

PAPER NAME

**1295-4292-1-RV.docx**

AUTHOR

**Sunneng Sandino Berutu**

WORD COUNT

**3351 Words**

CHARACTER COUNT

**21443 Characters**

PAGE COUNT

**7 Pages**

FILE SIZE

**792.2KB**

SUBMISSION DATE

**Jul 13, 2022 9:52 PM GMT+7**

REPORT DATE

**Jul 13, 2022 9:53 PM GMT+7**

### ● 23% Overall Similarity

The combined total of all matches, including overlapping sources, for each database.

- 23% Internet database
- 19% Publications database
- Crossref database
- Crossref Posted Content database
- 17% Submitted Works database

### ● Excluded from Similarity Report

- Manually excluded sources

# Uji Kinerja Metode Deep Convolutional Neural Networks untuk Identifikasi Gangguan Daya Listrik

**Sunneng Sandino Berutu<sup>1\*</sup>**

<sup>1</sup>Program Studi Informatika, Universitas Kristen Immanuel Yogyakarta

<sup>1</sup>Jln. Solo km 11,1 Sleman, Yogyakarta Indonesia

**E-mail: sandinoberutu@ukrimuniversity.ac.id**

---

## Abstrak

---

### Info Naskah:

Naskah masuk:

Direvisi:

Diterima:

Model berbasis deep convolutional neural networks (CNNs) untuk identifikasi sinyal gangguan listrik membutuhkan data yang cukup besar, tetapi data riil sangat sulit diperoleh sehingga banyak peneliti menggunakan data buatan. Data buatan diproduksi menggunakan persamaan-persamaan berstandar IEEE. Dalam persamaan tersebut, sinyal gangguan jenis interruption dan sag memiliki rumus yang sama tetapi nilai parameter intensitas ( $\alpha$ ) berbeda. Dalam artikel ini, penulis menganalisis kinerja model untuk identifikasi ke dua jenis gangguan tersebut dengan mengatur nilai interval  $\alpha$  untuk memproduksi dataset. Pada data sinyal disertakan beberapa level noise untuk menciptakan sinyal seperti data riil sehingga terdapat beberapa dataset bernoise dalam simulasi. Selanjutnya, dataset-dataset tersebut dilatih dengan model deep CNNs. Hasil simulasi menunjukkan bahwa model memiliki kemampuan mendeteksi gangguan jenis interruption lebih banyak dibanding gangguan jenis interruption. Selain itu, hasil kinerja model dengan dataset tanpa noise lebih baik dibanding model yang menggunakan dataset bernoise.

---

## Abstract

---

### Keywords:

Power;

Disturbance;

Signal;

Convolutional neural networks;

The identification model development of the power disturbance signals with the deep convolutional neural networks (CNNs) method requires a large amount of data. However, the real signal data is limited. Therefore, researchers employ the synthetic signals data. These signals can be generated by the formula IEEE standardized. In these formulas, two categories have a similar formula i.e interruption and sag. The difference is only in the intensity parameter. This paper analyzed the model performance of identification those disturbances where the intensity values are set different for training and testing dataset. Several noise levels are included into the signals. So, there are several datasets with noises in this simulation. Furthermore, those datasets are trained using the model based on deep CNN. The simulation results show that the models are better in the interruption type disturbance identification than the sag type. In addition, the performance of model using dataset without noise obtained the high percentage in accuracy, precision, f1-score parameters.

---

**\*Penulis korespondensi:**

**Sunneng Sandino Berutu**

E-mail: sandinoberutu@ukrimuniversity.ac.id

## 1. Pendahuluan

Kualitas daya listrik merupakan salah faktor penting dalam penggunaan peralatan elektronik. Saat terjadi gangguan pada kualitas daya di jaringan listrik maka hal itu dapat menimbulkan dampak negatif pada perangkat listrik seperti kerusakan, penurunan kualitas dan masa pemakaian, biaya untuk perbaikan dan penggantian. Menurut standar IEEE [1], jenis - jenis gangguan kualitas daya tersebut adalah seperti *sag*, *swell*, *interruption*, *harmonic*, *transient*, *flicker*, *transient*, dan *notch*. Gangguan kualitas daya dapat disebabkan oleh pemakaian beberapa sumber energi yang berbeda, beban pemakaian listrik yang berlebihan [2], faktor alam dan sebagainya. Untuk mengurangi dan mencegah terjadinya dampak-dampak negatif tersebut, sebuah sistem identifikasi gangguan kualitas daya listrik perlu dikembangkan.

