

UJI HOMOGENITAS DAN HETEROGENITAS CLUSTER DATA INTERKOMPARASI ANAK TIMBANGAN

Arif Fajar Solikin¹, Kusrini², Ferry Wahyu Wibowo³

^{1,2,3}Magister Teknik Informatika Universitas AMIKOM Yogyakarta,

e-mail: arif.1311@students.amikom.ac.id, kusrini@amikom.ac.id,
ferry.w@amikom.ac.id

Abstract

Intercomparison of mass quantities is an activity to compare performance between laboratories of mass quantities and reference laboratories which produces intercomparative data in the form of conventional mass values and uncertainty values. Clustering of weights was carried out to obtain an analysis of the laboratory's participants management. The analysis carried out is very dependent on the accuracy of the cluster. Clustering using self-organizing maps algorithm, and the results are tested for the level of homogeneity within the cluster and the level of heterogeneity between clusters using the icdrate value. The clustering of intercomparison's data using the self-organizing maps method resulted in an icdrate value of 0,0713 for an artifact of 1000 g and an icdrate of 0,2889 for an artifact of 200g.

Keywords: Cluster, icdrate, Intercomparison

PENDAHULUAN

Jaminan kebenaran hasil pengukuran transaksi perdagangan yang menggunakan alat ukur metrologi legal salah satunya dilakukan dengan membandingkan unjuk kerja laboratorium metrologi di setiap unit metrologi legal kabupaten / kota dengan laboratorium acuan (referensi). Kegiatan membandingkan unjuk kerja laboratorium disebut dengan interkomparasi.

Interkomparasi atau interlaboratory comparison adalah organisasi, kinerja dan evaluasi pengukuran atau tes pada dua laboratorium atau lebih sesuai dengan kondisi yang telah ditentukan[1]. Interkomparasi atau disebut juga dengan istilah uji profisiensi telah menjadi aspek penting dalam praktik laboratorium di semua bidang pengujian, kalibrasi, dan inspeksi. Sebagian besar skema uji profisiensi memiliki ciri umum berupa perbandingan hasil dari satu laboratorium dengan hasil dari satu atau lebih laboratorium yang berbeda. Sifat pengujian atau pengukuran yang dilakukan dalam interkomparasi dimaksudkan untuk membandingkan kinerja laboratorium. Dapat disimpulkan bahwa tujuan dari interkomparasi adalah untuk mengetahui kemampuan atau unjuk kerja dari suatu laboratorium.

Ada tiga jenis pemeriksaan laboratorium dasar: kuantitatif, kualitatif dan interpretatif[2].

1. Hasil pengukuran kuantitatif adalah numerik dan dilaporkan dalam skala interval atau rasio. Pengujian untuk pengukuran kuantitatif dapat bervariasi dalam presisi, kebenaran, kepekaan analitis, dan kekhususan. Dalam skema pengujian profisiensi kuantitatif, hasil numerik biasanya dianalisis secara statistik.
2. Hasil tes kualitatif bersifat deskriptif dan dilaporkan dalam skala kategorikal atau ordinal, misalnya identitas mikro-organisme, atau dengan identifikasi adanya ukuran tertentu (seperti obat atau penilaian suatu karakteristik). Penilaian kinerja dengan analisis statistik mungkin tidak sesuai untuk pemeriksaan kualitatif.

3. Dalam tes interpretatif, uji profisiensi berupa hasil tes seperti pernyataan morfologi deskriptif, atau satu set data (misalnya untuk menentukan garis kalibrasi) atau satu set informasi lainnya misalnya studi kasus tentang fitur interpretatif dari kompetensi peserta.

Interkomparasi dilakukan pada besaran massa yaitu anak timbangan dimana hasil interkomparasi berupa data yang memuat massa konvensional uji anak timbangan beserta nilai ketidakpastian pada level kepercayaan 95%[3]. Data ini kemudian dilakukan perhitungan dengan menggunakan metode derajat kesetaraan (Degrees of Equivalent / DoE) atau yang lebih dikenal sebagai rasio EN yang mengacu pada ISO/IEC 17043:2010. Hasilnya berupa pernyataan kesetaraan laboratorium peserta interkomparasi, laboratorium dinyatakan setara jika nilai $EN \leq 1$ [3]. Selama ini laboratorium akan menerima hasil berupa nilai En dengan status inlier atau outlier. Untuk status inlier umumnya laboratorium dalam kondisi normal seperti laboratorium acuan, namun jika statusnya outlier laboratorium perlu melakukan identifikasi sumber masalahnya secara mandiri.

Identifikasi dapat dilakukan dengan menggunakan salah satu teknik data mining dengan melakukan clustering[4]. *Clustering* data interkomparasi dilakukan dengan memakai algoritma *self organizing maps*. *Clustering* atau pengelompokan data dilakukan supaya data hasil interkomparasi dari masing-masing laboratorium yang memiliki permasalahan yang sama atau sumber ketidakpastian yang sama dapat diidentifikasi. Identifikasi perlu dilakukan khususnya oleh penyelenggara interkomparasi agar dapat memberikan bimbingan dan rekomendasi perbaikan pengelolaan laboratorium metrologi legal kepada unit metrologi legal yang menjadi peserta interkomparasi. Penggunaan algoritma *self organizing maps* didasarkan pada cara kerja algoritma dalam menyederhanakan dimensi data dan hubungan antar neuron pada layer input dan output yang secara terus menerus memperbarui bobotnya sehingga diperoleh kesamaan ciri antar anggota dalam cluster yang sama[4].

