

Perancangan Sistem Prediksi Penggunaan Listrik Rumah Tangga Berbasis Website

1st Muhamad Nofyantoro
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

muhamadnofyantoro@student.telkomu
niversity.ac.id

2nd Desri Kristina Silalahi
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

desrikristina@telkomuniversity.ac.id

3rd Novi Prihatiningrum
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

nprihatiningrum@telkomuniversity.ac.i
d

Abstrak-Prediksi konsumsi beban listrik merupakan langkah awal yang tepat untuk mengatasi permasalahan kebutuhan konsumsi listrik di berbagai sektor rumah tangga. Prediksi konsumsi beban listrik juga sangat dibutuhkan dalam pengembangan jaringan listrik untuk ke depannya.

Dalam penelitian ini dirancang suatu sistem untuk prediksi beban listrik berbasis website untuk dapat memprediksi beban listrik dan biaya selang waktu yang diinginkan. Pada pembuatan website ini metode prediksi yang akan di gunakan adalah metode Extreme Gradient Boosting (XGBoost) serta Framework streamlit digunakan dalam penelitian ini dalam membuat website.

Data yang digunakan dalam prediksi konsumsi beban listrik harian per jam (24 jam) adalah 38 hari, yaitu dari tanggal 22 Maret 2020 hingga 28 April 2020. Hasil prediksi yang di dapat yaitu selama 6 hari untuk tanggal 23 April sampai tanggal 28 April yang menghasilkan nilai dengan MSE (Mean Square Error) sebesar: 9,861 dan MAE (Mean Absolute Error): 0,055 MAPE (Mean Absolute Percent Error): 0,1414. Kata kunci— Kata kunci sedapat mungkin menjelaskan isi tulisan, dan ditulis dengan huruf kecil, kecuali akronim. Kata kunci tidak lebih dari 6 kata

I. PENDAHULUAN

Pertambahan penduduk yang semakin pesat dan diiringi pertumbuhan ekonomi yang tinggi menyebabkan kebutuhan akan tenaga listrik semakin meningkat, sehingga dibutuhkan penyediaan dan penyaluran tenaga listrik yang memadai, baik dari segi teknis maupun ekonomisnya. Konsumsi listrik di Indonesia menurut data dari Statistik Ketenagalistrikan KESDM pada tahun 2020 mencapai 243.58 GigaWatt hour (GWh) atau tumbuh rata – rata sebesar 5% dari tahun 2018 sebesar 232,43 GWh. Dari angka tersebut porsi konsumsi dari golongan rumah tangga mencapai 54% dari total konsumsi atau sekitar 112.15 GWh dan tumbuh secara rata – rata 13% dari tahun 2018 yang saat itu sebesar 97,14 GWh. Angka tersebut menunjukkan bahwa porsi konsumsi terbesar adalah dari golongan pelanggan rumah tangga [1]. Di dalam rumah tangga terdapat banyak peralatan elektronik yang dalam pemakaiannya mengkonsumsi energi listrik. Akan tetapi, konsumsi energi di kalangan rumah tangga tergolong boros. Hal ini dikarenakan masyarakat belum bisa mengatur

konsumsi energi listrik di dalam rumah tangga dengan baik. Selain itu, belum adanya sistem yang tepat untuk diterapkan pada rumah tangga juga menjadi salah satu penyebab tingginya tingkat keborosan penggunaan energi dalam rumah tangga [2]. Pengembangan aplikasi hingga saat ini hanya terbatas pada pengujian alat elektronik tertentu sehingga untuk prediksi penggunaan beban daya listrik hanya terbatas pada alat rumah tangga biasa seperti (kipas, lampu dan beberapa alat elektronik lainnya). Permasalahan yang penulis temui hingga saat ini yaitu masih kurangnya data uji sebagai acuan untuk perhitungan machine learning. Karena semakin banyaknya data uji maka prediksi penggunaan daya listrik dapat diprediksi dengan tingkat keakuratan yang lebih tinggi. Namun karena keterbatasan tertentu penulis sudah berusaha semaksimal mungkin untuk mendapatkan data uji sebagai acuan untuk perhitungan machine learning. Penulis berharap dapat terus berinovasi dalam mengembangkan tugas akhir penulis, adapun beberapa rencana inovasi yang penulis miliki yaitu dapat menggolongkan target pasar untuk Perancangan sistem prediksi listrik rumah tangga berbasis website. Berdasarkan jurnal yang penulisan baca konsumsi listrik perumahan tipe 36 dengan daya 900 VA cenderung pemakaian listrik yang lebih besar di banding dengan tipe rumah 45 dengan daya 1300 VA, maka dari itu penulis memfokuskan pengimplementasian dari TA yang penulis buat sangat disarankan untuk perumahan tipe 36 dengan daya 900 VA yang memiliki kecenderungan penggunaan daya yang lebih boros [3].

