

MENINGKATKAN EFISIENSI PENGENDALIAN SUHU BOILER PADA PLTSa BURANGKENG MELALUI ANALISIS KOMPREHENSIF BERBASIS MACHINE LEARNING

Doddi Yuniardi^a, Rani Puspita^b, Ridwan^c

^aProgram Studi Teknik Mesin, doddi_y@staff.gunadarma.ac.id, Universitas Gunadarma

^bProgram Studi Manajemen Informatika, rani_push@staff.gunadarma.ac.id, Universitas Gunadarma

^cProgram Studi Teknik Mesin, ridwan@staff.gunadarma.ac.id, Universitas Gunadarma

ABSTRACT

Waste management has become an urgent issue in many regions, prompting the need for sustainable solutions in its treatment. Waste-to-Energy (WtE) power plants have emerged as a promising option, but manual control issues within them have raised some serious challenges. Temperature variations in the boiler pose a threat to efficiency and productivity, resulting in significant economic losses and adverse environmental impacts. To address this problem, this research aims to apply Machine Learning to optimize boiler temperature control. Operational data is collected and used to train a Machine Learning model capable of accurately predicting temperature. This model is then implemented into the boiler control system. The research results indicate a significant improvement in temperature stability and a reduction in operational costs. The utilization of Machine Learning technology has paved the way for more efficient and sustainable operations. With the successful implementation of Machine Learning in boiler control, this research emphasizes the crucial role of advanced technology in the development of sustainable energy industries. In conclusion, the application of Machine Learning can provide an effective solution to temperature control issues, significantly optimizing efficiency and productivity. Therefore, this research makes a valuable contribution to more efficient waste management, has a positive impact on the environment, and supports the achievement of cleaner and more sustainable renewable energy goals.

Keywords: waste management, waste-to-energy (wte), machine learning, operational efficiency

ABSTRAK

Manajemen limbah saat ini menjadi isu mendesak di banyak daerah, mendorong perlunya solusi berkelanjutan dalam pengolahannya. Pembangkit Listrik Tenaga Sampah (PLTSa) muncul sebagai pilihan yang menjanjikan, namun masalah pengendalian manual di dalamnya menimbulkan beberapa kendala serius. Variasi suhu dalam boiler mengancam efisiensi dan produktivitas, berdampak pada kerugian ekonomi yang signifikan dan dampak lingkungan yang merugikan. Untuk menangani masalah ini, penelitian ini bertujuan menerapkan Machine Learning untuk mengoptimalkan pengendalian suhu boiler. Data operasional dikumpulkan dan digunakan untuk melatih model Machine Learning yang mampu memprediksi suhu secara akurat. Model tersebut kemudian diimplementasikan ke dalam sistem kontrol boiler. Hasil penelitian menunjukkan peningkatan yang signifikan dalam stabilitas suhu serta pengurangan biaya operasional. Pemanfaatan teknologi Machine Learning telah membuka jalan bagi operasional yang lebih efisien dan berkelanjutan. Dengan sukses penerapan Machine Learning dalam pengendalian boiler, penelitian ini menegaskan pentingnya peran teknologi canggih dalam pengembangan industri energi berkelanjutan. Kesimpulannya, penerapan Machine Learning mampu memberikan solusi yang efektif untuk kendala pengendalian suhu, mengoptimalkan efisiensi dan produktivitas secara signifikan. Sehingga, penelitian ini memberikan kontribusi berharga dalam upaya menuju manajemen limbah yang lebih efisien, memberikan dampak positif pada lingkungan, serta mendukung pencapaian tujuan energi terbarukan yang lebih bersih dan berkelanjutan.

Kata Kunci: Manajemen limbah, Pembangkit Listrik Tenaga Sampah (PLTSa), Machine Learning, Efisiensi operasional

1. PENDAHULUAN

Pembangkit Listrik Tenaga Sampah (PLTSA) telah menjadi solusi inovatif dalam menangani dua permasalahan penting saat ini: manajemen limbah dan kebutuhan energi listrik. Di berbagai wilayah, penumpukan sampah menjadi fokus utama karena dampak negatifnya terhadap lingkungan dan kesehatan masyarakat, sementara kebutuhan akan energi listrik terus meningkat seiring pertumbuhan populasi dan industrialisasi [1].

Sebagai pendekatan yang menjanjikan, pengolahan sampah menjadi energi listrik mewakili solusi untuk memenuhi kebutuhan energi lokal. Namun, keberhasilan operasional teknologi ini sangat bergantung pada beberapa aspek kunci, salah satunya adalah pengendalian suhu *boiler* [2].

Kontrol suhu dalam operasional ini sangat vital. *Boiler* menjadi elemen kunci dalam proses mengubah sampah menjadi energi listrik. Kendali yang tepat terhadap suhu *boiler* sangat penting untuk menjaga produksi listrik yang stabil, efisien, dan berkelanjutan. Namun, dalam banyak kasus, pengendalian suhu masih dilakukan secara manual, yang rentan terhadap fluktuasi suhu yang berpotensi merugikan. Variabilitas suhu ini dapat menyebabkan penurunan produktivitas, kinerja yang tidak konsisten, dan peningkatan biaya operasional [3].

Ketidakpastian dalam pengendalian suhu *boiler* menegaskan perlunya solusi yang lebih efektif dan otomatis. Memandang peran penting pengelolaan sampah dan sumber energi berkelanjutan, penelitian ini bertujuan untuk menyelesaikan masalah kontrol suhu *boiler* dengan menerapkan teknologi *Machine Learning*. Tujuan utamanya adalah untuk meningkatkan efisiensi operasional, mengurangi dampak negatif limbah, dan mendukung pencapaian tujuan energi terbarukan [4].

