

Analisa Predictive Berbasis Supervised Machine Learning Terhadap Kerusakan Peralatan Pembangkit

Mochamad Marte Ardhiyanto⁽¹⁾, Rudi Sumarwanto⁽²⁾

PT. PLN (Persero) Pusat Pendidikan dan Pelatihan (UPDL) Makassar

marte@pln.co.id



Abstract

Predictive maintenance is a treatment for the actual operation of the equipment to optimize the company's operations. The output of predictive program maintenance is data, this treatment includes the type of "condition based maintenance" where changes in the condition of the machine or equipment are detected so that proactive actions are taken before the occurrence of machine damage. The K-nearest Neighbor (K-NN) algorithm is a simple supervised machine learning algorithm that is used to solve problems based on classification and regression. K-NN works by finding the query distance and all database examples, selecting a certain number of examples (K) adjacent to the query, then selecting the frequent label (in classification) or the average label (in regression). The purpose of this algorithm is to classify new object conditions based on attributes and samples from the training database. So that a predictive analysis is carried out on the damage to generating equipment using the machine learning application method of the Nearest Neighbor type or the classification of conditions used to predict the age or condition of an equipment by modeling according to the standard Operation & Maintenance of equipment. By doing predictive analysis, maintenance will lead to condition based maintenance so that the KPI (Key Performance Indicator) of operating performance in the form of increasing values, such as Capacity Factor (CF), Equivalent Availability Factor (EAF) becomes optimal and prevents the generator from tripping suddenly. which is called sudden outage frequency (SdOF), as well as more efficient maintenance costs.

Keywords: *Predictive Maintenance, Machine Learning, Condition Based Maintenance*

Abstrak

Perawatan predictive merupakan treatment untuk operasi sesungguhnya dari peralatan untuk mengoptimalkan operasi perusahaan. Output dari perawatan program predictive adalah data, perawatan ini termasuk jenis "condition based maintenance" dimana perubahan kondisi mesin atau peralatan dideteksi sehingga tindakan yang bersifat proaktif dilakukan sebelum terjadinya kerusakan mesin. Algoritma K-nearest Neighbor (K-NN) adalah algoritma supervised machine learning simple yang digunakan untuk menyelesaikan masalah berdasarkan klasifikasi dan regresi. K-NN bekerja dengan mencari jarak query dan semua contoh basis data, memilih contoh nomor tertentu (K) yang berdekatan dengan query, kemudian memilih label yang sering (pada klasifikasi) atau rata-rata label (pada regresi). Tujuan dari algoritma ini adalah untuk mengklasifikasikan kondisi obyek baru berdasarkan atribut dan sample dari training database. Sehingga dilakukan analisa predictive terhadap kerusakan peralatan pembangkit dengan metode aplikasi machine learning tipe Nearest Neighbour atau pengklasifikasian kondisi yang digunakan untuk memprediksi umur atau kondisi suatu peralatan dengan pemodelan sesuai standar Operation & Maintenance peralatan. Dengan dilakukan analisa predictive, maka pemeliharaan akan menuju ke arah condition based maintenane sehingga KPI (Key Performance Indicator) kinerja operasi berupa peningkatan nilai, seperti Capacity Factor (CF), Equivalent Availability Factor (EAF) menjadi optimal dan mencegah pembangkit mengalami trip secara tiba-tiba yang disebut dengan sudden outage frequency (SdOF), serta biaya pemeliharaan lebih efisien.

Kata Kunci: *Pemeliharaan Prediktif, Mesin Pembelajaran, Pemeliharaan Berbasis Kondisi*

I. PENDAHULUAN

Perawatan *predictive* pada dasarnya merupakan *treatment* untuk operasi sesungguhnya dari peralatan untuk mengoptimalkan operasi perusahaan. *Output* dari perawatan dari program *predictive* adalah data, perawatan ini termasuk jenis "*condition*

based maintenance" dimana perubahan kondisi mesin atau peralatan dapat dideteksi sehingga tindakan yang bersifat proaktif dapat segera dilakukan sebelum terjadinya kerusakan mesin.[1]

Pola pemeliharaan *predictive* dianggap lebih efektif dan efisien karena pemeliharaan dilakukan berdasarkan hasil pengamatan (*monitoring*) dan analisa untuk menentukan kondisi dan kapan pemeliharaan akan dilaksanakan, berbeda dengan pola pemeliharaan yang lain seperti pada pola pemeliharaan *time base maintenance*. Pada pola pemeliharaan *time base maintenance*, pemeliharaan dilakukan hanya berdasarkan pada jam operasi peralatan / komponen tanpa mempertimbangkan apakah peralatan tersebut masih baik atau tidak.

