

Klasterisasi Kualitas Kesehatan Gardu Distribusi Pada PT. PLN Unit Layanan Pelanggan Kota Malang Dengan Kohonen *Neural Network* (KNN)

Syachbani Amin Hidayat¹, Nur Alif Mardiyah², Novendra Setyawan³

^{1,2,3}Jurusan Teknik Elektro, Universitas Muhammadiyah Malang
novendra@umm.ac.id

Abstrak- Gardu distribusi adalah suatu bangunan gardu listrik yang setiap komponennya harus bekerja secara kontinu dalam suatu sistem penyaluran energi listrik. Manajemen perbaikan atau pemeliharaan ribuan gardu distribusi harus terus dilakukan untuk memperpanjang umur operasi, mengantisipasi kerusakan yang tidak diinginkan, dan untuk memastikan gardu distribusi dapat terus bekerja dalam kondisi yang prima. Pada penelitian ini klasterisasi gardu distribusi dapat memaksimalkan manajemen gardu distribusi. Metode klasterisasi yang digunakan adalah Kohonen *neural network* (KNN) dengan hasil pengukuran *load reading and profiling* sebagai variabel klasterisasinya (persentase pembebanan arus, keseimbangan arus antar fasa, persentase arus netral, dan persentase pembebanan trafo). Hasil terbaik yang paling mendekati hasil klasterisasi secara konvensional adalah hasil pengujian kedua dengan besar kecocokan data 50,94%, di mana ada 72 unit gardu dalam klaster “Baik”, 12 unit gardu dalam klaster “Cukup”, 116 unit gardu dalam klaster “Kurang”, dan 65 unit gardu dalam klaster “Buruk”.

Kata kunci: Klasterisasi, gardu distribusi, manajemen, load reading and profiling.

I. PENDAHULUAN

Gardu distribusi adalah sistem terakhir dalam pendistribusian energi listrik dari pembangkit ke pelanggan. Masing - masing komponen gardu distribusi harus bekerja secara kontinu sehingga harus memiliki manajemen aset yang baik dalam perbaikan atau pemeliharannya. Hal tersebut bertujuan untuk memaksimalkan masa operasi gardu distribusi dan mencegah adanya kerugian dari kerusakan alat.

Manajemen sistem pendistribusian energi listrik terhadap aset gardu distribusi di Indonesia telah diatur dalam Surat Edaran Direksi PT. PLN (Persero) No. 17 tahun 2014 tentang Metode Pemeliharaan Trafo Distribusi. Pada surat edaran tersebut terdapat dua jenis inspeksi dalam menentukan kualitas kesehatan suatu gardu distribusi yaitu: *visual inspection* dan *load reading and profiling inspection* [1].

Load reading and profiling inspection adalah inspeksi utama yang paling berkontribusi dalam menentukan kualitas manajemen gardu distribusi. Pada inspeksi ini kualitas dilihat dari besar pembebanan pada transformator dan kabel jaringan tegangan rendah yang langsung diukur dari jalur tenaga masukan dan keluaran PHB-TR. Model inspeksi ini memuat 4 variabel penting seperti, persentase pembebanan arus trafo (PPT_r), persentase pembebanan arus pada jaringan tegangan rendah (PPA JTR), persentase ketidakseimbangan arus

(KAAF), dan persentase pembebanan arus netral trafo (PPA NT) [2]–[6].

Memajemen aset gardu distribusi dalam jumlah banyak dibutuhkan pengaturan skala prioritas yang mengatur tingkat kepentingan dalam melakukan perbaikan atau pemeliharaan. Ratusan aset gardu distribusi harus diawasi dan ditinjau secara konvensional oleh *user* berdasarkan hasil yang diolah secara konvensional, sehingga memiliki faktor *human error* seperti: kelelahan atau kelalaian dalam prosesnya. Berdasarkan permasalahan tersebut penentuan klasterisasi gardu distribusi dengan *learning machine* akan sangat memudahkan *user* dalam memajemen dan menentukan kualitas kesehatan gardu distribusi [7].

Pada penelitian ini *learning machine* yang paling cocok digunakan adalah Kohonen *neural network* (KNN) karena memiliki pemrosesan yang cepat, skalabilitas yang tinggi, dan mudah, sehingga dapat menghasilkan pengolahan data yang lebih akurat dan cepat untuk diterapkan pada klasterisasi gardu distribusi [8], [9]. Selain itu, penelitian ini juga menggunakan variabel *health index load reading and profiling* yang mana pemodelan data ini jauh lebih mudah didapat dan lebih sederhana dibandingkan pemodelan data pada variabel *health index (dissolved gas analysis (DGA), oil quality analysis (OQA), furans factor analysis (FFA), conductivity factor, polarization index, loss factor)* pada penelitian umumnya [6], [7], [10]–[13].

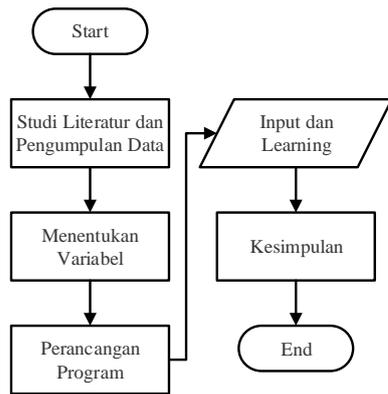
II. METODE PENELITIAN

A. Alur Pengerjaan Penelitian

Klasterisasi kualitas gardu distribusi pada penelitian ini akan dibagi menjadi 3 tahap, pertama melakukan studi literatur, pengumpulan data dan pengolahan data, kedua perancangan program Kohonen *neural network*, dan ketiga penginputan dan menjalankan program pembelajaran Kohonen *neural network* pada aplikasi MATLAB R2016a. Sebagaimana *flowchart* alur pengerjaan pada Gambar 1.