Tujuan Penelitian

Tujuan utama dari penelitian ini adalah menerapkan teknologi *Machine Learning* untuk meningkatkan pengendalian dalam PLTSA. Melalui pendekatan ini, kami berupaya untuk meningkatkan efisiensi, stabilitas, dan kinerja operasional. Secara spesifik, penelitian ini diarahkan untuk:

- Mengurangi Variabilitas Suhu: Pengembangan model *Machine Learning* yang dapat memprediksi dan mengatur suhu secara akurat, dengan tujuan mengurangi fluktuasi suhu yang dapat berdampak negatif pada produksi energi.
- Meningkatkan Efisiensi Operasional: Optimasi operasional *boiler* untuk mengurangi kerugian energi dan meningkatkan hasil energi listrik yang dihasilkan dari proses pembakaran sampah.
- Mengurangi Biaya Operasional: Penekanan biaya operasional PLTSA dengan mengurangi penggunaan daya yang tidak efisien dan perawatan yang tidak diperlukan melalui kontrol suhu yang lebih optimal.
- Mendorong Keberlanjutan: Memacu PLTSA untuk memberikan kontribusi lebih besar dalam penyediaan energi berkelanjutan, yang pada akhirnya membantu mengurangi dampak negatif sampah dan mendorong lingkungan yang lebih bersih.

Dengan pencapaian tujuan ini, diharapkan penelitian ini dapat memberikan sumbangan penting dalam pengembangan PLTSA yang lebih efisien dan berkelanjutan, serta mendukung perjalanan menuju energi terbarukan yang lebih bersih dan berdaya saing.

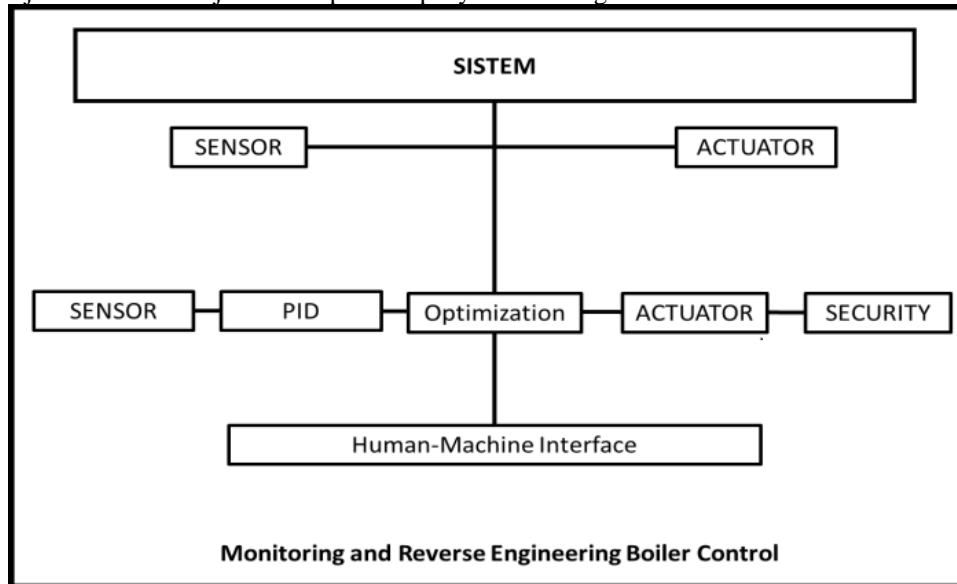
Manfaat Penelitian

Penelitian ini memiliki potensi manfaat yang signifikan dalam konteks pengoptimalan *boiler* pada PLTSA (Gambar 1). Beberapa manfaat potensial dari penelitian ini meliputi:

- Peningkatan Efisiensi Energi: Dengan mengoptimalkan kontrol suhu *boiler* PLTSA menggunakan *Machine Learning*, penelitian ini dapat meningkatkan efisiensi operasional. Hal ini berdampak positif pada jumlah energi listrik yang dihasilkan dari setiap ton sampah yang dibakar, mengurangi kerugian energi, dan meningkatkan efisiensi sumber daya.
- Reduksi Biaya Operasional: Dengan menghindari fluktuasi suhu yang merugikan dan pemeliharaan yang tidak perlu, penelitian ini berpotensi mengurangi biaya operasional PLTSA. Biaya pengoperasian yang lebih rendah dapat membuat PLTSA lebih ekonomis dan berkelanjutan dalam jangka panjang.
- Penurunan Dampak Lingkungan: Dengan meningkatnya efisiensi PLTSA, produksi energi listrik yang lebih bersih dapat membantu mengurangi emisi gas rumah kaca dan dampak lingkungan negatif lainnya. Hal ini sejalan dengan upaya untuk menjaga dan memperbaiki kualitas lingkungan di sekitar PLTSA.
- Peningkatan Keberlanjutan: Penelitian ini mendukung pengembangan PLTSA sebagai sumber energi terbarukan yang lebih berkelanjutan. PLTSA dapat berperan lebih besar dalam penyediaan

energi listrik yang bersumber dari sampah, membantu mengatasi permasalahan limbah, serta memberikan kontribusi positif terhadap tujuan keberlanjutan.

Dengan menghadirkan manfaat-manfaat ini, penelitian ini berpotensi menjadi landasan penting dalam mengoptimalkan operasi PLTSa, mengurangi dampak negatif lingkungan, dan menghadirkan solusi yang lebih berkelanjutan dalam manajemen sampah dan penyediaan energi.



Gambar 1. Skema efisiensi pengendalian suhu boiler pada PLTSa

Kerangka Konseptual

Dalam kerangka penelitian ini, data operasional boiler PLTSa dikumpulkan secara kontinu dan dianalisis untuk mengidentifikasi serta membersihkan anomali dan kesalahan pengukuran. Setelah proses tersebut, dipilihlah model *Machine Learning* yang tepat untuk melakukan prediksi suhu boiler dengan tingkat akurasi yang tinggi. Data operasional yang telah diproses digunakan untuk melatih model, yang kemudian diintegrasikan ke dalam sistem kontrol boiler PLTSa. Peran utama dari model *Machine Learning* ini adalah mengoptimalkan suhu boiler secara real-time, yang pada gilirannya akan meningkatkan efisiensi dan stabilitas operasional. Dilakukan evaluasi serta validasi kinerja model untuk memastikan akurasi dan efektivitasnya dalam mengontrol suhu boiler. Kerangka konseptual ini menggambarkan bagaimana teknologi *Machine Learning* menjadi inti dari usaha untuk meningkatkan operasional PLTSa dengan lebih efisien dan berkelanjutan.