Dalam web aplikasi yang dibuat oleh penulis memiliki beberapa fitur seperti hasil dari peramalan pemakaian beban listrik serta Estimasi Biaya. Dengan hasil prediksi yang di dapatkan penulis mengharapkan agar masyarakat dapat mempermudah pengaturan penggunaan perangkat elektronika rumah tangga agar lebih efisien dan hemat dalam penggunaannya.

II. KAJIAN TEORI

A. Website

Website merupakan salah satu aplikasi yang berisikan dokumen- dokumen multimedia (teks, foto, suara, animasi, video) didalamnya yang memakai protokol HTTP (Hyper Text Transfer Protocol) dan untuk mengaksesnya menggunakan fitur lunak yang disebut browser. Sebagian tipe browser yang terkenal dikala ini di antara lain: Internet Explorer yang diproduksi oleh Microsoft, Mozilla Firefox, Opera serta Safari yang diproduksi oleh Apple. Browser (perambah) merupakan aplikasi yang sanggup menjalankan dokumen- dokumen website dengan cara diterjemahkan. Prosesnya dilakukan oleh komponen yang ada didalam aplikasi browser yang biasa disebut web engine. Seluruh dokumen web ditampilkan dengan cara di terjemah kan [4].

B. Streamlit

Streamlit merupakan salah satu library open source didalam python yang mudah dibuat serta disebarakan sebagai wujud website atau apps untuk keperluan data science serta machine learning [5]. Pemahaman lain dijelaskan oleh penemu streamlit ialah Adrian yang mengatakan bahwa streamlit merupakan apps framework yang digunakan oleh machine learning engineers serta informasi scientist secara khusus untuk membangun tools internal ataupun web apps yang users dimudahkan dalam menggunakannya serta programmer tidak butuh membuat bahasa pemrograman yang rumit [5]. Streamlit sendiri merupakan penerapan dari API (*Application Programming Interface*). API ini berperan selaku tools buat membuat perangkat lunak. Secara singkat API bisa menghubungkan antara 2 ataupun lebih komponen terpisah pada sesuatu sistem komputer.

C. Pickle Python

Pickle adalah proses dimana objek python dirubah menjadi byte data. Pickle berguna untuk mengimplementasikan protokol biner untuk membuat serial dan deserialisasi objek python [6]

D. Beban Listrik

Klasifikasi Beban

Berdasarkan jenis konsumen energi listrik, secara garis besar, ragam beban dapat diklasifikasikan ke dalam [7]:

A. Beban rumah tangga

Pada umumnya beban rumah tangga berupa lampu untuk penerangan, alat rumah tangga, seperti kipas angin, pemanas air, lemari es, penyejuk udara, mixer, oven, motor pompa air serta sebagainya. Beban rumah tangga umumnya memuncak pada malam hari.

B. Beban komersial

Pada biasanya terdiri atas penerangan untuk reklame, kipas angin, penyejuk udara serta alat- alat listrik yang lain yang dibutuhkan untuk restoran. Beban hotel juga diklasifikasikan sebagai beban komersial (bisnis) begitu pula perkantoran. Beban ini secara ekstrem naik di siang hari untuk beban perkantoran serta pertokoan serta menurun di waktu sore.

C. Beban industri

Beban industri dibedakan dalam skala kecil serta skala besar. Untuk skala kecil banyak beroperasi di siang hari sebaliknya industri besar saat ini ini banyak yang beroperasi hingga 24 jam.

D. Beban Fasilitas Umum

Pengklasifikasian ini sangat penting artinya bila kita melakukan analisa karakteristik beban untuk suatu sistem yang sangat besar. Perbedaan yang paling prinsip dari empat jenis beban diatas, selain dari daya yang digunakan dan juga waktu pembebanannya. Pemakaian daya pada beban rumah tangga akan lebih dominan pada pagi dan malam hari, sedangkan pada beban komersial lebih dominan pada siang dan sore hari.

E. Peramalan

Peramalan merupakan perkiraan atau dugaan atas suatu kejadian tertentu di waktu yang akan datang. Peramalan memiliki fungsi sebagai tindakan preventif terhadap hal-hal yang tidak diinginkan di waktu mendatang. Hasil dari peramalan tersebut dapat dijadikan acuan untuk mempersiapkan tindakan yang perlu dilakukan agar hasil aktualnya sesuai dengan yang diinginkan.