Pada tahap pertama, proses pengumpulan data dan pengolahan data diambil berdasarkan literatur yang telah dipelajari dan telah dikumpulkan selama proses praktek lapangan di PT. PLN (Persero) Unit Layanan Pelanggan Malang Kota. Pada tahap kedua, ada 4 variabel yang akan digunakan sebagai data input pada sistem klasterisasi KNN di antaranya: persentase pembebanan arus, keseimbangan arus antar fasa, persentase arus netral, dan persentase pembebanan trafo. Variabel tersebut diambil dari inspeksi *load reading and*

profiling, Tier II – Operasi HAR Gardu Distribusi seperti dalam surat edaran direksi [1].



Gambar. 1 Flowchart alur pengerjaan penelitian

Pada tahap selanjutnya, rancangan program akan menggunakan pendekatan konsep jaringan syaraf tiruan yang mampu mengidentifikasi nilai keanggotaan suatu data sehingga memungkinkan untuk melakukan klusterisasi dengan menggunakan aplikasi pembelajaran matlab. Penginputan dan pemrosesan program pembelajaran *kohonen neural network* akan dilakukan setelah menyelesaikan pengolahan data yang sudah dikumpulkan. Data pada hasil akhir setelah seluruh tahap telah selesai dilakukan, data tersebut akan menjadi laporan tertulis dalam tulisan penelitian ini.

B. Pengumpulan Data

Data yang dikumpulkan pada PT. PLN (Persero) Unit Layanan Pelanggan Malang Kota adalah data inspeksi *load reading and profiling* yang diambil bersama tim pencegahan/pemeliharaan (preventif) pada saat operasi HAR baik secara rutin, korektif dan darurat. Berikut kumpulan data lapangan yang digunakan:

1. data nomor gardu trafo tiang.
2. data spesifikasi transformator.
3. data hasil pengukuran beban per jurusan.
4. data hasil pengukuran beban total gardu distribusi.

Setelah semua data di atas didapatkan data tersebut akan diolah lagi dengan menggunakan persamaan *load reading and profiling* agar data – data tersebut bisa dimasukkan sebagai data input ke dalam program pembelajaran. Data yang digunakan dan dikelompokkan adalah data gardu distribusi umum sebanyak 265 unit.

C. Pre-processing Data

Data hasil lapangan diolah untuk menghasilkan data input persentase pembebanan arus, keseimbangan arus antar fasa, persentase arus netral, dan persentase pembebanan trafo dengan menggunakan persamaan *load reading and profiling*.

Load reading and profiling adalah salah satu model inspeksi untuk menentukan kualitas performa pada suatu gardu distribusi. Inspeksi *load reading and profiling* harus dilaksanakan secara *insourcing* dan periodik oleh petugas PLN selama 6 bulan sekali. Berikut variabel beserta persamaan untuk menghasilkan nilai bobotnya [1], [14]:

- a. Persentase pembebanan arus tegangan rendah terhadap kuat hantar arus penghantar [3].

$$I \text{ Arus TR} = \frac{I_{Rata-rata}}{KHA \text{ TR}} \times 100\% \tag{1}$$

$$I \text{ Rata - rata} = \frac{IR + IS + IT}{3} \tag{2}$$

di mana I Arus TR adalah persentase arus tegangan rendah, KHA TR adalah kuat hantar arus tegangan rendah (A), I Rata – rata adalah arus rata – rata tegangan rendah (A), dan I R,S,T adalah Beban arus fasa R, S, dan T

- b. Ketidakseimbangan beban arus antar fasa [4].

$$a = \frac{IR}{I_{Rata-rata}} \quad b = \frac{IS}{I_{Rata-rata}} \quad c = \frac{IT}{I_{Rata-rata}} \tag{3}$$

$$I \text{ KB} = \frac{(|a-1|+|b-1|+|c-1|)}{3} \times 100\% \tag{4}$$

di mana I Rata – rata adalah beban arus rata – rata (A) dan I KB adalah persentase ketidakseimbangan arus beban antar fasa.

- c. Persentase besar arus netral tegangan rendah terhadap arus beban transformator [5].

$$PI \text{ N} = \frac{I_N}{I_{Max}} \times 100\% \tag{5}$$

di mana PI N adalah persentase arus netral, I N adalah arus netral (A), I Max adalah beban arus line utama tertinggi (A).