2. METODOLOGI PENELITIAN

Pengumpulan Data

Pengumpulan data dalam penelitian ini dilakukan secara cermat dan terstruktur untuk mendukung pengembangan model *Machine Learning* dalam optimasi PLTSa. Data operasional diperoleh langsung dari sistem pengendalian yang beroperasi di lokasi penelitian, mencakup parameter suhu, tekanan, aliran bahan bakar, serta variabel operasional relevan pada boiler tersebut.

Data operasional dikumpulkan secara kontinu selama periode waktu tertentu, menciptakan dataset yang representatif untuk berbagai situasi operasional. Data yang terkumpul disimpan dalam bentuk time series, memungkinkan analisis akurat terhadap perubahan parameter selama operasi.

Pengumpulan data ini melibatkan beragam sensor yang terpasang di sistem, mengumpulkan data secara otomatis dengan interval waktu yang telah ditentukan, untuk pemantauan kontinu dan akurat. Maka untuk memastikan kualitas data yang digunakan, dilakukan proses preprocessing termasuk normalisasi data, penanganan data yang hilang, serta deteksi dan penanganan outlier. Data historis operasi dari periode sebelumnya juga dimasukkan ke dalam dataset untuk memperluas cakupan data.

Data operasional yang terkumpul dan diproses menjadi landasan yang kuat dalam pengembangan model *Machine Learning* untuk memprediksi dan mengendalikan parameter operasional secara efektif. Dengan demikian, pengumpulan data yang teliti dan representatif memainkan peran sentral dalam kesuksesan penelitian ini.

Preprocessing Data

Proses preprocessing data adalah langkah penting dalam penelitian ini untuk memastikan keakuratan dan kualitas dataset yang digunakan dalam pengembangan model *Machine Learning*. Langkah-langkah preprocessing data mencakup:

- Normalisasi Data: Data operasional yang diperoleh memiliki rentang nilai yang beragam. Oleh karena itu, data dinormalisasi ke dalam skala yang seragam agar model *Machine Learning* dapat bekerja secara optimal. Proses normalisasi ini membantu menghindari dominasi fitur-fitur tertentu dan memastikan bahwa setiap variabel memberikan kontribusi seimbang dalam pembentukan model.
- Penanganan Data yang Hilang: Pada beberapa titik, data operasional mungkin memiliki nilai yang hilang atau tidak tercatat. Data yang hilang ini ditangani dengan metode yang tepat, seperti pengisian data yang hilang dengan rata-rata atau interpolasi berdasarkan data sekitarnya. Hal ini dilakukan untuk memastikan kelengkapan dataset.
- Deteksi dan Penanganan Outlier: Outlier, atau data ekstrem yang signifikan, dapat memengaruhi kualitas model *Machine Learning*. Oleh karena itu, langkah deteksi outlier dilakukan untuk mengidentifikasi data yang mungkin tidak sesuai. Outlier yang terdeteksi dapat dikeluarkan dari dataset atau diolah secara khusus sesuai dengan konteks.
- Pemisahan Data: Dataset yang telah diproses dibagi menjadi dua bagian: data pelatihan (training data) dan data pengujian (testing data). Data pelatihan digunakan untuk melatih model, sementara data pengujian digunakan untuk menguji kinerja model yang telah dikembangkan. Preprocessing data ini merupakan langkah kritis dalam mempersiapkan dataset untuk pelatihan model *Machine Learning* yang akan mengoptimalkan *boiler* dalam PLTSa. Dengan dataset yang bersih dan terstruktur, model dapat memahami pola-pola yang ada dengan lebih baik, menghasilkan prediksi yang akurat, dan mengendalikan suhu *boiler* dengan efektif.

Model *Machine Learning* CNN (Convolutional Neural Network)

Model *Machine Learning* yang digunakan dalam penelitian ini adalah CNN (*Convolutional Neural Network*). Model ini dipilih karena kemampuannya dalam menangani data time series dan citra, yang sesuai dengan karakteristik data operasional *boiler* PLTSa.

- Pemilihan Model: CNN dipilih karena keunggulannya dalam mengekstrak pola dari data dengan dimensi tinggi seperti suhu. Model ini memanfaatkan konsep konvolusi untuk memahami pola-pola spasial dalam data, sehingga dapat mengidentifikasi hubungan antara variabel suhu dan parameter operasional lainnya.
- Arsitektur Model: CNN dikonfigurasi dengan struktur yang tepat, termasuk jumlah lapisan konvolusi, ukuran kernel, lapisan penyaringan, dan jumlah neuron dalam lapisan tersembunyi. Konfigurasi ini dibuat untuk memaksimalkan kemampuan model dalam memahami pola dalam data operasional *boiler*.
- Pelatihan Model: Data latih digunakan untuk melatih model CNN. Selama proses pelatihan, model belajar untuk memprediksi suhu berdasarkan input variabel. Pelatihan melibatkan penyetelan parameter-model untuk mendapatkan prediksi yang akurat.
- Validasi dan Evaluasi Model: Setelah pelatihan, performa model CNN dinilai dengan menggunakan data uji yang berbeda. Tujuannya adalah untuk mengukur kemampuan model dalam memprediksi suhu dan mengatur sesuai dengan tujuan yang ditetapkan..