Berdasarkan jangka waktunya, peramalan dapat dibagi menjadi tiga periode, yaitu [8]:

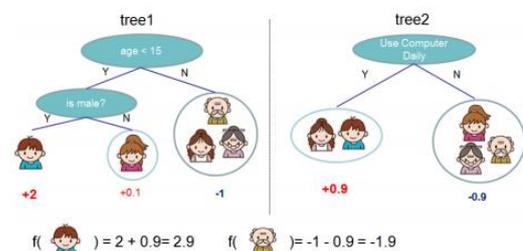
a. Peramalan Jangka Panjang (*Long-Term Forecasting*) peramalan jangka panjang merupakan peramalan yang memprediksikan keadaan dalam jangka waktu beberapa tahun ke depan (tahunan).

b. Peramalan Jangka Menengah (*Mid-Term Forecasting*) peramalan jangka menengah merupakan peramalan yang memprediksikan keadaan dalam jangka waktu bulanan atau mingguan.

c. Peramalan Jangka Pendek (*Short-Term Forecasting*) peramalan jangka pendek merupakan peramalan yang memprediksikan keadaan dalam jangka waktu harian hingga tiap jam.

F. Extreme Gradient Boosting XGBoost

Extreme Gradient Boosting (XGBoost) merupakan sebuah algoritma machine learning yang digunakan pada supervised learning buat melatih dataset dan memprediksi nilai sasaran. XGBoost merupakan algoritma pembelajaran ensemble yang ditingkatkan berdasarkan pohon keputusan peningkatan gradien dan dapat membangun pohon yang ditingkatkan secara efisien dan beroperasi secara paralel. Pohon yang didorong di XGBoost dibagi menjadi pohon regresi dan klasifikasi. Inti dari algoritma adalah untuk mengoptimalkan nilai fungsi tujuan[9].



GAMBAR I

XGBoost milik pembelajaran ensemble algoritma, yang terutama mewarisi gagasan GBDT dan memperbaikinya. GBDT menggunakan informasi orde pertama ketika menghitung nilai gradien negatif, sementara XGBoost menggunakan ekspansi orde kedua untuk mendapatkan informasi orde pertama dan orde kedua. Pada saat yang sama waktu, XGBoost meminjam ide kolom fitur pengambilan sampel dan pengambilan sampel data, yang tidak hanya

meningkatkan kecepatan pelatihan, tetapi juga secara efektif mencegah *over-fitting*.

G. Mean Square Error (MSE)

Mean Square Error untuk mengevaluasi metode peramalan. Masing-masing kesalahan atau sisa dikuadratkan. Kemudian dijumlahkan dengan jumlah observasi nilai ini mengukur kualitas estimator dan selalu non-negative. Semakin mendekati nol, maka model prediksi sangat baik [10].

$$MSE = \frac{1}{n} \sum (y - \hat{y})^2$$

Dimana:

\hat{y} = nilai hasil forecast.

y = nilai observasi ke - i dan n = banyaknya data.

H. Mean Absolute Error (MAE)

Evaluasi MAE ini merupakan nilai rata-rata kesalahan (*error*) absolute antara hasil dari peramalan dengan nilai data sebenarnya.

$$MAE = \frac{1}{n} \sum |f_i - y_i|$$

f_i = nilai hasil forecast.

y_i = nilai observasi ke - i dan n = banyaknya data

I. Mean Absolute Percent Error (MAPE)

MAPE merupakan rata-rata diferensiasi absolut antara nilai peramalan dan aktual, yang dinyatakan sebagai persentase nilai aktual. MAPE dihitung sebagai rata-rata diferensiasi absolut antara nilai yang diramal dan aktual, dinyatakan sebagai persentase nilai aktual. Nilai MAPE dapat dicari dengan menggunakan rumus pada persamaan [11].

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|\hat{y}_t - y_t|}{y_t} \times 100$$

dimana:

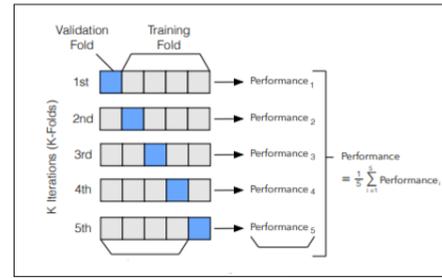
\hat{y} = nilai aktual pada data t .

y = nilai peramalan pada data t .

n = jumlah periode data.