Beberapa tahun terakhir, penelitian terkait identifikasi gangguan kualitas daya sudah mengadopsi teknologi berbasis *deep training*. Teknologi ini bekerja dengan cara mempelajari fitur-fitur data. Beberapa arsitektur metode deep learning yang sudah diimplementasikan pada domain klasifikasi atau identifikasi gangguan kualitas daya listrik seperti *convolution neural network* (CNN), *recurrent neural network* (RNN), *identity-recurrent neural network* (I-RNN), *long short-term memory* (LSTM), *gated recurrent units* (GRU) dan *convolutional neural network-long short-term memory* (CNN-LSTM) [3]. Selanjutnya, *multi layer perceptron* (MLP) dan CNN dikombinasikan dengan metode *wavelet transform* (WT) [4-5]. Selain itu, penulis dalam referensi [6] menggunakan Hilbert Huang transform dan MLP. Peneliti dalam referensi [7] mengusulkan arsitektur deep CNN sebagai pengembangan dari arsitektur CNN. Penulis [8] mengabungkan metode principal component analysis (PCA) dengan metode CNN. Berdasarkan hasil eksperimen penelitian sebelumnya, CNN merupakan metode paling populer untuk identifikasi gangguan kualitas daya [2] karena memiliki kemampuan untuk mempelajari fitur-fitur yang kompleks [9].

Peneliti sebelumnya [2,3,5,7-17] menggunakan data sinyal buatan karena terbatasnya jumlah data aktual yang tersedia untuk proses pelatihan model. Data sinyal buatan diproduksi dengan menggunakan rumus matematika [10] sesuai standar IEEE [1]. Dalam persamaan tersebut gangguan kategori *Sag* dan *Interruption* memiliki rumus yang sama tetapi berbeda pada nilai parameter intensitasnya ( $\alpha$ ) di mana nilai maksimal  $\alpha$  pada jenis *Sag* sama dengan nilai minimal  $\alpha$  pada jenis *Interruption*. Berdasarkan artikel-artikel yang ada, para peneliti belum membahas secara khusus kemampuan metode *deep CNN* dalam mengidentifikasi ke dua gangguan tersebut ketika nilai intensitasnya mirip atau berdekatan. Oleh karena itu, penulis melakukan simulasi untuk mengukur kinerja metode *deep CNN*

pada identifikasi kualitas gangguan daya jenis *Sag* dan *Interruption*. Dalam simulasi ini, nilai intensitas ke dua gangguan tersebut ditentukan berbeda untuk memproduksi data *training* dan data *testing*.

## 2. Tinjauan Pustaka

Dalam penelitian ini, penulis hanya menggunakan dua jenis gangguan kualitas daya, yaitu *Sag* dan *interruption*. Persamaan kedua gangguan ini mengacu kepada penelitian yang sudah dilakukan sebelumnya [2,3,5,7,9,11-13] untuk memproduksi sinyal gangguan buatan.

*Sag* merupakan gangguan kualitas daya listrik karena terjadinya penyimpangan ( $\alpha$ ) besaran tegangan atau arus antara 0,1 dan 0,9 pu pada frekuensi daya untuk rentang waktu dari T hingga 9T detik [18]. Rumus untuk memproduksi sinyal gangguan kategori *Sag* ditunjukkan berikut ini.

$$y(t) = A[1 - \alpha(u(t - t_1) - u(t - t_2))] \sin(\omega t) \quad (1)$$

$$\omega = 2\pi f \quad (2)$$

Dengan nilai frekuensi dasar ( $f$ ) adalah 50 Hz. Nilai  $t_1$  dan  $t_2$  ditentukan dari

$$T \leq t_2 - t_1 \leq 9T \quad (3)$$


$$T = \frac{1}{f} \quad (4)$$

$T$  merupakan periode gelombang.

Nilai intensitas ( $\alpha$ ) diperoleh dari interval berikut,

$$0,1 \leq \alpha \leq 0,9 \quad (5)$$

Salah satu contoh sinyal *Sag* yang dihasilkan menggunakan Persamaan (1) ditampilkan dalam Gambar 1 berikut, di mana nilai  $\alpha$  pada Persamaan (5) ditentukan secara acak.