- d. Persentase pembebanan arus pada transformator terhadap kapasitasnya [5]:

$$PI \text{ FL} = \frac{I_{Rata-Rata}}{S / \sqrt{3} \times V} \times 100\% \tag{6}$$

di mana PI FL adalah persentase pembebanan arus transformator, S adalah kapasitas transformator, V adalah nominal tegangan sekunder transformator

D. Perancangan Sistem Kohonen Neural Network

Kohonen *neural network* atau *k-nearest neighbor* adalah suatu program algoritma yang menggunakan metode *neural network* atau suatu metode yang diambil berdasarkan jaringan syaraf manusia. KNN telah diperkenalkan oleh Teuvo Kohonen pada tahun 1990 [9] dan Laurent Fausett tahun 1994 [15]. KNN dapat digunakan sebagai *supervised learning* (klasifikasi) ketika menggunakan data yang telah diketahui (*labelled data*) terhadap data yang tidak diketahui (*unlabelled data*), sehingga pada proses ini bobot unlabelled data akan diklasifikasi berdasarkan jumlah tetangga sejumlah k terdekat. KNN dapat digunakan sebagai *unsupervised learning* (klusterisasi) ketika sekelompok *unlabelled data* dikelompokkan sejumlah k kelompok tanpa dipengaruhi oleh *labelled data*. Persamaan Kohonen *neural network* [15], [8]:

$$D(j) = \sum (w_{ij} - x_i)^2 \tag{7}$$

$$w_{ij}(new) = w_{ij}(old) + \alpha [x_i - w_{ij}(old)] \tag{8}$$

di mana wij adalah bobot, xi adalah data input ke-I D(j) adalah jarak Euclidean, alpha adalah *learning rate*.

1) *Penentuan parameter*: pembatasan parameter dalam menentukan klusterisasi kualitas gardu distribusi dengan menggunakan Kohonen *neural network* harus dilakukan. Beberapa batasan yang ditetapkan [7]:

- *Learning rate* = 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8 dan 0.9, Iterasi = 100, jumlah kelas = 4, jumlah input = 4.

- Nilai pada variabel persentase pembebanan arus tegangan rendah terhadap kuat hantar arus akan menggunakan nilai persentase yang terbesar.
- Pada variabel keseimbangan beban, seluruh nilai negatif hasil hitung diabaikan.
- Penentuan kualitas kesehatan trafo berdasarkan Surat Edaran Direksi [1]. Sebagaimana Tabel 1 berikut:

TABEL 1
HEALTH INDEX LOAD READING AND PROFILLING

Load Reading and Profilling	Variabel	Baik	Cukup	Kurang	Buruk
	Persentase Pembebanan Arus	< 60%	60% ~ < 80%	80% ~ < 100%	≥ 100%
Keseimbangan Arus Antar Fasa	< 10%	10% ~ < 20%	20% ~ < 25%	≥ 25%	
Persentase Arus Netral TR	< 10%	10% ~ < 15%	15% ~ < 20%	≥ 20%	
Persentase Pembebanan Trafo	< 60%	60% ~ < 80%	80% ~ < 100%	≥ 100%	

III. HASIL DAN PEMBAHASAN

Bab ini akan membahas hasil klasterisasi data kualitas gardu distribusi yang menggunakan parameter *load reading and profilling* dengan metode Kohonen *neural network* untuk mengetahui kondisi kualitas gardu. *Load reading and profilling* akan berfungsi sebagai parameter atau batasan dasar yang digunakan PLN dalam menentukan kondisi kesehatan gardu suatu distribusi, kemudian Kohonen *neural network* berfungsi sebagai pengelompok atau pengklaster data input. Pengolahan klasterisasi data dilakukan dengan menggunakan software *learning machine* MATLAB R2016a dan disajikan berdasarkan besar variasi nilai *learning ratenya*.

A. Pemodelan Data

Pemodelan data ini harus dilakukan untuk menghasilkan data klasterisasi yang sesuai dengan standar yang berlaku di PLN. Model data latih pada penelitian ini menggunakan data parameter *health index load reading and profilling* dan membiarkan sistem menentukan 4 kelas klasterisasi secara otomatis. Berikut kutipan data latih dan data uji yang digunakan.

Data latih pada Tabel 2 di bawah, menggunakan batas bawah dari nilai masing – masing variabel pada klaster dan digunakan untuk menentukan kondisi atau predikat pada masing – masing klaster dimana klaster 1 “Baik”, klaster 2 “Cukup”, klaster 3 “Kurang”, dan klaster 4 ”Buruk”. Hal ini dilakukan agar data yang telah terklasterisasi bisa langsung dibandingkan dengan data hasil dari metode konvensional. Berikut data latih yang digunakan pada Tabel 2:

TABEL 2
DATA LATIH (BOBOT W)

Kelas	(PPAJTR)	(KAAF)	(PPANT)	(PPTr)
1	0	0	0	0
2	60	10	10	60
3	80	20	15	80
4	100	25	20	100

TABEL 3
DATA UJI KLAUSTERISASI

Nomor		PPAJTR %	KAAF %	PPANT %	PPTr %
Dt	GTT				
1	1	51,36	27,89	37,61	48,96
2	2	52,55	37,61	42,79	67,32
3	3	62,59	38,76	36,25	60,14
4	4	37,59	42,65	41,96	39,55
5	5	50,68	32,95	41,59	43,01
6	6	24,83	48,13	61,68	21,25
7	7	22,96	32,55	46,03	34,87
8	8	51,19	32,72	48,89	49,94
9	9	13,95	13,65	109,52	11,84
...
265	1538	31,29	39,38	82,22	73,90

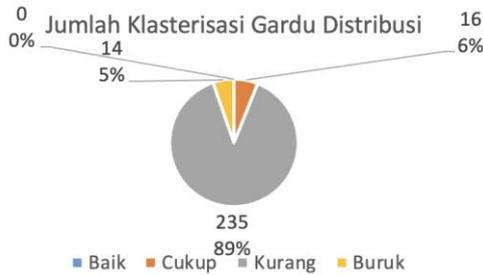
Di mana PPAJTR adalah persentase pembebanan arus jaringan tegangan rendah, KAAF adalah keseimbangan arus antar fasa, PPANT adalah persentase pembebanan arus netral trafo, dan PPTr adalah persentase pembebanan trafo.

