

Identifikasi Beban Listrik Rumah Tangga Menggunakan Metode *Convolutional Neural Network*

1st Vinni Ariesta
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

vinniariesta@student.telkomuniversity.ac.id

2nd Randy Erfa Saputra
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

resaputra@telkomuniversity.ac.id

3rd Casi Setianingsih
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

setiacasie@telkomuniversity.ac.id

Abstrak – Dewasa ini energi listrik sudah menjadi kebutuhan untuk manusia. Hampir seluruh kegiatan menggunakan energi listrik mulai dari dunia industri sampai kebutuhan rumah tangga. Setiap tahunnya kebutuhan energi listrik terus bertambah. Konsumsi energi listrik yang berlebihan dapat mengurangi kualitas energi listrik tersebut. Pengguna energi listrik perlu memiliki sistem pemantau penggunaan energi listrik agar konsumsi energi listrik yang berlebihan tidak terjadi. Convolutional Neural Network (CNN) menjadi algoritma pada sistem identifikasi jenis beban listrik pada perangkat elektronik rumah tangga. Dengan adanya sistem ini dapat membantu pengguna mengetahui perangkat elektronik mana yang memakai banyak daya. Pengujian sistem identifikasi jenis beban listrik dilakukan pada 3 jenis perangkat elektronik, yaitu pemanas air, setrika, dan kipas angin. Kemudian 3 jenis perangkat elektronik tersebut akan dikombinasikan sehingga menjadi 7 class. Diperoleh hasil pengujian bahwa sistem dapat mengidentifikasi ke-3 jenis perangkat elektronik beserta kombinasinya dengan akurasi 97.83%, presisi 98.29%, recall 97.30%, dan F1 Score 97.73% menggunakan metode Convolutional Neural Network yang terbentuk, dengan rata-rata waktu yang diperlukan sistem untuk mengenali adalah kurang dari 1 second.

Kata kunci— identifikas, jenis beban listrik, dataset, *Convolutional Neural Network*

I. PENDAHULUAN

Di masa sekarang ini energi listrik sudah menjadi kebutuhan untuk setiap manusia. Berbagai macam kegiatan sudah banyak menggunakan energi listrik. Dari kegiatan rumah tangga, lalu lintas, perbankan, dan masih banyak lagi. Oleh karena itu kebutuhan energi listrik terus meningkat setiap tahunnya. Tetapi banyak orang yang tidak sadar bahwa mereka telah banyak membuang energi listrik dengan sia-sia, oleh karena itu penulis membuat prediksi beban listrik yang menggunakan metode dari *deep learning* untuk memonitor penggunaan energi listrik.

Penggunaan energi listrik akan terus meningkat setiap tahunnya, terutama di pada sektor rumah tangga, sehingga permintaan energi listrik juga akan meningkat. Untuk itu manajemen

penggunaan energi listrik sangat dibutuhkan agar tidak terjadi penurunan kualitas dari energi listrik itu. Sebelum memonitor penggunaan energi listrik, perlu memantau semua peralatan yang menggunakan energi listrik untuk merekam pembacaan daya [1].

Penelitian prediksi beban listrik menggunakan *Artificial Intelligent* (AI) sudah banyak dilakukan. Seperti prediksi beban listrik di pulau bali menggunakan Jaringan Syaraf Tiruan Backpropagation [2]. Tetapi dengan metode itu prediksi beban listrik memiliki kekurangan yaitu hanya bisa mengeluarkan satu nilai keluaran. Saat ini sistem pemantauan yang bertujuan untuk memonitor konsumen mengelola penggunaan dan pengeluaran energi listrik sedang dalam tahap dikembangkan [3].

Monitoring merupakan salah satu cara untuk pemantauan dan pengumpulan data dari suatu perangkat yang menghasilkan nilai. Dari nilai itu kita dapat mengetahui jenis beban listrik apa yang sedang dalam kondisi menyala atau berjalan. Metode tersebut dapat dibuat dengan bentuk sistem yang akan menampilkan jenis perangkat yang sedang menyala.

Di penelitian ini menggunakan model *deep learning* dengan algoritma *Convolutional Neural Network* (CNN). Algoritma tersebut akan melakukan identifikasi dari *dataset* yang diambil dari perangkat listrik rumah tangga. Data yang dimaksud adalah data dari nilai tegangan, arus, daya, daya semu, dan faktor daya dari perangkat listrik yang sedang menyala.

II. KAJIAN TEORI

A. Jenis Perangkat Listrik


Peralatan listrik merupakan semua benda yang berfungsi ketika menggunakan listrik sebagai sumber energinya. Sedangkan peralatan listrik rumah tangga yaitu yang berkaitan dengan peralatan listrik yang biasa digunakan di rumah. Banyak peralatan yang terdapat di rumah tangga yang menggunakan listrik sebagai sumber energinya. Dalam tugas akhir ini menggunakan pemanas air, setrika, dan kipas angin sebagai objek

beban listrik pada pengujiannya. Beban listrik sendiri merupakan semua hal yang membutuhkan energi listrik dalam bentuk arus dan kemudian mengubahnya menjadi bentuk lain seperti panas, cahaya, angin, dan lain-lain.

B. Model Convolutional Neural Network


Convolutional Neural Network (CNN) merupakan pengembangan dari Multilyer Perceptron (MLP) yang didesain untuk mengolah data dua dimensi. CNN pertama kali dikembangkan dengan nama *NeoCognitron* oleh Kunihiko Fukushima, seorang peneliti yang berasal dari NHK *Broadcasting Science Research Laboratories*, Kinuta, Setagaya, Tokyo, Jepang [15]. Konsep tersebut kemudian dimatangkan oleh Yann LeChun, seorang peneliti yang berasal dari AT&T *Bell Laboratories* di *Holmdel, New Jersey, USA*. Model CNN dengan nama LeNet telah berhasil diterapkan oleh LeChun pada penelitiannya mengenai pengenalan angka dan tulisan tangan [16]. Dengan berkembang *deep learning*, ditemukan bahwa untuk mengatasi kekurang MLP dalam menangani data kompleks, diperlukan fungsi untuk mentransformasi data input menjadi bentuk yang lebih mudah untuk dipahami oleh MLP.

