

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terkait

1. Berdasarkan Penelitian yang telah dilakukan oleh yang berjudul “*Reliability Analysis of Real Time Operation State of Power System Based on K- Nearest Neighbor*” Studi mengenai *reliability analysis* pada sistem tenaga listrik dengan menggunakan algoritma *K-Nearest Neighbor (KNN)* menunjukkan bahwa metode ini memiliki efektivitas tinggi dalam mengidentifikasi kondisi operasi secara real-time. Melalui klasifikasi data operasional ke dalam status normal maupun abnormal, *KNN* dapat membantu operator dalam mendeteksi potensi gangguan sehingga keandalan sistem tetap terjaga [3]. Algoritma *KNN* mampu diimplementasikan pada sistem yang kompleks, termasuk pembangkit tenaga listrik. Relevansi metode ini semakin kuat ketika diterapkan pada PLTGU Cilegon, khususnya di unit desalinasi *plant*, yang menuntut tingkat keandalan operasional tinggi. Dengan pendekatan tersebut, *Health Index* desalinasi *plant* dapat dianalisis secara lebih tepat, sehingga prediksi jadwal pemeliharaan menjadi lebih akurat dan risiko breakdown di luar perencanaan dapat ditekan.
2. Berdasarkan Penelitian yang telah dilakukan oleh yang berjudul “*A hybrid k-means-GMM machine learning technique for turbomachinery condition monitoring*” mengembangkan metode *hybrid machine learning* dengan mengombinasikan algoritma *k-means clustering* dan *Gaussian Mixture Model (GMM)* untuk pemantauan kondisi *turbomachinery*. Metode tersebut terbukti mampu mengatasi keterbatasan standar OEM yang sering gagal mendeteksi degradasi mesin ketika *parameter* sensor masih berada pada batas normal. Hasil penelitian menunjukkan bahwa algoritma *k-means-GMM* dapat mengklasifikasikan kondisi mesin ke dalam status *off*, normal, dan abnormal, sekaligus memetakan tren degradasi secara visual berdasarkan data sensor. Studi kasus pada *LM2500 axial compressor gas generator* memperlihatkan bahwa degradasi komponen dapat diidentifikasi lebih awal, bahkan sebelum ditemukan kerusakan aktual pada saat inspeksi [4]. Konsep tersebut memiliki relevansi kuat dengan penelitian ini, khususnya pada PLTGU Cilegon di unit desalinasi *plant*. Sama seperti *turbomachinery*, unit desalinasi memiliki *parameter* operasi yang dapat

dianalisis untuk mendeteksi degradasi kinerja. Dengan memanfaatkan algoritma *machine learning* dalam hal ini *K-Nearest Neighbor (KNN)* penelitian ini diarahkan untuk menentukan *Health Index* desalinasi plant. Analisis tersebut diharapkan dapat memberikan prediksi pemeliharaan yang lebih akurat, sehingga mampu mencegah terjadinya *breakdown* di luar jadwal dan mendukung implementasi *predictive maintenance* dalam sistem digitalisasi pembangkit.

3. Berdasarkan Penelitian yang telah dilakukan oleh yang berjudul “**Analisis Performa Metode *K-Nearest Neighbor* Untuk Identifikasi Jenis Kaca**” penelitian ini membahas penerapan algoritma *K-Nearest Neighbor (KNN)* untuk mengidentifikasi jenis kaca berdasarkan komposisi kimianya. Dengan menggunakan dataset dari UCI Machine Learning Repository, penelitian ini menguji performa *KNN* pada variasi nilai *K* dan mengevaluasinya melalui metrik akurasi, presisi, *recall*, serta F-measure. Hasil terbaik diperoleh pada nilai *K*=3 dengan akurasi sebesar 64%, presisi 63%, *recall* 71%, dan F-measure 67%. Meskipun akurasi yang dicapai belum tinggi, penelitian ini membuktikan bahwa *KNN* mampu melakukan klasifikasi berbasis data numerik dengan tingkat keandalan yang cukup baik [5]. Temuan tersebut memiliki keterkaitan erat dengan penelitian di PLTGU Cilegon, khususnya pada unit desalinasi *plant*, yang juga bergantung pada analisis *parameter* operasional. Sama halnya dengan identifikasi jenis kaca, algoritma *K-Nearest Neighbor (KNN)* dapat dimanfaatkan untuk mengklasifikasikan kondisi operasional unit ke dalam kategori normal maupun abnormal. Melalui klasifikasi ini, *Health Index* desalinasi *plant* dapat ditentukan, sehingga prediksi waktu pemeliharaan dapat dilakukan dengan lebih tepat serta potensi *breakdown* di luar jadwal dapat ditekan seminimal mungkin.
4. Berdasarkan Penelitian yang telah dilakukan oleh yang berjudul “**Implementasi Algoritma Klasifikasi *K-Nearest Neighbor (KNN)* Untuk Klasifikasi Seleksi Penerima Beasiswa**”. Implementasikan algoritma *K-Nearest Neighbor (KNN)* untuk membantu proses klasifikasi seleksi penerima beasiswa di tingkat SMA. Penelitian ini dilakukan karena proses seleksi sebelumnya masih dilakukan secara manual sehingga rawan tidak tepat sasaran. Dengan memanfaatkan data penerima beasiswa tahun sebelumnya sebagai *training data* dan data pendaftar baru sebagai *testing data*, algoritma *KNN* mampu menyeleksi penerima beasiswa secara lebih objektif. Hasil pengujian menggunakan *confusion matrix* menunjukkan akurasi rata-rata sebesar

