

Deteksi Partial Discharge dengan Metode CNN VGG16

Martin Pardede*¹, Triyogatama Wahyu Widodo²

¹Program Studi Elektronika dan Instrumentasi, DIKE, FMIPA, UGM, Yogyakarta, Indonesia

²Departemen Ilmu Komputer dan Elektronika, FMIPA UGM, Yogyakarta, Indonesia

e-mail: *¹martinpardede@mail.ugm.ac.id, yogatama@365.ugm.ac.id

Abstrak

Partial discharge adalah peristiwa loncatan listrik yang pada bahan isolasi listrik yang menimbulkan kerusakan pada peralatan listrik. Untuk itu diperlukan suatu metode untuk mendeteksi peristiwa partial discharge. Salah satu metode yang dapat digunakan untuk deteksi partial discharge adalah metode CNN VGG16. CNN akan melakukan pemodelan dari analisa dataset gambar partial discharge VSB lalu menggunakannya untuk mengklasifikasikan data baru sebagai partial discharge atau tidak.

Pada penelitian ini akan dianalisa bagaimana pengaruh parameter pemodelan dan pembagian dataset terhadap peforma. Penyesuaian parameter dilakukan dengan memvariasikan nilai learning rate, steps per epoch, dan validation steps untuk melihat nilai terbaik sehingga nantinya nilai terbaik yang akan digunakan. Pembagian dataset dilakukan dengan tiga variasi yaitu pembagian train, validasi, dan test pada dataset pertama dibagi rata, yang kedua didominasi ke train, dan yang ketiga jumlah data noPD terlebih dahulu dikurangi agar seimbang dengan PD kemudian data didominasi juga pada train.

Berdasarkan penelitian, terbukti bahwa variasi dataset ketiga yang memiliki peforma terbaik dan menunjukkan bahwa CNN arsitektur VGG16 terbukti mampu untuk mengenali pola dari data sinyal partial discharge dan membuat model yang mampu mengklasifikasi data partial discharge atau tidak dengan akurasi train 95,70%, akurasi validasi 93,12% dan akurasi prediksi data test 92,50% juga dengan nilai MCC sebesar 0,75.

Kata kunci—Partial Discharge, CNN, VGG16, dataset VSB, pengenalan pola

Abstract

Partial discharge is an electric jump event on an electrical insulating material that causes damage to electrical equipment. For this reason, a method is needed to detect partial discharge events. One method that can be used for partial discharge detection is the CNN VGG16 method. CNN will perform modeling from the analysis of the VSB partial discharge image dataset and then use it to classify the new data as partial discharge or not.

In this study, it will be analyzed how the influence of modeling parameters and dataset distribution on performance. Parameter adjustment is done by varying the value of learning rate, steps per epoch, and validation steps to see the best value so that later the best value will be used. The distribution of the dataset is carried out in three variations, namely the distribution of train, validation, and test on the first dataset divided equally, the second is dominated by train, and thirdly the number of noPD data is reduced to balance with PD then the data is also dominated by train.

Based on the research, it is proven that the third variation of the dataset has the best performance and shows that the CNN architecture VGG16 is proven to be able to recognize patterns from partial discharge signal data and create a model that is able to classify partial discharge data or not with train accuracy of 95.70%, validation accuracy of 93.12% and the prediction accuracy of the test data is 92.50% also with an MCC value of 0.75.

Keywords— Partial Discharge, CNN, VGG16, VSB dataset, pattern recognition

1. PENDAHULUAN

Partial discharge(PD) adalah fenomena yang umum terjadi pada peralatan listrik misalnya pada generator dan kabel listrik. Partial discharge merupakan peristiwa pelepasan/loncatan bunga api listrik yang terjadi pada suatu bagian bahan isolasi yang disebabkan oleh adanya beda potensial yang tinggi dalam bahan isolasi. Peristiwa tersebut merupakan hal yang tidak diinginkan dikarenakan dapat menimbulkan kerusakan peralatan sehingga mengakibatkan kerugian[1]. Oleh karena itu dibutuhkan suatu metode yang dapat mendeteksi partial discharge sedini mungkin dengan tingkat akurasi yang baik agar dapat segera dilakukan perbaikan pada peralatan yang mengalami partial discharge.

Pada dasarnya listrik merupakan gelombang dan aliran listrik yang baik memiliki pola gelombang tertentu. Bila terjadi partial discharge maka akan terbentuk suatu pola gelombang listrik yang berbeda[2]. Hal tersebut dapat dimanfaatkan untuk mendeteksi terjadinya partial discharge. Kemampuan analisa dari machine learning mampu mengenali dan membedakan pola-pola voltage signal tersebut sehingga dapat digunakan untuk membedakan gelombang yang mengalami PD dan yang tidak[3].