CNN merupakan variasi dari *Multilayer Perceptron* yang terinspirasi dari jaringan saraf manusia berdasarkan penemuan dari Hubel dan Wiesel yang melakukan penelitian korteks visual pada indra visual kucing. Hal ini menginspirasi cara kerjanya dikarenakan hasil dari penelitian. Berikut ini adalah urutan lapisan dari metode CNN [17].



GAMBAR 2.1
METODE CONVOLUTIONAL NEURAL NETWORK


Model *convolutional neural network* telah menjadi dominan dalam banyak tugas visi komputer dan banyak domain yang berminat menggunakan CNN termasuk radiologi [18]. CNN merupakan konstruksi matematis yang biasanya terdiri dari tiga jenis lapisan, yaitu konvolusi, penyatuan, dan lapisan yang sepenuhnya terhubung. Arsitektur CNN terbentuk ketika lapisan-lapisan tersebut ditumpuk. Berikut adalah gambar dari arsitektur dari CNN yang telah disederhanakan [19].



GAMBAR 2.2
ARSITEKTUR CONVOLUTIONAL NEURAL NETWORK

C. Convolutional Neural Network (CNN) 1D

Pada masa sekarang ini sudah banyak yang menggunakan *machine learning* di berbagai bidang. Salah satu model yang dimiliki oleh *machine learning* adalah *Artificial Neural Network* (ANN), model ini mampu melebihi kecerdasan buatan sebelumnya. ANN sendiri terinspirasi dari jaringan saraf manusia, itulah kenapa ANN mampu menyaingi kecerdasan buatan sebelumnya. ANN juga memiliki bentuk lain, yaitu *Convolutional Neural Network* (CNN). CNN dibuat untuk bertujuan mampu melakukan pengenalan terhadap pola berbasis gambar dan sinyal yang sulit untuk dipecahkan secara akurat [19]



GAMBAR 2.3
ARSITEKTUR CNN 1D [20]

CNN merupakan salah satu dari golongan *Survised learning*. CNN 1D memiliki kemampuan yang unggul dalam melakukan identifikasi dari data yang terbatas dan variasi sinyal tinggi yang dihasilkan sumber berbeda [21]. Ada dua bagian di dalam CNN 1D, yaitu *feature extraction* dan *classification*, seperti yang dicontohkan pada gambar diatas. Pada bagian *features extraction* terdapat *convolutional layer* dan ketika masuk ke *classification* program akan mulai melakukan proses pengidentifikasian.

1. *Feature Extraction*

Feature Extraction merupakan sebuah proses dalam pengambilan ciri-ciri unik yang dimiliki suatu data yang akan diproses. *Feature extraction* dilakukan dengan tujuan memperkecil jumlah data, mengambil informasi dari data yang akan diproses,

dan meningkatkan presisi pengolahan. Di dalam *features extraction* terdapat dua bagian, yaitu *convolutional layer* dan *pooling layer*.

a. Convolutional Layer

Convolutional layer digunakan untuk melakukan ekstraksi data masukan menjadi *features map*. Pada lapisan ini konvolusi dari setiap sub kawasan data masukan dengan kernel dihitung, ditambahkan oleh bias dan kemudian dimasukkan melalui fungsi aktivasi untuk menghasilkan peta fitur pada lapisan berikutnya.

Propagasi 1D pada lapisan konvolusi $l - 1$ ke input neuron di lapisan l dapat dinyatakan dengan persamaan [22].

$$h_i^{l,k} = f(b_i^{l,k} + \sum_{n=1}^N w_{n,i}^{l,k} \times x_{i+n-1}^{l-1,k}) \quad (2.1)$$

Berdasarkan dengan persamaan diatas, $h_i^{l,k}$ adalah output dari i^{th} Neuron di lapisan l , $f()$ adalah fungsi aktivitas dan $b_i^{l,k}$ adalah *offset neuron* di lapisan l , $x_{i+n-1}^{l-1,k}$ merupakan keluaran neuron di lapisan $l - 1$, dan $w_{n,i}^{l,k}$ adalah kernel konvolusi k^{th} di lapisan l^{th} .

b. Pooling Layer

Berdasarkan lapisan konvolusi, *pooling layer* merupakan proses untuk mengambil sampel yang akan digunakan dalam mengurangi ukuran *feature*. Jaringan yang kompleks dan *overfitting* diminimalkan dengan cara mengurangi dimensi dari data keluaran lapisan konvolusi [23]. Sedangkan untuk ketahanan jaringan ditingkatkan sebagai hasil dari operasi ini. Rata-rata *pooling layer* atau *feature map* konvolusi, dan metode lain yang sesuai adalah *average pooling* dan *maximum pooling*. *Maxpooling layer* merupakan proses pengambilan nilai yang paling besar di setiap bagian. Sedangkan *Mean pooling layer* adalah pengambilan rata-rata nilai pada setiap bagian. Dalam Tugas Akhir ini diaplikasikan *max pooling layer* untuk setiap *convolutional layer*. Hasil *pooling layer* terlihat pada persamaan di bawah [23].

$$o_i^{l,k} = f(\sigma_i^{l,k} \text{pool}(x_i^{l-1,k}) + b_i^{l,k}) \quad (2.2)$$

persamaan diatas $o_i^{l,k}$ Merupakan *output* dari i^{th} Di lapisan l , $f()$ adalah fungsi aktivitas $b_i^{l,k}$ adalah *offset neuron* di lapisan l , $\sigma_i^{l,k}$ adalah persamaan dari bobot sampling, $x_i^{l-1,k}$ merupakan keluaran neuron di lapisan $l - 1$, dan *pool* merupakan fungsi dari *pooling*.