B. Metode Konvensional PLN

Data metode konvensional ini menggunakan data dari hasil klasterisasi manual yang didapatkan dengan menggunakan parameter HI (*health index*), untuk menentukan kondisi gardu distribusi pada masing – masing variabel. Berikut penjelasan dan hasil data yang didapatkan dengan menggunakan metode konvensional PLN.

Data kondisi gardu distribusi pada Tabel 4 dibawah, didapatkan berdasarkan data hasil pengukuran dari lapangan yang golongannya ditentukan berdasarkan *health index load reading and profilling* pada Tabel 3 di atas. Sebagai contoh, variabel persentase pembebanan arus (PPAJTR) pada data 1 diatas, nilai hasil pengukuran lapangannya adalah 51,36% maka akan tergolong “Baik” karena hasil pengukurannya sama dengan 60% atau di bawahnya. Begitu juga penggolongan variabel – variabel lainnya.

Selanjutnya, data hasil klasterisasi konvensional didapatkan berdasarkan hasil dari kondisi gardu distribusi pada masing – masing variabelnya. Suatu gardu distribusi diklasterisasi “Baik” jika seluruh variabelnya tergolong baik dan akan diklasterisasi “Buruk” jika seluruh variabelnya tergolong buruk. Dalam hal ini, di lapangan umumnya *user* PLN dalam menentukan prioritas perbaikan atau pemeliharaan hanya memperhatikan nilai *sorting* pada variabel persentase pembebanan arus transformator (PPTr) karena biasanya besar angka persentase pembebanan pada suatu transformator akan mempengaruhi variabel – variabel lainnya yang ada pada gardu distribusi tersebut.



Gambar 2. Jumlah klasterisasi gardu distribusi

TABEL 4
HASIL DATA KLASTERISASI KONVENSIONAL

No	Load Reading and Profilling (%)				Kondisi Gardu Distribusi				Klas ter
	PPAJ TR	KA AF	PPA NT	PP Tr	PPAJ TR	KA AF	PP A NT	PP Tr	
1	51,36	27,89	70,59	48,96	B	Bk	Bk	B	K
2	52,55	37,61	57,30	67,32	B	Bk	Bk	C	K
3	62,59	38,76	72,41	60,14	C	Bk	Bk	C	K
4	37,59	42,65	61,70	39,55	B	Bk	Bk	B	K
5	50,68	32,95	100	43,01	B	Bk	Bk	B	K
6	24,83	48,13	72,73	21,25	B	Bk	Bk	B	K
7	22,96	32,55	72,41	34,87	B	Bk	Bk	B	K
8	51,19	32,72	69,70	49,94	B	Bk	Bk	B	K
9	13,95	13,65	100	11,84	B	C	Bk	B	C
...
265	31,29	39,38	93,24	73,90	B	Bk	Bk	C	K

Hasil data kondisi gardu distribusi dari metode konvensional diatas menghasilkan klasterisasi, 0 gardu “Baik”(B), 16 gardu “Cukup”(C), 235 gardu “Kurang”(K), dan 14 gardu “Buruk”(Bk). Pada klasterisasi konvensional ini tidak ada gardu yang tergolong baik karena variabel pada masing – masing gardu distribusi tidak ada yang memenuhi syarat klaster “Baik” pada HI. Berikut hasil datanya pada [Gambar 2](#).

C. Metode Klasterisasi KNN (Kohonen Neural Network)

Pada tahap ini klasterisasi data uji dilakukan secara otomatis menggunakan Kohonen *neural network* sesuai dengan rancangan sistem pada subbab III.C. Klasterisasi data uji pada [Tabel 3](#) akan diuji berdasarkan nilai *learning rate*: 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9 dengan maksimum iterasi 100. Kemudian data hasil pengujian akan disajikan menjadi data klaster dan data hasil klasterisasi gardu distribusi. Berikut penjelasannya:

- Maksimum iterasi yang digunakan adalah 100.
- Data latih akan menjadi karakteristik klaster tersebut karena menjadi data center.

- Perbandingan hasil data KNN dengan konvensional dilakukan sesuai dengan klaster, “Baik” (B), “Cukup” (C), “Kurang” (K), dan “Buruk” (Bk). dst.
- Persentase kecocokan data dilakukan pada hasil KNN dan konvensional, kemudian membaginya dengan jumlah data uji lalu dikali 100%.

Pada pengujian pertama dengan *learning rate* 0,1 yang ditunjukkan pada [Tabel 5](#) dan [Tabel 6](#), dihasilkan persentase kecocokan antara data KNN dan konvensional sebesar 48.30% dengan total 128 data klaster yang sama.