90,5%, dengan nilai presisi 89% dan *recall* 83%, yang membuktikan bahwa *KNN* efektif untuk klasifikasi berbasis data numerik [6]. Sejumlah *parameter* operasional seperti dapat dianalisis menggunakan algoritma *KNN*. Sama seperti klasifikasi data penerima beasiswa, algoritma *KNN* pada penelitian ini dapat diterapkan untuk mengklasifikasikan kondisi operasional desalinasi *plant* ke dalam kategori *normal* atau *abnormal*. Hasil klasifikasi tersebut kemudian menjadi dasar dalam menentukan *Health Index* desalinasi *plant*.

5. Berdasarkan Penelitian yang telah dilakukan oleh yang berjudul “***Use of Machine Learning-Based Health Index With K-Nearest Neighbors Method to Maintain Desalination Plant Performance Gas and Steam Power Plants Applications***”. pendekatan *Health Index* (HI) berbasis *machine learning* sebagai dukungan pemeliharaan prediktif pada *desalination plant* yang beroperasi di lingkungan PLTGU. Dalam penelitian tersebut, *HI* diposisikan sebagai variabel kunci yang diprediksi dari data historis parameter operasi, sedangkan algoritma *K-Nearest Neighbors (KNN)* digunakan untuk memperkirakan *HI* pada kondisi operasional baru melalui prinsip kemiripan jarak terhadap data latih. Pendekatan ini dipandang aplikatif karena perubahan kondisi peralatan pada umumnya memunculkan pola parameter yang relatif serupa dengan kondisi sebelumnya yang telah diketahui status kesehatannya. Lebih lanjut, penelitian menekankan fungsi *HI* sebagai indikator diagnostik sekaligus dasar pengambilan keputusan pemeliharaan untuk mengurangi risiko pemeliharaan yang terlalu dini maupun keterlambatan tindakan yang berdampak pada penurunan performa dan gangguan operasi. Meskipun demikian, kinerja *KNN* bergantung pada kualitas konstruksi fitur, proses normalisasi, pemilihan metrik jarak, serta penentuan nilai *k*, dan model juga berpotensi sensitif terhadap noise serta ketidakseimbangan data kondisi[7]. Dengan demikian, studi Harmoko dapat dijadikan rujukan implementatif.

2.2 Landasan Teori


2.2.1 Pembangkit Listrik Tenaga Gas dan Uap (PLTGU)

Pembangkit Listrik Tenaga Gas dan Uap (PLTGU) merupakan pembangkit dengan siklus kombinasi, yaitu penggabungan siklus *Brayton* pada PLTG dan siklus *Rankine* pada PLTU. Pada konfigurasi ini, energi panas dari gas buang turbin gas tidak langsung dibuang ke atmosfer, melainkan dimanfaatkan untuk menghasilkan uap

melalui *Heat Recovery Steam Generator*, sehingga efisiensi sistem meningkat dibanding pembangkit siklus tunggal. Pemanfaatan gas buang turbin gas sebagai sumber kalor utama *HRSG* menjadikan kinerja PLTG sangat berpengaruh terhadap kinerja keseluruhan PLTGU. *HRSG* dijelaskan sebagai peralatan yang bekerja seperti *boiler* namun memanfaatkan gas buang turbin gas tanpa pembakaran tambahan, sehingga keberadaan *HRSG* menjadi komponen kunci dalam peningkatan efisiensi PLTGU[8]

