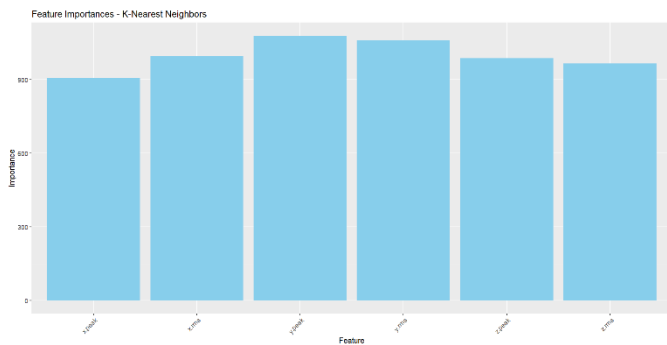
Berdasarkan tabel 8 diatas dapat diamati dari hasil MAPE, RMSE dan *R-Squared* lebih mudah menentukan model yang terbaik, sehingga model *K-Nearest Neighbors* adalah model yang terbaik berdasarkan hasil perhitungan MAPE (4,44%) yang menunjukkan prediksi sangat baik, nilai RMSE (1,9623) yang mendekati nilai 0 (nol) sehingga mendekati nilai aktualnya dan nilai *R-Squared* (0,849) yang menandakan bahwa variabel *independent* (X) memiliki pengaruh yang kuat terhadap variabel *dependent* (Y).

H. Analisis Data Dengan *Feature Importances*

Pada pengolahan data dengan algoritma *machine learning* yang telah dilakukan, peneliti melakukan analisis *feature importance* dengan model *K-Nearest Neighbors* guna mengetahui fitur-fitur apa saja yang penting dan memiliki pengaruh yang besar terhadap memprediksi temperatur.

Feature	Importance.var	Importance.Overall
1	3	z.rms 1023.5485
2	4	z.peak 955.4948
3	1	y.rms 1082.4209
4	2	y.peak 1066.7731
5	5	x.rms 942.3703
6	6	x.peak 891.2600

Gambar 2 Nilai *Feature Importance*



Gambar 3. *Feature Importance* Pada *K-Nearest Neighbors*

Berdasarkan hasil gambar 2 dan gambar 3 diatas dapat dilihat bahwa variabel yang memiliki nilai tertinggi yaitu: Y.rms bernilai (1082,4209), posisi kedua Y.peak bernilai (1066,7731) dan posisi ketiga Z.rms bernilai (1023,5485). Dengan hasil *feature importance* ini, dapat diketahui jika terjadi perubahan yang signifikan pada ketiga variabel tersebut maka akan berdampak signifikan pada perubahan temperatur. Selain itu, jika terjadi perubahan signifikan terlalu panas pada temperatur maka akan terjadi *overhate* pada *part bearing* di mesin kertas tersebut. Jika sudah terjadi *overheat* maka mesin perlu dihentikan sehingga menyebabkan turunnya hasil produksi dan dapat memperpendek usia pemakaian *part bearing*. Peningkatan getaran pada *part bearing* dapat disebabkan oleh beberapa hal seperti kecepatan mesin yang tidak konstan, komponen *part bearing* yang aus, pelumas yang belum diganti, dan penggunaan komponen yang tidak sesuai standar operasional prosedur.

Peneliti menyarankan kepada pihak perusahaan untuk dapat menjaga kestabilan getaran pada variabel Y.rms, Y.peak dan Z.rms agar tetap dalam batasan normal sehingga tidak terjadi perubahan temperatur mesin yang signifikan dan *overheat*. Berharap perusahaan dapat melakukan tindakan yang tepat dan benar untuk menghindari kerusakan sebelum benar-benar terjadi.