TABEL 5
TABEL DATA KLASTER SAJIAN DATA 1

Kelas	Data Load Reading and Profilling (%)			
	PPAJTR	KAAF	PPANT	PPTr
1	20,82	34,43	58,81	26,06
2	8,94	25,69	96,10	10,59
3	36,67	35,97	51,83	55,08
4	75,66	32,73	45,50	65,00

TABEL 6
TABEL DATA HASIL KLASTERISASI 1

Kelas	Klaster	Jumlah Gardu	Anggota yang sama	Kecocokan Data (%)
1	Baik	76	0	48,30
2	Cukup	18	8	
3	Kurang	107	106	
4	Buruk	64	14	

Pada pengujian kedua dengan *learning rate* 0,2 yang ditunjukkan pada [Tabel 7](#) dan [Tabel 8](#), dihasilkan persentase kecocokan antara data KNN dan konvensional sebesar 50,94% dengan 135 data klaster yang sama.

TABEL 7
TABEL DATA KLASTER SAJIAN DATA 2

Kelas	Data Load Reading and Profilling (%)			
	PPAJTR	KAAF	PPANT	PPTr
1	18,88	33,69	61,33	26,89
2	8,05	17,42	105,41	9,37
3	34,40	35,96	56,66	58,47
4	75,99	30,22	45,01	63,66

TABEL 8
TABEL DATA HASIL KLASTERISASI 2

Kelas	Klaster	Jumlah Gardu	Anggota yang sama	Kecocokan Data (%)
1	Baik	72	0	50,94
2	Cukup	12	7	
3	Kurang	116	114	
4	Buruk	65	14	

Pada pengujian ketiga dengan *learning rate* 0,3 yang ditunjukkan pada [Tabel 9](#) dan [Tabel 10](#), dihasilkan persentase kecocokan antara data KNN dan konvensional sebesar 43,02% dengan 114 data klaster yang sama.

TABEL 9
TABEL DATA KLASTER SAJIAN DATA 3

Kelas	Data Load Reading and Profilling (%)			
	PPAJTR	KAAF	PPANT	PPTr
1	19,86	32,73	60,23	30,36
2	7,33	14,39	104,30	7,54
3	33,43	36,07	60,91	61,34
4	75,90	28,24	44,80	63,32

TABEL 10
TABEL DATA HASIL KLASTERISASI 4

Kelas	Klaster	Jumlah Gardu	Anggota yang sama	Kecocokan Data (%)
1	Baik	71	0	43,02
2	Cukup	12	7	
3	Kurang	97	93	
4	Buruk	85	14	

Pada pengujian keempat dengan *learning rate* 0,4 yang ditampilkan pada [Tabel 11](#) dan [Tabel 12](#), diperoleh persentase kecocokan antara data KNN dan konvensional sebesar 41,51% dengan 110 data klaster yang sama.

TABEL 11
TABEL DATA KLASTER SAJIAN DATA 4

Kelas	Data Load Reading and Profilling (%)			
	PPAJTR	KAAF	PPANT	PPTr
1	18,86	32,09	58,98	30,58
2	7,04	11,34	102,02	6,39
3	32,53	36,10	65,50	63,82
4	74,43	27,13	45,51	62,57

TABEL 12
TABEL DATA HASIL KLASTERISASI 4

Kelas	Klaster	Jumlah Gardu	Anggota yang sama	Kecocokan Data (%)
1	Baik	75	0	41,51
2	Cukup	12	7	
3	Kurang	92	89	
4	Buruk	86	14	

Pada pengujian kelima dengan *learning rate* 0,5 yang ditampilkan pada [Tabel 13](#) dan [Tabel 14](#) diperoleh persentase kecocokan antara data KNN dan konvensional sebesar 23,02% dengan 61 data klaster yang sama.

TABEL 13
TABEL DATA KLASTER SAJIAN DATA 5

Kelas	Data Load Reading and Profilling (%)			
	PPAJTR	KAAF	PPANT	PPTr
1	9,99	21,76	79,94	10,88
2	31,42	37,33	69,89	69,57
3	72,77	26,33	46,40	62,08
4	26,02	31,18	51,50	38,45

TABEL 14
TABEL DATA HASIL KLASTERISASI 5

Kelas	Klaster	Jumlah Gardu	Anggota yang sama	Kecocokan Data (%)
1	Baik	56	0	23,02
2	Cukup	69	1	
3	Kurang	62	47	
4	Buruk	78	13	

Pada pengujian keenam dengan *learning rate* 0,6 yang ditunjukkan pada [Tabel 15](#) dan [Tabel 16](#) diperoleh persentase kecocokan antara data KNN dan konvensional sebesar 34,34% dengan 91 data klaster yang sama.

TABEL 15
TABEL DATA KLASTER SAJIAN DATA 6

Kelas	Data Load Reading and Profilling (%)			
	PPAJTR	KAAF	PPANT	PPTr
1	9,58	18,15	81,41	9,94
2	30,85	37,31	73,42	70,83
3	24,87	31,20	52,38	38,47
4	71,05	25,73	47,35	61,75

TABEL 16
TABEL DATA HASIL KLASTERISASI 6

Kelas	Klaster	Jumlah Gardu	Anggota yang sama	Kecocokan Data (%)
1	Baik	30	0	34,34
2	Cukup	78	1	
3	Kurang	84	77	
4	Buruk	72	13	

Pada pengujian ketujuh dengan *learning rate* 0,7 sebagaimana ditampilkan dalam [Tabel 17](#) dan [Tabel 18](#), dihasilkan persentase kecocokan antara data KNN dan konvensional sebesar 34,34% dengan 89 data klaster yang sama.