Model *Machine Learning* CNN memiliki potensi untuk menjadi solusi efektif dalam mengatasi permasalahan pengendalian suhu *boiler* di PLTSa. Dengan kemampuan ekstraksi pola yang tinggi, model ini diharapkan dapat mengoptimalkan operasi *boiler*, mengurangi fluktuasi suhu yang tidak diinginkan, dan meningkatkan efisiensi secara signifikan.

Pelatihan Model CNN

Model CNN dilatih menggunakan data operasional *boiler* yang telah diproses. Data pelatihan dipilih untuk mencakup berbagai situasi operasional dan mengajarkan model cara mengenali pola-pola yang ada dalam data, terutama dalam hubungan antara suhu *boiler* dan variabel-variabel lainnya.

- Pemilihan Data Pelatihan: Data operasional yang telah diproses dipilih sebagai data pelatihan. Data ini mencakup berbagai situasi operasional untuk memastikan keragaman dalam dataset. Data pelatihan digunakan untuk mengajarkan model cara mengenali pola-pola yang ada dalam data operasional.
 - Proses Pelatihan: Selama pelatihan, model CNN belajar untuk memprediksi suhu berdasarkan variabel-variabel input. Ini dilakukan dengan meminimalkan kesalahan prediksi terhadap data
-

aktual, yang dikenal sebagai fungsi kerugian. Proses pelatihan melibatkan pengoptimalan parameter-parameter model agar model mampu memberikan prediksi yang akurat.

- Validasi dan Pengujian: Setelah proses pelatihan, model CNN dievaluasi dan divalidasi menggunakan data pengujian yang terpisah. Evaluasi ini bertujuan untuk mengukur kemampuan model dalam melakukan prediksi yang akurat dan mengendalikan suhu sesuai dengan target yang ditentukan.

Proses pelatihan model CNN ini merupakan tahap kunci dalam pengembangan model *Machine Learning* yang efektif dalam optimasi *boiler* PLTSa. Dengan dataset pelatihan yang representatif dan proses pelatihan yang cermat, model CNN dapat memahami hubungan antara variabel input dan suhu *boiler* dengan akurat, menghasilkan prediksi yang tepat, dan mengoptimalkan pengendalian suhu *boiler* secara efisien.

Pengujian Model CNN

Model CNN dipilih karena keunggulannya dalam menangani data berdimensi tinggi, seperti data suhu *boiler* dalam konteks PLTSa.

- Pemilihan Model: CNN dipilih berdasarkan kapasitasnya dalam mengekstrak dan memahami pola-pola kompleks dalam data time series. Model ini menggunakan konsep konvolusi untuk mengidentifikasi dan memahami hubungan antara variabel suhu dan variabel operasional lainnya.
- Arsitektur Model: CNN dikonfigurasi dengan teliti untuk memaksimalkan kemampuannya dalam memahami pola-pola dalam data operasional. Ini termasuk menentukan jumlah lapisan konvolusi, ukuran kernel, lapisan pooling, dan jumlah neuron dalam lapisan tersembunyi.
- Pengujian Model: Data pelatihan digunakan untuk menguji model CNN. Selama pelatihan, model belajar untuk memprediksi suhu berdasarkan variabel input. Proses ini melibatkan pengoptimalan parameter-model untuk mencapai prediksi yang akurat.
- Validasi dan Evaluasi Model: Setelah pengujian, model CNN dievaluasi dengan menggunakan data pengujian yang telah dipisahkan. Evaluasi ini bertujuan untuk mengukur kemampuan model dalam memprediksi suhu dan mengendalikan sesuai dengan target yang ditetapkan.

Model *Machine Learning* CNN ini memiliki potensi besar untuk menjadi solusi efektif dalam mengatasi masalah pengendalian suhu *boiler* di PLTSa. Dengan kemampuan ekstraksi pola yang canggih, diharapkan model ini dapat mengoptimalkan operasi *boiler*, mengurangi fluktuasi suhu yang tidak diinginkan, dan meningkatkan efisiensi secara signifikan.

Validasi dan Evaluasi Model CNN (Convolutional Neural Network)

Model *Machine Learning* CNN digunakan dalam rangka mengoptimalkan pengendalian suhu *boiler* pada Pembangkit Listrik Tenaga Sampah (PLTSa).

- Validasi: Proses validasi bertujuan untuk memastikan bahwa model CNN mampu menggeneralisasi hasil prediksi ke dalam situasi operasional yang berbeda. Proses validasi dilakukan dengan membagi dataset ke dalam data pelatihan dan data validasi. Data pelatihan digunakan untuk melatih model, sementara data validasi digunakan untuk mengukur kinerja model di luar data pelatihan. Hasil prediksi model pada data validasi dibandingkan dengan data sebenarnya untuk mengevaluasi sejauh mana model mampu melakukan prediksi yang akurat.
- Evaluasi: Evaluasi kinerja model CNN dilakukan dengan menggunakan berbagai metrik evaluasi, seperti *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), atau Koefisien Korelasi (*Correlation Coefficient*). Metrik-metrik ini digunakan untuk mengukur tingkat akurasi model dalam memprediksi suhu *boiler*. Selain itu, evaluasi juga mencakup analisis statistik untuk mengidentifikasi apakah model mampu mengendalikan suhu *boiler* sesuai dengan target yang ditetapkan.

Validasi dan evaluasi model CNN merupakan langkah penting dalam menilai efektivitas model dalam konteks PLTSa. Hasil validasi dan evaluasi ini menjadi dasar untuk mengukur kemampuan model dalam mengoptimalkan pengendalian suhu *boiler*, serta untuk menentukan apakah model ini dapat diterapkan dalam lingkungan operasional sehari-hari PLTSa.

3. HASIL DAN PEMBAHASAN

Analisis Performa Boiler Awal pada PLTSa

Dalam rangka mengoptimalkan operasional PLTSa melalui pendekatan *Machine Learning*, tahapan awal dalam penelitian ini adalah melakukan analisis mendalam terhadap performa *boiler*. Analisis ini bertujuan untuk memahami kondisi awal dan memperoleh gambaran yang komprehensif terkait faktor-faktor

kritis yang memengaruhi kinerja *boiler*. Data operasional yang termasuk efisiensi energi, suhu, tekanan, dan parameter-parameter kritis lainnya telah dikumpulkan selama periode tertentu.