Gambar 1. Sinyal gangguan kualitas daya jenis *Sag*

*Interruption* didefinisikan sebagai deviasi besaran ( $\alpha$ ) tegangan atau arus antara 0,9 dan 1 pu pada frekuensi daya untuk rentang waktu dari T hingga 9T detik [18]. Persamaan untuk


memproduksi jenis gangguan ini dinyatakan dalam rumus berikut.

$$y(t) = A[1 - \alpha(u(t - t_1) - u(t - t_2))] \sin(\omega t) \quad (6)$$

Nilai  $\omega$  diperoleh menggunakan Persamaan (2) dan nilai  $t_1$  dan  $t_2$  menggunakan Persamaan (3). Sementara itu, besaran nilai  $\alpha$  diperoleh berdasarkan interval berikut.

$$0,9 \leq \alpha \leq 1 \quad (7)$$

Sinyal *Interruption* yang diproduksi menggunakan Persamaan (6) dengan nilai intensitas ditentukan secara acak pada Persamaan (7) ditampilkan pada Gambar 2.



Gambar 2. Sinyal gangguan kualitas daya jenis *Interruption*.

Persamaan (1) dan (6) untuk memproduksi sinyal buatan sag dan interruption adalah sama tetapi berbeda pada persamaan (5) dan (7).

Metode *confusion matrix* [13] dipergunakan untuk mengevaluasi kinerja hasil pengujian model. Metode ini memiliki empat komponen utama [19] yaitu *true positive* (TP), *true negative* (TN), *false positive* (FP), dan *false negative* (FN). Keempat komponen tersebut digunakan untuk menghasilkan parameter [20] seperti *accuracy*(acc), *precision*(prec), *recall*(rec), dan *f1-score*(f1). Rumus untuk menghasilkan parameter-parameter tersebut disajikan dalam Persamaan (8-11).

### 3. Metode

Untuk menganalisis kemampuan metode deep CNN dalam mengidentifikasi gangguan jenis *sag* dan *interruption* pada kualitas daya listrik, pertama dataset *training* dan dataset *testing* diproduksi berdasarkan rumus matematika pada Persamaan (1) dan (6) di atas. Selanjutnya, arsitektur model identifikasi berbasis metode deep CNN dirancang. Terakhir, hasil pengujian model dianalisis menggunakan metode *confusion matrix*.

### 3.1 Data Sinyal Buatan

Data sinyal buatan *Sag* dan *Interruption* diproduksi menggunakan rumus yang terdapat dalam tabel 1. Nilai interval parameter intensitas ( $\alpha$ ) untuk data *training* dan *testing* ditentukan seperti dalam Tabel 1 berikut ini.

Tabel 1. Penentuan Nilai Interval Parameter  $\alpha$  pada Data *Training* dan *Testing*

Kategori	Data Training	Data Testing
<i>Sag</i>	$0,1 \leq \alpha \leq 0,85$	$0,85 \leq \alpha \leq 0,9$
<i>Interruption</i>	$0,95 \leq \alpha \leq 1$	$0,9 \leq \alpha \leq 0,95$

Untuk memproduksi sinyal gangguan, besaran frekuensi dasar ditentukan sebesar 50 hertz dan frekuensi *sampling* adalah 1600. Sementara jumlah siklus ditentukan sebanyak 11. Untuk setiap sinyal disertakan empat jenis *noise* dengan ukuran 10 db, 20 db, 30 db dan 40 db.

### 3.2 Dataset

Jumlah data *training* masing-masing gangguan diproduksi sebanyak 10.000 sinyal sedangkan untuk data *testing* sebanyak 1.000 sinyal. Dataset *training* dibagi lagi menjadi 2 bagian di mana 80 persen untuk *training* dan sisanya untuk *validation* seperti yang disajikan dalam Tabel 2 berikut.

Tabel 2. Pembagian Data

Jenis Gangguan	Dataset		Dataset Testing
	Training	Validation	
<i>Sag</i>	8.000	2.000	1.000
<i>Interruption</i>	8.000	2.000	1.000

Selanjutnya *noise* diaplikasikan pada sinyal dengan ukuran 10 db, 20 db, 30 db dan 40 db sehingga dalam simulasi terdapat lima jenis dataset seperti yang dideskripsikan pada Tabel 3 dan Tabel 4 berikut.