2. Classification

Setelah melewati tahapan *feature extraction*, dilakukan tahapan klasifikasi. Data yang telah diolah dalam proses *feature extraction* kemudian akan diidentifikasi di tahapan klasifikasi ini. Di tahap ini terdapat beberapa *layer*, yaitu *flatten layer* dan *fully connected layer* atau *dense layer*.

1. Flatten Layer

Hasil dari *feature extraction* berupa *feature map* dalam bentuk multidimensional *array* yang harus melalui proses *flatten* untuk menjadi *vector* yang dapat digunakan sebagai input dari *fully connected layer* [23]. Dalam tugas akhir ini tahapan ini akan mengubah *feature map* menjadi 1D *vector* untuk digunakan pada *fully connected layer*.

2. Dense Layer Atau Fully Connected Layer

Fully connected layer (*dense layer*) digunakan untuk menghubungkan semua fitur yang telah diekstraksi dari *flatten layer*. Dengan menggunakan klasifikasi regresi logistic, *softmax activation* akan mengklasikan kondisi sinyal EKG yang kelasnya lebih dari dua [24]. Lapisan ini mentransfer jumlah dari lapisan sebelumnya ke fungsi aktivasi. Persamaan dari keluaran ditunjukkan pada persamaan dibawah [24].

$$o_i^{l,k} = f(w_i^{l,k} x_i^{l-1,k} + b_i^{l,k}) \quad (2.3)$$

Menurut persamaan diatas, $o_i^{l,k}$ merupakan *output* dari neuron i^{th} di lapisan l , $f()$ adalah fungsi aktivitas $b_i^{l,k}$ adalah *offset neuron* di lapisan l , $\sigma_i^{l,k}$ adalah persamaan dari bobot sampling, $x_i^{l-1,k}$ merupakan keluaran neuron dilapisan $l - 1$, dan $w_i^{l,k}$ adalah bobot jaringan.

D. Accuracy, Precision, Recall, dan F1 Score

Untuk mengetahui kualitas dari sebuah sistem dalam *data mining*, maka dibutuhkan suatu percobaan untuk mengukur seberapa baik sistem yang telah dibuat. Percobaan tersebut mencakup kedalam perhitungan *accuracy*, *precision*, *recall*, dan *F1-Score*.

Accuracy merupakan tingkat perbandingan antara nilai prediksi dan nilai sebenarnya sejauh mana kedekatan nilai tersebut. Sedangkan *precision* adalah tingkat respon antara informasi yang diinputkan oleh *user* dengan jawab yang diberikan oleh sistem. *Recall* merupakan tingkat keberhasilan suatu sistem dalam menjalankan perintah yang diberikan. Dan yang terakhir yaitu *F1-Score* yang merupakan cara untuk menggunakan nilai *precision* dan *recall* dengan menggabungkan keduanya yang biasa disebut dengan nilai *F measure*.

$$Accuracy = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (2.4)$$

$$Precision = \frac{TP}{(TP + FP)} \quad (2.5)$$

$$Recall = \frac{TP}{(TP + FN)} \quad (2.6)$$


$$F1 - Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (2.7)$$

TN (*True Negative*) adalah jumlah contoh negatif jika hasil klasifikasi benar. FP (*False Negative*) adalah sejumlah contoh negatif jika hasil klasifikasi tidak benar. FN (*False Negative*) adalah jumlah contoh positif jika hasil klasifikasi tidak benar. Dan yang terakhir adalah TP (*True Positive*) yang merupakan jumlah sampel positif dan hasil klasifikasi positif.

III. METODE


A. Desain Sistem

Pada tugas akhir ini dibuat sebuah sistem yang mampu untuk melakukan identifikasi jenis perangkat listrik rumah tangga yang sedang dalam kondisi menyala. Penelitian ini memiliki bentuk penyelesaian antara *hardware* dan *software* yang digunakan.



GAMBAR 3.1
DESAIN SISTEM

Dalam penyelesaian dari segi *hardware* yang menggunakan beberapa perangkat pendukung seperti *Raspberry pi 3 Model B+* sebagai mikrokomputer untuk mengolah data yang diambil,



GAMBAR 3.2
DIAGRAM ALIR SISTEM

Berdasarkan diagram alir diatas, pada awal sistem yang pertama dilakukan adalah memastikan apakah rangkaian sudah terhubung dengan baik, selanjutnya alat akan mulai membaca parameter yang telah ditentukan, setelah itu dengan

EMG 25 sebagai *power meter* untuk mengukur arus, tegangan, daya, dan faktor daya pada beban yang sedang berjalan, hasil yang didapatkan dari pengukuran tersebut kemudian akan dibaca oleh *Raspberry pi 3 Model B+* dan RS485 sebagai penghubung antara EMG 25 dan *Raspberry pi 3 Model B+*.

Dari segi pengolahan *software system* ini mengolah data yang sudah didapat dari EMG 25 yang diterima oleh *Raspberry pi 3 Model B+* untuk disimpan sebagai *dataset*. Kemudian kumpulan *dataset* yang sudah didapat dijadikan *dataset* dan analisis *deep learning* untuk dilakukan proses identifikasi beban listrik. Dalam penelitian ini penulis menggunakan algoritma *Convolutional Neural Network (CNN)* dari pengolahan tersebut sistem melakukan proses identifikasi jenis perangkat listrik yang sedang beroperasi beserta tampilan konsumsi daya yang digunakan.

Berdasarkan diagram fungsi yang telah dibuat, sistem bekerja dengan masukan dari parameter beban listrik yang aktif dan waktu operasi. EMG 25 merupakan sebuah *power meter* berfungsi untuk mengambil data berupa arus, tegangan, daya, dan faktor daya dari keseluruhan beban listrik yang aktif. Kemudian data dari *output digital* EMG 25 dibaca oleh *Raspberry pi 3 Model B+* menggunakan komunikasi RS 485 dan protokol MODBUS RTU. Data yang sudah didapatkan kemudian diolah oleh mikrokomputer, dalam hal ini *Raspberry pi 3 Model B+* menjadi *dataset* dalam format *csv*. Kemudian *dataset* diinput kedalam sistem untuk melakukan proses *training* dan *testing* menggunakan algoritma *Convolutional Neural Network* untuk mengetahui ciri masing-masing beban yang beroperasi sehingga tercipta model algoritma identifikasi. Kemudian dilakukan pengujian menggunakan data acak yang diambil dari EMG 25 menggunakan model tersebut. Hasil dari pengujian tersebut berupa keluaran jenis perangkat elektronik yang sedang menyala.