Untuk dapat mempelajari dan membuat metode pendeteksian partial discharge dengan machine learning diperlukan suatu dataset yang berisi data-data sinyal yang mengalami partial discharge atau tidak. Salah satu instansi yang telah melakukan pengumpulan data tersebut adalah ENET Center di Technical University of Ostrava (VSB)[4]. Dataset ini sendiri dipublikasikan secara bebas melalui website kaggle agar orang-orang dapat menggunakannya dalam pembuatan metode deteksi partial discharge menggunakan machine learning atau deep learning. Jenis algoritma deep learning ada beberapa yaitu Deep Neural Networks (DNN), Artificial Neural Networks (ANN), Convolutional Neural Networks (CNN), Recurrent neural network (RNN), Long short term memory network (LSTM), dan Self organizing maps (SOM). Di antara beberapa jenis deep learning tersebut, peneliti mengusulkan penggunaan CNN sebagai metode deteksi partial discharge yang akan digunakan dalam sistem. Hal ini dikarenakan peneliti menggunakan data VSB yang dimana berupa sinyal yang dapat divisualisasikan. Dan untuk metode deep learning yang dapat mengolah gambar dengan hasil yang terbaik adalah metode CNN. Untuk metode lain memiliki keahlian yang berbeda misalnya DNN untuk pengolahan keputusan, ANN untuk pengolahan tabular data, RNN untuk pengolahan sequence data, dan seterusnya[5]. Selain itu juga sudah ada beberapa penelitian terdahulu tentang bagaimana CNN dalam deteksi partial discharge yang menjadi rujukan peneliti.

Di antara arsitektur CNN yang ada, peneliti memilih untuk menggunakan arsitektur VGG16 dikarenakan sudah memiliki akurasi yang cukup baik dan untuk spesifikasi komputer yang dapat menjalannya dengan baik tidak terlalu tinggi sehingga peneliti dapat menggunakan komputer pribadi[6]. Hal lain yang juga mendukung peneliti untuk menggunakan arsitektur ini adalah dikarenakan VGG16 masih sering digunakan sehingga masih mudah untuk mencari referensi. Sedangkan untuk datanya, data yang akan digunakan dalam penelitian ini adalah dataset VSB power lines.

2. METODE PENELITIAN


Secara umum tujuan utama dilakukannya penelitian ini adalah untuk membuat sistem pengolahan data voltage meter untuk mendeteksi partial discharge dengan menggunakan CNN VGG16 lalu menganalisa bagaimana kinerjanya dalam mendeteksi partial discharge. Sistem yang dibentuk adalah CNN VGG16 untuk mendeteksi pola partial discharge pada dataset VSB. Untuk dataset VSB sendiri adalah berupa 8712 data_train dan 20337 data_test. Akan tetapi dikarenakan

data_test tersebut merupakan data tanpa label yang dimana labelnya masih dirahasiakan oleh penyelenggara untuk menilai hasil deteksi peneliti-peneliti lainnya, maka peneliti hanya menggunakan data_train untuk pembuatan sistem ini[4].

Data_train berjumlah 8712 tadi akan dibagi oleh peneliti menjadi 3 jenis yaitu data train, data validation, dan data test yang akan digunakan dalam pembuatan sistem. Dalam pembuatan tiap jenis data yaitu data train, validation, dan test peneliti membuat tiga buah versi yaitu dengan perbandingan pembagian data yang berbeda. Data train akan digunakan sebagai model pada sistem CNN sedangkan data validation digunakan untuk mengetes performa dari model yang sudah dibentuk menggunakan data train tadi. Proses train akan dilakukan hingga validasi menggunakan validation data yang dicapai mencapai target yang diinginkan. Setelah itu performa dari model yang dibentuk dites dengan mencoba memprediksi data yang tidak digunakan dalam pembuatan model yaitu data test. Performa training model dan prediksi yang telah dilakukan kemudian dianalisa untuk menilai kualitas model dan kemampuannya dalam deteksi. Analisis yang dilakukan adalah seperti misalnya menganalisa grafik training, membuat confusion matrix dari prediksi dan melihat pengaruh dari tiap parameter serta data terhadap performa model.

2.1 Analisis Data

Dataset partial discharge yang diberikan oleh VSB sendiri hanyalah berupa 8187 data berlabel dan 20337 data tanpa label. Dalam pengerjaan dalam penelitian ini, data yang dapat digunakan hanyalah data yang berlabel yaitu sebagai data train, data validation, dan data test. Data train berjumlah 8712 tadi akan dibagi oleh peneliti menjadi 3 jenis yaitu data train, data validation, dan data test yang akan digunakan dalam pembuatan sistem. Dalam pembuatan tiap jenis data yaitu data train, validation, dan test peneliti membuat tiga buah versi yaitu dengan perbandingan pembagian data yang berbeda.