Tabel 3. Daftar Dataset Training

Nama Dataset	Keterangan
DL-0db	Dataset training tanpa noise
DL-10db	Dataset training noise 10 db
DL-20db	Dataset training noise 20 db
DL-30db	Dataset training noise 30 db
DL-40db	Dataset training noise 40 db

$$acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (8)$$

$$prec = \frac{TP}{TP + FN} \quad (9)$$

$$rec = \frac{TP}{TP + FP} \quad (10)$$

$$f1 = \frac{(2 * prec * rec)}{(prec + rec)} \quad (11)$$


Dataset pada Tabel 3 akan digunakan pada pelatihan model, sedangkan dataset dalam Tabel 4 akan diimplementasikan pada pengujian model.

Tabel 4. Daftar *Dataset Testing*

Nama Dataset	Keterangan
DT-0db	Dataset testing tanpa noise
DT-10db	Dataset testing noise 10 db
DT-20db	Dataset testing noise 20 db
DT-30db	Dataset testing noise 30 db
DT-40db	Dataset testing noise 40 db

### 3.3 Rancangan Arsitektur Model

Arsitektur model berbasis deep CNN untuk mengidentifikasi kualitas daya listrik ditampilkan pada Gambar 3, sementara lapisan - lapisan yang dipergunakan pada model deep CNN disajikan dalam Tabel 5.



Gambar 3. Arsitektur model deep CNN

Tabel 5. Daftar Lapisan dalam Model

Lapisan	Deep CNN satu dimensi
Convolution1	Conv1D (64,4), aktivasi = rectified linier unit (ReLU)
Convolution2	Conv1D (64,4), aktivasi =ReLU
Pooling1	Maxpooling1D (2)
Drop out1	Dropout (0,2)
Convolution3	Conv1D (32,4), aktivasi =ReLU
Convolution4	Conv1D (32,4), aktivasi =ReLU
Pooling2	Maxpooling1D (2)
Drop out2	Dropout (0,2)
Dense1	Units = 128, aktivasi =ReLU
Dense2	Units = 2, aktivasi = softmax

Arsitektur model ini akan dipergunakan untuk semua dataset yang ada di Tabel 3 di atas, sehingga dalam simulasi terdapat 5 model yang akan dilatih seperti yang disajikan dalam Tabel 6 berikut.

Tabel 6. Nama Model dengan Dataset

Nama Model	Dataset Training	Dataset Testing
Model-0db	DL-0db	DT-0db
Model-10db	DL-10db	DT-10db
Model-20db	DL-20db	DT-20db
Model-30db	DL-30db	DT-30db
Model-40db	DL-40db	DT-40db

## 4. Hasil dan Pembahasan

Pada tahap pembelajaran, proses kompilasi menggunakan algoritma Adam untuk optimisasi dengan besaran *training rate* 0,001. Sementara itu, *categorical-cross-entropy* diadopsi pada *loss*

*function* sedangkan ukuran *batch shape* ditentukan sebesar 32. Untuk proses *fitting* model, jumlah *epoch* tiap model ditentukan sebanyak 100 putaran. Untuk proses pembelajaran model, *Google Collaboratory* diadopsi karena menyediakan kecepatan GPU yang cukup tinggi.

### 4.1 Tahap Pelatihan Model

Pembelajaran model deep CNN dilakukan dengan menggunakan dataset yang disajikan dalam Tabel 3. Dalam simulasi, setiap model dilatih berulang kali hingga kondisi *fitting* model terpenuhi. Kesesuaian model diperoleh melalui pengukuran nilai akurasi hasil *training* dan *validation* model dari keseluruhan *epoch* yang dilakukan. Setelah model memenuhi kesesuaian maka nilai akurasi rata-rata hasil *training* dan *validation* setiap model dihitung. Hasil perhitungan tersebut disajikan dalam Tabel 7 berikut.

Tabel 7 Hasil Pengukuran Akurasi pada Tahap Training


Nama Model	Nilai akurasi (%)	
	Training	Validation
Model-0db	99,99	99,99
Model-10db	99,25	99,49
Model-20db	99,93	99,96
Model-30db	99,95	99,97
Model-40db	99,93	99,98

Dari Tabel 7, model yang dilatih menggunakan data tanpa noise memperoleh nilai akurasi training dan validation lebih tinggi dibandingkan dengan model lainnya. Sementara itu, model dengan data noise 10 db memiliki nilai akurasi training dan validation paling rendah.