B. Diagram Alir Sistem

Berikut adalah diagram alir sistem untuk mengidentifikasi beban listrik rumah tangga sedang berjalan menggunakan algoritma *Convolutional Neural Network*.

menggunakan algoritma *Convolutional Neural Network (CNN)* melakukan proses identifikasi jenis beban listrik tersebut dengan menggunakan parameter yang telah ditentukan.

C. Pengambilan Dataset

Pada Tugas Akhir ini, pengambilan data beban listrik rumah tangga menggunakan EMG 25. Data yang diambil adalah data perangkat elektronik yang tersambung dengan EMG 25, diantaranya ada pemanas air, setrika, dan kipas angin. Proses pengambilan data dilakukan pada masing-masing perangkat yang dalam kondisi menyala, setelah itu proses pengambilan data dilakukan dengan kombinasi semua perangkat yang ada dengan semua kemungkinan. Total kombinasi pengambilan data sebanyak tujuh kombinasi. Proses pengambilan data diperlukan waktu kurang lebih 18 menit. Data yang sudah didapatkan nantinya akan diolah menjadi *dataset* yang akan digunakan untuk identifikasi perangkat elektronik menggunakan algoritma *Convolutional Neural Network*. Berikut adalah Langkah-langkah yang dilakukan pada pengujian sistem:

1. Memasang CT pada terminal yang akan digunakan.
2. Merangkai EMG 25 dengan Modbus RS485, CT dan terminal yang digunakan.
3. Merangkai Raspberry pi 3 dengan Modbus RS485.
4. Mengaktifkan Raspberry pi 3 dan membuka VNC.
5. Menghubungkan port USB dan mengatur EMG 25 agar bisa terhubung dengan Raspberry pi 3 dan VNC.
6. Mengirim program untuk pengambilan data yang diperlukan dan memastikan tidak adanya *error*.
7. Pada kondisi yang pertama menyalakan tiga jenis beban listrik satu persatu.
8. Pada kondisi kedua menyalakan dua jenis beban listrik yang berbeda secara bersamaan.
9. Pada kondisi ketiga menyalakan semua jenis beban listrik secara bersamaan.
10. Hasil dari data-data yang telah dikumpulkan akan diolah menjadi perubahan untuk membentuk *dataset* yang akan dipilih sesuai fitur yang dibutuhkan.

TABEL 3.1
CONTOH DATASET

| Tegangan | Arus | Daya | Daya Tot | Daya Semu | Faktor Daya | Label |
|----------|--------|-------|----------|-----------|-------------|-------|
| 238.03 | 0.7115 | 152.2 | 168.0 | 168.0 | 0.92 | 1 |
| | 2 | | 5 | 5 | | |
| 237.93 | 0.7015 | 152.9 | 166.5 | 168.1 | 0.92 | 1 |
| | 1 | 5 | 5 | 4 | | |
| 238.26 | 0.8216 | 164.7 | 195.8 | 195.8 | 0.88 | 2 |
| | 4 | 3 | 5 | 5 | | |
| 238.6 | 0.8216 | 168.6 | 195.1 | 195.1 | 0.9 | 2 |

| Tegangan | Arus | Daya | Daya Tot | Daya Semu | Faktor Daya | Label |
|----------|--------|-------|----------|-----------|-------------|-------|
| | 8 | 8 | 8 | 8 | | |
| 239.75 | 0.1019 | 18.94 | 24.21 | 24.25 | 0.94 | 3 |
| 239.75 | 0.1017 | 18.35 | 23.02 | 23.49 | 0.89 | 3 |
| 241.42 | 0.8918 | 187.0 | 214.1 | 215.0 | 0.92 | 4 |
| | 7 | 4 | 5 | 8 | | |
| 240.64 | 0.8918 | 186.0 | 213.4 | 213.4 | 0.92 | 4 |
| | 6 | 2 | 5 | 5 | | |
| 238.08 | 1.1516 | 166.2 | 274.5 | 274.5 | 0.72 | 5 |
| | 6 | 3 | 1 | 1 | | |
| 237.94 | 1.1516 | 166.2 | 274.1 | 274.2 | 0.73 | 5 |
| | 6 | 8 | | 3 | | |
| 236.9 | 0.7115 | 157.1 | 167.2 | 167.9 | 0.95 | 6 |
| | 5 | 7 | 5 | 4 | | |
| 236.91 | 0.7115 | 158.1 | 168.8 | 168.8 | 0.96 | 6 |
| | 8 | 1 | 8 | 8 | | |
| 235.7 | 1.1215 | 154.9 | 263.5 | 263.5 | 0.72 | 7 |
| | 4 | 2 | 2 | 2 | | |
| 235.34 | 1.1115 | 155.5 | 267.1 | 262.1 | 0.73 | 7 |
| | 5 | | 7 | 7 | | |

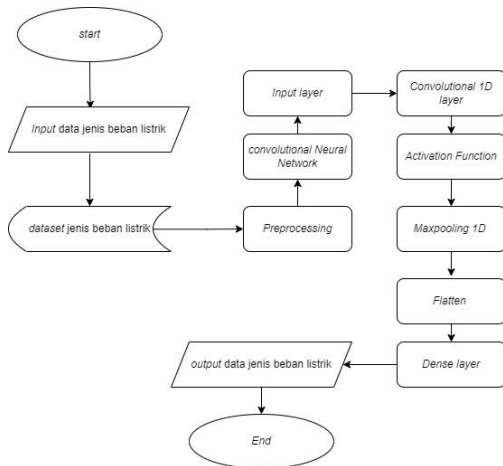
Pada tabel 3.1 merupakan tampilan sampel dari *dataset* yang digunakan pada proses identifikasi jenis perangkat listrik menggunakan algoritma *Convolutional Neural Network*. *Dataset* tersebut merupakan hasil akhir dari data-data yang telah dikumpulkan dan dijadikan sebagai data perubahan. *Dataset* yang digunakan untuk proses identifikasi sebanyak 5541 data dan sudah terdapat kombinasi dari tiga jenis beban yang berbeda mendapatkan tujuh kombinasi. Berikut merupakan keterangan dari label.

