

Uji Kinerja Metode *Deep Convolutional Neural Networks* Untuk Identifikasi Gangguan Daya Listrik

Sunneng Sandino Berutu*

Program Studi Informatika, Universitas Kristen Immanuel Yogyakarta

Jln. Solo km 11,1 Sleman, Yogyakarta, Indonesia

E-mail: sandinoberutu@ukrimuniversity.ac.id

Abstrak

Info Naskah:

Naskah masuk: 30 April 2022

Direvisi: 15 Juli 2022

Diterima: 18 Juli 2022

Model berbasis *deep convolutional neural networks* (CNNs) untuk identifikasi sinyal gangguan listrik membutuhkan jumlah data yang besar, tetapi data riil untuk membangun model tersebut sangat sulit diperoleh sehingga beberapa peneliti menggunakan data buatan pada tahap pelatihan model. Data buatan diproduksi menggunakan fungsi matematika berstandar IEEE. Dalam standar tersebut, fungsi matematika untuk memproduksi sinyal gangguan listrik jenis *interruption* dan *sag* adalah sama, tetapi besaran nilai interval parameter intensitasnya (α) berbeda. Dalam artikel ini, penulis menganalisis kinerja model dalam mengidentifikasi ke dua jenis gangguan listrik tersebut. Dataset sinyal untuk pelatihan dan pengujian model diproduksi dengan mengatur nilai interval variabel α berdasarkan nilai batas maksimal α sinyal jenis *Sag* dan nilai batas minimal α jenis *interruption*. Pada data sinyal buatan disertakan beberapa level *noise* untuk memperoleh data sinyal mendekati data riil sehingga terdapat beberapa dataset *noise* dalam simulasi. Selanjutnya, dataset-dataset tersebut dilatih dengan model deep CNNs. Hasil pengujian menunjukkan bahwa nilai *true positive* (TP) model dalam mengidentifikasi pada sinyal gangguan jenis *interruption* sebesar 93,54% dan jenis *sag* sebesar 78,78%. Selain itu, model dengan *dataset* tidak bernoise memiliki kinerja lebih baik pada parameter *accuracy*, *precision* dan *f1-score* dengan masing-masing nilai 92,4%, 97,4% dan 92,76%.

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 involves a large amount of data. However, the real signal data is limited. Therefore, researchers employ synthetic signal 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 (α). This paper analyzed the model performance of identifying those disturbances where the intensity values are set differently for training and testing datasets based on the upper bound value α of sag and the lower bound value α of interruption. Several noise levels are included in 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 test results show that the true positive (TP) of the model's performance in identifying the interruption signal is 93.54% and the sag signal is 78.78%. In addition, the performance of the model using a dataset without noise obtained a high percentage in accuracy, precision, and f1-score parameters with 92.4%, 97.4%, and 92.76%, respectively.

*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, faktor alam dan sebagainya.


Beberapa tahun terakhir, penelitian terkait identifikasi gangguan kualitas daya sudah mengadopsi teknologi berbasis *deep training*. Beberapa arsitektur metode *deep learning* yang sudah diimplementasikan pada domain klasifikasi atau identifikasi gangguan kualitas daya listrik seperti *recurrent neural network* (RNN), *long short-term memory* (LSTM), *gated recurrent units* (GRU) dan *convolutional neural network-long short-term memory* (CNN-LSTM)[2], dan CNN. Selanjutnya, CNN dikombinasikan dengan metode *wavelet transform* (WT)[3], *principal component analysis* (PCA)[4] dan *curvelet transform*[5]. Kemudian, kombinasi metode Hilbert Huang *transform* dengan *neural network*[6]. Selanjutnya, metode *deep CNN*[7] dikombinasikan dengan *winger-ville distribution*[8] dan *compressed sensing*[9]. Berdasarkan hasil eksperimen penelitian-penelitian di atas, kinerja metode CNN lebih baik dan populer untuk mengidentifikasi gangguan kualitas daya karena metode ini mampu mempelajari fitur-fitur yang kompleks [10][11].

Peneliti sebelumnya menggunakan data sinyal buatan untuk proses pelatihan model karena terbatasnya jumlah data aktual yang tersedia. Data sinyal buatan diproduksi dengan menggunakan fungsi matematika[12] sesuai standar IEEE. Dalam persamaan tersebut gangguan kategori *sag* dan *interruption* memiliki fungsi matematika yang sama tetapi berbeda pada nilai parameter intensitasnya (α) di mana nilai maksimal α pada jenis *sag* sama dengan nilai minimal α pada jenis *interruption*.