### 4.2 Tahap Pengujian Model


Pengujian dilakukan untuk mengukur kinerja model dalam identifikasi ke dua jenis gangguan kualitas daya. Dalam proses pengujian, *Dataset testing* dalam Tabel 5 diinput ke dalam model-model yang telah melakukan pembelajaran sesuai dengan Tabel 8. Jumlah data yang diuji sebanyak 2000 sinyal yang terdiri dari 1000 sinyal jenis gangguan *Sag* dan 1000 sinyal jenis gangguan *interruption*. Selanjutnya, hasil pengujian model-mode tersebut ditampilkan ke dalam *confusion matrix*.

*Confusion matrix* pada Gambar 4 dibawah ini menunjukkan bahwa model-0db memprediksi sebanyak 1100 data jenis *interruption* dimana sebanyak 974 data merupakan *interruption* sedangkan sisanya merupakan *sag*. Sementara itu, jenis *sag* diprediksi sebanyak 900 data dimana sebanyak 874 merupakan jenis *sag* dan lainnya sebagai *interruption*. Dalam hal ini, model-0db mengidentifikasi lebih banyak data *interruption* dibandingkan dengan data *sag*.



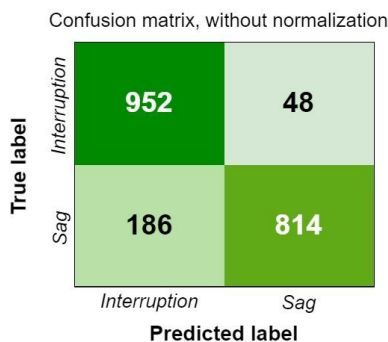
Gambar 4. Hasil pengujian dalam *confusion matrix* pada model-0db.

Pada *confusion matrix* model-10db dengan data *noise* 10db seperti yang ditampilkan dalam Gambar 5 berikut, model ini mengidentifikasi sebanyak 1348 data pada kategori *interruption*, sedangkan sebanyak 652 data sebagai kategori *sag* atau. Dalam hal ini, model mendeteksi sebanyak 67 persen sebagai data *interruption*. Dengan demikian model memiliki kemampuan lebih baik memprediksi data tipe gangguan *interruption* dibandingkan tipe *sag*.




Gambar 5. Hasil pengujian dalam *confusion matrix* pada model-10db.

Tampilan *confusion matrix* model-20db pada Gambar 6 dibawah ini menunjukkan bahwa model memprediksi 1138 sinyal jenis *interruption* dan 862 sinyal sebagai jenis *sag*. Model ini mengidentifikasi jumlah data tipe *interruption* lebih besar dibandingkan dengan tipe *sag*. Oleh karena itu, model ini memiliki kemampuan lebih baik dalam mendeteksi sinyal jenis *interruption* dibandingkan dengan sinyal jenis *sag*.




Gambar 6. Hasil pengujian dalam *confusion matrix* pada model-20db

Hasil pengujian model-30db dalam *confusion matrix* pada Gambar 7 berikut menunjukkan bahwa model mendeteksi jumlah data kategori *interruption* sebanyak 972 data sedangkan data kategori *sag* sebanyak 1028 data. Kinerja model ini lebih baik dalam mendeteksi jenis gangguan *sag* dibandingkan dengan jenis *interruption*.



Gambar 7. Hasil pengujian dalam *confusion matrix* pada model-30db

*Confusion matrix* model-40db dalam Gambar 8 di bawah ini menunjukkan bahwa model mengidentifikasi sebanyak 1280 sinyal gangguan jenis *interruption* dan sebanyak 820 jenis *sag*. Dengan demikian, kinerja model mendeteksi lebih banyak sinyal gangguan kategori *interruption* disbanding dengan *sag*.



Gambar 8. Hasil pengujian dalam *confusion matrix* pada model-40db.

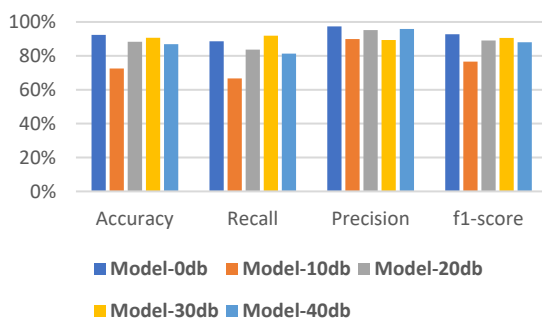
Berdasarkan analisis hasil pengujian menggunakan 5 model dengan dataset yang berbeda maka sebanyak 4 model seperti model-0db, model-10db, model 20db, dan model-40db memiliki kemampuan lebih baik mengidentifikasi gangguan jenis *interruption*. Sementara itu, model-30db lebih baik memprediksi gangguan jenis *sag*. Dengan demikian, fitur gangguan jenis *interruption* lebih mudah diidentifikasi oleh model dibandingkan dengan jenis *sag*.