I. Analisis Implementasi *Predictive Maintenance* Pada *Part Bearing*

Dalam implementasi *predictive maintenance* ini peneliti melibatkan variabel temperatur dan variabel-variabel yang sangat berpengaruh yang didapatkan dari hasil *feature importance*. Variabel tersebut dapat membantu dalam penentuan kapan *part bearing* perlu dilakukan *maintenance* sehingga dapat memperpanjang usia *part bearing* dan

mencegah kerusakan fatal sebelum benar-benar terjadi. Variabel-variabel tersebut adalah:

Tablel 9. Indikator Variabel Normal dan Perlu *Maintenance*


No.	Variabel	Batas Normal	Perlu <i>Maintenance</i>
1.	Temperatur	20°C - 75°C	≥ 75°
2.	Peak	0 - 12	> 12
3.	RMS	0 - 4	> 4
4.	Battery	≥ 3	< 3

Langkah-langkah implementasi *predictive maintenance* pada *part bearing* di mesin kertas, yaitu:

1. Pemasangan Sensor Pada *Part Bearing*. Pasang sensor pada *part bearing* yang telah diidentifikasi dan pastikan sensor dapat memberikan data suhu dan variabel penting lainnya yang akurat dan dapat diandalkan.
2. Integrasikan dengan Sistem Pemantauan. Lakukan integrasi sensor dengan sistem pemantauan mesin, pastikan data sensor dapat terhubung dan terkirim secara *real-time* ke sistem pemantauan.
3. Pemantauan dan Pengumpulan Data. Mulai pemantauan data sensor terutama suhu secara kontinu pada *part bearing*. Kumpulkan data sensor selama periode waktu yang cukup untuk membangun *dataset* yang representatif.
4. Analisis Data Historis/ Lakukan analisis data historis suhu dan variabel lainnya untuk mengidentifikasi pola anomali yang dapat menjadi prediktor keausan atau masalah pada *part bearing*.
5. Pengembangan Model Prediktif. Gunakan teknik analisis data, seperti *machine learning* untuk mengembangkan model prediktif yang dapat memprediksi kegagalan *part bearing* berdasarkan pola temperatur.
6. Pengaturan *Threshold* dan Peringatan. *Threshold* temperatur yang mengindikasikan kondisi normal pada *part bearing* (20°C - 75°C) dan kondisi bermasalah (> 75°C = *overheat*). Sistem harus memberikan peringatan atau notifikasi kepada tim *maintenance*.
7. Integrasi Sistem Peringatan. Lakukan integrasi sistem peringatan ke sistem manajemen *maintenance* dan dapat diakses dengan cepat.
8. Perencanaan Jadwal *Maintenance*. Berdasarkan hasil prediksi, tentukan jadwal *maintenance* pada *part bearing* sebelum terjadi kerusakan yang sangat fatal. Pilih waktu yang paling sesuai untuk melakukan *maintenance* tanpa mengganggu operasi produksi secara signifikan.
9. Implementasi Tindakan Pencegahan. Lakukan *maintenance* sesuai jadwal *predictive maintenance* yang telah ditentukan. Gantilah *part bearing* yang memerlukan perhatian dan perbaikan berdasarkan prediksi temperatur.
10. Pemantauan Pasca – *Maintenance*. Setelah melakukan *maintenance*, terus pantau temperatur *part bearing* dan pastikan bahwa *maintenance* atau perbaikan yang dilakukan berhasil mengembalikan kondisi mesin ke dalam rantang normal.
11. Evaluasi dan Peningkatan. Evaluasi secara berkala kinerja sistem *predictive maintenance*. Analisis hasil *maintenance*, identifikasi penyebab kerusakan/kegagalan, dan perbaharui model prediktif jika diperlukan untuk meningkatkan akurasi.

J. Analisis Finansial Dengan *Potential Cost Savings*

Selain melakukan penelitian untuk memprediksi temperatur dengan algoritma *Machine Learning*, peneliti juga melakukan penelitian mengenai dampak finansial hasil implementasi *Predictive Maintenance* dengan model *Potential Cost Savings*. Dari hasil observasi lapangan, diketahui bahwa Perusahaan masih menggunakan *Reactive Maintenance*, sehingga peneliti akan menganalisis *Potential Cost Savings* antara biaya *Reactive Maintenance* dengan *Predictive Maintenance*.