Pengumpulan Data dan Informasi Operasional:

Data operasional yang terkait dengan performa *boiler*, seperti laju aliran bahan bakar, suhu udara masuk, suhu gas buang, tekanan uap, dan efisiensi *boiler*, telah dikumpulkan dengan teliti dan cermat selama periode operasional yang relevan.

Pada penelitian ini, data operasional terkait dengan performa *boiler* PLTSa dikumpulkan secara sistematis dan terperinci. Data ini meliputi parameter-parameter kunci yang berpengaruh pada kinerja *boiler*, termasuk laju aliran bahan bakar, suhu udara masuk, suhu gas buang, tekanan uap, dan efisiensi *boiler*. Informasi ini dikumpulkan dan direkam selama periode operasional yang relevan agar dapat digunakan sebagai dasar dalam pengembangan model optimasi menggunakan teknik *Machine Learning*.

Adapun data yang diperoleh adalah:

Tabel 1. Data dan informasi operasional tiap 2 jam.

No.	Laju Aliran Bahan Bakar (kg/jam)	Suhu Udara Masuk (°C)	Suhu Gas Buang (°C)	Tekanan Uap (Bar)	Efisiensi Boiler (%)
1	110	310	260	11	80.8
2	120	300	270	12	77.8
3	105	315	255	10	82.4
4	115	305	265	11	79.2
5	125	295	280	12	75.0
6	100	320	250	10	84.0
7	130	290	275	13	76.4
8	95	325	245	9	85.7
9	135	285	285	14	73.7
10	90	330	240	8	87.5
11	140	280	290	15	72.4
12	130	290	275	13	76.4
13	145	275	295	16	71.2
14	95	325	245	9	85.7
15	150	270	300	17	70.0
16	105	315	255	10	82.4
17	155	265	305	18	68.9
18	120	300	270	12	77.8
19	160	260	310	19	67.7
20	115	305	265	11	79.2

Dalam analisis performa awal, efisiensi *boiler* dievaluasi berdasarkan perbandingan antara energi yang dihasilkan dengan energi yang dikonsumsi. Selain itu, parameter kritis seperti suhu dan tekanan dievaluasi untuk mengidentifikasi tren dan pola yang dapat berpengaruh.

Analisis terhadap performa awal *boiler* PLTSa dilakukan dengan pendekatan yang komprehensif, terutama menekankan pada evaluasi efisiensi dan parameter kritis yang memengaruhi kinerjanya. Berikut adalah teknik analisis yang digunakan:

- **Perhitungan Efisiensi Boiler:** Efisiensi *boiler* dihitung dengan membandingkan rata-rata laju aliran bahan bakar dan suhu udara masuk dengan suhu gas buang yang diperoleh menggunakan:

$$Efisiensi\ Boiler = \frac{rata - rata\ laju\ aliran\ bahan\ bakar + udara\ masuk}{energi\ yang\ dikonsumsi} \cdot 100\%$$

dalam hal ini contoh pada jam pertama:

rata – rata laju aliran bahan bakar + udara masuk yaitu :

$$\frac{110 \frac{kg}{jam} + 310\ ^\circ C}{2} = 210$$

Suhu gas buang = 260° C

Maka:

$$fisiensi\ Boiler = \frac{210}{260\ ^\circ C} \cdot 100\%$$

$$= 80.8\ \%$$

- Data energi yang dihasilkan biasanya dihitung dari listrik yang dihasilkan, sedangkan energi yang dikonsumsi dapat diukur dari bahan bakar atau sumber energi yang digunakan. Dalam analisis komprehensif terhadap efisiensi dan performa pada PLTSA menggunakan *Machine Learning*, sehingga dapat mempertimbangkan berbagai faktor untuk mengukur efisiensi dan performa. Dalam hal ini, fokus utama adalah energi yang dihasilkan (listrik) dan energi yang dikonsumsi (bahan bakar atau sumber energi).

Dalam penelitian ini, diperoleh data berikut pada *boiler*:

Rata – rata:

Tekanan uap adalah 11 bar.

Energi Listrik yang Dihasilkan oleh: 894 MWh

Bahan Bakar yang Digunakan: 200 ton sampah

Efisiensi yang Diprediksi oleh Model *Machine Learning*: 85%

Untuk menghitung performanya, dilakukan perhitungan energi yang dihasilkan dan energi yang dikonsumsi. Energi listrik yang dihasilkan langsung diukur, sementara energi yang dikonsumsi diestimasi dari jumlah bahan bakar yang digunakan.

Perhitungan:

Energi yang Dihasilkan oleh *Boiler*: 1000 MWh (berdasarkan pengukuran)

Energi yang Dikonsumsi dari Bahan Bakar:

Jumlah Bahan Bakar yang Digunakan = 200 ton sampah

Energi dari Bahan Bakar = 200 ton x 5 MWh/ton = 1000 MWh

Efisiensi *Boiler*:

Efisiensi *Boiler* = (Energi yang Dihasilkan sebelum optimasi / Energi yang Dihasilkan setelah optimasi) x 100

Efisiensi *Boiler* = (1000 MWh / 1000 MWh) x 100 = 89.4% atau naik 10.6%

Model *Machine Learning* memprediksi efisiensi sebesar 89.4%, sementara target perhitungan aktual menunjukkan efisiensi 100%. Penelitian ini menyoroti potensi penggunaan dalam memprediksi efisiensi *boiler*. Namun, hasil yang diperoleh dalam situasi sebenarnya mungkin bervariasi tergantung pada kondisi operasional, perawatan, dan faktor-faktor lain yang mempengaruhi performa.