J. Cross Validation

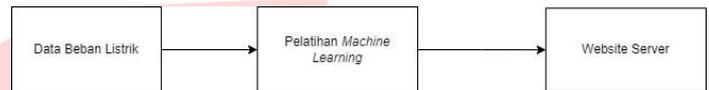
Cross validation merupakan sebuah ukuran yang digunakan untuk melihat kinerja model dalam melakukan prediksi ada beberapa jenis cross validation diantaranya K-fold validation, random sum-sampling validation, leave-neoutcross-validation dan masih banyak lagi. K-fold validation merupakan teknik yang paling sering digunakan karena kesederhanaan dalam komputasi. K-fold validation adalah suatu teknik untuk membagi sampel asli secara acak berdasarkan nilai k yang ditentukan. Selanjutnya, satu sub sampel digambarkan sebagai data uji dan $k-1$ sub sampel dijadikan data latih untuk model yang dibangun. Proses ini akan berulang sebanyak k yang ditentukan dan kemudian hasil prediksi dari setiap k di rata-rata kan untuk menghasilkan hasil estimasi tunggal [12]



GAMBAR 2

III. METODE

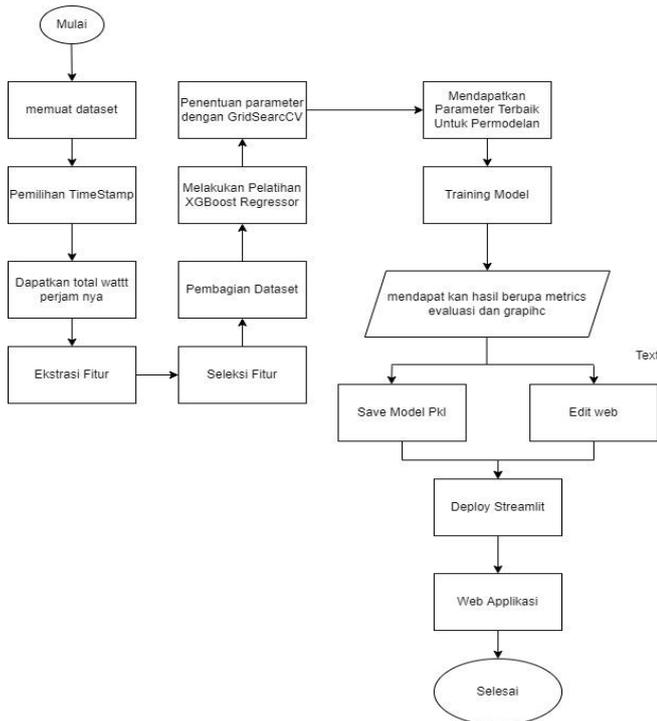
A. Desain Sistem



GAMBAR 3

Pada Gambar 3 menjelaskan tentang blok diagram sistem dimana proses awal adalah pengambilan data beban listrik, data yang diambil adalah data beban dari perangkat 9 perangkat elektronik. Selanjutnya data yang diambil nantinya akan diolah dengan menggunakan metode *XGBoost*. *XGBoost* (*Extreme Gradient Boosting*) merupakan algoritma boosting berdasarkan pada *Gradient Boosting Machine*. *XGBoost* menerapkan teknik regulasi untuk mengurangi *overfitting* dan itu adalah salah satu pembeda dari *Gradient Boosting*, keuntungan yang lainnya adalah kecepatan eksekusi yang cepat dan berkinerja baik dalam permodelan prediksi. Pada proses prediksi ini peneliti mengimplementasikannya menggunakan bahasa pemrograman Python di google collab untuk melakukan prediksi *XGBoost*. Setelah itu akan dilakukan preprocessing data, preprocessing data dilakukan untuk membersihkan data yang masih mengandung noise hingga data siap digunakan untuk permodelan *XGBoost*. Selanjutnya melakukan pembagian data dimana data menjadi data training dan data testing kemudian memisahkan bagian fitur- X dan label- Y . Dataset testing tidak digunakan dalam pemasangan model karena mendapatkan cross-validation error estimate dari data training, sementara dataset testing digunakan sebagai hold-out validation untuk model akhir yang cocok untuk semua data training. Kemudian penulis mencari parameter terbaik yang diambil setelah dilakukan *tuning hyper* parameter secara grid search, setelah mendapatkan model terbaik dari *XGBoost* untuk melakukan prediksi konsumsi beban listrik, maka hasil dari prediksi *XGboost* akan ditampilkan pada Web Server pada platform website