Gambar 1 Diagram Pembagian Dataset

2.2 Perangkat keras

Perangkat keras yang digunakan dalam pembuatan sistem deteksi partial discharge dengan metode CNN adalah laptop/PC yang memiliki GPU serta memiliki daya komputasi yang cukup baik. GPU sendiri sangat dibutuhkan dikarenakan GPU bekerja dalam pengolahan grafis bila komputer tidak memiliki GPU maka proses training nantinya akan berlangsung sangat lama. Untuk RAM yang diperlukan dalam pelatihan data dalam penelitian ini tidak cukup besar yaitu 4 GB, akan tetapi semakin besar RAM yang dimiliki maka akan semakin baik dalam menunjang performa train yang lebih cepat. Untuk processornya sendiri, intel core i5 sudah cukup mampu dalam menjalankan sistem. Akan tetapi, bila menggunakan google colaboratory maka laptop yang digunakan tidak memerlukan GPU dan hanya memerlukan akses internet dan komputasi yang cukup untuk dapat mengakses google colaboratory.


2. 2 Perangkat lunak

Perangkat lunak yang digunakan pada penelitian ini google colab sebagai tool Bahasa pemrograman python. Bahasa pemrograman python sendiri dipilih dikarenakan Bahasa pemrograman ini yang paling umum dan menunjang untuk pengolahan deep learning terlebih lagi CNN. Google Colaboratory sendiri merupakan layanan berbasis cloud Google yang mereplikasi Jupyter Notebook di cloud, Jupyter sendiri merupakan tool yang populer untuk mengolah data di python. Dengan menggunakan google colab, peneliti dapat meminjam resource google berupa GPU, processor, dan lain-lain sehingga yang diperlukan hanyalah komputer dengan akses internet untuk hanya sebagai interface menjalankan perintah di cloud google colab. Selain itu dengan google colab ada juga kelebihan yang dapat diperoleh seperti pre-installed berbagai library sehingga tidak perlu lagi menginstall banyak library besar di komputer, juga google colab terhubung dengan google drive sehingga untuk pengaksesan dan penyimpanan dapat terjadi secara real-time. Untuk resourcenya sendiri, google colab menyediakan resource yang cukup baik terutama GPU yang cukup kuat walaupun akses yang digunakan masih yang gratis. Pada penelitian ini google colab digunakan dikarenakan waktu pemrosesan oleh google colab lebih cepat daripada yang dilakukan menggunakan komputer sendiri via jupyter.

2. 3 Rancangan Sistem

Seperti yang ditampilkan pada gambar 2, untuk dapat melakukan train dan membuat model dibutuhkan dataset gambar, mengeset optimizer dan metrics, dan membuat checkpoint, earllystop, dan mengeset parameter train. Untuk data inputnya sendiri berupa dataset gambar train dan validation, data tersebut kemudian diubah ukurannya dan diolah menggunakan ImageDataGenerator agar dapat diterima dan digunakan oleh layer CNN nantinya pada proses train. Bersamaan dengan itu optimizer perlu digunakan untuk meningkatkan kualitas dari proses train nantinya sehingga model yang dihasilkan memiliki kualitas yang baik, untuk metricsnya sendiri perlu diset agar dapat dilakukan identifikasi terhadap hasil train yaitu menggunakan akurasi. Checkpoint dan earllystop dibuat untuk membantu dalam menjaga kualitas model yang dibentuk selama train supaya tidak overfitted dan hasil yang disimpan adalah hasil teroptimal. Parameter training sendiri memiliki pengaruh yang cukup besar yaitu sebagai penentu bagaimana dataset yang sudah diinput tadi diolah saat train.

Dengan adanya hal-hal tersebut sehingga dapat dilakukan train dan menghasilkan model yang diinginkan. Model ini kemudian dapat terlebih dahulu disimpan sehingga nantinya dapat digunakan kembali tanpa melakukan train. Lalu model juga digunakan untuk memprediksi dataset terpisah dari sebelumnya yaitu dataset test, hasil prediksi kemudian dapat ditampilkan dalam bentuk tabel agar dapat dilihat gambar mana saja yang salah maupun benar prediksinya. Untuk mempermudah penilaian kinerja dari prediksi data prediksi ditampilkan dalam bentuk confusion matriks. Lalu model juga dapat digunakan untuk dianalisa bagaimana efek dari tiap layer dalam model terhadap suatu gambar sehingga menunjukkan bagaimana model yang dibentuk terhadap suatu gambar pada setiap layernya.