Pengembangan pola pemeliharaan *predictive*, memanfaatkan berbagai peralatan *test*, peralatan monitoring yang telah dimiliki dan mengikuti berbagai metoda analisis yang dapat diterapkan dalam meningkatkan *quality* pemeliharaan maupun *reliability* operasi pembangkit serta efektifitas dalam penggunaan biaya pemeliharaan itu sendiri. Penggunaan dari teknologi *predictive maintenance* memungkinkan kinerja pemeliharaan dapat meningkat, karena kondisi suatu mesin atau peralatan dapat diketahui dengan baik tanpa menghentikan jalannya mesin. Perawatan *predictive* menunjukkan penyimpangan dari kondisi normal kerja mesin dengan cara ini dapat memberikan cara yang lebih handal untuk mengetahui kerusakan yang sedang dan akan terjadi, dengan menunjukkan komponen yang rusak maka pihak manajemen dapat menyiapkan komponen sesuai kebutuhan yang diinginkan. Kunci utama perawatan *predictive* adalah mendeteksi kondisi abnormal yang akan terjadi atau *impending trouble* dan segera menyelesaikan masalah tersebut sebelum

terjadinya kerusakan mesin atau *machine breakdown*.

Predictive Maintenance bekerja berdasarkan proses *monitoring condition* yang dilakukan terhadap peralatan yang diinginkan. Hasil dari proses ini adalah data – data hasil pengukuran atau pengujian, yang selanjutnya data – data tersebut dibandingkan dengan data – data acuan yang sudah diketahui sebelumnya (*known engineering limit*) untuk menentukan kondisi operasi dari peralatan tersebut. Teknik pemantauan yang umumnya digunakan dalam *predictive maintenance* meliputi *monitoring vibrasi, process parameter, tribologi, thermography, inspeksi visual dan metode non – destructive testing* seperti metode ultrasonic.[1]

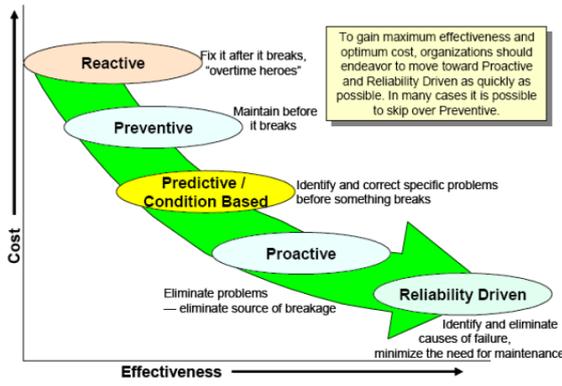
Dengan demikian dilakukanlah analisa *predictive* terhadap kerusakan peralatan pembangkit dengan metode aplikasi *machine learning* tipe *Nearest Neighbour* atau pengklasifikasian kondisi yang digunakan untuk memprediksi umur atau kondisi dari suatu peralatan dengan pemodelan sesuai dengan standar *Operation & Maintenance* peralatan. Dengan dilakukan analisa *predictive* ini, maka pemeliharaan akan menuju ke arah *condition based maintenane* sehingga KPI (*Key Performance Indicator*) kinerja operasi berupa peningkatan nilai, seperti *Capacity Factor (CF)*, *Equivalent Availability Factor (EAF)* menjadi optimal dan mencegah pembangkit mengalami stop / trip secara tiba tiba yang biasa disebut dengan *sudden outage frequency (SdOF)*, serta biaya pemeliharaan dapat lebih efisien.