Dalam artikel-artikel sebelumnya, 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 bertujuan untuk melakukan analisis kinerja metode *deep CNN* pada identifikasi sinyal gangguan daya listrik jenis *sag* dan *interruption*. Dalam simulasi ini, nilai variabel interval α ke dua gangguan tersebut ditentukan berdasarkan nilai batas maksimal variabel α pada jenis *sag* dan nilai batas minimal α pada jenis *interruption* untuk memproduksi data *training* dan data *pengujian*.

2. Metode

Tahapan yang dilakukan untuk menganalisis kinerja metode *deep CNN* dalam mengidentifikasi gangguan jenis *sag* dan *interruption* pada kualitas daya listrik ditunjukkan pada Gambar 1.



Gambar 1. Tahapan analisis kinerja metode *deep CNN*.

Dari Gambar 1, tahap pertama, menentukan nilai interval variabel α sinyal *sag* dan *interruption*. Selanjutnya, *dataset* pelatihan dan *pengujian* diproduksi menggunakan fungsi matematika dengan nilai α yang ditentukan sebelumnya. *Noise* disisipkan ke sinyal dengan ukuran 10 db, 20 db, 30 db dan 40 db. Kemudian, data dibagi ke dalam *dataset* pelatihan dan *pengujian*. Tahap kedua, arsitektur model dengan metode *deep CNN* dirancang. Tahap selanjutnya, model dilatih dan diuji. Terakhir, hasil *pengujian* model dianalisis menggunakan metode *confusion matrix*.

2.1 Pemrosesan Data

Penelitian ini menggunakan dua jenis gangguan kualitas daya, yaitu *Sag* dan *interruption*. Fungsi matematika kedua gangguan ini mengacu pada penelitian yang sudah dilakukan sebelumnya dalam memproduksi sinyal gangguan buatan.

Fungsi matematika untuk memproduksi sinyal gangguan kategori *sag* ditunjukkan pada persamaan (1) dan (2).

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

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

Dengan nilai frekuensi dasar (f) adalah 50 hz. Sementara nilai t_1 dan t_2 diperoleh dari persamaan (3).

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

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

Dimana, T merupakan periode gelombang.

Nilai intensitas (α) diperoleh dari interval berikut,

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

Fungsi matematika untuk memproduksi jenis gangguan *interruption* dinyatakan dalam Persamaan (6).

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

Nilai ω diperoleh menggunakan Persamaan (2) dan nilai t_1 dan t_2 menggunakan Persamaan (3). Sementara itu, besaran nilai α diperoleh berdasarkan interval pada Persamaan (7) berikut.

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

Selanjutnya data sinyal buatan *Sag* dan *Interruption* diproduksi dengan Persamaan (1) dan (6) menggunakan interval yang terdapat dalam tabel 1. Nilai interval parameter intensitas (α) untuk data pelatihan dan pengujian ditentukan seperti dalam Tabel 1.

Tabel 1. Penentuan Nilai Interval Parameter α pada Data Pelatihan dan Pengujian

Kategori	Data Pelatihan	Data Pengujian
<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 gelombang sinyal ditentukan sebanyak 11. Untuk setiap sinyal disertakan empat jenis *noise* dengan ukuran 10 db, 20 db, 30 db dan 40 db.

2.2 Dataset

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

Tabel 2. Pembagian Data

Jenis Gangguan	Dataset		Dataset Pengujian
	Latih	Validasi	
<i>Sag</i>	8.000	2.000	1.000
<i>Interruption</i>	8.000	2.000	1.000

Tabel 3. Daftar *Dataset* Pelatihan

Nama <i>Dataset</i>	Keterangan
DL-0db	<i>Dataset</i> pelatihan tanpa <i>noise</i>
DL-10db	<i>Dataset</i> pelatihan <i>noise</i> 10 db
DL-20db	<i>Dataset</i> pelatihan <i>noise</i> 20 db
DL-30db	<i>Dataset</i> pelatihan <i>noise</i> 30 db
DL-40db	<i>Dataset</i> pelatihan <i>noise</i> 40 db