Gambar 2 Diagram Alur Rancangan Sistem

2.4 Rancangan Preprocessing

Preprocessing yang dilakukan pada penelitian ini hanya berupa penyesuaian ukuran data terhadap input CNN VGG16 yaitu menjadi ukuran 224x224. Bentuk-bentuk preprocessing lain tidak dilakukan dikarenakan kurang tepat dilakukan terhadap data partial discharge tersebut dikarenakan dikhawatirkan dapat mengubah nilai dari sinyal partial discharge. Beberapa dari preprocessing yang umum dilakukan pada CNN tetapi tak dilakukan oleh peneliti antara lain seperti rotate, horizontal mirror, dan vertical mirror. Rotate tidak diperlukan dikarenakan data yang digunakan berupa gambar grafik yang sudah terstruktur yaitu memiliki sumbu sendiri sehingga kesalahan dikarenakan perbedaan sumbu rotasi tidak akan terjadi. Sedangkan mirror tidak dapat dilakukan dikarenakan apabila dilakukan mirror akan merubah nilai dari sinyal itu sendiri. Seperti yang sudah dijelaskan sebelumnya pada dasar teori, sinyal yang mengalami maupun tidak mengalami partial discharge dibedakan berdasarkan bentuk gelombang, urutan pulsanya, dan pola fasenya.

2.5 Rancangan Model VGG16

VGG 16 memiliki total layer 16 yaitu 13 layer convolution dan 3 layer fully connected. VGG16 menggunakan konsep blok untuk membentuk Convolution layer yang masing-masing convolution layer nya memiliki ukuran 3 x 3 dan stride 1. Pada akhir blok, digunakan max pooling layer dengan ukuran 2 x 2 dan stride 2[7]. Untuk arsitektur VGG16 sendiri dapat dilihat pada tabel 1.

Tabel 1 Arsitektur Layer VGG16

Nama	Filter size	Stride	Jumlah filter
Input	Shape : 224x224x3		
Convolution 1	3x3	1	64
Convolution 2	3x3	1	64
Maxpooling 1	2x2	2	64
Convolution 3	3x3	1	128
Convolution 4	3x3	1	128
Maxpooling 2	2x2	2	128
Convolution 5	3x3	1	256
Convolution 6	3x3	1	256
Convolution 7	3x3	1	256
Maxpooling 3	2x2	2	256
Convolution 8	3x3	1	512
Convolution 9	3x3	1	512
Convolution 10	3x3	1	512
Maxpooling 4	2x2	2	512
Convolution 11	3x3	1	512
Convolution 12	3x3	1	512
Convolution 13	3x3	1	512
Maxpooling 5	2x2	2	512
Flatten			
Fully connected 1			4096
Fully connected 2			4096
Fully connected 3			4096
Softmax			2

2.6 Rancangan pelatihan

Pelatihan yang dilakukan pada penelitian ini berfungsi untuk membuat model yang mampu membedakan antara partial discharge dan tidak. Pada proses pelatihan model akan dibuat dengan menggunakan layer-layer yang sudah disusun sebelumnya. Secara garis besar gambar terlebih dahulu dilakukan proses pembuatan feature map menggunakan layer konvolusi, lalu pixel warna diubah menggunakan relu, setelah itu untuk mengatur dimensi digunakan layer maxpooling, kemudian feature map diubah menjadi vector satu dimensi menggunakan layer flattening, hasilnya kemudian diteruskan ke layer fully connected yang berfungsi untuk mendeteksi fitur-fitur apa saja yang ada pada gambar dan membuat nilai probabilitas yang berfungsi untuk klasifikasi nantinya, dan yang terakhir adalah softmax layer yang berfungsi untuk menunjang hasil prediksi oleh fully connected layer yaitu dengan menganalisa kembali nilai probabilitas yang diberikan FC layer agar penjumlahan probabilitas antara PD dan noPD selalu bernilai 1 sehingga dengan begitu sistem lebih mudah melakukan klasifikasi yaitu bila salah satu probabilitas bernilai lebih dari 0,5 maka hasil deteksi yang disimpulkan adalah kelas probabilitas tersebut. Untuk lossnya sendiri juga dinilai menggunakan loss cross entropy pada layer softmax, semakin tinggi loss maka akan semakin tinggi kemungkinan untuk salah memprediksi kelas[8]. Model yang telah terbentuk melalui layer-layer tersebut kemudian disimpan untuk nantinya dapat digunakan menguji data test.

Juga dalam pelatihan ini ditambahkan yang namanya checkpoint dan earlystop. Checkpoint sendiri merupakan penyimpanan sementara dari model yang sudah dibentuk ketika train masih berlangsung. Model akan terus dilanjutkan hingga mencapai epoch yang telah diset dan selama pembuatan model tentunya ada pengecekan validation akurasi dan validation loss menggunakan data validation. Jika model yang dibentuk memiliki performa yang lebih baik maka akan disimpan dengan menimpa model checkpoint yang telah dibuat sebelumnya namun bila

performanya lebih buruk maka akan diabaikan dan kembali melanjutkan proses train. Akan tetapi seringkali terlalu banyak epoch yang dilakukan malah membuat model overfitting. Overfitting sendiri adalah berupa model yang dibentuk sudah terlalu kompleks sehingga akurasi kecocokan yang diterima harus sangat tinggi atau sama persis dengan gambar yang dipakai saat train, tentunya hal ini tidak diinginkan karena model yang dibutuhkan adalah model yang mampu menilai gambar yang mirip namun tak harus sama persis. Pada saat overfitting model terlalu cocok dengan data pelatihan sehingga loss terus berkurang sementara val_loss tidak berubah, atau meningkat[9]. Oleh karena itu peneliti menambahkan earllystop yang berfungsi untuk menghentikan proses train walaupun epoch yang diset masih belum terpakai semua demi menghindari overfitting. Dengan early stop proses train akan dihentikan ketika sudah mulai tidak ada lagi perubahan performa validation akurasi.