II. KAJIAN LITERATUR

A. Condition Based Maintenance

Condition Based Maintenance (CBM) merupakan perawatan pencegahan yang dilakukan sesuai dengan kondisi yang berlangsung dimana tidak memiliki jadwal yang spesifik dengan menunda proses maintenance maka biaya yang digunakan untuk proses maintenance tersebut dapat disimpan. Fungsi lain dari *Condition Based Maintenance* adalah mengurangi terjadinya *breakdown* atau *emergency shutdown*, optimalisasi penggunaan *resource* dan mengurangi waktu *down time* akibat kerusakan peralatan.

Condition Based Maintenance menggunakan berbagai macam parameter seperti temperatur, vibrasi dan arus listrik untuk memonitor kondisi peralatan. CBM mengasumsikan bahwa seluruh peralatan akan mengalami kerusakan, CBM memonitor kondisi atau performa dari peralatan pembangkit menggunakan teknologi pengolah data.



Gambar 1. Maintenance Evolution

B. Machine Learning

Sejak tahun 1980-an, bidang ilmu *soft computing* mulai muncul dan berkembang berdampingan dengan bidang ilmu *hard computing*. Adapun yang membedakan antara kedua ilmu ini adalah setelah diprogram, *hard computing* akan memberikan hasil yang sama untuk input yang sama, sementara *soft computing* akan belajar dari input-input yang diberikan sebelumnya untuk memberikan hasil yang lebih akurat di masa depan yang lebih dikenal dengan *Machine Learning*. Dalam cabang *Machine Learning* terdapat tiga bidang ilmu besar yang dikembangkan terus menerus untuk mencapai tujuan diatas adalah *Supervised Learning*, *Unsupervised Learning*, *Reinforcement Learning*. Pada pembahasan selanjutnya akan difokuskan pada *k-Nearest Neighbour* dimana termasuk *supervised learning*. Rancangan *computing* menggunakan bahasa pemograman *Python* di Google Collab. *Machine learning* dapat dijadikan sebagai *computerized maintenance management* salah satunya *predict analyst*.

1) **K - Nearest Neighbor (K-NN)**

Algoritma K-nearest Neighbor (K-NN) adalah algoritma *supervised machine learning simple* yang dapat digunakan untuk menyelesaikan masalah berdasarkan klasifikasi dan regresi. K-NN bekerja dengan mencari jarak antara query dan semua contoh basis data, memilih contoh nomor tertentu (K) yang berdekatan dengan query, kemudian memilih label yang paling sering (pada klasifikasi) atau rata-rata label (pada regresi). Tujuan dari algoritma ini adalah untuk mengklasifikasikan kondisi obyek baru berdasarkan atribut dan sample dari training database. Sepanjang seluruh berasumsi bahwa

domain instan , X , diberkahi dengan fungsi metrik .Itu adalah $\rho : X \times X \rightarrow R$ adalah sebuah fungsi dimana pengembalikan jarak anantara dua element x

$$\rho(x, x') = \|x - x'\| = \sqrt{\sum_{i=1}^d (x_i - x'_i)^2} \quad (1)$$

Seperti contoh jika $X= Rd$ kemudian ρ dapat menjadi jarak Euclidian, jari $S = (x_1, y_1), \dots, (x_m, y_m)$ menjadi urutan contoh pelatihan. Untuk setiap $x \in X$, let $\pi_1(x), \dots, \pi_m(x)$ menjadi penataan ulang $\{1, \dots, m\}$ berdasarkan jarak tersebut, $\rho(x, x_i)$. Artinya, untuk semuanya $i < M$

$$\rho(x, x_{\pi_i(x)}) \leq \rho(x, x_{\pi_{i+1}(x)}) \quad (2)$$

Untuk jumlah k, batasan k-NN untuk klasifikasi binary didefiniikan sebagai

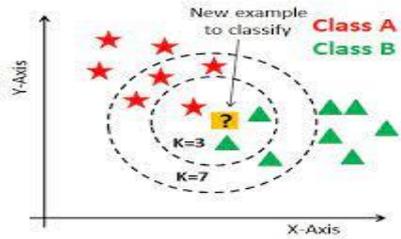
k-NN	
input:	a training sample $S = (x_1, y_1), \dots, (x_m, y_m)$
output:	for every point $x \in X$, return the majority label among $\{y_{\pi_i(x)} : i \leq k\}$