Selanjutnya pengukuran kinerja model menggunakan parameter seperti *accuracy*, *recall*, *precision* dan *f1-score* diperoleh berdasarkan angka-angka yang ada dalam *confusion matrix* setiap

model. Hasil perhitungan parameter masing-masing model disajikan dalam Tabel 8 dan Gambar 9 berikut ini.

Tabel 8 Perbandingan Kinerja Pengujian Model Deep CNN

Model	Accuracy (%)	Recall (%)	Precision (%)	f1-score (%)
Model-0db	92,4	88,54	97,4	92,76
Model-10db	72,5	66,69	89,9	76,57
Model-20db	88,3	83,65	95,2	89,05
Model-30db	90,7	91,87	89,3	90,56
Model-40db	86,9	81,27	95,9	87,98



Gambar 9. Grafik perbandingan kinerja model CNN

Pada Tabel 8, Kinerja model-0db memperoleh akurasi lebih tinggi mencapai 92,4 persen sedangkan model-10db memiliki kinerja akurasi paling rendah nilai 72,5 persen. Kemudian, untuk parameter *recall*, model-30db memiliki sensitivitas lebih tinggi dengan nilai 91,87 dibandingkan dengan model yang lain. Sementara itu, model-10db memperoleh sensitivitas terendah dengan nilai 66,69 persen. Selanjutnya, untuk parameter *precision*, model-0db memiliki kinerja lebih baik dengan perolehan 97,4 persen. Disisi lain, model-30db memperoleh nilai terendah dengan nilai 89,3 persen. Terakhir, nilai *f1-score* model-0db melampaui perolehan model yang lain yaitu 92,76 persen sedangkan nilai terendah diperoleh model-10db dengan nilai 76,57 persen.

Grafik bar pada Gambar 9 menunjukkan bahwa model-0db mengungguli model yang lain pada nilai parameter *accuracy*, *precision* dan *f1-score*. Sementara itu, model-30db memperoleh nilai parameter *recall* lebih tinggi dibandingkan dengan model-model yang lain. Disisi lain, model-10db memperoleh nilai terendah pada parameter *accuracy*, *recall* dan *f1-score*.

Berdasarkan Tabel 1 yang mengatur nilai variabel  $\alpha$  untuk memproduksi sinyal gangguan buatan jenis *interruption* dan *sag* dimana data *testing*

jenis *interruption* dan *sag* diperoleh menggunakan aturan nilai tepi atas interval *sag* sama dengan nilai tepi bawah interval *interruption* maka dari hasil pengujian model menunjukkan bahwa fitur-fitur gangguan jenis *interruption* lebih mudah dideteksi oleh model. Hal tersebut dibuktikan melalui kinerja beberapa model yang memprediksi jenis *interruption* lebih baik dari *sag*.

## 5. Kesimpulan

Penelitian ini menguji kinerja model berbasis deep CNN untuk identifikasi sinyal gangguan listrik. Dalam simulasi, model menggunakan data sinyal buatan yang diproduksi menggunakan rumus-rumus berstandar IEEE. Dua jenis sinyal gangguan yaitu *interruption* dan *sag* menjadi perhatian dalam penelitian ini karena rumus untuk memproduksi sinyal buatan sama, di mana perbedaan hanya terletak pada nilai intensitas saja. Untuk menguji kemampuan model pada identifikasi ke dua gangguan tersebut maka dilakukan pengaturan nilai intensitas untuk memproduksi *dataset training* dan *testing*. Setiap sinyal diberikan beberapa tingkat *noise* yang berbeda sehingga terdapat 5 jenis dataset dalam simulasi ini. Selanjutnya, model dilatih menggunakan ke lima dataset tersebut diatas. Hasil pengujian menunjukkan bahwa model lebih baik dalam mengidentifikasi sinyal gangguan jenis *interruption* dibandingkan dengan *sag*. Selain itu, kinerja model dengan data sinyal tanpa noise memiliki nilai *accuracy*, *precision*, dan *f1-score* lebih baik dibanding dengan model yang menggunakan data sinyal bernoise.