2.7 Rancangan pengujian sistem

Pengujian akan dilakukan pada data test dengan menggunakan model yang telah dibentuk. Cara kerja pengujian adalah dengan cara seperti “menyaring” gambar dengan “saringan” yaitu model hasil training data train dan validation. Berdasarkan kecocokan terhadap model, gambar akan diberi poin rentang kemiripan terhadap kelas PD atau noPD dengan total nilai 1, misalnya suatu gambar diprediksi maka akan keluar nilai PD = 0,27 dan noPD = 0,73 maka kelas prediksi gambar adalah noPD sebagai nilai terbesar. Dan apabila nilai PD dan noPD sama yaitu 0,5 maka kelas yang diprediksikan adalah sebagai noPD yaitu model dengan data train terbanyak.

Untuk menganalisis bagaimana pengaruh dari tiap parameter terhadap keberhasilan sistem deteksi partial discharge dengan CNN yang dibentuk maka peneliti membuat berbagai variasi seperti merubah learning rate, mengubah epoch, memvariasikan data yang dipakai, dan lain-lain.

Agar proses training yang perlu dilakukan tidak terlalu banyak, pengujian pengaruh learning rate dan nilai parameter training seperti epoch, validation steps, dan steps per epoch hanya dilakukan pada salah satu data yang dibentuk dari ketiga data sebelumnya. Pengujian tersebut dilakukan hanya ke dataset1 dengan memvariasikan learning rate terlebih dahulu, setelah learning rate terbaik didapatkan kemudian peneliti memvariasikan nilai epoch, validation steps, dan steps per epoch. Nilai dengan performa terbaik kemudian digunakan untuk dataset2 dan dataset3.

Setiap kombinasi dari parameter yang dilakukan tersebut memberikan performa yang berbeda, dimana dapat dilihat melalui pengujian terhadap data test. Nantinya sistem dengan performa kemampuan terbaik yang menjadi hasil akhir penelitian ini. Keberhasilan penelitian ini dapat dilihat dan diukur berdasarkan parameter-parameter yang disajikan seperti pada Tabel 2.

Tabel 2 Parameter Keberhasilan Sistem

Parameter	Pengujian
Sistem dapat mengolah dataset dan membuat model	Sistem dapat berjalan dengan baik tanpa error, model dapat terbentuk sesuai dengan layer yang telah disusun, model merupakan hasil train dengan performa terbaik, dan model dapat disimpan sehingga nantinya tidak perlu menetrain ulang
Training model memiliki performa yang baik	Training dapat berjalan dengan baik dan memiliki validation akurasi training diatas 90%
Model dapat digunakan mendeteksi partial discharge	Model dapat dipakai untuk memprediksi data gambar lain diluar yang digunakan dalam pembuatan model dengan akurasi prediksi diatas 90% untuk menentukan apakah termasuk PD maupun tidak

3. HASIL DAN PEMBAHASAN

Pada bagian ini dijelaskan hasil dari pengujian implementasi deteksi partial discharge dengan metode CNN VGG16. Pengujian dilakukan dengan beberapa parameter dan skema yang telah ditentukan. Ketentuan-ketentuan ini diberikan berdasarkan berbagai pertimbangan dan ditujukan untuk dapat menampilkan bagaimana pengaruh dari tiap parameter tersebut terhadap pengoptimalan kinerja dari sistem deteksi CNN yang dilakukan. Peneliti akan menampilkan bagaimana hasil pengujian terhadap pengaruh learning rate dan parameter training terhadap kualitas model, juga bagaimana kinerjanya dalam klasifikasi partial discharge pada data yang tidak dipakai dalam pemodelan sesuai dengan rancangan pengujian. Lalu peneliti akan menampilkan bagaimana pengujian terhadap ketiga dataset dan membandingkan bagaimana pengaruh dataset terhadap kualitas dari model yang dibentuk. Penampilan kinerjanya sendiri dilakukan dengan menggunakan grafik pada training antara epoch terhadap nilai dari tiap parameter loss maupun akurasi dan untuk prediksi ditampilkan dalam bentuk confusion matrix. Pada confusion matrix sendiri, kelas PD diberi nilai 0 sedangkan kelas noPD diberi nilai 1. Confusion matrix sendiri dapat dibaca dan diberi penilaian mengenai kemampuan prediksinya yaitu menggunakan MCC(Matthews correlation coefficient). Dengan MCC ini nilai dari confusion matrix dapat dibaca lebih baik dan kemudian dapat dibandingkan bagaimana performa prediksi antar klasifikasi walaupun jumlah data yang digunakan berbeda[10]. Untuk persamaan dari MCC dapat dilihat pada persamaan 1.