TABEL 17
TABEL DATA KLASTER SAJIAN DATA 7

Kelas	Data Load Reading and Profilling (%)			
	PPAJTR	KAAF	PPANT	PPTr
1	40,62	34,86	41,72	41,11
2	10,56	12,14	80,83	13,61
3	69,50	25,27	48,23	61,56
4	30,51	37,40	77,11	72,15

TABEL 18
TABEL DATA HASIL KLASTERISASI 7

Kelas	Klaster	Jumlah Gardu	Anggota yang sama	Kecocokan Data (%)
1	Baik	41	0	33,58
2	Cukup	45	11	
3	Kurang	88	76	
4	Buruk	91	2	

Pada pengujian kedelapan dengan *learning rate* 0,8 yang ditunjukkan dalam [Tabel 19](#) dan [Tabel 20](#) diperoleh persentase kecocokan antara data KNN dan konvensional sebesar 18,87% dengan 50 data klaster yang sama.

TABEL 19
TABEL DATA KLASTER SAJIAN DATA 8

Kelas	Data Load Reading and Profilling (%)			
	PPAJTR	KAAF	PPANT	PPTr
1	68,26	24,95	48,93	61,44
2	30,80	37,76	79,10	72,85
3	9,88	8,84	83,55	11,39
4	40,22	34,87	42,22	39,28

TABEL 20
TABEL DATA HASIL KLASTERISASI 8

Kelas	Klaster	Jumlah Gardu	Anggota yang sama	Kecocokan (%)
1	Baik	68	0	18,87
2	Cukup	84	7	
3	Kurang	49	40	
4	Buruk	64	3	

Pada pengujian kesembilan dengan *learning rate* 0,9 sebagaimana yang ditunjukkan dalam [Tabel 21](#) dan [Tabel 22](#) dihasilkan persentase kecocokan antara data KNN dan konvensional sebesar 37% dengan 99 data klaster yang sama.

TABEL 21
TABEL DATA KLASTER SAJIAN DATA 9

Kelas	Data Load Reading and Profilling (%)			
	PPAJTR	KAAF	PPANT	PPTr
1	15,23	65,97	76,95	24,53
2	9,10	5,78	86,56	8,73
3	31,07	38,38	80,83	73,40
4	67,45	24,75	49,37	61,36

TABEL 22
TABEL DATA HASIL KLASTERISASI 9

Kelas	Klaster	Jumlah Gardu	Anggota yang sama	Kecocokan Data (%)
1	Baik	42	0	37
2	Cukup	79	7	
3	Kurang	94	86	
4	Buruk	50	6	

D. Analisa Hasil Klasterisasi Kohonen Neural Network

Data yang dihasilkan dari seluruh pengujian pada subbab di atas menunjukkan bahwa hasil *learning* yang paling mendekati hasil konvensional ada pada pengujian kedua dengan besar kecocokan nilai 50,94% dengan karakteristik klaster pada [Tabel 23](#) sebagai berikut:

TABEL 23
TABEL KARAKTERISTIK KLASTER SAJIAN DATA 2

Klaster	Karakteristik Klaster <i>learning rate</i> 0,2 (%)				KNN	Konvensional	Anggota sama	Persentase (%)
	20,82	34,43	58,81	26,06				
Baik	20,82	34,43	58,81	26,06	72	0	0	0
Cukup	8,94	25,69	96,10	10,59	12	16	7	2,64
Kurang	36,67	35,97	51,83	55,08	116	235	114	43,01

Buruk	75,66	32,73	45,50	65,00	65	14	14	5,29
-------	-------	-------	-------	-------	----	----	----	------

TABEL 24
TABEL DATA GARDU HASIL KLASTERISASI

No	Penyulang	Load Reading and Profilling (%)				Konvensional	KNN
		PPAJTR	KAAF	PPANT	PPTr		
1	Patimura	51	28	71	49	K	K
2	Tenaga Baru	53	38	58	67	K	K
3	Tenaga Baru	63	39	72	60	K	K
4	Bunul	38	43	62	40	K	K
5	Bunul	51	33	100	43	K	K
6	Zainal Zakse	25	48	73	21	K	B
7	Jodipan	23	33	73	35	K	B
8	Ahmad Dahlan	51	33	70	50	K	K
9	Jodipan	14	14	100	12	C	C
...
26	Zainal Zakse	15	26	93	25	K	K

Pada [Tabel 23](#) diketahui bahwa klaster “Baik” dengan karakteristik 20,82%, 34,43%, 58,81%, dan 26,06% memiliki 72 anggota gardu dengan 0 anggota gardu yang sama dengan hasil konvensional. Pada klaster “Cukup” dengan karakteristik 8,94%, 25,69%, 96,10%, dan 10,59% memiliki 12 anggota gardu dengan 7 anggota gardu yang sama. Pada klaster “Kurang” dengan karakteristik 36,67%, 35,97%, 51,83%, dan 55,08% memiliki 116 anggota gardu dengan 114 anggota gardu yang sama. Kemudian, pada klaster “Buruk” dengan karakteristik 75,66%, 32,73%, 45,50%, dan 65,00% memiliki 65 anggota gardu dengan 14 anggota gardu yang sama.