Pembangkit Listrik Tenaga Gas dan Uap (PLTGU) merupakan instalasi yang berfungsi mengonversi energi panas hasil pembakaran bahan bakar dan udara menjadi energi listrik yang dapat dimanfaatkan. Secara prinsip, PLTGU merupakan gabungan antara Pembangkit Listrik Tenaga Gas (PLTG) dan Pembangkit Listrik Tenaga Uap (PLTU). Pada sistem ini, gas buang dari PLTG yang masih memiliki temperatur tinggi dimanfaatkan oleh *Heat Recovery Steam Generator* (*HRSG*) untuk menghasilkan uap jenuh kering. Uap tersebut kemudian digunakan untuk memutar sudu turbin sehingga menghasilkan energi mekanik yang selanjutnya dikonversi menjadi energi listrik melalui generator [9].


Susunan peralatan utama pada PLTGU dapat dilihat pada Gambar 2.1, yang menunjukkan keterkaitan antara turbin gas, *Heat Recovery Steam Generator* (*HRSG*), turbin uap, dan generator sebagai satu kesatuan sistem pembangkit.



Gambar 2. 1 Peralatan di PLTGU

Gas yang dihasilkan dalam ruang bakar pada Pembangkit Listrik Tenaga Gas (PLTG) akan menggerakkan turbin dan kemudian generator, yang akan mengubahnya menjadi energi listrik. Sama halnya dengan PLTU, bahan bakar PLTG bisa berwujud cair (BBM) maupun gas (gas alam). Penggunaan bahan bakar menentukan tingkat efisiensi pembakaran dan prosesnya.

Siklus kerja PLTGU merupakan gabungan antara siklus *Brayton* (siklus gas) dan siklus *Rankine* (siklus uap), di mana *Heat Recovery Steam Generator* berperan sebagai komponen utama dalam siklus *Rankine*. Hubungan antara kedua siklus tersebut dapat dilihat pada Gambar 2.2, yang memperlihatkan alur perpaduan antara siklus gas dan siklus uap dalam sistem PLTGU.



Gambar 2. 2 Siklus kombinasi pada PLTGU

Siklus *Brayton* pada kondisi state ($1' \rightarrow 2'$), terjadi proses kompresi adiabatik di dalam kompresor turbin gas. Selanjutnya, pada state ($2' \rightarrow 3'$) berlangsung proses pembakaran, yaitu pencampuran bahan bakar dengan udara bertekanan yang dialirkan ke ruang bakar. Proses berikutnya, state ($3' \rightarrow 4'$), merupakan tahap ekspansi di mana gas hasil pembakaran digunakan untuk memutar sudu turbin gas. Pada siklus terbuka atau sederhana, gas panas hasil ekspansi dari state ($4'$) kembali menuju state ($1'$) sebagai pembuangan ke atmosfer. Namun, pada pembangkit dengan siklus kombinasi, gas buang tersebut tidak langsung dilepas ke udara, melainkan dialirkan ke penukar panas pada *boiler HRSG*. Dengan demikian, gas buang pada state ($4'$) dalam siklus *Brayton* dimanfaatkan untuk memasuki state ($5'$) pada siklus *Rankine* sebagai sumber panas dalam pengoperasian *boiler HRSG*.

Pada proses kerja *boiler HRSG*, tahapan state ($1 \rightarrow 2$) merupakan proses kompresi *isentropik* oleh pompa, di mana air dikompresi menjadi air bertekanan sebelum dialirkan ke penukar panas pada *HRSG*. Selanjutnya, pada state ($2 \rightarrow 3$), air bertekanan tersebut dipanaskan di dalam boiler hingga berubah menjadi uap. Proses berikutnya, state ($3 \rightarrow 4$), adalah ekspansi *isentropik* uap kering yang digunakan untuk memutar sudu turbin uap. Sementara itu, pada state ($4 \rightarrow 1$) terjadi proses kondensasi di kondensor, sehingga uap kembali berubah menjadi air.

Kapasitas uap yang dihasilkan *HRSG* dalam sistem PLTGU sangat dipengaruhi oleh jumlah energi panas yang masih terkandung dalam gas buang dari turbin gas. Dengan demikian, kapasitas produksi uap juga bergantung pada beban turbin gas. Pada prinsipnya, turbin gas beroperasi pada kecepatan putar konstan dengan aliran udara masuk ke kompresor yang juga relatif konstan. Perubahan beban turbin dipengaruhi oleh jumlah bahan bakar, yang berdampak pada fluktuasi suhu gas buang. Untuk menjaga kestabilan suhu gas buang, digunakan mekanisme *Inlet Guide Vane (IGV)*, yaitu sirip pengatur aliran udara masuk ke kompresor yang diatur berdasarkan umpan balik suhu gas buang.