TABEL 3.2
KETERANGAN LABEL

| Label | Keterangan |
|-------|-----------------------------------|
| 1 | Pemanas Air |
| 2 | Setrika |
| 3 | Kipas Angin |
| 4 | Setrika, Kipas Angin |
| 5 | Pemanas Air, Setrika |
| 6 | Pemanas Air, Kipas Angin |
| 7 | Pemanas Air, Setrika, Kipas Angin |

D. Flowchart Convolutional Neural Network


Berikut adalah gambaran *flowchart* dari *Convolutional Neural Network* (CNN).



GAMBAR 3.3
FLOWCHART CNN SISTEM IDENTIFIKASI JENIS PERANGKAT LISTRIK

E. Arsitektur *Convolutional Neural Network*

Pada arsitektur *Convolutional Neural Network* (CNN) yang ditunjukkan pada gambar dibawah, CNN *layer* yang digunakan pada merupakan *conv1d layer* dengan satu *layer*, pada *layer* selanjutnya merupakan *flatten layer* dengan jumlah *neuron* sebanyak 128 *neuron*, selanjutnya pada *output layer* digunakan satu *layer* dengan jumlah *neuron* sebanyak 128 *neuron* pada seluruh *layer*, fungsi aktivasi yang digunakan adalah *LeakyReLU*.




GAMBAR 3.4
ARSITEKTUR CNN SISTEM IDENTIFIKASI JENIS PERANGKAT LISTRIK

F. Proses Latih Model CNN

Data yang telah melalui tahap *preprocessing* selanjutnya dimasukkan kedalam model CNN

untuk dilatih. Pelatihan model akan terus berulang sesuai dengan jumlah iterasinya. Pemisalan dari kalkulasi algoritma CNN:

Diketahui input dari data sebagai berikut:
 $f = 5, g = 2, x = [0.3, 0.5, 0.6, 0.2, 0.4], weight = [0.2, 0.3]$



GAMBAR 3.5
PEMISALAN PERHITUNGAN

IV. HASIL DAN PEMBAHASAN

A. Tujuan dan Skenario Pengujian

Pengujian ini bertujuan untuk mengetahui apakah sistem yang telah dibuat telah berjalan dengan baik dengan bisa mengidentifikasi jenis beban listrik dan mendapatkan hasil akurasi, presisi, *recall*, dan *F1-score* yang tinggi.

1. Skenario Pengujian dengan Partisi Data

Pengujian ini berfungsi untuk mengetahui kerja dari algoritma *Convolutional Neural Network* dalam melakukan klasifikasi data ke dalam kelas yang telah ditentukan sebelumnya. Pada percobaan pengujian ini diberikan data *testing* untuk menguji tabel keputusan yang sudah terbentuk. Untuk kerjanya diperoleh dengan memberikan nilai *confusion matrix* dengan menghitung nilai *accuracy*, *precision*, *recall*, dan *F1-score* dari hasil pengujian. Kinerja pengujian akan dilakukan sebanyak lima kali dengan membagi data *Training* dan data *Testing* dengan porsi yang berbeda-beda. Pengujian ini akan diuji sebanyak lima pengujian.

TABEL 4.1
SKENARIO PENGUJIAN PARTISI DATA

| Pengujian | Data <i>Training</i> % | Data <i>Testing</i> % |
|-------------------|---------------------------|--------------------------|
| Pengujian Pertama | 50 | 50 |
| Pengujian Kedua | 60 | 40 |
| Pengujian Ketiga | 70 | 30 |

| Pengujian | Data Training % | Data Testing % |
|-------------------|-----------------|----------------|
| Pengujian Keempat | 80 | 20 |
| Pengujian Kelima | 90 | 10 |

Dari nilai *accuracy*, *precision*, *recall*, dan *F1-score* tertinggi selanjutnya akan diuji kembali menggunakan parameter *learning rate*, *batch size*, dan *epoch* untuk melihat apakah ada perubahan nilai di *accuracy*, *precision*, *recall*, dan *F1-score*.

2. Skenario Pengujian *Learning Rate*

Dalam pengujian *learning rate* akan menggunakan partisi data yang menghasilkan nilai *accuracy*, *precision*, *recall*, dan *F1-score* tertinggi pada pengujian partisi data. Dan menggunakan *batch size* sebesar 16 dengan *epoch* sebesar 100. Pengujian *learning rate* akan dimulai secara terurut dengan nilai 0.0001, 0.001, 0.01, 0.1, dan 1.

TABEL 4.2
SKENARIO PENGUJIAN LEARNING RATE

| Pengujian | Learning Rate | Batch Size | Epoch |
|-------------------|---------------|------------|-------|
| Pengujian pertama | 0.0001 | 16 | 100 |
| Pengujian kedua | 0.001 | 16 | 100 |
| Pengujian ketiga | 0.01 | 16 | 100 |
| Pengujian keempat | 0.1 | 16 | 100 |
| Pengujian kelima | 1 | 16 | 100 |

3. Skenario Pengujian *Batch Size*

Dalam pengujian *batch size* akan menggunakan partisi data yang menghasilkan nilai *accuracy*, *precision*, *recall*, dan *F1-score* tertinggi pada pengujian partisi data. Dan menggunakan *epoch* sebesar 100 dan *learning rate* yang memiliki nilai *accuracy*, *precision*, *recall*, dan *F1-score* tertinggi pada pengujian *learning rate*. Pengujian *batch size* ini akan dimulai berurut dengan nilai sebesar 8, 16, 32, 64, dan 128.