Secara khusus kecocokan data antar klaster pada hasil pengujian kedua, yang paling besar kecocokannya adalah klaster “Kurang” yang mana dari 116 anggota gardu memiliki 114 anggota gardu yang sama dengan persentase kecocokan data antar klaster sebesar 43,01%. Dari besaran persentase tersebut menunjukkan bahwa kecocokan antar data hasil *learning* KNN dan data hasil konvensional hanya dihubungkan oleh klaster “Kurang”.

Pada [Tabel 24](#) dapat dilihat bahwa ada 130 data hasil klasterisasi secara konvensional mengalami perubahan klaster ketika data yang sama diproses menggunakan KNN dengan *learning rate* 0,2. Tiga di antaranya yang mengalami perubahan adalah gardu P0003, P0006 dan P0007 yang dapat dilihat pada [Tabel 24](#) diatas. Gardu P0003 dengan karakteristik 62,59% - 38,76% - 72,41% - 60,14% termasuk klaster “Kurang” pada hasil klasterisasi konvensional dan berubah menjadi klaster “Buruk” pada hasil klasterisasi KNN. Hal ini terjadi karena

klasterisasi KNN memiliki fleksibilitas dalam melakukan pengelompokan data sehingga KNN mampu melengkapi seluruh data kelas yang tersedia menggunakan data yang ada. Namun, akan berbanding terbalik terhadap hasil klasterisasi yang dilakukan secara konvensional. Di mana data diproses secara tegas atau baku sesuai dengan parameter yang telah ditetapkan sehingga membuat hasil klasterisasi data gardu distribusi tidak memiliki data klaster “Baik” dan data yang dihasilkan bertumpuk pada salah satu klaster, yaitu “Kurang”.

Analisa berikutnya, nilai maksimal kecocokan data hanya mencapai 50,94%. Hal ini terjadi karena beberapa hal. Pertama, karena adanya perbedaan pada proses penentuan klaster antara hasil data yang dilakukan secara konvensional dengan hasil data yang dilakukan dengan learning machine KNN. Kedua, karena data hasil pengukuran lapangan atau data uji yang didapatkan tidak dapat melengkapi seluruh klaster yang tersedia.

Penjelasan poin pertama, pada klasterisasi konvensional, data uji menggunakan batasan yang baku dimana ketika ada salah satu variabel termasuk dalam kelompok selain “Baik” maka akan langsung masuk ke dalam kelompok “Cukup” dst. Contoh, dengan menggunakan karakteristik klaster “Baik” pada table 4.23 (20,82%, 34,43%, 58,81%, 26,06%) diatas maka data tersebut akan masuk dalam klaster “Cukup” karena variabel ke-2 (34,43%) dan ke-3 (58,81%) termasuk kedalam kelompok “Buruk” berdasarkan parameter *load reading and profiling*. Sedangkan pada KNN data diatas termasuk dalam kelompok “Cukup”, karena KNN menggunakan data latih sebagai *data center* (pusat) yangmana data tersebut terus diperbarui setiap ada data baru yang masuk menjadi anggota klasternya. Hal inilah yang membuat data gardu distribusi P0006 dan P0007 berubah kelompok dari klaster “Kurang” menjadi klaster “Baik” karena seluruh variabel P0006 dan P0007 memiliki ciri – ciri variabel yang sama dengan data center pada klaster “Baik”.

Penjelasan poin kedua, besar maksimal nilai persentasi kecocokan data konvensional dan KNN hanya mencapai 50,94% terjadi karena tidak adanya data uji yang mampu menempati klaster “Baik” sehingga KNN tidak dapat membuat data center yang sesuai dengan parameter *load reading and profiling*. Sehingga, untuk meningkatkan nilai kecocokan antara data konvensional dan *learning KNN* ada beberapa cara yang dapat dilakukan diantaranya: pertama, menentukan perbaikan pada penentuan klaster secara manual, yaitu dengan melakukan batasan kontribusi pada masing – masing variabel yang digunakan, kedua, penentuan variabel yang lebih baik, seperti halnya mengabaikan variabel PPANT atau membatasi kontribusinya karena sudah pasti seluruh gardu distribusi yang bekerja di bawah 40% kapasitasnya akan mengalami persentase arus netral dan ketidakseimbangan beban yang tinggi dan yang terakhir, data uji yang mampu mengisi seluruh klaster yang tersedia, yaitu dengan mengambil data uji dari lokasi yang berbeda yangmana seluruh data hasil pengukuran lapangan tersebut mampu mengisi seluruh klaster yang tersedia.

IV. KESIMPULAN

A. Kesimpulan

Klasterisasi kualitas gardu distribusi dengan menerapkan metode *load reaing and profiling* PLN ke dalam sistem *learning machine kohonen neural network* telah berhasil dilakukan. Pada proses klasterisasi secara konvensional didapati hasil data, 0 unit gardu klaster “Baik”, 16 unit gardu klaster “Cukup”, 235 unit gardu klaster “Kurang”, dan 14 unit gardu klaster “Buruk”. Kemudian, pada pengujian data menggunakan Kohonen *neural network* didapati hasil terbaik yang paling mendekati hasil konvensional adalah hasil pengujian kedua dengan persentase 50,94% dan yang paling buruk atau menjauhi hasil konvensional adalah pengujian kedelapan dengan persentase 18,87%.