$$MCC = \frac{(TP \times TN) - (FP \times FN)}{\sqrt{((TP + FP)(TP + FN)(TN + FP)(TN + FN))}} \quad (1)$$

TP(True Positif) adalah ketika data PD tepat diprediksi sebagai PD, TN(True Negatif) adalah ketika data noPD tepat diprediksi sebagai noPD, FP(False Positif) adalah ketika data PD salah diprediksi sebagai PD, FN(False Negatif) adalah ketika data noPD salah diprediksi sebagai PD.

Tabel 3 Pengujian Learning Rate

Learning Rate	Val Akurasi Training	Ketepatan Prediksi Data Test	MCC
0.01	0.9490	2560/2720	-
0.001	0.9531	2560/2720	-
0.0001	0.9688	2608/2720	0,56
0.00001	0.9635	2625/2720	0,65

Berdasarkan nilai-nilai pengujian learning rate pada tabel 3 dapat dilihat bahwa semakin kecil learning ratenya maka akan semakin baik hasil deteksi oleh CNN. Hal ini dikarenakan semakin kecil learning rate maka jumlah bobot yang diupdate ke model semakin kecil sehingga proses updatenya lebih sering dan detail, oleh karena itulah juga semakin kecil learning rate maka akan semakin lama proses training sistem. Sebaliknya, bila learning rate besar maka proses training semakin cepat tetapi kualitasnya berkurang. Akan tetapi tetap ada batasan learning rate terkecil yang dapat diterapkan yaitu berdasarkan ukuran dan kualitas gambar yang dijadikan model. Bila learning rate dipaksa tetap semakin kecil maka sistem akan tidak mampu memetakan model lagi sehingga akurasi akan jatuh.

Pada percobaan dapat dilihat bahwa ketika learning rate 0,01 dan 0,001 sistem kesulitan untuk menganalisa gambar dan membuat model sehingga loss pada awal train sangat besar. Seiring dengan berjalannya training maka loss baik pada data train maupun validation akan menurun tetapi tidak disertai peningkatan akurasi. Oleh karena itu akhirnya sistem membuat model yang buruk. Model menjadi overfitted kearah noPD selaku data dengan kuantitas terbanyak, sehingga ketika diuji ke data test maka semua gambar diklasifikasi sebagai noPD. Akan tetapi ketika learning rate semakin dikecilkan yaitu 0,0001 dan 0,0001 model yang dibentuk akhirnya cukup baik yaitu dibuktikan melalui kemampuan prediksi di confusion matrix. Kemudian yang menjadi perbedaan yaitu terhadap validation loss, model dengan learning rate 0,00001 memiliki validation loss yang lebih kecil dan stabil sehingga model yang dibentuk lebih

baik. Hal itu dapat dibuktikan ketika pengujian ke data test, model dengan learning rate 0,00001 memiliki error 95 sedangkan model dengan learning rate 0,0001 memiliki error 112 buah. Oleh karena itu peneliti berkesimpulan bahwa learning rate terbaik untuk sistem ini adalah 0,00001 dan kemudian akan diujikan ke penentuan steps per epoch dan validation steps.

Dari hasil pengujian learning rate tersebut, peneliti mendapatkan bahwa learning rate terbaik adalah 0,00001 sehingga peneliti kemudian menggunakan learning rate tersebut untuk mencoba kombinasi nilai steps per epoch dan validation steps. Dalam pengujian ini epoch dilakukan berjumlah 100 karena tanpa mencapai epoch sebanyak itu biasanya model sudah mulai overfitting dan sudah dihentikan proses training oleh earllystop. Peneliti membuat 3 buah kombinasi steps per epoch dan validation steps untuk melihat pengaruhnya terhadap kualitas dari model.

Tabel 4 Pengujian Steps per Epoch dan Validation Steps

Steps per Epoch	Validation Steps	Val_Akurasi Training	Ketepatan Prediksi Data Test	MCC
60	30	0.9635	2625/2720	0,65
120	30	0.9677	2631/2720	0,68
120	60	0.9620	2624/2720	0,64

Dalam pengujian parameter seperti yang ditampilkan pada tabel 4, terlebih dahulu peneliti menggunakan 60 steps yaitu setengah dari maksimal steps yang dapat digunakan dan untuk validation stepsnya peneliti menggunakan seperempat jumlah steps per epoch yaitu 30. Kemudian setelah itu peneliti menggunakan jumlah steps maksimal yaitu 120 steps, jumlah maksimal steps ini ditentukan oleh generator berdasarkan pertimbangan jumlah data yang diinputkan. Berdasarkan hasil pada pengujian, peneliti melihat bahwa semakin banyak steps yaitu maksimal steps maka hasil klasifikasi model terhadap datatest semakin baik. Oleh karena itu peneliti selanjutnya akan menggunakan maksimal steps dalam training model selanjutnya.