TABEL 4.3
SKENARIO PENGUJIAN BATCH SIZE

| Pengujian | Learning Rate | Batch Size | Epoch |
|-------------------|----------------------------------|------------|-------|
| Pengujian pertama | Menggunakan <i>learning rate</i> | 8 | 100 |
| Pengujian kedua | dengan <i>accuracy</i> , | 16 | 100 |

| Pengujian | Learning Rate | Batch Size | Epoch |
|-------------------|------------------------------------------------------------------------------------------------------|------------|-------|
| Pengujian ketiga | <i>precision</i> , <i>recall</i> , dan <i>F1-score</i> tertinggi pada pengujian <i>learning rate</i> | 32 | 100 |
| Pengujian keempat | | 64 | 100 |
| Pengujian kelima | | 128 | 100 |

4. Skenario Pengujian *Epoch*

Dalam pengujian *epoch* akan menggunakan partisi data yang menghasilkan nilai *accuracy*, *precision*, *recall*, dan *F1-score* tertinggi pada pengujian partisi data. Dan menggunakan *batch size* dan *learning rate* yang memiliki nilai *accuracy*, *precision*, *recall*, dan *F1-score* tertinggi. Pengujian *epoch* ini akan dimulai berurut dengan nilai sebesar 50, 100, 150, 200, dan 250.

TABEL 4.4
SKENARIO PENGUJIAN EPOCH

| Pengujian | Learning Rate | Batch Size | Epoch |
|-------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------|-------|
| Pengujian pertama | Menggunakan <i>learning rate</i> dengan <i>accuracy</i> , <i>precision</i> , <i>recall</i> , dan <i>F1-score</i> tertinggi pada pengujian <i>learning rate</i> | Menggunakan <i>batch size</i> dengan <i>accuracy</i> , <i>precision</i> , <i>recall</i> , dan <i>F1-score</i> tertinggi pada pengujian <i>batch size</i> | 50 |
| Pengujian kedua | | | 100 |
| Pengujian ketiga | | | 150 |
| Pengujian keempat | | | 100 |
| Pengujian kelima | | | 250 |

5. Pengujian Validasi

Pengujian ini bertujuan untuk mengetahui apakah sistem bisa mendeteksi jenis beban listrik alat elektronik rumah tangga dengan benar dengan menggunakan partisi data, *learning rate*, *batch size*, dan *epoch* yang memiliki nilai *accuracy*, *precision*, *recall*, dan *F1-score* tertinggi pada pengujian sebelumnya.

TABEL 4.5
PENGUJIAN VALIDASI DATA

| No | Data | Hasil Prediksi | True/False |
|----|----------------------|----------------------|------------|
| 1 | Pemanas Air | Pemanas Air | True |
| 2 | Setrika, Kipas Angin | Setrika, Kipas Angin | True |

| No | Data | Hasil Prediksi | True/False |
|----|-----------------------------------|-----------------------------------|------------|
| 3 | Kipas Angin | Kipas Angin | True |
| 4 | Setrika | Pemanas Air, Kipas Angin | False |
| 5 | Pemanas Air, Kipas Angin | Pemanas Air, Kipas Angin | True |
| 6 | Pemanas Air, Kipas Angin, Setrika | Pemanas Air, Kipas Angin | False |
| 7 | Pemanas Air, Setrika | Pemanas Air, Setrika | True |
| 8 | Kipas Angin | Kipas Angin | True |
| 9 | Setrika, Kipas Angin | Setrika, Kipas Angin | True |
| 10 | Pemanas Air, Kipas Angin, Setrika | Pemanas Air, Kipas Angin, Setrika | True |
| 11 | Pemanas Air, Kipas Angin | Pemanas Air, Kipas Angin | True |
| 12 | Pemanas Air | Pemanas Air | True |
| 13 | Setrika, Kipas Angin | Setrika, Kipas Angin | True |
| 14 | Setrika | Setrika | True |
| 15 | Setrika, Kipas Angin | Setrika, Kipas Angin | True |
| 16 | Kipas Angin | Kipas Angin | True |
| 17 | Pemanas Air, Kipas Angin | Pemanas Air, Kipas Angin | True |
| 18 | Setrika, Kipas Angin | Setrika, Kipas Angin | True |
| 19 | Kipas Angin | Kipas Angin | True |
| 20 | Setrika | Setrika | True |

Berdasarkan tabel diatas, model dapat melakukan deteksi jenis beban listrik alat elektronik rumah tangga sebanyak 20 kali percobaan. Dalam 20 kali percobaan, terdapat 2 data yang terdeteksi salah dan 18 data terdeteksi dengan benar.

B. Pengujian Sistem Partisi Data


Pengujian ini berfungsi untuk mengetahui kerja algoritma *Convolutional Neural Network* dalam mengklasifikasikan data ke dalam kelas yang telah ditentukan. Pada percobaan pengujian ini diberikan data *testing* untung menguji tabel keputusan yang sudah terbentuk. Untuk kerjanya diperoleh dengan memberikan nilai *confusion matrix* dengan menghitung nilai *accuracy*, *precision*, *recall*, dan *F1-score* dari hasil pengujian.

Dari hasil partisi data tersebut didapatkan nilai partisi data dengan tingkat *accuracy*, *precision*, *recall*, dan *F1-score* tertinggi yaitu pada partisi data 70%:30% dengan nilai *accuracy* 97.78%, *precision* 98.28%, *recall* 97.30%, dan *F1-score* 97.73%

TABEL 4. 6
TABEL PENGUJIAN PARTISI DATA

| Data latih : Data uji | Accuracy | Precision | Recall | F1-Score |
|--------------------------|----------|-----------|--------|----------|
| 50% : 50% | 97.47% | 97.93% | 96.87% | 97.34% |
| 60% : 40% | 97.74% | 98.19% | 97.22% | 97.65% |
| 70% : 30% | 97.78% | 98.28% | 97.30% | 97.73% |
| 80% : 20% | 97.65% | 98.18% | 97.15% | 97.59% |
| 90% : 10% | 97.29% | 97.85% | 96.89% | 97.30% |

Dari tabel pengujian kinerja sistem diatas dapat dilihat grafik perbandingannya dibawah ini :



GAMBAR 4.1

DIAGRAM PENGUJIAN PARTISI DATA

C. Pengujian Kinerja Sistem *Learning Rate*


Dari nilai *accuracy*, *precision*, *recall*, dan *F1-score* tertinggi akan diuji kembali dengan menggunakan parameter *learning rate* untuk melihat apakah ada perubahan nilai di *accuracy*, *precision*, *recall*, dan *F1-score*.