Tabel 4. Daftar *Dataset* Pengujian

Nama <i>Dataset</i>	Keterangan
DT-0db	<i>Dataset</i> pengujian tanpa <i>noise</i>
DT-10db	<i>Dataset</i> pengujian <i>noise</i> 10 db
DT-20db	<i>Dataset</i> pengujian <i>noise</i> 20 db
DT-30db	<i>Dataset</i> pengujian <i>noise</i> 30 db
DT-40db	<i>Dataset</i> pengujian <i>noise</i> 40 db

Dataset pada Tabel 3 akan digunakan pada Selanjutnya, setelah *noise* disisipkan pada sinyal dengan ukuran 10 db, 20 db, 30 db dan 40 db maka dalam simulasi terdapat lima jenis *dataset* seperti yang dideskripsikan pada Tabel 3 dan Tabel 4. Pelatihan model, sedangkan *dataset* dalam Tabel 4 akan diimplementasikan pada pengujian model.

2.3 Rancangan Arsitektur Model

Arsitektur model berbasis *deep* CNN untuk mengidentifikasi kualitas daya listrik ditampilkan pada Gambar 2, sementara lapisan - lapisan yang dipergunakan pada model *deep* CNN disajikan dalam Tabel 5.



Gambar 2. Arsitektur model *deep* CNN

Tabel 5. Daftar Lapisan dalam Model

Lapisan	Deep CNN satu dimensi
Convolution1	Conv1D (64,4), aktivasi = <i>rectified linier unit</i> (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 = <i>softmax</i>

Tabel 6. Nama Model dengan *Dataset* yang dipergunakan

Nama Model	Dataset	
	Pelatihan	Pengujian
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

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

2.4 Confusion matrix

Metode *confusion matrix*[13] dipergunakan untuk mengevaluasi kinerja hasil pengujian model. Metode ini memiliki empat komponen utama[14] yaitu *true positive* (TP), *true negative* (TN), *false positive* (FP), dan *false negative* (FN). Keempat komponen tersebut digunakan untuk menghasilkan parameter-parameter[15] seperti *accuracy*(*acc*), *precision*(*prec*), *recall*(*rec*), dan *f1-score*(*f1*). Rumus untuk menghasilkan parameter-parameter tersebut disajikan dalam Persamaan (8-11).

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

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

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

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

3. 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.

3.1 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 *pelatihan* dan *validasi* model dari keseluruhan *epoch* yang dilakukan. Setelah model memenuhi kesesuaian maka nilai akurasi rata-rata hasil *pelatihan* dan *validasi* setiap model dihitung. Hasil perhitungan tersebut disajikan dalam Tabel 7 berikut.

Tabel 7. Hasil Pengukuran Akurasi pada Tahap Pembelajaran

Nama Model	Nilai akurasi (%)	
	Pelatihan	Validasi
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 latih dan validasi lebih tinggi dibandingkan dengan model lainnya. Sementara itu, model dengan data *noise* 10 db memiliki nilai akurasi latihan dan validasi paling rendah.

3.2 Tahap Pengujian Model


Pengujian dilakukan untuk mengukur kinerja model dalam identifikasi ke dua jenis gangguan kualitas daya. Dalam proses pengujian, *dataset pengujian* 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 3, sebanyak 1100 data jenis *interruption* dimana sebanyak 974 data (TP) atau 97,4% merupakan *interruption* atau sedangkan sisanya adalah *sag*. Sementara itu, jenis *sag* diprediksi sebanyak 900 data dimana sebanyak 874 data (TP) atau 87,4% merupakan jenis *sag* dan sisanya sebagai *interruption*. Dalam hal ini, model-0db mengidentifikasi lebih banyak data *interruption* dibandingkan dengan data *sag*.



Gambar 3. Hasil pengujian dalam *confusion matrix* pada model-0db.



Gambar 4. Hasil pengujian dalam *confusion matrix* pada model-10db.




Gambar 5. Hasil pengujian dalam *confusion matrix* pada model-20db

Pada *confusion matrix* model-10db dengan data *noise* 10db seperti yang ditampilkan dalam Gambar 4, model ini mengidentifikasi sebanyak 1348 data pada kategori


interruption dengan nilai TP sebesar 899 atau 89,9%. Sementara itu, sebanyak 652 data sebagai kategori *sag* dengan nilai TP sebesar 551 atau 55,1%. Dalam hal ini, model mendeteksi sebesar 67% sebagai data *interruption*. Dengan demikian model memiliki kemampuan lebih baik memprediksi data tipe gangguan *interruption* dibandingkan tipe *sag*.