Setelah itu peneliti kemudian menguji parameter validation steps dengan menambah jumlahnya menjadi 60 yaitu setengah dari jumlah steps per epoch, akan tetapi hal itu justru membuat model yang terbentuk menjadi lebih buruk. Peneliti tidak mengurangi jumlah validation steps yang digunakan dikarenakan validation steps sejumlah 30 sudah sangat kecil dibandingkan jumlah data yang dipakai yaitu 3822. Oleh karena itu peneliti berkesimpulan untuk jumlah data yang cukup besar tersebut validation steps sebanyak 30 sudah tepat. Parameter terbaik yang sudah didapatkan kemudian lanjut digunakan oleh peneliti untuk membuat pengujian akhir pada dataset1, dataset2, dan dataset3.

Tabel 5 Pengujian Dataset1, Dataset2, dan Dataset3

Dataset	Val_Akurasi Training	Ketepatan Prediksi Data Test	MCC
1	0.9677	2631/2720	0,68
2	0.9667	1660/1740	0,54
3	0.9312	381/420	0,75

Berdasarkan pengujian pada dataset1, dataset2, dan dataset3 peneliti membuat perbandingan bagaimana data dapat mempengaruhi kualitas dari model yang dibentuk dalam klasifikasi selain dari parameter-parameter yang perlu disesuaikan sebelumnya seperti yang ditampilkan tabel 5. Pada dataset1, perbandingan antara jumlah data train:validation:test hampir sama yaitu 7:4:5. Dampaknya performa dari model yang dibentuk cukup baik, dengan perbedaan antara jumlah data PD dan noPD tidak begitu jauh, kesalahan prediksi data PD tidak begitu besar dan secara keseluruhan sistem memiliki kemampuan deteksi data baru sebesar 96,7% yaitu kesalahan 89 dari 2720 dan nilai MCC 0,68.

Lalu pada dataset2 jumlah data train ditingkatkan dengan maksud agar sistem yang dimiliki memiliki performa yang lebih baik. Pada dataset2, perbandingan antara jumlah data train:validation:test ditekankan di bagian train yaitu 13:3:4. Akan tetapi hasil yang diterima tidak sesuai dengan harapan, perbedaan jumlah data PD dan noPD pada data train semakin besar sehingga model yang dibentuk cenderung memprediksi data yang diterima sebagai noPD. Alhasil sistem memiliki kemampuan deteksi data baru hanya sebesar 95,4% yaitu kesalahan 80 dari 1740 dan nilai MCC 0,54.

Dikarenakan hal tersebut kemudian jumlah data noPD dari dataset2 dikurangi untuk membuat dataset3. Untuk perbandingannya, pada dataset3 perbandingan antara jumlah data train:validation:test tetap ditekankan di bagian train yaitu 13:3:4. Hasilnya, dengan mengurangi jumlah noPD kemampuan model menjadi lebih baik dan kesalahan prediksi PD sebagai noPD jauh berkurang. Akan tetapi sebaliknya, kemampuan sistem untuk mendeteksi noPD menjadi lebih buruk. Alhasil model memiliki kemampuan deteksi data baru sebesar 92,5% yaitu kesalahan 39 dari 520 tetapi nilai MCC yang dimiliki lebih baik daripada dataset1 dan dataset2 yaitu sebesar 0,75.

Berdasarkan penelitian ini dapat dilihat bahwa CNN VGG16 mampu bekerja dengan cukup baik untuk deteksi data yang cukup kompleks seperti data partial discharge yang telah dilakukan. Umumnya CNN sendiri dilakukan untuk deteksi dan mengklasifikasi data gambar dengan pola atau bentuk yang umum dan dapat dibedakan secara kasat mata oleh manusia, seperti membedakan anjing dan kucing, membedakan meja, kursi, dan lemari, dan lain-lain. Akan tetapi dataset dari partial discharge merupakan data grafik antara nilai terhadap waktu dengan pola fase, pola pulsa, dan bentuk gelombang yang berbeda dimana manusia sangat kesulitan untuk membedakannya hanya dengan sekadar melihatnya. Dan berdasarkan penelitian yang telah dilakukan CNN VGG16 mampu menganalisa dari tiap pola tersebut secara otomatis dan mampu membuat model yang kemudian dapat membedakan pola-pola gelombang diluar data yang dipakai untuk training dengan persentase ketepatan prediksi yang cukup besar yakni mencapai 96%.