Pada pengujian kedua dengan nilai terdapat 72 unit gardu distribusi yang termasuk dalam klaster “Baik”, 12 unit gardu distribusi pada klaster “Cukup”, 116 unit gardu distribusi pada klaster “Kurang”, dan 65 unit gardu distribusi pada klaster “Buruk”. Selain itu, pengujian kedua ini juga merubah atau mengevaluasi 130 data klaster hasil klasterisasi konvensional yang tiga diantaranya adalah data gardu distribusi P0003 yang termasuk dalam klaster “Kurang” menjadi “Buruk”, P0006 dan P0007 yang termasuk dalam klaster “Kurang” menjadi “Baik”.

B. Saran

Hasil persentase kecocokan data hasil klasterisasi konvensional PLN dengan klasterisasi KNN dapat diperbesar atau diperbaiki dengan melakukan beberapa perbaikan. Pertama melakukan perbaikan pada penentuan klaster secara manual, yaitu dengan melakukan batasan kontribusi pada masing – masing variabel yang digunakan. Selanjutnya, melakukan penentuan variabel yang lebih baik, seperti halnya mengabaikan variabel persentase pembebanan arus netral trafo atau membatasi kontribusinya karena sudah pasti seluruh gardu distribusi yang bekerja di bawah 40% kapasitasnya akan mengalami persentase arus netral dan ketidakseimbangan beban yang tinggi dan yang terakhir, menggunakan data uji yang mampu mengisi seluruh klaster yang tersedia, yaitu dengan mengambil data uji dari lokasi yang berbeda yangmana seluruh data hasil pengukuran lapangan tersebut mampu mengisi seluruh klaster yang tersedia.

REFERENSI

- [1] I. W. Y. Prasetya, I. N. Setiawan, dan I. G. D. Arjana, “Analisis ketidakseimbangan beban dan harmonisa pada transformator distribusi MI 0096 penyulang Abianbase,” *J. Spektrum*, vol. 7, no. 1, pp. 109–115, 2020.
- [2] S. Hidayat, S. Legino, dan N. F. Mulyanti, “Penyeimbangan beban pada jaringan tegangan rendah gardu distribusi Cd 33 penyulang Sawah di PT PLN (Persero) Area Bintaro,” *SUTET*, vol. 8, no. 1, pp. 21–27, 2018.
- [3] A. Bachtiar dan M. I. Samindha, “Studi analisa kinerja transformator pemakaian sendiri PT. PLN (Persero) Sektor Bukittinggi PLTA Batang Agam dengan menggunakan ESA,” *J. Tek. Elektro*, vol. 7, no. 2, pp. 133–142, 2018.
- [4] S. Pranoto, S. Sofyan, dan N. N. Rusli, “Penyeimbangan beban pada trafo distribusi penyulang Akkarena di Unit Layanan Pelanggan Mattoanging PT PLN (Persero),” in *Seminar Nasional Teknik Elektro dan Informatika (SNTEI)*, 2020, pp. 37–46.
- [5] D. Kongah, M. Sarjan, dan B. Mukhlis, “Analisis pembebanan transformator Gardu Selatan Kampus Universitas Tadulako,” *Mektrik*, vol. 1, no. 1, 2014.
- [6] S. Bahri, “Studi penambahan beban transformator daya pada gardu Induk Parit Baru PT. PLN (Persero) Cabang Pontianak,” *J. Tek. Elektro*

- Univ. Tanjungpura*, vol. 2, no. 1, 2015.
- [7] A. Alqudsi dan A. El-Hag, "Application of machine learning in transformer health index prediction," *Energies*, vol. 12, no. 14, p. 2694, 2019.
- [8] T. Khotimah, A. Syukur, dan M. A. Soeleman, "Clustering trafo distribusi menggunakan algoritma Self-Organizing Map," *Simetris J. Tek. Mesin, Elektro dan Ilmu Komput.*, vol. 8, no. 1, pp. 15–20, 2017.
- [9] T. Kohonen, "The self-organizing map," *Proc. IEEE*, vol. 78, no. 9, pp. 1464–1480, 1990.
- [10] B. Gorgan, P. V Notingher, L. V Badicu, dan G. Tanasescu, "Calculation of power transformers health indexes," *Ann. Univ. Craiova, Electr. Eng. Ser.*, vol. 34, pp. 13–18, 2010.
- [11] A. Jahromi, R. Piercy, S. Cress, J. Service, dan W. Fan, "An approach to power transformer asset management using health index," *IEEE Electr. Insul. Mag.*, vol. 25, no. 2, pp. 20–34, 2009.
- [12] G. D. Miner *et al.*, *Practical Predictive Analytics And Decisioning Systems For Medicine: Informatics Accuracy And Cost-Effectiveness For Healthcare Administration And Delivery Including Medical Research*. Academic Press, 2014.
- [13] B. Soeroso, Y. D. Y. Rindengan, dan L. S. Patras, "Identifikasi gardu distribusi tenaga listrik di Kota Manado berbasis sistem informasi geografis," *J. Tek. Elektro dan Komput.*, vol. 5, no. 1, pp. 21–27, 2016.
- [14] P. T. PLN, *Standar Kontruksi Gardu Distribusi Dan Gardu Hubung Tenaga Listrik*, PT. PLN (Persero), Jalan Trunajoyo Blok M-1/kebayoran lama, Jakarta Selatan, 2010.
- [15] L. V Fausett, *Fundamentals Of Neural Networks: Architectures, Algorithms And Applications*. Pearson Education India, 2006.