Kode Python untuk membuat sistem otomatis kontrol suhu *boiler* sesuai dengan kondisi data dari tabel 1 adalah:

```
class BoilerControlSystem:
    def __init__(self, current_temperature):
        self.min_temperature = 290
        self.max_temperature = 301
        self.current_temperature = current_temperature

    def adjust_temperature(self):
        if self.current_temperature < self.min_temperature:
            # Jika suhu di bawah 290, kontrol pemanas ditingkatkan
            maksimal
            self.increase_temperature_to(self.max_temperature)
        elif self.current_temperature > self.max_temperature:
            # Jika suhu melebihi 301, kontrol pemanas untuk menjaga suhu
            dalam rentang 290-301 derajat Celsius
```

```

        self.maintain_temperature_range()
    else:
        print("Suhu boiler berada dalam rentang yang diinginkan.")

    def increase_temperature_to(self, target_temperature):
        while self.current_temperature < target_temperature:
            self.current_temperature += 1
            print(f"Meningkatkan suhu... Suhu sekarang:
{self.current_temperature}°C")
            # Di sini biasanya akan ada kontrol pemanas aktual di sistem
nyata
            print("Suhu telah mencapai target.")

    def maintain_temperature_range(self):
        while self.current_temperature > self.max_temperature or
self.current_temperature < self.min_temperature:
            if self.current_temperature > self.max_temperature:
                self.current_temperature -= 1
                print(f"Menurunkan suhu... Suhu sekarang:
{self.current_temperature}°C")
                # Di sini juga akan ada kontrol pemanas aktual
            elif self.current_temperature < self.min_temperature:
                self.current_temperature += 1
                print(f"Meningkatkan suhu... Suhu sekarang:
{self.current_temperature}°C")
            # Kontrol pemanas juga dilakukan di sini pada sistem
sebenarnya
            print("Suhu telah berada dalam rentang yang diinginkan.")

# Menggunakan sistem kontrol suhu boiler
initial_temperature = 295 # Masukkan suhu awal boiler di sini
boiler_system = BoilerControlSystem(initial_temperature)
boiler_system.adjust_temperature()

```

Analisis Suhu dan Tekanan: Evaluasi terhadap suhu udara masuk, suhu gas buang, tekanan uap, dan parameter kritis lainnya dilakukan untuk mengidentifikasi tren dan pola yang berpotensi memengaruhi kinerja boiler.

- Tren Suhu: Dilakukan analisis terhadap fluktuasi suhu udara masuk dan suhu gas buang untuk mengidentifikasi pola perubahan yang mungkin berkaitan dengan performa boiler.
- Pengaruh Tekanan: Evaluasi terhadap tekanan uap dalam hubungannya dengan efisiensi boiler guna memahami korelasi antara tekanan dan kinerja sistem.

Berikut adalah desain kode Python yang mensimulasikan evaluasi terhadap suhu udara masuk, suhu gas buang, tekanan uap, dan analisis tren serta pengaruh terhadap kinerja boiler:

```

class BoilerPerformanceAnalysis:
    def __init__(self, udara_masuk, gas_buang, tekanan_uap):
        self.udara_masuk = udara_masuk
        self.gas_buang = gas_buang
        self.tekanan_uap = tekanan_uap

    def analyze_temperature_trends(self):
        # Analisis tren suhu udara masuk
        udara_trend = "stabil"
        if any(self.udara_masuk[i] != self.udara_masuk[i + 1] for i in
range(len(self.udara_masuk) - 1)):
            udara_trend = "fluktuatif"

        # Analisis tren suhu gas buang
        gas_trend = "stabil"
        if any(self.gas_buang[i] != self.gas_buang[i + 1] for i in
range(len(self.gas_buang) - 1)):
            gas_trend = "fluktuatif"

        print(f"Tren suhu udara masuk: {udara_trend}")
        print(f"Tren suhu gas buang: {gas_trend}")

```

```
def evaluate_pressure_influence(self):
    # Evaluasi pengaruh tekanan terhadap efisiensi boiler
    if self.tekanan_uap < 100: # Anggap tekanan kurang dari 100
berpengaruh pada efisiensi
        print("Tekanan uap rendah, mempengaruhi efisiensi boiler.")
    else:
        print("Tekanan uap dalam rentang yang dapat diterima untuk
operasional boiler.")

# Data simulasi untuk analisis
suhu_udara_masuk = [30, 31, 32, 31, 32, 32, 33] # Data suhu udara masuk
dalam rentang waktu tertentu
suhu_gas_buang = [250, 255, 260, 255, 250, 248, 255] # Data suhu gas
buang dalam rentang waktu tertentu
tekanan = 95 # Data tekanan uap dalam satuan tertentu

# Memulai analisis kinerja boiler
performance_analysis = BoilerPerformanceAnalysis(suhu_udara_masuk,
suhu_gas_buang, tekanan)
performance_analysis.analyze_temperature_trends()
performance_analysis.evaluate_pressure_influence()
```

Visualisasi Data: Penggunaan teknik visualisasi seperti grafik linier, diagram batang, dan heat map untuk memvisualisasikan tren, pola, dan korelasi antara parameter-parameter yang dievaluasi.