Dari pengujian *learning rate* tersebut didapatkan *learning rate* dengan tingkat *accuracy*, *precision*, *recall*, dan *F1-score* tertinggi yaitu pada *learning rate* 0.0001 dengan nilai *accuracy* 97.59%, *precision* 98.59%, *recall* 97.13%, dan *F1-score* 97.59%.

Tabel 4.7 Tabel Pengujian Learning Rate

| Learning Rate | Accuracy | Precision | Recall | F1-Score |
|---------------|----------|-----------|--------|----------|
| 0.0001 | 97.59% | 98.59% | 97.13% | 97.59% |
| 0.001 | 96.69% | 97.58% | 96.34% | 96.34% |
| 0.01 | 97.47% | 98.07% | 97.00% | 97.47% |
| 0.1 | 78.77% | 77.30% | 82.64% | 78.44% |
| 1 | 90.49% | 91.64% | 91.30% | 90.49% |

Dari tabel pengujian kinerja sistem diatas dapat dilihat grafik perbandingannya dibawah ini :



GAMBAR 4.2
DIAGRAM PENGUJIAN LEARNING RATE

D. Pengujian Kinerja Sistem Batch Size


Dari nilai *accuracy*, *precision*, *recall*, dan *F1-score* tertinggi akan diuji kembali dengan menggunakan parameter *batch size* untuk melihat apakah ada perubahan nilai di *accuracy*, *precision*, *recall*, dan *F1-score*.

Dari pengujian *batch size* tersebut didapatkan *batch size* dengan tingkat *accuracy*, *precision*, *recall*, dan *F1-score* tertinggi yaitu pada *batch size* 64 dengan nilai *accuracy* 97.89%, *precision* 98.38%, *recall* 97.38%, dan *F1-score* 97.82%.

TABEL 4.8
TABEL PENGUJIAN BATCH SIZE

| Batch Size | Accuracy | Precision | Recall | F1-Score |
|------------|----------|-----------|--------|----------|
| 8 | 97.83% | 98.29% | 97.30% | 97.74% |
| 16 | 97.65% | 98.13% | 97.12% | 97.57% |
| 32 | 97.77% | 98.22% | 97.22% | 97.66% |
| 64 | 97.89% | 98.38% | 97.38% | 97.82% |
| 128 | 97.65% | 98.06% | 97.08% | 97.50% |

Dari tabel pengujian kinerja sistem diatas dapat dilihat grafik perbandingannya dibawah ini :



GAMBAR 4.3 DIAGRAM PENGUJIAN BATCH SIZE

E. Pengujian Kinerja Epoch


Dari nilai *accuracy*, *precision*, *recall*, dan *F1-score* tertinggi akan diuji kembali dengan menggunakan parameter *epoch* untuk melihat apakah ada perubahan nilai di *accuracy*, *precision*, *recall*, dan *F1-score*.

Dari pengujian *epoch* tersebut didapatkan *epoch* dengan tingkat *accuracy*, *precision*, *recall*, dan *F1-score* tertinggi yaitu pada *epoch* 200 dengan nilai *accuracy* 97.83%, *precision* 98.29%, *recall* 97.30%, dan *F1-score* 97.74%.

TABEL 4.9
TABEL PENGUJIAN EPOCH

| Epoch | Accuracy | Precision | Recall | F1-Score |
|-------|----------|-----------|--------|----------|
| 50 | 69.39% | 70.45% | 70.18% | 61.15% |
| 100 | 95.24% | 95.84% | 94.91% | 95.25% |
| 150 | 97.77% | 98.25% | 97.25% | 97.69% |
| 200 | 97.83% | 98.29% | 97.30% | 97.74% |
| 250 | 97.77% | 98.22% | 97.22% | 97.66% |

Dari tabel pengujian kinerja sistem diatas dapat dilihat grafik perbandingannya dibawah ini :



GAMBAR 4.4
DIAGRAM PENGUJIAN EPOCH

V. KESIMPULAN DAN SARAN

A. Kesimpulan

Berdasarkan hasil dari Tugas Akhir ini, dapat ditarik beberapa kesimpulan yaitu:

1. Proses identifikasi beban listrik rumah tangga di tugas akhir ini memiliki tujuh kelas (pemanas air, setrika, kipas angin, setrika kipas, setrika pemanas air, pemanas air kipas, dan setrika pemanas air kipas) menggunakan algoritma *Convolutional neural Network*.
2. Pada tahap pengujian ini mendapatkan nilai akurasi sebesar 97.83%, presisi sebesar 98.29%, *recall* sebesar 97.30%, dan *F1 Score* 97.73% dengan menggunakan partisi data 70%:30%, *learning rate* 0.0001, *batch size* 64, *epoch* 200.