Ketika $k=1$, yang memiliki aturan 1-NN: $h_S(x) = y_{\pi_1(x)}$. Sebuah ilustrasi geometris dari aturan 1-NN diberikan Untuk masalah regresi, yaitu, $Y = R$, seseorang dapat mendefinisikan prediksi menjadi target rata-rata dari k tetangga terdekat. Yaitu, $h_S(x) = \frac{1}{k} \sum_{i=1}^k y_{\pi_i(x)}$. Lagi umumnya, untuk beberapa fungsi:

$$h_S(x) = \Phi((x_{\pi_1(x)}, y_{\pi_1(x)}), \dots, (x_{\pi_k(x)}, y_{\pi_k(x)})) \quad (3)$$

Sangat mudah untuk memverifikasi bahwa kita dapat memberikan prediksi dengan sebagian besar label (untuk klasifikasi) atau dengan target rata-rata (untuk regresi) seperti dalam Persamaan dengan pilihan yang tepat dari .Kerumuman dapat menyebabkan aturan lain; misalnya, jika $Y = R$, kita dapat mengambil rata-rata tertimbang dari target sesuai dengan jarak dari x:

$$h_S(x) = \sum_{i=1}^k \frac{\rho(x, x_{\pi_i(x)})}{\sum_{j=1}^k \rho(x, x_{\pi_j(x)})} y_{\pi_i(x)} \quad (4)$$



Gambar 2. Contoh k-NN

2) Python

Python adalah bahasa pemrograman interpreter tingkat tinggi, berorientasi objek, dengan memiliki semantik yang dinamis. Bahasa tingkat tinggi yang dibangun dalam struktur data, dikombinasikan dengan pengetikan dinamis dan pengikatan dinamis, membuatnya sangat menarik untuk pengembangan Aplikasi cepat, serta untuk digunakan sebagai bahasa scripting. Sintaksis Python yang sederhana dan mudah dipelajari menekankan keterbacaan dan karena mengurangi biaya pemeliharaan program. Python mendukung modul dan paket, yang mendorong modularitas program dan penggunaan kode kembali. Intepeter Python dan pustaka standar yang luas tersedia dari berbagai sumber dan dapat didistribusikan secara bebas.

Python mendukung pemrograman dengan paradigma multiguna, utamanya; namun tidak dibatasi; pada pemorgaman berorientasi objek, pemrogram imperatif, dan pemrograman fungsional. Salah satu fitur yang tersedia pada python adalah bahasa pemrograman dinamis yang dilengkapi dengan manajemen memori otomatis.

III. METODOLOGI

Metode pelaksanaan yang digunakan dalam penelitian ini sebagai berikut.

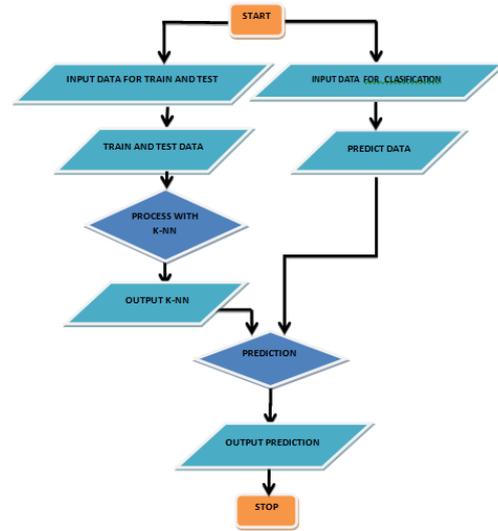
- a. Pengumpulan Data dan Studi Pustaka
- b. Analisa menggunakan Metode-metode *supervised learning*
- c. Penentuan Metode dan implementasi Aplikasi
- d. Melakukan diskusi dengan pihak terkait melalui *Community of Practice (COP)*
- e. Penyusunan Laporan

Ruang lingkup dari penelitian ini adalah sebagai berikut.

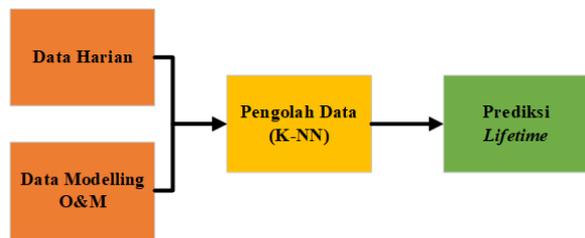
- a. Metode analisis predictive kerusakan peralatan pembangkitan dengan

menggunakan analisa *Nearest Neighbor Analysis*.