B. Diagram alir sistem



GAMBAR 4

Pada Gambar 4 merupakan penjelasan prinsip kerja mining data berdasarkan diagram alir diatas ini adalah sebagai berikut:

1. Berdasarkan diagram alir diatas proses kerja mining data diawali dengan memuat input dataset.
2. Melakukan pemilihan timestamp. Timestamp disini itu melakukan penanggalan pengambilan data dimulai tanggal berapa sampai dengan tanggal akhir pengambilan data.
3. Mendapatkan hasil dari total dataset perjamnya.
4. Melakukan ekstraksi fitur untuk membuat sebuah variasi data.
5. Melakukan fitur seleksi untuk mengurangi parameter parameter yang tidak kita perlukan kedalam dataset.
6. Setelah itu dataset dibagi menjadi data train dan data test.
7. Melakukan pelatihan model dengan *XGBoost Regresor*.
8. Menentukan parameter masukkan untuk *GridSearchCV*.
9. Mendapatkan parameter terbaik untuk permodelan.
10. Setelah mendapatkan parameter terbaik untuk permodelan selanjutnya melakukan training model.
11. Mendapatkan hasil metrics error MSE dan MAE.
12. Menyimpan permodelan menggunakan library pickle menjadi format .pkl.
13. Melakukan edit pada frontend web.
14. Melakukan deploy ke framework streamlit.
15. Web menyajikan data hasil prediksi dengan grafik, angka dan estimasi biaya pemakaian.

IV. HASIL DAN PEMBAHASAN

A. Pengambilan Data

Data yang di ambil merupakan data dari penelitian sebelumnya. Pengambilan data di mulai dari tanggal 22 maret 2020 hingga 28 april 2020, pengambilan data di laksanakan di indekost pondok DR, desa sukabirus kecamatan dayuehkolot kab Bandung, data yang di peroleh 912 data dengan interval 1 jam. Dengan menggunakan beban 9 perangkat elektronika. Perangkat elektronika tersebut berupa rice cooker, dispenser, cash leptop, setrika, kipas angin, TV, lampu 1, lampu 2, lampu 3

B. Preprocessing Data

Pengambilan data tidak selalu ideal, maka pembersihan data sangat dibutuhkan untuk mempermudah pemrosesan data, maka dari itu dilakukan pembersihan data. Dari pengamatan data, untuk mendapatkan daya total dengan cara menjumlah seluruh penggunaan daya setiap jam

TABEL 1

No	Time Stamp	Total daya (Wh)
0	2020-03-22 02:00:00	53,770
1	2020-03-22 03:00:00	64,617
2	2020-03-22 04:00:00	427,561
3	2020-03-22 05:00:00	194,825
4	2020-03-22 06:00:00	113,098
5	2020-03-22 07:00:00	11,017
6	2020-03-22 08:00:00	3,85
7	2020-03-22 09:00:00	9,983
8	2020-03-22 10:00:00	10,049
9	2020-03-22 11:00:00	9,967
...		
910	2020-04-28 23:00:00	20,445
911	2020-04-29 00:00:00	10,125
912	2020-04-29 01:00:00	3,263

C. Ekstraksi Data

TABEL2

No	TimeStamp	Total daya (Wh)	Yesterday	Yesterday_diff
0	22/03/2020 02:00	53,770	NaN	NaN
1	22/03/2020 03:00	64,617	53,770	NaN
2	22/03/2020 04:00	427,561	64,617	10,846
3	22/03/2020 05:00	194,825	427,561	362,945
4	22/03/2020 06:00	113,098	194,825	-232,736
5	22/03/2020 07:00	11,017	113,098	-81,727
6	22/03/2020 08:00	3,85	11,017	-102,082
7	22/03/2020 09:00	9,983	3,85	-7,167
8	22/03/2020 10:00	10,049	9,983	6,133
9	22/03/2020 11:00	9,967	10,049	0,066
...				
909	28/04/2020 23:00	20,445	20,582	-1,036
910	29/04/2020 00:00	10,125	20,445	-0,137
911	29/04/2020 01:00	3,263	10,125	-10,320

Ditinjau Pada Tabel 1 adalah hasil dari dataset dengan kolom jumlah kolom hanya berjumlah 2 yang akan membuat kurang bagusnya model prediksi, maka pada tabel 2 ditambahkan *feature engineering*. *Feature engineering* ini fungsinya untuk mengekstrak atau menerapkan metode metode baru ke dalam dataset dengan tujuan untuk membuat sebuah variasi data. Selanjutnya disini mencoba untuk melakukan ekstraksi di bagian time diferensial. Time differensial ini penerapan metode T dikurangi jumlah indeks yang telah di definisikan dengan tujuan untuk mengekstraksi informasi pada hari sebelumnya. menjelaskan time diferensial menggunakan yesterday dan yesterday dif. Yesterday didapat dari baris dikurang 1 baris sebelumnya, sedangkan Yesterday_diff didapatkan dari selisih Yesterday(i+1) dan yesterday(i) nan merupakan *missing value* dari sebuah data.