2.2.2 Water Treatment System di PLTGU

Sistem pengolahan air merupakan rangkaian proses yang bertujuan mengubah air baku menjadi air dengan kualitas tertentu sesuai kebutuhan operasional pada PLTGU. Dalam pengoperasian PLTGU, air memiliki peranan penting sebagai air pengisi pada *HRSG*, media pendingin, serta untuk berbagai kebutuhan utilitas lainnya. Apabila kualitas air tidak memenuhi standar, dapat menimbulkan permasalahan serius seperti korosi, *scaling*, *fouling*, hingga penurunan efisiensi termal pembangkit. Oleh karena itu, proses pengolahan air dilakukan untuk menghilangkan kontaminan dalam air baku sehingga dihasilkan air dengan tingkat kemurnian yang sesuai dengan persyaratan penggunaannya [10]. Dalam industri pembangkit listrik, proses pengolahan air dituntut untuk menghasilkan air dengan tingkat kemurnian sangat tinggi guna mencegah terjadinya risiko operasional yang dapat menimbulkan kerugian.

Sistem pengolahan air pada PLTGU Cilegon dilaksanakan melalui dua tahap utama. Tahap pertama adalah proses distilasi, di mana air laut sebagai air baku diolah untuk mengurangi kadar garam serta mineral terlarut sehingga dihasilkan air baku olahan yang dikenal sebagai *raw water*. Selanjutnya, *raw water* tersebut diproses lebih lanjut melalui sistem demineralisasi dengan tujuan menghilangkan sisa ion-ion terlarut. Hasil akhir dari tahap ini berupa air dengan tingkat kemurnian tinggi yang disebut sebagai *make-up water*, yang digunakan untuk mendukung kebutuhan operasi pembangkit.



Gambar 2. 3 Desalinasi *Plant*


Sumber : (PLTGU Cilegon)

Desalinasi *Plant* adalah unit sistem yang berfungsi mengolah air laut menjadi air tawar melalui mekanisme pemanasan atau distilasi termal. Keberadaan dan pengoperasian unit ini dalam sistem pembangkit listrik memiliki peranan penting karena turut memengaruhi kinerja serta efisiensi daya yang dihasilkan oleh turbin uap[11]

Gambar 2.3 memperlihatkan unit Desalinasi *Plant* di PLTGU Cilegon yang beroperasi dengan menggunakan prinsip multi *stage* flash evaporation system (Prayudi et al., 2019). Sistem ini dilengkapi dengan *anti-scale* dan *anti- foam chemical dosing system*, serta mampu memproduksi hingga 1.000 ton air per hari pada kondisi beban penuh (100%). Pada tekanan atmosfer, air mulai mendidih pada suhu 100 °C. Akan tetapi , jika tekanan diturunkan dengan sistem vakum hingga mencapai suhu jenuh (*saturated temperature*), maka air akan mengalami *flash evaporation*. Proses tersebut dapat diulangi dengan penurunan tekanan lebih lanjut untuk menghasilkan tambahan uap. Uap yang dihasilkan bersifat murni, dan ketika melalui proses kondensasi, akan menghasilkan *raw water*.

Adapun komponen utama pada unit Desalinasi *Plant* terdiri dari :

- Dua unit *Flash Evaporator*
- Satu unit *Brine heater*
- Satu unit *Venting System*
- Satu unit *Chemical Injection System*
- Pompa dan Motor
- Sistem instrumentasi, perpindahan dan *Fitting*
- Kontrol, dll.



Gambar 2. 4 Ilustrasi Skematis Desalinasi Plant

Gambar 2.4 menunjukkan bahwa Desalinasi *Plant* bekerja dengan prinsip *multi stage flash evaporation system* untuk mengubah air laut menjadi *distillate water* atau *raw water*. Air laut dipompa dari *intake* oleh *sea water feed pump* menuju unit desalinasi dan dialirkan ke dalam *evaporator*. Sebagian kecil air laut dialihkan ke *ejector condenser* sebagai pendingin. Laju aliran air laut ini diatur secara otomatis oleh *flow control valve* pada bagian masuk *evaporator*.