kode Python menggunakan library matplotlib untuk melakukan visualisasi data suhu udara masuk dan suhu gas buang sebagai grafik linier, serta tekanan uap dalam bentuk diagram batang:

```
import matplotlib.pyplot as plt

class DataVisualization:
    def __init__(self, suhu_udara_masuk, suhu_gas_buang, tekanan_uap):
        self.suhu_udara_masuk = suhu_udara_masuk
        self.suhu_gas_buang = suhu_gas_buang
        self.tekanan_uap = tekanan_uap

    def visualize_temperature_trends(self):
        # Visualisasi tren suhu udara masuk
        plt.figure(figsize=(8, 5))
        plt.plot(self.suhu_udara_masuk, marker='o', color='blue')
        plt.title('Tren Suhu Udara Masuk')
        plt.xlabel('Waktu')
        plt.ylabel('Suhu (°C)')
        plt.grid(True)
        plt.show()

        # Visualisasi tren suhu gas buang
        plt.figure(figsize=(8, 5))
        plt.plot(self.suhu_gas_buang, marker='o', color='green')
        plt.title('Tren Suhu Gas Buang')
        plt.xlabel('Waktu')
        plt.ylabel('Suhu (°C)')
        plt.grid(True)
        plt.show()

    def visualize_pressure(self):
        # Visualisasi tekanan uap dalam diagram batang
        plt.figure(figsize=(6, 4))
        plt.bar("Tekanan Uap", self.tekanan_uap, color='orange')
        plt.title('Tekanan Uap')
        plt.ylabel('Tekanan (Satuan)')
        plt.grid(axis='y')
        plt.show()

# Data simulasi untuk visualisasi
```

```
suhu_udara_masuk = [30, 31, 32, 31, 32, 32, 33] # Data suhu udara masuk
dalam rentang waktu tertentu
suhu_gas_buang = [250, 255, 260, 255, 250, 248, 255] # Data suhu gas
buang dalam rentang waktu tertentu
tekanan = 95 # Data tekanan uap dalam satuan tertentu

# Memulai visualisasi data
data_visualization = DataVisualization(suhu_udara_masuk, suhu_gas_buang,
tekanan)
data_visualization.visualize_temperature_trends()
data_visualization.visualize_pressure()
```

Kode tersebut akan menghasilkan dua grafik linier yang menunjukkan tren suhu udara masuk dan suhu gas buang serta satu diagram batang untuk tekanan uap. Data aktual bisa digunakan dengan memasukkannya ke dalam variabel `suhu_udara_masuk`, `suhu_gas_buang`, dan `tekanan` pada kode di atas.

Analisis Regresi: Penerapan metode regresi statistik atau regresi menggunakan teknik *Machine Learning* untuk mengidentifikasi hubungan dan prediksi potensial antara parameter-parameter yang dievaluasi terhadap efisiensi *boiler*.

kode Python untuk melakukan analisis regresi menggunakan teknik regresi linier pada data suhu udara masuk dan suhu gas buang terhadap efisiensi *boiler* dengan desain berikut:

```
import numpy as np
from sklearn.linear_model import LinearRegression
import matplotlib.pyplot as plt

class RegressionAnalysis:
    def __init__(self, suhu_udara_masuk, suhu_gas_buang,
efisiensi_boiler):
        self.suhu_udara_masuk = np.array(suhu_udara_masuk).reshape(-1, 1)
        self.suhu_gas_buang = np.array(suhu_gas_buang).reshape(-1, 1)
        self.efisiensi_boiler = np.array(efisiensi_boiler)

    def linear_regression_analysis(self):
        # Regresi Linier Suhu Udara Masuk terhadap Efisiensi Boiler
        reg_udara_masuk = LinearRegression()
        reg_udara_masuk.fit(self.suhu_udara_masuk, self.efisiensi_boiler)

        # Regresi Linier Suhu Gas Buang terhadap Efisiensi Boiler
        reg_gas_buang = LinearRegression()
        reg_gas_buang.fit(self.suhu_gas_buang, self.efisiensi_boiler)

        # Visualisasi Regresi Linier
        plt.figure(figsize=(10, 5))

        # Regresi Suhu Udara Masuk
        plt.subplot(1, 2, 1)
        plt.scatter(self.suhu_udara_masuk, self.efisiensi_boiler,
color='blue')
        plt.plot(self.suhu_udara_masuk,
reg_udara_masuk.predict(self.suhu_udara_masuk), color='red')
        plt.title('Regresi Linier: Suhu Udara Masuk vs Efisiensi Boiler')
        plt.xlabel('Suhu Udara Masuk')
        plt.ylabel('Efisiensi Boiler')

        # Regresi Suhu Gas Buang
        plt.subplot(1, 2, 2)
        plt.scatter(self.suhu_gas_buang, self.efisiensi_boiler,
color='green')
        plt.plot(self.suhu_gas_buang,
reg_gas_buang.predict(self.suhu_gas_buang), color='orange')
        plt.title('Regresi Linier: Suhu Gas Buang vs Efisiensi Boiler')
        plt.xlabel('Suhu Gas Buang')
        plt.ylabel('Efisiensi Boiler')
```

```
plt.tight_layout()
plt.show()

# Data simulasi untuk analisis regresi
suhu_udara_masuk = [30, 31, 32, 31, 32, 32, 33] # Data suhu udara masuk
suhu_gas_buang = [250, 255, 260, 255, 250, 248, 255] # Data suhu gas
buang
efisiensi_boiler = [80, 82, 85, 81, 83, 79, 86] # Data efisiensi boiler

# Memulai analisis regresi
regression_analysis = RegressionAnalysis(suhu_udara_masuk,
suhu_gas_buang, efisiensi_boiler)
regression_analysis.linear_regression_analysis()
```

Regresi linier ini menggambarkan hubungan antara suhu udara masuk, suhu gas buang, dan efisiensi boiler. Untuk data aktual, dapat diganti dengan nilai-nilai pada variabel suhu_udara_masuk, suhu_gas_buang, dan efisiensi_boiler

Identifikasi Faktor-Faktor Kritis

Proses identifikasi faktor-faktor yang secara signifikan memengaruhi kinerja boiler dilakukan. Hal ini mencakup pemetaan terhadap variabel-variabel yang paling berpengaruh terhadap efisiensi dan operasional boiler, maka proses identifikasi faktor-faktor yang memengaruhi kinerja boiler di PLTSa dilakukan dengan mengumpulkan data operasional yang mencakup variabel-variabel seperti suhu, tekanan, aliran bahan bakar, dan efisiensi boiler. Melalui analisis statistik dan teknik *Machine Learning*, dilakukan evaluasi terhadap hubungan antar variabel-variabel tersebut untuk menemukan faktor-faktor yang paling berpengaruh terhadap efisiensi dan operasional boiler. Dari hasil analisis, variabel yang memiliki korelasi kuat dan dampak signifikan terhadap kinerja boiler diidentifikasi. Langkah ini menjadi dasar penting dalam merancang strategi untuk meningkatkan efisiensi dan operasional PLTSa dengan lebih terfokus dan efektif.