Dalam penelitian ini, penulis hanya menggunakan satu variasi dataset terkait dengan komposisi nilai interval intensitas. Untuk penelitian lebih lanjut, variasi nilai interval parameter intensitas akan didefinisikan lebih banyak lagi untuk memproduksi beberapa dataset sehingga analisis kinerja model berbasis deep CNN untuk identifikasi sinyal ke dua jenis gangguan ini menjadi lebih komprehensif. Selain itu, nilai ideal interval intensitas dapat diperoleh untuk menjadi acuan pada penelitian-penelitian selanjutnya.

## Daftar Pustaka

- [1] IEEE 1159. IEEE Recommended Practice for Monitoring Electric Power Quality 2009:c1-81.
- [2] A. Sindi, M. Nour, M. Rawa, Ş. Öztürk, dan K. Polat, "A novel hybrid deep training approach including combination of 1D power signals and 2D signal images for power quality disturbance classification," *Expert Systems with Applications*, vol. 174, 2021.
- [3] N. Mohan, K. P. Soman, dan R. Vinayakumar, "Deep power: Deep training architectures for power quality disturbances classification," in *2017 International Conference on Technological Advancements in Power and Energy (TAP Energy)*,

- Kollam, 2017, pp. 1-6, doi: 10.1109/TAPENERGY.2017.8397249.
- [4] S. B. Mohod and V. N. Ghate, "MLP-neural network based detection and classification of Power Quality Disturbances," in *2015 International Conference on Energy Systems and Applications, Pune*, 2015, pp. 124-129, doi: 10.1109/ICESA.2015.7503325.
- [5] S. S. Berutu and Y. C. Chen, "Power Quality Disturbances Classification Based on Wavelet Compression and Deep Convolutional Neural Network," in *2020 International Symposium on Computer, Consumer and Control (IS3C)*, Taichung City, Taiwan, 2020, pp. 327-330, doi: 10.1109/IS3C50286.2020.00091.
- [6] M. A. Rodriguez, J. F. Sotomonte, J. Cifuentes, and M. Bueno-López, "Classification of Power Quality Disturbances using Hilbert Huang Transform and a Multilayer Perceptron Neural Network Model," in *2019 International Conference on Smart Energy Systems and Technologies (SEST)*, Porto, Portugal, 2019, pp. 1-6, doi: 10.1109/SEST.2019.8849114.
- [7] S. Wang and Y. C. Chen, "A novel deep training method for the classification of power quality disturbances using deep convolutional neural network," *Applied Energy*, vol. 235, pp. 1126–1140, 2019.
- [8] Y. Shen, M. Abubakar, H. Liu, and F. Hussain, "Power Quality Disturbance Monitoring and Classification Based on Improved PCA and Convolution Neural Network for Wind-Grid Distribution Systems," *Energies*, vol. 12, no. 7, p. 1280, 2019.
- [9] H. Liu, F. Hussain, Y. Shen, S. Arif, A. Nazir, and M. Abubakar, "Complex power quality disturbances classification via curvelet transform and deep training," *Electric Power Systems Research*, vol.163, pp. 1-9, 2018, <https://doi.org/10.1016/j.epsr.2018.05.018>.
- [10] K. Igual, C. Medrano, F. J. Arcega and G. Mantescu, "Integral mathematical model of power quality disturbances," in *2018 18th International Conference on Harmonics and Quality of Power (ICHQP)*, Ljubljana, 2018, pp. 1-6, doi: 10.1109/ICHQP.2018.8378902.
- [11] Z. Balouji and O. Salor, "Classification of power quality events using deep training on event images," in *2017 3rd International Conference on Pattern Recognition and Image Analysis (IPRIA)*, Shahrekord, 2017, pp. 216-221, doi: 10.1109/PRIA.2017.7983049.
- [12] S. R. G. Manikonda, S. Gangwani, S. P. K. Sreckala, J. Santhosh, and D. N. Gaonkar, "Power Quality Event Classification Using Convolutional Neural Networks on Images," in *2019 IEEE Ist International Conference on Energy, Systems and Information Processing (ICESIP)*, Chennai, India, 2019, pp. 1-5, doi: 10.1109/ICESIP46348.2019.8938324.
- [13] C. I. Chen, S. S. Berutu, Y. C. Chen, H. C. Yang, C. H. Chen, "Regulated Two-Dimensional Deep Convolutional Neural Network-Based Power Quality Classifier for Microgrid", *Energies*. 2022; 15(7):2532. <https://doi.org/10.3390/en15072532>.
- [14] H. Xue, A. Chen, D. Zhang and C. Zhang, "A Novel Deep Convolution Neural Network and Spectrogram Based Microgrid Power Quality Disturbances Classification Method," in *2020 IEEE Applied Power Electronics Conference and Exposition (APEC)*, New Orleans, LA, USA, 2020, pp. 2303-2307, doi: 10.1109/APEC39645.2020.9124252.
- [15] Y. Ma, J. Zhang, L. Xiao, K. Chen, J. Wu, "Classification of Power Quality Disturbances via Deep Learning", *IETE Technical Review*, Vol. 34, pp.408-415, 2016.
- [16] K. Cai, W. Cao, L. Aarniovuori, H. Pang, Y. Lin and G. Li, "Classification of Power Quality Disturbances Using Wigner-Ville Distribution and Deep Convolutional Neural Networks," *IEEE Access*, vol. 7, pp. 119099-119109, 2019. Doi: 10.1109/ACCESS.2019.2937193.
- [17] J. Wang, Z. Xu and Y. Che, "Power Quality Disturbance Classification Based on Compressed Sensing and Deep Convolution Neural Networks," *IEEE Access*, vol. 7, pp. 78336-78346, 2019, doi: 10.1109/ACCESS.2019.2922367.
- [18] S. S. Berutu, "IoT Power Monitor System Development and Using Deep Learning Technology for Disturbances Classification," Asia University, 2021. Tersedia pada: <http://hdl.handle.net/11296/6spkhq>
- [19] A. R. Hezam, S. A. Mostafa, Z. Baharum, A. Alanda, and M.Z. Salikon, "Combining Deep Learning Models for Enhancing the Detection of Botnet Attacks in Multiple Sensors Internet of Things Networks", *JOIV: International Journal on Informatics Visualization*, vol 5, no 4, 2021.
- [20] H. S. Park, S. J. Yoon, "Early Dropout Prediction in Online Learning of University using Machine Learning", *JOIV : International Journal on Informatics Visualization*, vol 5, no 4, 2021.