Di dalam sistem, air laut mengalir dari satu tahap (*stage*) ke tahap berikutnya, sambil dipanaskan oleh uap kondensat yang terdapat pada *condenser* di tiap tahap. Setelah itu, air laut dipanaskan lebih lanjut di *brine heater* hingga mencapai *temperature* sekitar 113 °C (*top brine temperature*). Pada tahap pertama (*stage 1*), air laut masuk ke ruang flash chamber yang tekanannya dijaga sedikit lebih rendah dari tekanan jenuhnya, sehingga air mulai menguap. Uap yang terbentuk kemudian dialirkan ke *stage* berikutnya dengan tekanan lebih rendah, sehingga proses penguapan berulang. Proses ini terus berlangsung hingga mencapai *stage* terakhir.

Brine heater sendiri berupa *heat exchanger* berbentuk silinder dengan tabung, yang dipasang pada saluran masuk *evaporator* di *stage* pertama. Pada alat ini, air laut dialirkan melalui tabung (*tube*), sedangkan uap (*steam*) dari *auxiliary boiler* atau uap bertekanan rendah (*LP steam*) dialirkan ke bagian *shell*. Jumlah uap diatur otomatis dengan *temperature control valve* agar suhu air laut yang keluar dari *brine heater* tetap stabil. Pada akhirnya, uap air (*flashing brine*) dan hasil penguapan (*distillate*) terkumpul di *stage* terakhir. Air hasil penguapan (*distillate/raw water*) kemudian dipompa keluar menggunakan *distillate pump*, sedangkan air laut sisa yang tidak

menguap (*brine*) dibuang ke saluran pembuangan melalui *brine* blowdown pump [12]. Kualitas *raw water* yang dihasilkan :

Total Dissolved Solid (TDS)	:	< 10 ppm
- Total Iron	:	< 0,2 ppm
- pH	:	6,0 – 9,0
- Performance Ratio	:	> 6
- Conductivity	:	< 20 μ S/cm
- Silika	:	0,2 ppm
- Temperatur Max. <i>Brine</i>	:	113 °C
-TDS <i>Sea water</i>	:	38.300 ppm

Selanjutnya, *raw water* yang telah dihasilkan dialirkan menuju tangki penyimpanan air baku dengan kapasitas 5.500 kL menggunakan pompa. Penampungan air baku tersebut dapat dilihat pada Gambar 2.5



Gambar 2. 5 *Raw Water Tank*

Sumber : (PLTGU Cilegon)

2.2.3 Pemeliharaan (*Maintenance*)

Dalam dunia industri ketenagalistrikan, kegiatan pemeliharaan merupakan faktor yang sangat penting untuk menjaga keandalan dan kontinuitas operasi peralatan. Pemeliharaan pada umumnya dibagi menjadi empat jenis utama, yaitu *preventive*, *corrective*, *predictive*, dan *outage maintenance*.

Preventive maintenance adalah pemeliharaan yang dilakukan secara rutin dan terjadwal dengan tujuan mencegah terjadinya kerusakan. Kegiatan ini mencakup inspeksi berkala, pembersihan, hingga penggantian komponen berdasarkan umur

pakai tertentu. Dengan cara ini, kerusakan dapat dicegah sebelum benar-benar terjadi sehingga umur peralatan lebih panjang dan kinerja tetap optimal.[10]

Berbeda dengan itu, *corrective maintenance* dilakukan setelah peralatan mengalami kerusakan atau penurunan fungsi. Jenis pemeliharaan ini berfokus pada upaya perbaikan agar peralatan dapat kembali beroperasi dengan baik. Meskipun efektif untuk mengembalikan fungsi, metode ini biasanya membutuhkan waktu henti (*downtime*) yang lebih lama dan dapat mengganggu operasional pembangkit[13].

Selanjutnya, *predictive maintenance* merupakan bentuk pemeliharaan yang lebih modern karena didasarkan pada kondisi aktual peralatan. Dengan memanfaatkan data operasional dan pemantauan *parameter* seperti getaran, suhu, tekanan, maupun laju aliran, metode ini mampu memprediksi kapan peralatan berpotensi mengalami kegagalan. Kelebihan pendekatan ini adalah efisiensi, karena pemeliharaan hanya dilakukan pada saat yang benar-benar diperlukan, bukan semata mengikuti jadwal tetap [14].

Jenis terakhir adalah *outage maintenance*, yaitu pemeliharaan yang dilakukan secara terencana dengan cara menghentikan operasi peralatan atau unit pembangkit untuk sementara waktu. Kegiatan ini biasanya dilakukan secara periodik, misalnya tahunan atau dua tahunan, dengan tujuan melakukan pemeriksaan menyeluruh, perawatan besar, hingga overhaul atau penggantian komponen kritis.[15]

2.2.4 Health Index

Metode *Health Index* (HI) merupakan pendekatan yang digunakan untuk menilai kondisi aset ketenagalistrikan secara menyeluruh. Prinsip dasar metode ini adalah menggabungkan hasil pengamatan operasional, inspeksi lapangan, serta pengujian laboratorium untuk menghasilkan indikator kuantitatif berupa nilai indeks yang menggambarkan tingkat kesehatan suatu peralatan. Pada penelitian terdahulu, metode ini banyak diterapkan pada *transformator* daya untuk mengetahui kondisi dan memperkirakan sisa umur operasionalnya.