Tampilan *confusion matrix* model-20db pada Gambar 5 dibawah ini menunjukkan bahwa model memprediksi 1138 sinyal jenis *interruption* dengan nilai TP sebesar 952 atau 95,2%. Di sisi lain, nilai TP jenis *sag* sebesar 814 atau 81,4%. 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*.

Hasil pengujian model-30db dalam *confusion matrix* pada Gambar 6 menunjukkan bahwa model mendeteksi jumlah data kategori *interruption* sebanyak 972 data dengan nilai TP sebesar 893 atau 89,3% sedangkan model mengidentifikasi data kategori *sag* sebanyak 1028 data dengan nilai TP sebesar 921 atau 92,1 %. Kinerja model ini lebih baik dalam mendeteksi jenis gangguan *sag* dibandingkan dengan jenis *interruption*.



Gambar 6. Hasil pengujian dalam *confusion matrix* pada model-30db



Gambar 7. Hasil pengujian dalam *confusion matrix* pada model-40db.

Confusion matrix model-40db dalam Gambar 7 bahwa model mengidentifikasi sebanyak 1280 sinyal gangguan jenis *interruption* dengan nilai TP sebesar 959 atau 95,9%.


Di sisi lain, model mengidentifikasi jenis *sag* sebanyak 820 atau 82%. Dengan demikian, model ini mendeteksi lebih banyak sinyal gangguan kategori *interruption* dibandingkan dengan *sag*.

Berdasarkan analisis hasil pengujian pada 5 model dengan *dataset* yang berbeda maka terdapat 4 model memiliki kemampuan lebih baik mengidentifikasi gangguan jenis *interruption* dibanding dengan jenis *sag*, yaitu model-0db, model-10db, model 20db, dan model-40db. Sementara itu, model-30db memiliki nilai TP lebih baik dalam mengidentifikasi gangguan jenis *sag* dibanding jenis *interruption*. Rata-rata nilai TP dari keseluruhan model untuk identifikasi jenis *interruption* sebesar 93,54% sedangkan untuk jenis *sag* sebesar 78,78%. Dengan demikian, fitur gangguan jenis *interruption* lebih mudah diidentifikasi oleh model dibandingkan dengan jenis *sag*.

Selanjutnya hasil pengukuran kinerja model berdasarkan parameter-parameter seperti *accuracy*, *recall*, *precision* dan *f1-score* yang dihitung berdasarkan angka-angka yang ada dalam *confusion matrix* setiap model disajikan dalam Tabel 8 dan Gambar 8 berikut ini.

Tabel 8. Perbandingan Kinerja Pengujian Model Deep CNN

Nama Model	<i>accuracy</i> (%)	<i>Recall</i> (%)	<i>Precision</i> (%)	<i>f1-score</i> (%)
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 8. Grafik perbandingan kinerja model CNN

Pada Tabel 8, Kinerja model-0db memperoleh akurasi lebih tinggi mencapai 92,4% sedangkan model-10db memiliki kinerja akurasi paling rendah dengan nilai 72,5%. 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%. Selanjutnya, untuk parameter *precision*, model-0db memiliki kinerja lebih baik dengan perolehan 97,4%. Disisi lain, model-30db memperoleh nilai terendah dengan nilai 89,3%. Terakhir, nilai *f1-score* model-0db melampaui

perolehan model yang lain yaitu 92,76% sedangkan nilai terendah diperoleh model-10db dengan nilai 76,57%.

Grafik *bar* pada Gambar 8 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 α untuk memproduksi sinyal gangguan buatan jenis *interruption* dan *sag* dimana data pengujian jenis *interruption* dan *sag* diperoleh menggunakan aturan nilai batas atas interval *sag* sama dengan nilai batas bawah interval *interruption* maka dari hasil pengujian model menunjukkan bahwa fitur-fitur gangguan jenis *interruption* lebih mudah dideteksi oleh model.

4. Kesimpulan

Hasil pengujian menunjukkan bahwa kinerja model menggunakan metode deep CNN memiliki kemampuan lebih baik dalam mengidentifikasi sinyal gangguan *interruption* dibanding sinyal *sag* dengan nilai persentase *true positive* sinyal *interruption* sebesar 93,54% dan sinyal *sag* sebesar 78,78%. Selanjutnya, kinerja model-0db dengan *dataset* yang tidak memiliki *noise* memperoleh nilai persentase tertinggi pada parameter *accuracy* sebesar 92,4%, *precision* sebesar 97,4% dan *f1-score* sebesar 92,76%. Untuk penelitian selanjutnya, jumlah *dataset* dengan beberapa variasi nilai interval parameter intensitas dapat ditambahkan untuk memperoleh kinerja model yang lebih baik.