TABEL 3

TimeStamp	Hour	Dayofweek	Quarter	Month	Year	Dayofyear	Dayofmonth	weekofyear
2020-03-22 04:00:00	4	6	1	3	2020	82	22	12
2020-03-22 05:00:00	5	6	1	3	2020	82	22	12
2020-03-22 06:00:00	6	6	1	3	2020	82	22	12
2020-03-22 07:00:00	7	6	1	3	2020	82	22	12
2020-03-22 08:00:00	8	6	1	3	2020	82	22	12
2020-03-22 09:00:00	9	6	1	3	2020	82	22	12
2020-03-22 10:00:00	10	6	1	3	2020	82	22	12
2020-03-22 11:00:00	11	6	1	3	2020	82	22	12
.....								
2020-04-28 23:00:00	23	1	2	4	2020	119	28	18
2020-04-29 00:00:00	0	2	2	4	2020	120	29	18
2020-04-29 01:00:00	1	2	2	4	2020	120	29	18

selanjutnya setelah didapat hasil feature dari timeseries yang sudah didefinisikan selanjutnya mencoba untuk mengekstrak fitur dari timestamp yaitu:

1. *Hour* sebagai jam.
2. *Dayofweek* sebagai posisi dataset pada hari keberapa di satu minggu.
3. *Quarter* sebagai posisi dataset pada quarter.
4. *Month* sebagai bulan.
5. *Year* sabagai tahun.
6. *Dayofyear* sebagai posisi dataset pada hari keberapa di satu tahun.
7. *Dayofmonth* posisi dataset pada hari keberapa di satu 1 bulan.
8. *Weekofyear* sebagai posisi dataset pada minggu keberapa di satu tahun.

Setelah mendapatkan fitur timestamp nya maka selanjutnya disini menggabungkan dataset extractor timestamp dengan dataset fitur engineering total. Fitur selection berguna mengurangi parameter-parameter yang tidak di perlukan ke dalam dataset.

TABEL 4

	Total daya (Wh)	Yesterday	Yesterday_diff	Hour	Dayof week	Quarter	Month	Year	Dayof year	Dayof month	weekof year
0	427,561	64,617	10,846	4	6	1	3	2020	82	22	12
1	194,825	427,561	362,945	5	6	1	3	2020	82	22	12
2	113,098	194,825	-232,736	6	6	1	3	2020	82	22	12
3	11,017	113,098	-81,727	7	6	1	3	2020	82	22	12
4	3,85	11,017	-102,082	8	6	1	3	2020	82	22	12
5	9,983	3,85	-7,167	9	6	1	3	2020	82	22	12
6	10,049	9,983	6,133	10	6	1	3	2020	82	22	12
7	9,967	10,049	0,066	11	6	1	3	2020	82	22	12
...											
907	20,445	20,582	-1,036	23	1	2	4	2020	119	28	18
908	10,125	20,445	-0,137	0	2	2	4	2020	120	29	18
909	3,263	10,125	-10,320	1	2	2	4	2020	120	29	18

Tabel 4 merupakan Penggabungan dataset timestamp dan dataset fitur engineering

D. Pembagian Data

Pada tahapan pembagian data dilakukan untuk mengetahui berapa jumlah data yang digunakan untuk proses pelatihan dan proses pengujian. Pada penelitian ini data yang digunakan adalah 912 (sembila ratus dua belas). Pembagian data training dan data testing yaitu data training sebanyak 85% data training dan data test sebanyak 15% data

E. Penentuan Parameter

Prediksi beban listrik menggunakan algoritma *XGBoost* membutuhkan beberapa training parameter sebagai penunjang kesuksesan pengujian. Parameter yang digunakan adalah general parameters, booster parameter, dan learning task parameters. Model ini menggunakan parameter Booster, *max_depth*, *learning_rate*

TABEL 5

Parameter	Nilai
Booster	Gbtree, Gblinear
Learning rate	0.01, 0.1
Max_depth	3, 9, 12, 15

Pada Tabel 5 setelah menentukan parameter *XGBoost* maka selanjut menggabungkan metode *GridsearchCV* dengan parameters *XGBoost* agar mendapatkan model yang terbaik dari *XGBoost*.