Beberapa *parameter* yang digunakan dalam perhitungan *Health Index* antara lain *Dissolved Gas Analysis (DGA)*, kondisi minyak isolasi (misalnya *breakdown voltage*, kadar air, tingkat keasaman, dan *interfacial tension*), serta analisis furan untuk

menilai degradasi kertas isolasi. Masing-masing *parameter* diberikan bobot dan skor sesuai standar internasional seperti *IEEE C57.104-2008* dan *IEEE C57.106-2006*. Hasil pengolahan *parameter* tersebut menghasilkan nilai *Health Index* yang berkisar dari 0 hingga 100. Nilai yang tinggi menunjukkan kondisi peralatan yang baik, sedangkan nilai yang rendah mengindikasikan potensi kegagalan atau mendekati akhir masa pakai.

Interpretasi nilai *Health Index* pada transformator dibagi ke dalam beberapa kategori, yaitu: sangat baik (85–100), baik (70–85), cukup (50–70), buruk (30–50), dan sangat buruk (0–30). Semakin rendah nilai indeks, semakin tinggi pula kemungkinan terjadinya kegagalan komponen. Selain itu, metode analisis tambahan seperti *key gas method*, *Doernenburg ratio*, *oil comparison*, dan *Total Dissolved Combustible Gas (TDCG)* digunakan untuk mendeteksi jenis gangguan, misalnya dekomposisi minyak, penuaan kertas isolasi, kelembaban tinggi, *partial discharge*, hingga potensi *arcing*.

Hasil penelitian pada ratusan unit *transformator* menunjukkan bahwa sebagian besar berada dalam kondisi baik hingga sangat baik, meskipun ditemukan juga sejumlah unit dengan kondisi buruk dan sangat buruk. Beberapa kegagalan potensial yang berhasil diidentifikasi antara lain dekomposisi selulosa, dekomposisi minyak, kelembaban berlebih, korosi, endapan (*sediment*), serta kerusakan akibat *partial discharge* dan *arcing*. [16]

Nilai *HI* yang dihasilkan dapat dipetakan ke dalam kategori kondisi, mulai dari sangat baik, baik, cukup, buruk, hingga sangat buruk. Kategori ini membantu operator dalam menentukan strategi pemeliharaan, misalnya kapan harus melakukan pemeliharaan rutin, pemantauan intensif, atau bahkan penggantian aset. Dengan pendekatan ini, evaluasi kondisi *transformator* tidak hanya dilihat dari sisi teknis, tetapi juga mempertimbangkan efisiensi ekonomi [17].

2.2.5 Machine Learning

Machine learning (ML) merupakan bagian dari kecerdasan buatan yang memanfaatkan data untuk membentuk pola atau pengetahuan sehingga sistem dapat melakukan prediksi atau klasifikasi secara otomatis. Dalam konteks ketenagalistrikan, penerapan konsep *ML* banyak digunakan untuk pemodelan berbasis data, termasuk

klasifikasi kondisi dan prediksi gangguan, misalnya melalui algoritma perceptron yang diposisikan sebagai bagian dari teknik kecerdasan buatan untuk kebutuhan klasifikasi di sistem distribusi listrik[18].

Pengembangan model ML umumnya melibatkan pemisahan data menjadi data latih dan data uji. Data latih digunakan untuk membentuk pola misalnya bobot pada model, sedangkan data uji digunakan untuk menguji kemampuan model pada data yang tidak digunakan saat pembelajaran. Pendekatan ini membantu memastikan model tidak hanya “menghafal” data pelatihan, tetapi mampu melakukan generalisasi. Implementasi *ML* dijelaskan menggunakan data latih dan data uji: data input dijadikan data latih, target digunakan untuk memperoleh bobot optimal, kemudian dilakukan pengujian untuk melihat kesesuaian hasil model terhadap target.[19]

Proses memperoleh pengetahuan (*knowledge*) dapat dilakukan melalui berbagai cara. Cara yang paling sederhana adalah rote learning, yaitu menyimpan informasi yang telah dihitung atau dipelajari sebelumnya. Selain itu, pengetahuan juga dapat diperoleh dari orang lain yang lebih ahli di bidang tertentu. Manusia pun belajar melalui pengalaman dalam menyelesaikan suatu permasalahan. Setelah berhasil mengatasi suatu masalah, pola dan langkah penyelesaiannya akan tersimpan dalam ingatan. Ketika dihadapkan pada permasalahan yang serupa di kemudian hari, manusia mampu menyelesaikannya dengan lebih cepat dan efisien berdasarkan pengalaman sebelumnya.