Gambar 4. Model *Maintenance Cost*

Berdasarkan gambar 4 diatas terlihat bahwa *Maintenance Cost* pada model *Predictive Maintenance* (PdM) adalah yang paling optimum dibandingkan *Preventive Maintenance* dan *Corrective/Reactive Maintenance* (CM/RM). Peneliti akan membuat skenario perhitungan analisis finansial dengan *Potential Cost Savings* pada perusahaan PT. XYZ yang telah menggunakan sensor dari PT. Integral Industrial Indonesia pada *bearing* di mesin pembuat kertasnya.

Skenario perhitungan dibuat untuk 1 mesin pembuat kertas, sebagai berikut:

- Reactive Maintenance:**
Dari hasil wawancara dengan operator *maintenance* didapatkan data, sebagai berikut:
Frekuensi kerusakan: 24 kerusakan/Tahun.
Biaya perbaikan darurat: Rp 50.000.000./Perbaikan.
Downtime Overhaul per-perbaikan: 3 Hari/Perbaikan
- Predictive Maintenance:**
Dari hasil wawancara dengan pihak PT. Integral Industrial Indonesia didapatkan data, sebagai berikut:
Implementasi sistem pemantauan dengan sensor:
Rp 150.000.000./Tahun.
Biaya perawatan *preventif* per-minggu: Rp 3.000.000.
Downtime Overhaul per-perbaikan = 3 hari/perbaikan
Frekuensi Perbaikan = 2 Kerusakan/Tahun
Umur pakai *bearing* yang ditingkatkan: 22 minggu.

Perhitungan:

- Reactive Maintenance:**
Biaya perbaikan per tahun:
24 (frekuensi) x Rp 50.000.000 = Rp 1.200.000.000.
Downtime per tahun: 24 (frekuensi) x 3 hari = 72 Hari.
- Predictive Maintenance:**
Biaya perawatan *preventif* per tahun:
22 (minggu) x Rp 3.000.000 = Rp 66.000.000.

$$\text{Downtime Overhaul per-tahun} = 2 \text{ (perbaikan)} \times 3 \text{ hari} = 6 \text{ hari}$$

Peningkatan produktivitas:

$$\text{Produktivitas Tambahan} = \left(\frac{365 \text{ Hari} - \text{Total Hari Downtime PdM}}{365 \text{ Hari} - \text{Total Hari Downtime RM}} \times 100\% \right) - 100\%$$

$$\text{Produktivitas Tambahan} = \left(\frac{365 \text{ Hari} - 6 \text{ Hari}}{365 \text{ Hari} - 72 \text{ Hari}} \times 100\% \right) - 100\%$$

$$\text{Produktivitas Tambahan} = \left(\frac{359 \text{ Hari}}{293 \text{ Hari}} \times 100\% \right) - 100\%$$

$$\text{Produktivitas Tambahan} = 122,52\% - 100\%$$

$$\text{Produktivitas Tambahan} = 22,52\%$$

Produksi Tahunan : 350.000 ton

Analisis Perhitungan:

Total Biaya:

- Reactive Maintenance:**
Rp 1.200.000.000 (biaya perbaikan) + X (biaya *downtime*)
= Rp 1.200.000.000 + X.
- Predictive Maintenance:**
Rp 150.000.000 (biaya implementasi) + Rp 66.000.000 (biaya perawatan) + Y (biaya *downtime*) = Rp 216.000.000 + Y.

Downtime:

- Reactive Maintenance:**
Downtime Overhaul/Tahun = 24 (kerusakan) x 3 hari = 72 Hari
- Predictive Maintenance:**
Downtime/Tahun = 6 Hari (Perbaikan)

Produktivitas Tambahan:

Predictive Maintenance memberikan 22,52% peningkatan produksi.

$$\text{Produktivitas PM} = 22,52\% \times 350.000 \text{ ton/mesin} = 78.820 \text{ ton/mesin}$$