TABEL 6

	booster	learning_rate	max_depth	split_0	split_1	split_2	split_3	split_4	mean_score	std_score	ranking
0	Gbtree	0.01	3	0.0145	0.1490	0.1506	0.0389	0.1295	0.0965	0.0580	2
1	Gbtree	0.01	6	-0.0203	0.1543	0.1282	0.0373	0.1800	0.0959	0.0755	3
2	Gbtree	0.01	9	-0.0126	0.0674	0.0975	0.0135	0.1533	0.0638	0.0592	4
3	Gbtree	0.01	12	-0.0533	-0.1038	0.0576	-0.0025	0.0997	-0.0004	0.0733	16
4	Gbtree	0.01	15	-0.0454	-0.1144	-0.0179	-0.0009	0.0926	-0.0172	0.0671	17
5	Gbtree	0.1	3	0.0786	0.1688	0.2064	0.1409	0.2629	0.1715	0.0618	1
6	Gbtree	0.1	6	-0.0395	-0.1516	0.1221	0.0681	0.1983	0.0394	0.1230	15
7	Gbtree	0.1	9	0.0096	-0.3708	-0.0088	0.0541	0.1385	-0.0354	0.1752	18
8	Gbtree	0.1	12	-0.0104	-0.3948	-0.1066	0.0784	0.1510	-0.0564	0.1899	19

Berdasarkan Tabel 6 hasil dari *GridserchCV* dimana *split_0* sampai *split_4* merupakan hasil scoring *Cross Validation* dan *mean_score* merupakan nilai rata rata dari *Cross Validation* dan *std_score* merupakan nilai setandar devisiasi dari *Cross Validation*. Indeks nomer 5 menunjukkan nilai scoring yang paling tinggi maka indeks nomer 5 yang

akan dijadikan sebagai model *XGBoost* yaitu: $Boster = gbtree$, $learning\ rate = 0.1$ dan $Max_depth = 3$. Parameter terbaik dari keluaran *gridsearchCV* menjadi masukan parameter untuk permodelan *XGBoost*.

yang nantinya akan diisi menggunakan deksripsi dan eksplorasi dari data prediksi beban listrik.

F. Prediksi Biaya Konsumsi Beban Listrik

Prediksi biaya konsumsi beban listrik didapatkan dari data daya pada 9 perangkat elektronika rumah. Data tersebut membandingkan data daya pada hasil prediksi konsumsi beban listrik menggunakan metode *XGBoost* dengan hasil data aktual yang dihasilkan dari pengambilan data beban listrik.

TABEL 7


No	Tanggal	Total KWh aktual	Total KWh prediksi	Biaya Listrik aktual (Rp)	Biaya Listrik prediksi (Rp)	Selisih Biaya aktual dan prediksi (Rp)
1	2020-04-23	2,059	1,73	2,783,768	2,336,8	446,968
2	2020-04-24	2,109	1,78	2,851,368	2,402,15	449,218
3	2020-04-25	1,787	1,74	2,416,024	2,348,29	67,734
4	2020-04-26	1,522	1,77	2,057,744	2,389,250	331,506
5	2020-04-27	2,045	1,6	2764,84	2,158,45	606,39
6	2020-04-28	1,976	1,4	2,671,552	1,897,79	773,762

Pada Table 7 didapatkan cost harian hasil prediksi beban listrik selama 6 hari dan hasil beban aktual yang didapat dari pengambilan data yang telah diperoleh. Serta hasil dari selisih data aktual dengan data hasil prediksi menggunakan *XGBoost*. Pada hasil selisih tersebut dapat menjadi acuan untuk menekan biaya pembayaran beban listrik jika hasil prediksi diaplikasikan pada proses penjadwalan. Jika hasil prediksi konsumsi beban listrik menggunakan metode *XGBoost* di aplikasikan pada sistem penjadwalan penggunaan beban listrik maka akan di dapatkan estimasi pengurangan biaya konsumsi beban listrik senilai selisih yang telah di sajikan pada Table 7 Berdasarkan pengujian menggunakan data aktual dan data prediksi web dari beban listrik selama 6 hari maka di dapatkan hasil $MSE = 9,861$ dan $MAE = 0,055$ dan $MAPE = 0,1414$.