REFERENSI

- [1] K. He, L. StanKovic, J. Liao and V. Stankovic, "Non-Instructive Load

- Disaggregation Using Graph Signal Processing," *IEEE Trans*, Vols. 1739-1747, p. 9, 2018.
- [2] Q. Fitriyah and I. D, "Prediksi Beban Listrik Pulau bali Dengan Menggunakan Metode Backpropogasi," p. 1, 2012.
- [3] Y. Liu, Y. Wang and W. You, "Non-Intrusive Load Monitoring by Voltage-Current Trajectory Enabled Transfer Learning," *IEEE Trans*, Vols. 5609-5619, p. 10, 2018.
- [4] "Jual Teko Mug Elektrik Fleco 13 Cm Teko Listrik Pemanas Air Listrik Gelas," Blibli, [Online]. Available: <https://www.blibli.com/p/teko-mug-elektrik-fleco-13-cm-teko-listrik-pemanas-air-listrik-gelas/ps--TOE-70261-09109>.
- [5] MEREKBAGUS, "15 Merk Setrika Yang Bagus, Hemat Listrik Dan Tahan Lama," [Online]. Available: <https://merekbagus.com/merk-setrika-bagus/>.
- [6] D. Andriandi, "Pengertian Kipas Angin Dan Cara Memperbaikinya," [Online]. Available: <https://www.scribd.com/doc/215894282/Pengertian-Kipas-Angin-Dan-Cara-Memperbaikinya>.
- [7] M. Arief, "Pengertian Listrik 1 Phase dan 3 Phase," 12 Oktober 2018. [Online]. Available: <https://primatekniksystem.com/artikel/pengertian-listrik-1-phase-dan-3-phase#:~:text=Listrik%201%20Phase%20adalah%20jaringan,volt%20yang%20digunakan%20banyak%20orang.>
- [8] T. A. Imani, "Perancangan Power Monitoring Gedung Berbasis IoT (Internet Of Things)," *Universitas Telkom, Bandung*, vol. 4, 2019.
- [9] B. Maulana, Rancang Bangun Aplikasi Android Sistem Monitoring Daya Listrik 3 Fasa Berbasis Power Meter Untuk Pengukuran Pada Tipe Gedung Praktikum, Universitas Telkom, 2020.
- [10] Y. Badruzzaman, "Real Time Monitoring Data Besaran Listrik Gedung Laboratorium Teknik Sipil Politeknik Negeri Semarang," *Jurnal Jtet*, vol. 1, no. 2, pp. 50-59, 2012.
- [11] A. A., PENINGKATAN FAKTOR DAYA PADA LAMPU SWABALAST UNTUK MENGURANGI ENERGI DAN EMISI CO2 PADA SEKTOR RUMAH TANGGA DI INDONESIA, Universitas Indonesia, 2012.
- [12] GAE, "GAE EMG 25 Digital Energy Power Meter," [Online]. Available: <https://www.gae.id/detail/gae-emg-25-digital-energy-power-meter-613>.
- [13] E. Alajrami, "Handwritten Signature Verification using Deep Learning," *International Journal of Academic Multidisciplinary Research (IJAMR)*, vol. 3, no. 12, pp. 39-44, 2020.
- [14] R. A. Barro, I. D. Sulvianti and F. M. Afendi, "PENERAPAN SYNTHETIC MINORITY OVERSAMPLING TECHNIQUE (SMOTE) TERHADAP DATA TIDAK SEIMBANG PADA PEMBUATAN MODEL KOMPOSISI JAMU," *Xplore*, vol. 1(1), p. 1, 2013.
- [15] K. Fukushima, "Neocognitron: A Self-organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position," *Biol. Cybernetics*, vol. 36, no. 193-202, 1980.
- [16] Y. LeCun, "Handwritten Digit Recognition with a Back-Propagation Network," 1990.
- [17] N. F. Nissa, "Aplication of Deep Learning Using Concolutional Neural Network (CNN) Method for Women's Skin Classification," *Scientific Journal of Informatics*, vol. 8, no. 1, p. 2, 2021.
- [18] R. Yamashita, M. Nishio, R. K. G. Do and K. Togashi, "Convolutional neural networks: an overview and application in radiology," *SpringerOpen*, vol. 9, no. 611-6629, p. 2, 2018.
- [19] K. O'Shea, "An Introduction to Convolutional Neural Networks," Cornell University, 2015.
- [20] Q. Zhao, Q. Mao and Z. Zhao, Nov 2018. [Online]. Available: https://www.researchgate.net/figure/The-architecture-of-our-1D-CNN-model-This-model-consists-of-two-convolutional-layers_fig2_329201018.

- [21] S. Kiranyaz, O. Avci, O. Abdeljaber, T. Ince, M. Gabbouj and D. J.Inman, "1D convolutional neural networks and applications: A survey," *Science Direct*, vol. 151, pp. 1-20, 2021.
- [22] E. L., I. T. and K. S., "A generic intelligent bearing fault diagnosis system using compact adaptive 1d cnn classifier," *J. Signal Process. Syst*, vol. 91, no. 2, pp. 179-189, 2019.
- [23] C. Chen, Z. Hua, R. Zhang, G. Liu and W. Wen, "Automated arrhythmia classification based on a combination network of CNN and LSTM," *Biomedical Signal Processing and Control*, vol. 57, 2019.
- [24] K. K. Patro, A. J. Prakash, M. J. Rao and P. R. Kumar, "An Efficient Optimized Feature Selection with Machine Learning Approach for ECG Biometric Recognition," *IETE Journal of Research*, 2020.
- [25] P. G. E. D. -. GAE, "USER MANUAL EMG25 - EMG 20B ENERGI ANALISIS," [Online]. Available: <https://www.gae.id/ged>.
- [26] Y. I. T. Y., "Implementasi Pengendali On / Off Peralatan Listrik Rumah / gedung Terpusat Berbasis Raspberry Pi Menggunakan Python dan Tkinter," *J. Comput. Sci. Coll*, vol. 13, no. 2, p. 35, 2017.
- [27] EtechnoG, "Resistive Load Examples, Properties, Power Consumption,," 2018. [Online]. Available: <https://www.etechnog.com/2021/02/resistive-load-example-application.html>.
- [28] J. Gaurav, "Types of Electrical Load | Resistive, Inductive & Capacitive Load," 30 Agustus 2022. [Online]. Available: theelectricalguy.in/tutorials/types-of-electrical-load-resistive-inductive-capacitive-load/.
- [29] A. Rahmad, "Explanations about Resistive, Inductive and Capacitive Loads," 11 Februari 2020. [Online]. Available: diary-of-electrical.blogspot.com/2020/02/explanations-about-resistive-inductive-and-capacitive-loads.html.