Return on Investment (ROI):

$$\text{ROI} = \frac{\text{Biaya Reactive} - \text{Biaya Predictive}}{\text{Biaya Implementasi}} \times 100\%$$

$$\text{ROI} = \frac{\text{Rp } 1.200.000.000 - \text{Rp } 216.000.000}{\text{Rp } 150.000.000} \times 100\%$$

$$\text{ROI} = 6,56\%$$

Tabel 10. Rekapitulasi Hasil Perhitungan *Potential Cost Savings*

Hasil Perhitungan	Reactive Maintenance (RM)	Predictive Maintenance (PdM)
Total Biaya	Rp 1.200.000.000 + X (biaya <i>downtime</i>)	Rp 216.000.000 + Y (biaya <i>downtime</i>)
<i>Downtime</i>	72 Hari	6 Hari
Produktivitas Tambahan	-	22,52% = 78.820 ton/mesin
<i>Return on Investment</i> (ROI)	-	6,56%

Berdasarkan perhitungan di atas, setelah dibandingkan total biaya, *downtime*, produktivitas tambahan dan *Return on Investment*. Pada skenario *Potential Cost Savings* dari *Predictive Maintenance* lebih efisien, ekonomis dan berdampak positif signifikan pada produktivitas pabrik, maka implementasi *predictive maintenance* pada *part bearing* mesin pembuat kertas bisa menjadi pilihan yang lebih menguntungkan.

Perhitungan yang dibuat peneliti masih sederhana dan perlu dikembangkan lebih lanjut, terutama pada faktor biaya *downtime* (X) pada *Reactive Maintenance* dan (Y) pada *Predictive Maintenance* yang masih belum diketahui,

dikarenakan informasi ini yang tidak boleh diketahui oleh pihak luar perusahaan. Meskipun begitu, tetap secara keseluruhan penerapan *Predictive Maintenance* pada *part bearing* di mesin kertas lebih menguntungkan dan dapat menghemat biaya jangka panjang bagi perusahaan PT. XYZ dengan berinvestasi pada penggunaan sensor dari PT. Integral Industrial Indonesia.

Selain itu, manfaat bagi Perusahaan PT. XYZ dapat memantau suhu *part bearing* mesin kertas, sehingga perusahaan dapat melakukan pemeliharaan yang diperlukan untuk menghindari terjadinya *overheat* pada *part bearing*. Perusahaan melakukan pemeliharaan sebelum benar-benar terjadi kerusakan yang fatal, sehingga bisa memperpanjang usia pemakaian *part bearing*, kondisi mesin kertas lebih aman dan bisa meningkatkan produktivitas pabrik.

IV. KESIMPULAN

Berdasarkan hasil evaluasi model dengan perhitungan *Mean Absolute Percentage Error*, *Root Mean Square Error* dan *R-Squared* pada *software* R Studio dari ketiga model yaitu: *K-Nearest Neighbors*, *Support Vector Machine*, dan *Artificial Neural Network* adalah sebagai berikut:

- Model *K-Nearest Neighbors* mendapatkan nilai hasil MAPE sebesar (4,44%), RMSE sebesar (1,9623) dan *R-Squared* sebesar (0,849).
- Model *Support Vector Machine* mendapatkan nilai hasil MAPE sebesar (7,52%), RMSE sebesar (1,8190) dan *R-Squared* sebesar (0,749).
- Model *Artificial Neural Network* mendapatkan nilai hasil MAPE sebesar (5,54%), RMSE sebesar (2,0209) dan *R-Squared* sebesar (0,799).

Berdasarkan dari analisis evaluasi model dengan MAPE, RMSE dan *R-Squared* sehingga model model *K-Nearest Neighbors* adalah model yang terbaik berdasarkan hasil perhitungan MAPE (4,44%) yang menunjukkan prediksi sangat baik, nilai RMSE (1,9623) yang mendekati nilai 0 (nol) sehingga mendekati nilai aktualnya dan nilai *R-Squared* (0,849) yang menandakan bahwa variabel *independent* (X) memiliki pengaruh yang kuat terhadap variabel *dependent* (Y).