- b. Penentuan metode prediksi yang tepat dari metode analisis yang digunakan realisasi FDT (*Failure Defense Task*) yang telah ditentukan.



Gambar 3. Diagram Alir Penelitian



Gambar 4. Blok diagram bagaimana memperoleh hasil prediksi *lifetime*

IV. PEMBAHASAN DAN HASIL

Sistem *machine learning* menggunakan metode *K- Nearest Neighbor* atau pengklasifikasian kondisi peralatan lalu digunakan untuk memprediksi kondisi peralatan tersebut berdasarkan kriteria-kriteria permodelan yang disesuaikan dengan spesifikasi *operation & Maintenance* dengan menggunakan aplikasi *Python* dan *Google Collab* yang bersifat *open source*.

3.1. Memasukkan Data *Modelling*

Tahap pertama adalah memasukkan data modelling dari data spesifikasi *Operation & Maintenance* sebagai acuan kondisi peralatan

untuk pengklasifikasian kondisi peralatan salah satu peralatan yang ada di Pembangkit PLTA Bakaru, menggunakan pemodelan prediksi *lifetime* dari *thrust bearing* Unit 1 PLTA Bakaru.

Tabel 1. Modelling Thrust Bearing

Waktu	Vibrasi Gen Shaft X	Temp. Bearing Metal	Temp. Bearing Metal Turbine	Kondisi
Comisioning	98	54,2	65	0
Comisioning	96	54	64	0
12/18/2015	104	57,3	64	1
12/16/2015	130	58,1	64,4	1
12/19/2015	134	56,5	61,9	1
1/20/2016	112	57	64	1
1/21/2016	83,42	54,7	64,8	0
1/22/2016	93	55,2	64,7	0
1/23/2016	85	57,3	62,5	0
1/25/2016	70	57,2	63	0

3.2 Memasukkan Data Trend

Untuk memprediksi umur *lifetime* peralatan tersebut diperlukan data harian untuk menambah akurasi ketepatan prediksi kondisi, pada contoh dimasukkan data inspeksi harian *thrust bearing* meliputi temperatur *oil bearing*, temperatur *metal*, dan *vibrasi*.

Tabel 2. Data Trend Thrust Bearing Data Testing for Classification

No	Temp Bearing Oil (°C)	Temp Bearing Metal (°C)	Vibrasi Bearing (µm)	Keterangan
1	43,2	39	120	
2	50,6	39,4	112	
3	38,2	37	79,5	
4	44	58,2	118,2	
5	35	39	82	
6	48	52	80	

3.3. Pengolahan Data

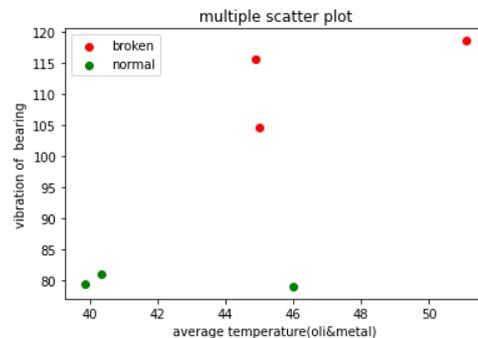
Setelah memasukkan data trend, lalu akan dilanjutkan pengolahan data dengan pengklasifikasian berdasar kondisi *modelling* dengan menggunakan aplikasi Google Collab lalu didapat hasil prediksi kondisi dari suatu peralatan.

```

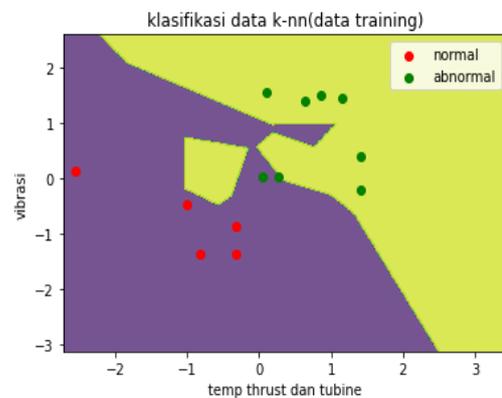
prediksi = pd.read_csv("DATA UNTUK LAPORAN PFL.csv")
predikat

TEMP BEARING OIL  TEMP BEARING METAL  VIBRASI BEARING  KETERANGAN
0      39.2          41.5          81.181618          1
1      50.6          39.4          104.696652          0
2      38.7          41.0          79.500000          1
3      44.0          58.2          118.200000          0
4      49.3          40.5          115.500000          0
5      42.3          49.7          79.111111          1
    
```