● **23% Overall Similarity**

Top sources found in the following databases:

- 23% Internet database
- 19% Publications database
- Crossref database
- Crossref Posted Content database
- 17% Submitted Works database

TOP SOURCES

The sources with the highest number of matches within the submission. Overlapping sources will not be displayed.

1	<b>ndltd.ncl.edu.tw</b> Internet	13%
2	<b>Sunneng Sandino Berutu, Yeong-Chin Chen. "Power Quality Disturbanc...</b> Crossref	2%
3	<b>iarjset.com</b> Internet	1%
4	<b>joiv.org</b> Internet	1%
5	<b>mdpi.com</b> Internet	<1%
6	<b>Cheng-I Chen, Sunneng Sandino Berutu, Yeong-Chin Chen, Hao-Cheng ...</b> Crossref	<1%
7	<b>123dok.com</b> Internet	<1%
8	<b>joiv.org</b> Internet	<1%

9	<b>acikbilim.yok.gov.tr</b>	Internet	<1%
10	<b>uad.portalgaruda.org</b>	Internet	<1%
11	<b>csie.asia.edu.tw</b>	Internet	<1%
12	<b>"Machine Intelligence and Soft Computing", Springer Science and Busi...</b>	Crossref	<1%
13	<b>jurnal.uisu.ac.id</b>	Internet	<1%
14	<b>jurnalmahasiswa.stiesia.ac.id</b>	Internet	<1%
15	<b>Jidong Wang, Zhilin Xu, Yanbo Che. "Power Quality Disturbance Classif...</b>	Crossref	<1%
16	<b>Sriwijaya University on 2021-07-07</b>	Submitted works	<1%
17	<b>core.ac.uk</b>	Internet	<1%
18	<b>dokumen.pub</b>	Internet	<1%
19	<b>ejournal.kopertis10.or.id</b>	Internet	<1%
20	<b>eprints.uny.ac.id</b>	Internet	<1%

21	<b>jurnaltoddoppuli.wordpress.com</b> Internet	<1%
22	<b>media.neliti.com</b> Internet	<1%

---

## ● Excluded from Similarity Report

- Manually excluded sources

---

### EXCLUDED SOURCES

**coursehero.com**

Internet

**2%**

---

**ejournal.pnc.ac.id**

Internet

**2%**

---

**Sastruyati Chao Test Account on 2021-11-23**

Submitted works

**2%**

---

**poltera on 2022-06-05**

Submitted works

**2%**