Feature Importance adalah metode untuk mengevaluasi pentingnya setiap fitur (variabel) dalam model prediksi, seperti model *machine learning*. Ini membantu kami memahami seberapa besar kontribusi setiap fitur terhadap target yang ingin diprediksi. Berdasarkan dari hasil model *machine learning* yang terbaik maka *feature importance* dilakukan pada model *K-Nearest Neighbors*. Hasil perhitungan *feature importance* dapat diketahui bahwa variabel yang memiliki nilai *Feature Importance* tertinggi yaitu: *Y.rms* bernilai (1082,4209), posisi kedua *Y.peak* bernilai (1066,7731) dan posisi ketiga *Z.rms*

bernilai (1023,5485). Dengan hasil *feature importance* ini, dapat diketahui jika terjadi perubahan yang signifikan pada ketiga variabel tersebut maka akan berdampak signifikan pada perubahan temperature pada *part bearing*. Sehingga, perlu tindakan pencegahan dari perusahaan untuk menjaga ketiga variabel tersebut dalam batasan normal.

Analisis finansial dengan perhitungan *Potential Cost Savings* didapatkan hasil *Reactive Maintenance* yaitu: total biaya sebesar Rp Rp 1.200.000.000 + X (biaya *downtime*) dan waktu *downtime* selama 72 hari dalam satu tahun. Sedangkan, hasil *Predictive Maintenance* yaitu: total biaya sebesar Rp 216.000.000 + Y (biaya *downtime*), waktu *downtime* 6 hari dalam setahun untuk perbaikan, mendapatkan produktivitas tambahan sebesar 22,52% atau 78.820 ton/mesin dan *Return of Investment* (ROI) sebesar 6,56%. Sehingga, dapat disimpulkan bahwa *Predictive Maintenance* lebih efisien, ekonomis dan berdampak positif signifikan pada produktivitas pabrik, maka implementasi *predictive maintenance* pada *part bearing* mesin pembuat kertas bisa menjadi pilihan yang lebih menguntungkan bagi perusahaan PT. XYZ.

REFERENSI

- [1] R. Rengaswamy, S. N. Balakrishnan, M. W. Lee, "A review of condition-based maintenance optimization models for stochastically deteriorating systems," in *European Journal of Operational Research*, vol. 293, no. 2, pp. 299-312, 2022. doi: 10.1016/j.ejor.2021.12.003.
- [2] Cinar, Zeki Murat, et.al. (2020). *Review Machine Learning in Predictive Maintenance towards Sustainable Smart Manufacturing in Industry 4.0. Sustainability* 2020, 12, 8211; doi:10.3390/su12198211.
- [3] Batta Mahesh. (2020). *Machine Learning Algorithms - A Review*.
- [4] Yogiek Indra Kurniawan, dan Tiyssa Indah Barokah. (2020). "Klasifikasi Penentuan Pengajuan Kartu Kredit Menggunakan *K-Nearest Neighbor*." *Jurnal Ilmiah Matrik*. Universitas Jenderal Soedirman dan Universitas Muhammadiyah Surakarta, Purwokerto dan Surakarta.
- [5] Octaviani, Pusphita, et al. "Penerapan Metode Klasifikasi *Support Vector Machine* (SVM) Pada Data Akreditasi Sekolah Dasar (SD) Di Kabupaten Magelang". Vol. 3, no. 4, 2014, pp.811-820.
- [6] Prapat, Indri, et.al. "Penerapan Metode *Support Vector Machine* (SVM) Pada Klasifikasi Penyimpangan Tumbuh Kembang Anak". *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, Vol.2, no. 10, 2018, pp. 3163-3169.
- [7] Sekar Handayani. (2022). "Implementasi Metode *Branch And Bound* Dan Metode *Cutting Plane* Dalam Memaksimalkan Keuntungan Di Cv. Demangan Digital Printing Berbantuan Aplikasi R". Universitas Islam Negeri Raden Intan Lampung, Lampung.
- [8] Fachid Syakirah, and Agung Triayudi. "Perbandingan Algoritma Regresi Linier dan Regresi Random Forest Dalam Memprediksi Kasus Positif Covid-19". *Jurnal Media Informatika Budidarma*, vol.6, no.1, 25 Jan. 2022, p. 208, <https://doi.org/10.30865/mib.v6i1.3373>.
- [9] Akhmad Syukron. (2019). "Metoda Random Over-Under Sampling Random Forest Untuk Klasifikasi Penilaian Kredit". Sekolah Tinggi Manajemen Informatika Dan Komputer Nusa Mandiri, Jakarta: Tesis