Machine learning merupakan salah satu cabang dari kecerdasan buatan. Agar dapat dianggap cerdas, sebuah sistem yang beroperasi dalam lingkungan dinamis harus mampu belajar. Dengan kemampuan belajar dan beradaptasi terhadap perubahan, sistem tidak lagi memerlukan perancangan solusi secara eksplisit untuk setiap kemungkinan situasi oleh pengembang[20].


2.2.6 K-Nearest Neighbors (KNN)

K-Nearest Neighbors (KNN) merupakan salah satu algoritma supervised learning yang digunakan untuk klasifikasi. Prinsip dasar *KNN* adalah mengklasifikasikan data uji berdasarkan kedekatan jarak terhadap data latih yang sudah diketahui labelnya. Proses pembelajaran hanya dilakukan ketika data uji dimasukkan algoritma akan mencari *K* data terdekat (*neighbors*) dari data uji dalam

dataset pelatihan dan menentukan kelasnya berdasarkan mayoritas label tetangga tersebut[7]. Menurut (Zhang, 2022), prosedur *KNN* terdiri dari dua tahap utama:

Tahap *training* yaitu Menentukan nilai *K* yang optimal untuk dataset pelatihan, umumnya menggunakan metode *cross-validation*.

Tahap Prediksi yaitu Mencari *K* data latih yang paling dekat dengan data uji menggunakan fungsi jarak seperti *Euclidean*, kemudian menentukan kelas data uji berdasarkan aturan mayoritas.



Gambar 2. 6 Proses Klasifikasi *KNN*

Gambar 2.5 menunjukkan ilustrasi konsep dasar dari *K-Nearest Neighbors* dalam klasifikasi. Pada gambar sebelah kiri "*Before K-NN*", titik data baru muncul di ruang fitur (dalam hal ini X_1 dan X_2). Titik ini belum memiliki label kategori, namun akan diklasifikasikan berdasarkan kedekatannya dengan tetangga-tetangga terdekat di sekitar titik tersebut.

Setelah algoritma *KNN* diterapkan, pada gambar sebelah kanan ("*After K-NN*"), algoritma mencari *K* tetangga terdekat (dalam contoh ini, tetangga yang paling dekat adalah titik-titik hijau dan oranye). Berdasarkan aturan mayoritas, data uji akan diberikan label sesuai kelas mayoritas dari *K* tetangga terdekat. Dalam ilustrasi ini, karena sebagian besar tetangga terdekat termasuk dalam Kategori A (titik hijau), titik data baru tersebut akan diklasifikasikan sebagai Kategori A.

Ilustrasi ini menggambarkan prinsip dasar dari *KNN*, yaitu bahwa kelas data uji ditentukan berdasarkan kedekatannya dengan data latih yang sudah diketahui kelasnya. Dengan pendekatan ini, *KNN* sangat bergantung pada distribusi tetangga dalam ruang fitur dan nilai *K* yang dipilih. performa *KNN* sangat dipengaruhi oleh empat aspek utama:

- Penentuan nilai K

Menentukan nilai K yang tepat untuk dataset tertentu adalah tantangan utama dalam KNN . Setiap dataset sering kali memiliki distribusi data yang berbeda-beda, sehingga tidak ada satu nilai K yang cocok untuk semua data. Salah satu pendekatan yang diusulkan adalah dengan menggunakan nilai K yang berbeda untuk sub-ruang data yang berbeda atau bahkan untuk setiap data uji yang berbeda. Pendekatan lain yang umum digunakan adalah dengan melakukan cross-validation untuk mencari nilai K yang memberikan akurasi terbaik.