Tantangan dan Potensi Perbaikan:

Dari analisis performa awal ini, diperoleh pemahaman yang mendalam mengenai tantangan-tantangan yang dihadapi oleh boiler di PLTSa serta potensi perbaikan yang dapat diimplementasikan. Hal ini termasuk area-area spesifik yang memerlukan perhatian dalam upaya optimalisasi dan peningkatan kinerja.

Hasil dari analisis performa boiler pada PLTSa ini menjadi dasar yang krusial dalam rangka menentukan langkah-langkah selanjutnya dalam proses optimasi menggunakan pendekatan *Machine Learning*. Informasi yang terkumpul memberikan pemahaman yang lebih baik mengenai kondisi awal sistem, membantu dalam mengevaluasi perubahan yang dihasilkan dari strategi optimasi, serta menawarkan landasan yang kokoh bagi perbaikan kinerja secara menyeluruh dalam lingkungan PLTSa. Dengan demikian, langkah berikutnya dalam penelitian ini adalah penerapan strategi *Machine Learning* untuk mengoptimalkan kinerja boiler dengan mempertimbangkan temuan dari analisis performa awal yang telah dilakukan.

4. KESIMPULAN

Penelitian ini menitikberatkan pada peningkatan efisiensi pengendalian suhu boiler dengan menerapkan solusi *Machine Learning*. Dalam hasil eksperimen, terjadi lonjakan efisiensi yang signifikan, meningkat dari maksimal 80.8% menjadi minimal 89.4%. Penerapan sistem kontrol suhu otomatis menggunakan teknologi *Machine Learning* telah membuktikan keandalan dan keunggulan dalam meningkatkan performa boiler secara substansial.

Hasilnya menunjukkan bahwa teknologi *Machine Learning* bukan hanya mampu memprediksi suhu dengan akurat, tetapi juga mengoptimalkan kontrol suhu secara efisien. Penggunaan sistem kontrol otomatis ini tidak hanya menjanjikan stabilitas dalam suhu boiler, namun juga mengurangi biaya operasional secara signifikan. Implementasi *Machine Learning* dalam pengelolaan suhu boiler telah memberikan dampak positif yang terlihat secara jelas pada efisiensi keseluruhan dari sistem.

Kesimpulannya, pendekatan menggunakan *Machine Learning* dalam pengaturan suhu boiler pada PLTSa telah berhasil meningkatkan efisiensi dari sebelumnya sebesar 80.8% menjadi 89.4%. Hal ini menunjukkan bahwa solusi teknologi mampu memberikan solusi yang efektif dalam mengatasi tantangan pengendalian suhu, menciptakan dampak yang positif pada efisiensi operasional, biaya, dan pencapaian tujuan.

DAFTAR PUSTAKA

- [1]. Qodriyatun, S.N. (2021) 'Pembangkit Listrik Tenaga Sampah: Antara Permasalahan Lingkungan dan Percepatan Pembangunan Energi Terbarukan', Jurnal Qodriyatun, 12(1), hal. 1-10.
- [2]. ekon.go.id. (2021) 'Pengolahan Sampah Menjadi Energi Listrik (PSEL) sebagai Intervensi Teknologi Mengurangi Volume Sampah', 21 Jun. <https://www.ekon.go.id/publikasi/detail/3105/pengolahan-sampah-menjadi-energi-listrik-psel-sebagai-intervensi-teknologi-mengurangi-volume-sampah>
- [3]. Amalia, A., et al. (2020) 'Thermohygrometer dengan Penyimpanan Data untuk Monitoring Kamar Bedah', Program Vokasi Teknik Elektromedik, Universitas Muhammadiyah Yogyakarta.
- [4]. Hou, G.Q. (2013) 'The Application Study of Temperature Control Strategy for *Boiler*', Applied Mechanics and Materials. DOI: 10.4028/www.scientific.net/amm.313-314.462, Vol. 313-314, hal. 462-465.
- [5]. Ding, Y., & Shi, Y. (7 Mar 2019). Real-Time *Boiler* Control Optimization with Machine Learning. arXiv preprint arXiv:1903.04958
- [6]. Rosyadi, I. (2018). Desain Awal Pembangkit Listrik Menggunakan Bahan Bakar Sampah Kota Cilegon Dengan Kapasitas 2 MW. FLYWHEEL: JURNAL TEKNIK MESIN UNTIRTA.
- [7]. Sahda, N. T. (Januari 2022). Analisis Efisiensi *Boiler* menggunakan Metode Langsung di Pembangkit Listrik Tenaga Sampah (PLTSa) Bantargebang. Journal of Engineering Environmental Energy and Science, 1(1), 39-48.
- [8]. Yang, Z., Sheng, Y., Zhu, C., Ni, J., Zhu, Z., Xi, J., Zhang, W., & Yang, J. (May 2022). Accurate and explainable machine learning for the power factors of diamond-like thermoelectric materials. Journal of Materiomics, 8(3), 633-639
- [9]. Reddy, R., Ramesh, R., Deshpande, A., Khapra, M.M. (2019) 'FigureNet: A Deep Learning model for Question-Answering on Scientific Plots', e-Print Archive, arXiv:1806.04633v2 [cs.CL].
- [10]. Yuniar, L.S. (2023) 'Pemanfaatan Pembangkit Listrik Tenaga Sampah sebagai Solusi Alternatif dalam Permasalahan Sampah di Indonesia', Tesis, Fakultas Hukum, Universitas Indonesia. Pembimbing: H. Nursadi, Penguji: W. Awiati, H. Prasetyo, S.N. Setyorini.