Gambar 5. Pengolahan Data



Gambar 6. Plotting modeling



Gambar 7. Plotting hasil prediksi

Selanjutnya akan muncul hasil prediksi kondisi suatu peralatan seperti pada Gambar 7 yang dimana hasilnya masih terevaluasi.

Tabel 3. Tabel hasil produksi

Jumlah Data	Data Evaluation		Hasil
	Hasil Prediksi Abnormal	Hasil Prediksi Normal	
13	8	5	Abnormal

3.4. Analisa Resiko

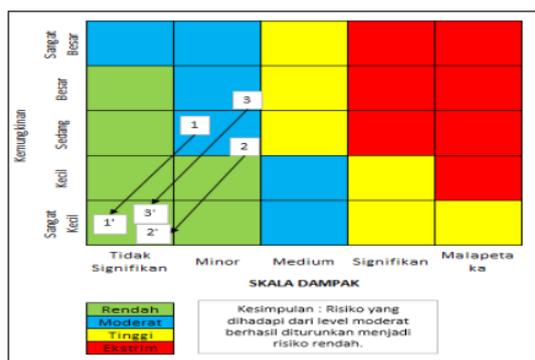
Adapun analisa resiko yang dapat dianalisa tertera pada Tabel 4 yang menjelaskan identifikasi resiko, mitigasi dan perubahan yang dilakukan sehingga dapat meminimalisir resiko. Resiko-resiko yang mungkin terjadi selama

penggunaan aplikasi adalah permasalahan yang menyangkut pada penggunaan aplikasi.

Tabel 4. Analisa Resiko

No	Identifikasi Resiko	Dampak	Mitigasi	Perubahan Resiko
1	Pengguna Tidak memahami penggunaannya	Kegagalan dalam aplikasi	Dibuat instruksi kerja sehingga mudah untuk dipahami oleh pengguna lainnya	Turun dari kemungkinannya sedang menjadi sangat kecil dan skala dampaknya dari minor menjadi tidak signifikan
2	Pada Aplikasi terdapat error dalam koding	Kegagalan dalam aplikasi	Dibuatkan sistem Google Collab untuk trouble shooting	Turun dari kemungkinannya sedang menjadi sangat kecil dan skala dampaknya dari minor menjadi tidak signifikan
3	Kesalahan memasukkan data	Kegagalan dalam aplikasi	Dibuat instruksi kerja sehingga mudah untuk dipahami oleh pengguna lainnya	Turun dari kemungkinannya sedang menjadi sangat kecil dan skala dampaknya dari minor menjadi tidak signifikan

Dari Resiko tersebut, dibuatlah tabel analisa pada Gambar 6 yang menyangkut level tingkat, skala dampak dan analisa resiko. Dari tabel tersebut dibuatlah matriks analisa resiko yang menjelaskan penurunan skala dampak dan kemungkinan dari resiko moderat menjadi rendah karena adanya mitigasi resiko yang telah dibuat, sehingga dapat mempercepat dan memudahkan penggunaan aplikasi tersebut.



Gambar 8. Tabel Analisa Resiko

3.5 Manfaat

A. Manfaat Finansial

Secara finansial mampu memberikan manfaat berupa penghematan anggaran pemeliharaan dan kerugian akibat *breakdown maintenance* dan *emergency shutdown*. Jadi untuk melakukan prediksi melalui program aplikasi, secara finansial membutuhkan anggaran Rp.0, karena aplikasi yang bersifat *openources*.

Dari sisi administrasi dan pemeliharaan dapat digunakan diberbagai lokasi pembangkitan dan peralatan yang terdapat parameter didalamnya dan memprediksi kondisi dan peralatan tersebut sehingga dapat difungsikan secara universal.