- Pemilihan tetangga terdekat

Pemilihan tetangga terdekat pada KNN memerlukan pengukuran kedekatan antar data, yang sering kali menggunakan fungsi jarak *Euclidean*. jarak yang paling umum dipakai adalah jarak *Euclidean* antara vektor fitur data uji dan data latih. Secara umum, jarak *Euclidean* didefinisikan sebagai :

$$d(\mathbf{x}, \mathbf{y}) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (2.1)$$

Dimana :

- $\mathbf{x}$ dan $\mathbf{y}$ adalah dua titik dalam ruang fitur n -dimensional (data uji dan data latih).
- x_i dan y_i adalah nilai dari fitur ke- i pada titik data $\mathbf{x}$ dan $\mathbf{y}$.
- n adalah jumlah dimensi fitur

Akurasi adalah metrik evaluasi yang digunakan untuk mengukur sejauh mana prediksi model sesuai dengan kondisi sebenarnya. Pada model *K-Nearest Neighbors* (KNN), akurasi dihitung dengan membandingkan hasil prediksi model terhadap label yang sebenarnya pada data uji. Secara matematis, akurasi dihitung dengan menggunakan persamaan berikut:

$$\text{Akurasi} = \frac{1}{N} \sum_{i=1}^N \mathbf{1}(\hat{y}_i = y_i) \quad (2.2)$$

Dimana:

- y^i adalah prediksi model untuk data uji ke- i ,
- y_i adalah label yang benar untuk data uji ke- i ,
- $I(y^i = y_i)$ adalah fungsi indikator yang bernilai 1 jika prediksi benar dan 0 jika salah,
- N adalah jumlah total data uji.

Precision mengukur seberapa banyak prediksi positif yang benar dibandingkan dengan total prediksi positif. Dengan kata lain, ini mengukur keakuratan prediksi untuk kelas tertentu.

Rumus Precision:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2.3)$$

Dimana:

- TP = True Positive (data yang benar diprediksi positif).
- FP = False Positive (data yang salah diprediksi positif).

Recall mengukur seberapa banyak data positif yang benar-benar terdeteksi oleh model dari seluruh data positif yang ada. Ini mengukur kemampuan model untuk mendeteksi kelas positif.

Rumus Recall:

$$\text{Recall} = \frac{TP}{TP + FN} \quad (2.4)$$

Dimana:

- TP = *True Positive* (data yang benar diprediksi positif).
- FN = *False Negative* (data yang salah diprediksi negatif).

F1-Score adalah harmoni rata-rata antara precision dan recall. Ini memberikan gambaran umum tentang kinerja model, terutama ketika terdapat ketidakseimbangan antara precision dan recall.

Rumus *F1-Score*:

$$\text{F1-score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (2.5)$$

2.2.7 Integrasi dengan Sistem Digitalisasi Pembangkit

Digital Power Plant (DPP) merupakan inovasi teknologi pengelolaan pembangkit listrik berbasis teknologi 4.0 bertujuan untuk meningkatkan keandalan dan efisiensi pembangkit. Digitalisasi yang dipicu oleh munculnya *Internet of Things (IoT)* dan munculnya sejumlah besar perangkat terhubung yang mengonsumsi daya, penggunaan pengukur pintar (*smart meter*), sensor pintar (*smart sensor*), otomatisasi, dan teknologi jaringan digital lainnya untuk mendigitalkan jaringan listrik dan melampaui meteran listrik menjadi salah satu *disruptive force* di bidang ketenagalistrikan.



Gambar 2. 7 transformasi PLN *Power Beyond Generation*

Hal tersebut menjadi latar belakang kenapa dikembangkannya *Digital Power Plant*. Oleh karena itu ada aspirasi pegawai bahwa tahun 2024, PLN akan bertransformasi perusahaan listrik terkemuka se-Asia Tenggara maka perlu dilakukan penguatan budaya untuk mewujudkan transformasi tersebut. Terdapat empat tema strategi dalam visi Transformasi PLN seperti yang ditunjukkan pada Gambar 2.6, yaitu:

1. *Green*, mengacu pada upaya PLN untuk beralih ke sumber energi yang lebih bersih dan ramah lingkungan, serta mengurangi dampak negatif dari operasional PLN terhadap lingkungan.
2. *Lean*, mengacu pada penggunaan prinsip-prinsip lean untuk meningkatkan efisiensi, produktivitas, dan kualitas layanan yang disediakan oleh PLN
3. *Innovative*, merujuk pada upaya untuk menciptakan perubahan atau kemajuan di dalam perusahaan melalui penerapan teknologi dan ide-ide baru yang dapat membawa manfaat bagi perusahaan dan Masyarakat

4. *Costumer Focused*, merujuk pada upaya perusahaan untuk meningkatkan pengalaman pelanggan melalui peningkatan kualitas layanan dan kepuasan pelanggan.

Digital Power Plant merupakan salah satu breakthrough program dari tema strategis Lean dalam transformasi PLN yang bertujuan untuk peningkatan keandalan dan efisiensi pembangkit