Selain itu penggunaan dari CNN VGG16 ini juga ada kelebihan seperti tidak perlu melakukan analisis manual seperti perhitungan untuk mencari bagaimana pola secara matematis dari partial discharge tersebut yang dimana hal ini tentunya lebih sulit daripada membuat sistem CNN menganalisa dan membuat model deteksi partial discharge. Nantinya juga bila ada perubahan atau pola baru yang didapatkan untuk sinyal listrik yang mengalami PD ataupun tidak diluar dataset yang dipakai untuk training maka dapat dilakukan update model yang sudah dibentuk. CNN memungkinkan untuk melakukan update model dengan data baru dengan menetrain data baru terhadap model tanpa menggunakan data pada data train yang lama untuk membuat model. Dengan begitu sistem dapat senantiasa ditingkatkan mengikuti kemampuan manusia untuk mengenali pola listrik normal maupun mengalami PD. Berdasarkan hal tersebut jugalah dapat dilihat bahwa metode ini memiliki kekurangan yaitu membutuhkan metode lain yang lebih konvensional untuk membedakan sinyal PD maupun tidak yang nantinya dapat digunakan sebagai dataset sistem CNN tersebut.

4. KESIMPULAN

Berdasarkan hasil penelitian pembuatan sistem deteksi partial discharge dengan metode CNN VGG16 yang telah dibentuk, maka dapat diambil kesimpulan sebagai berikut :

1. CNN VGG16 bekerja dengan baik dalam deteksi partial discharge yaitu pada variasi dataset ketiga. Proses train memiliki peforma akurasi 95,70%, val akurasi 93,12%, loss 8,76%, dan val_loss 21,86%. Sedangkan untuk prediksinya memiliki akurasi 92,5% yaitu dengan kesalahan 39 dari 520 data dan MCC 0,75.
2. Learning rate dengan kinerja terbaik pada sistem deteksi partial discharge dengan CNN VGG16 adalah sebesar 0.00001, dengan jumlah step per epoch maksimum yang dimungkinkan oleh Model Fit Generator dan validation steps berjumlah seperempat dari jumlah steps per epoch.
3. Semakin banyak jumlah data yang digunakan dalam proses train maka akan semakin baik model yang dibentuk akan tetapi dengan catatan perbandingan jumlah antara kedua kelas yaitu partial discharge dan bukan partial discharge cukup berimbang.
4. CNN VGG16 bekerja dengan membuat model yang berupa fitur-fitur berbentuk array dari gambar-gambar dataset partial discharge, yang kemudian fitur ini digunakan untuk mengklasifikasi data gambar baru apakah mengalami partial discharge ataupun tidak berdasarkan bobot yang dimiliki terhadap kelas dari fitur tersebut.

5. SARAN

Jumlah dataset data gambar sinyal listrik yang mengalami partial discharge dan tidak sebaiknya jumlahnya berimbang, dikarenakan bila jumlah data yang digunakan untuk salah satu kelas jauh lebih banyak maka model yang terbentuk dapat lebih condong untuk memilih kelas itu.

Bila nantinya telah ada data baru yang dapat digunakan untuk train model maka model yang sudah disimpan dapat diupdate tanpa melalui training kembali untuk data yang sudah digunakan dalam pembuatan model, hanya perlu mengetrain data baru terhadap model yang ada.

DAFTAR PUSTAKA

- [1] Navies, A., Firman, A., 2020, Makalah Partial Discharge (Peluhan Sebagian)
- [2] Herawan, M., 2019, Review : Analisis Bentuk Gelombang dan Pola Urutan Pulsa maupun Pola Fasa pada Partial Discharge
- [3] Michau, G., Hsu, C., dan Fink, O., 2021, Interpretable Detection of Partial Discharge in Power Lines with Deep Learning
- [4] Dong, M., Sun, J., dan Wang, C., 2019, A Pattern Recognition Method for Partial Discharge Detection on Insulated Overhead Conductors
- [5] Johansson, A., Sandberg, O., 2018, A COMPARATIVE STUDY OF DEEP-LEARNING APPROACHES FOR ACTIVITY RECOGNITION USING SENSOR DATA IN SMART OFFICE ENVIRONMENTS
- [6] Florkowski, M., 2020, Classification of Partial Discharge Images Using Deep Convolutional Neural Networks
- [7] Saxena, P., 2020, VGG-16 CNN model dari <https://www.geeksforgeeks.org/vgg-16-cnn-model/>
- [8] Tammina, S., 2019, Transfer learning using VGG-16 with Deep Convolutional Neural Network for Classifying Images
- [9] McCullum, N., 2019, Understanding Convolutional Neural Networks

- [10] Chicco, D., Totsch, N., dan Jurman, G., 2021, The Matthews correlation coefficient (MCC) is more reliable than balanced accuracy, bookmaker informedness, and markedness in two-class confusion matrix evaluation