B. Manfaat Non-Finansial

Breakdown maintenance dapat dicegah dengan adanya prediksi dan analisa berdasarkan *condition based maintenance*. Sehingga secara non finansial mampu memberikan manfaat, diantaranya :

1. Mengoptimalkan nilai kinerja perusahaan disisi pengoperasian pembangkit berupa peningkatan nilai *Equivalent Availability Factor (EAF)* dan *Capacity Factor (CF)*
2. Berkontribusi mengurangi potensi *Emergency Shutdown* atau *Sudden Outage Frequency (SdOF)*
3. Berkontribusi dan menunjang ketercapaian nilai *Maturity Level Reliabilty*
4. Dengan mencegah *failure* pada pembangkit maka suplai ketersediaan listrik ke pelanggan akan terjaga dan citra perusahaan akan meningkat.

C. Manfaat terhadap KPI Korporat & Besarannya

1. Meningkatkan nilai EAF dari 99,3 % menjadi 99,51%
2. Meningkatkan nilai CF dari 83,89% menjadi 84,17%
3. Mempertahankan nilai SDOF 0 %

V. KESIMPULAN

Berdasarkan implementasi yang telah dilakukan sistem Commet dapat bekerja

dengan baik dan dapat disimpulkan bahwa sistem Commet

- a. Memiliki sistem yang sederhana, biaya murah, monitoring mudah, keandalan cukup baik, mengikuti perkembangan teknologi dan mendukung tata kelola *world class hydropower generation*.
- b. Dengan adanya analisa prediktif maka akan mengurangi potensi terjadinya *breakdown maintenance* atau *shutdown emergency* atau Sdof sehingga nilai kinerja pengoperasian pembangkit seperti EAF dan CF akan lebih optimal.
- c. Dengan adanya aplikasi analisa prediktif maka pemeliharaan berbasis *condition based maintenance* dapat lebih optimal dan nilai *maturity level reliability management* meningkat.
- d. Dengan mencegah *failure* pada pembangkit maka suplai ketersediaan listrik ke pelanggan akan terjaga dan citra perusahaan akan meningkat.

UCAPAN TERIMA KASIH

Terima kasih untuk keluarga penulis, teman-teman dari PT. PLN (Persero) Pusat Pendidikan dan Pelatihan (UPDL) Makassar, serta semua pihak, dan instansi yang telah terlibat dalam proses menyelesaikan penelitian dan penulisan jurnal ini.

REFERENSI

- [1] Higgins, Lindley R., and R. Keith. *Maintenance engineering handbook McGraw-Hill, 6th. Edition*, New York, 2002.
- [2] Yong Xua,, Zhaohui Lib , Xide Laic, *Dynamic model for hydro-turbine generatorunits based on a database method for guidebearings*, 2012.
- [3] Erwin Rianto, *Analisa Vibrasi Untuk Mendeteksi Kerusakan Pada Turbin Uap UBB Perusahaan III di PT.Petrokimia*, 2016.
- [4] Guodong Han^{1,2, a}, Zhangqin Wu^{3, b}, Shuting Wan^{2,c}, Zhanjie Lv^{1,2,d} , Ronghai Liu^{3, e}, Jin Wang³, *The fault analysis and research of turbine generator sliding bearing oilfilm instability*, 2014.
- [5] Sukendi¹, Ikhwansyah Isranuri², Suherman, *Analisa Karakteristik*

Getaran Dan Machine Learning Untuk Deteksi Dini Kerusakan Bearing, 2015.

- [6] Hosameldin Ahmed, Asoke K. Nandi, *Condition Monitoring with Vibration Signals*, 2020.
- [7] Fadhli Hakim Akbar, Titin Isna Oesman, Endang Widuri Asih, *Analisa Kegagalan Turbine Guide Bearing Menggunakan Metode Reliability Centered Maintenance (RCM)*, 2017.
- [8] ISO 19283 (Condition monitoring and diagnostics of machine-hydroelectric generating units)
- [9] <https://medium.com/@16611077/klasifikasi-k-nearest-neighbors-knn-menggunakan-python-10c64bcb10a1>