Daftar Pustaka

- [1] H. Sindi, M. Nour, M. Rawa, Ş. Öztürk, and K. Polat, "A novel hybrid deep learning approach including combination of 1D power signals and 2D signal images for power quality disturbance classification," *Expert Syst. Appl.*, vol. 174, no. November 2020, 2021, doi: 10.1016/j.eswa.2021.114785.
- [2] N. Mohan, K. P. Soman, and R. Vinayakumar, "Deep power: Deep learning architectures for power quality disturbances classification," *Proc. 2017 IEEE Int. Conf. Technol. Adv. Power Energy Explor. Energy Solut. an Intell. Power Grid, TAP Energy 2017*, pp. 1–6, 2018, doi: 10.1109/TAPENERGY.2017.8397249.
- [3] S. S. Berutu and Y. C. Chen, "Power quality disturbances classification based on wavelet compression and deep convolutional neural network," *Proc. - 2020 Int. Symp. Comput. Consum. Control. IS3C 2020*, pp. 327–330, 2020, doi: 10.1109/IS3C50286.2020.00091.
- [4] 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, 2019, doi: 10.3390/en12071280.
- [5] H. Liu, F. Hussain, Y. Shen, S. Arif, A. Nazir, and M. Abubakar, "Complex power quality disturbances classification via curvelet transform and deep learning," *Electr. Power Syst. Res.*, vol. 163, no. April, pp. 1–9, 2018, doi: 10.1016/j.epsr.2018.05.018.
- [6] M. A. Rodriguez, J. F. Sotomonte, J. Cifuentes, and M. Bueno-Lopez, "Classification of Power Quality Disturbances using Hilbert Huang Transform and a Multilayer Perceptron Neural Network Model," *SEST 2019 - 2nd Int. Conf. Smart Energy Syst. Technol.*, 2019, doi: 10.1109/SEST.2019.8849114.
- [7] S. Wang and H. Chen, "A novel deep learning method for the classification of power quality disturbances using deep convolutional neural network," *Appl. Energy*, vol. 235, no. November 2018, pp. 1126–1140, 2019, doi: 10.1016/j.apenergy.2018.09.160.
- [8] 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, no. Vmd, pp. 119099–119109, 2019, doi: 10.1109/ACCESS.2019.2937193.
- [9] 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.
- [10] E. Balouji and O. Salor, "Classification of power quality events using deep learning on event images," *3rd Int. Conf. Pattern Anal. Image Anal. IPRIA 2017*, no. Ipria, pp. 216–221, 2017, doi: 10.1109/PRIA.2017.7983049.
- [11] S. K. G. Manikonda, S. Gangwani, S. P. K. Sreckala, J. Santhosh, and D. N. Gaonkar, "Power Quality Event Classification Using Convolutional Neural Networks on Images," *2019 IEEE 1st Int. Conf. Energy, Syst. Inf. Process. ICESIP 2019*, pp. 0–4, 2019, doi: 10.1109/ICESIP46348.2019.8938324.
- [12] R. Igual, C. Medrano, F. J. Arcega, and G. Mantescu, "Integral mathematical model of power quality disturbances," *Proc. Int. Conf. Harmon. Qual. Power, ICHQP*, vol. 2018-May, pp. 1–6, 2018, doi: 10.1109/ICHQP.2018.8378902.
- [13] C. Chen, S. S. Berutu, Y. Chen, H. Yang, and C. Chen, "Regulated Two-Dimensional Deep Convolutional Neural Network-Based Power Quality Classifier for Microgrid," 2022.
- [14] H. S. Park and S. J. Yoo, "Early Dropout Prediction in Online Learning of University using Machine Learning," *Int. J. Informatics Vis.*, vol. 5, no. 4, pp. 347–353, 2021, doi: 10.30630/JOIV.5.4.732.
- [15] A. A. 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," *Int. J. Informatics Vis.*, vol. 5, no. 4, pp. 380–387, 2021, doi: 10.30630/JOIV.5.4.733.