G. Perancangan Webiste

Dalam membangun website penulis menggunakan *Micro framework streamlit*. *Micro framework streamlit* ini dapat digunakan untuk membangun website interaktif berbasis machine learning. Dalam pembuatan website interaktif menggunakan *streamlit* harus melalui beberapa tahapan, pertama adalah menyimpan model dalam bentuk *pickle* yang memuat model *XGBoost*. Pembuatan laman website sendiri menggunakan bahasa *python* yang di konversikan secara otomatis oleh *streamlit*. Yang dimulai membangun kerangka

Peramalan Beban listrik & Estimasi Biaya



GAMBAR 5

Pada Gambar 5 merupakan tampilan micro web interaktif dari prediksi beban listrik rumah tangga beserta estimasi biaya.

V. KESIMPULAN

Berdasarkan pengerjaan Tugas Akhir yang berjudul "Perancangan Sistem Prediksi Penggunaan Listrik Rumah Tangga Berbasis Website" maka penulis dapat menarik kesimpulan sebagai berikut:

1. Dengan adanya sistem prediksi berbasis web dengan menggunakan framework *streamlit* memudahkan dalam perhitungannya dalam memprediksi listrik rumah kedepannya. Hasil dari prediksi sangat dipengaruhi oleh banyaknya data yang dimiliki untuk meningkatkan keakuratan hasil hitung prediksi.
2. Berdasarkan dari model runtun waktu yang digunakan dalam melakukan prediksi beban listrik rumah, yakni metode *XGBoost* dengan *forecase* selama 6 hari ke depan yaitu untuk tanggal 23 April sampai tanggal 28 April yang menghasilkan nilai *MSE (Mean Square Error)* sebesar: 9,861 dan *MAE (Mean Absolute Error)* sebesar 0,055 dan *MAPE (Mean Absolute Percent Error)* sebesar 0,1414.

REFERENSI

- [1] Agustin, R., & Wikarya, U. (2019). Pengaruh Kebijakan Tariff Adjustment Listrik terhadap Konsumsi Listrik Rumah Tangga di Indonesia. *Jurnal Kebijakan Ekonomi*, 15(1), 11.
- [2] Sholeh, M., & Firdaus, F. Analisis Efisiensi Penggunaan Energi Listrik Sektor Rumah Tangga di Pekanbaru Menggunakan Perangkat Lunak LEAP (Doctoral dissertation, Riau University).
- [3] Muhtar, G. A. (2022). LISTRIK BERDAYA RENDAH LEBIH EFISIEN DI PERKOTAAN: PENDEKATAN SISTEM INFORMASI GEOGRAFIS. *JUIK (Jurnal Ilmu Komputer)*, 2(1), 67-71.
- [4] Arief, M. R. (2011). *Pemrograman Web Dinamis Menggunakan Php Dan Mysql*. Yogyakarta: Andi.
- [5] Streamlit. (2020). Home: Streamlit. Diambil Kembali Dari [Streamlit.io: https://docs.streamlit.io/en/stable/#:~:Text=Streamlit%20is%20an%20open%20source,Apps%20%2d%20so%20let's%20get%20started!](https://docs.streamlit.io/en/stable/#:~:Text=Streamlit%20is%20an%20open%20source,Apps%20%2d%20so%20let's%20get%20started!)
- [6] Python. "Pickle – Python Object Serialization" [Online],

- [7] Suswanto, D. (2009). Sistem Distribusi Tenaga Listrik. Universitas Negeri Padang, Padang.
- [8] Dwiantoro, B. (2012). Peramalan Beban Listrik Jangka Pendek Berdasarkan Data Historis Menggunakan Metode Generalized Autoregressive Conditionalheteroskedasticity (Garch).
- [9] N. Zheng, Y. Shao, S. Zou, And Z. Ma, "Short-Term Load Forecasting Based On Wavelet Decomposition And Xgboost," Proc. 2020 10th Int. Work. Comput. Sci. Eng. (Wcse 2020), No. Wcse, Pp. 19–21, 2020, Doi: 10.18178/Wcse.2020.06.060.
- [10] Sautomo, S., & Pardede, H. F. (2021). Prediksi Belanja Pemerintah Indonesia Menggunakan Long Short-Term Memory (Lstm). Jurnal Resti (Rekayasa Sistem Dan Teknologi Informasi), 5(1), 99-106.
- [11] Putro, B. (2018). Prediksi Jumlah Kebutuhan Pemakaian Air Menggunakan Metode Exponential Smoothing (Studi Kasus: Pdam Kota Malang) (Doctoral Dissertation, Universitas Brawijaya).
- [12] Putra, M. L. P. (2021). Sistem Prediksi Harga Rumah Di Pulau Jawa Dengan Analisis Random Forest Dan Website Interaktif Menggunakan Framework Streamlit.