Penggunaan algoritma *self organizing maps* beberapa waktu ini telah dapat ditemukan dari hasil penelitian yang telah dilakukan sebelumnya. Ni Putu Nanik melakukan penelitian yang mengkombinasikan penggunaan algoritma *self organizing maps* dengan k means untuk menentukan ketepatan *clustering*. Proses *clustering* dilakukan dengan menentukan vector node yang dipilih untuk selanjutnya ditentukan BMU nya dengan node lain[5]. Penelitian lainnya oleh IY Purbasari et al, yang melakukan *clustering* minat jurusan pada pelajar SMU dengan data yang dinormalisasi pada rentang 0 sampai dengan 1. Data yang sudah dinormalisasi kemudian dilakukan *clustering* dengan menetapkan jumlah iterasi dan nilai learning rate-nya[6]. Penelitian lain yang dilakukan Siti Kania et al pada pembuatan aplikasi *clustering* data IPM Aceh dengan menggunakan *bubble function* sebagai *neighborhood function* dimana radius *neighborhood* sama dengan nol. Fungsi *bubble* dipilih dengan alasan proses komputasi lebih cepat dan kuantisasi kesalahan lebih kecil[7]. Penelitian selanjutnya oleh Firmansyah et al adalah pengelompokan wilayah berdasarkan kesejahteraan sosial menggunakan *Silhouette Coefficient* untuk mengukur kualitas hasil *clustering* dengan membatasi nilai rentang lebih dari 1[8]. Penelitian yang dilakukan oleh Sivakkumaran Lakshminarayanan, mencoba menentukan pengelompokan penggunaan BBM berdasar data manuver pengemudi kendaraan dengan menggunakan perluasan algoritma SOM yaitu *super organizing maps*[9]. Dimana data input dibedakan menjadi 4 (empat) layer, masing-masing layer kemudian dilakukan proses pengelompokan. Penelitian terakhir oleh Jin Tian dan Mengyi Gu menentukan subruang pada neuron

dengan tujuan mereduksi noise pada data. Algoritma SOM menghasilkan cluster yang mungkin dari setiap dimensi, kemudian dilakukan proses penggabungan untuk menggabungkan file kelompok neuron dan subruang yang sesuai dengan dimensi terkait[10]. Hasil pengelompokan akhir disimpulkan dari cluster neuron yang terbentuk dengan mengganti setiap neuron dengan poin data di dalamnya.

Penelitian-penelitian tersebut telah menerapkan algoritma *self organizing maps* untuk pengelompokan data dengan tujuan yang berbeda-beda. Evaluasi *clustering* perlu dilakukan untuk mendapatkan ketepatan pengelompokan data. *Clustering* dikatakan berhasil jika cluster yang terbentuk memiliki kesamaan anggota dalam cluster yang tinggi dan kesamaan antar cluster yang rendah. Penelitian ini akan menguji tingkat homogenitas dan heterogenitas cluster yang dihasilkan melalui algoritma *self organizing maps*.

METODE PENELITIAN

Data Interkomparasi anak timbangan berupa nilai massa konvensional dan nilai ketidakpastian yang bersumber dari budget ketidakpastian pengujian. Data tersebut kemudian dihitung nilai rasio EN nya dengan menggunakan persamaan berikut[1]:

$$E_N = \left| \frac{x_i - x_{ref}}{\sqrt{U_i^2 + U_{ref}^2}} \right| \quad (1)$$

Dimana,

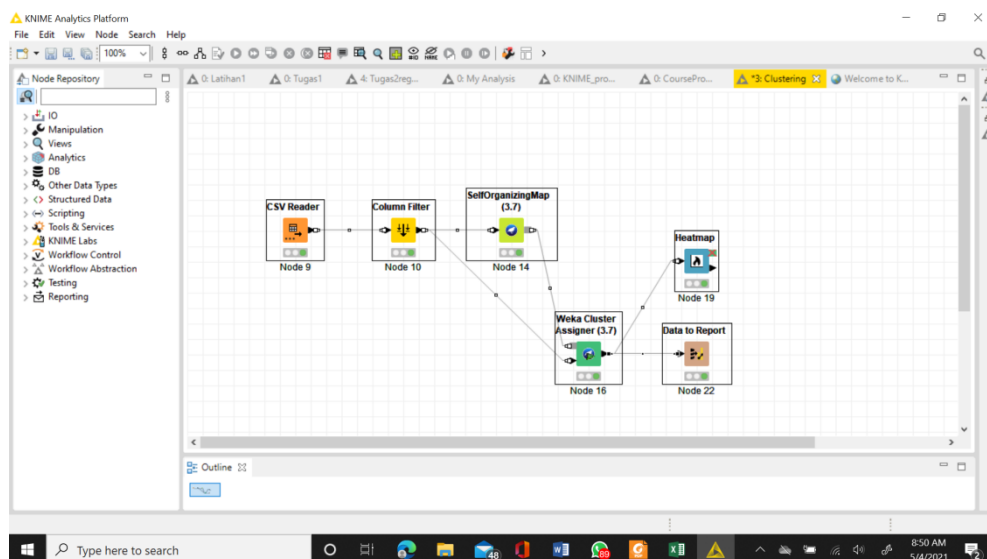
x_i merupakan nilai koreksi anak timbangan pada laboratorium peserta dengan i merujuk pada urutan no peserta interkomparasi.

x_{ref} merupakan nilai koreksi anak timbangan pada laboratorium referensi.

U_i merupakan ketidakpastian laboratorium peserta pada level kepercayaan 95%.

U_{ref} merupakan ketidakpastian laboratorium referensi pada level kepercayaan 95%.

Setelah diperoleh nilai rasio EN, data kemudian dikelompokkan dengan menggunakan algoritma *self organizing maps* yang terdapat pada KNIME platform analytics yang merupakan platform analisis, pelaporan, dan integrasi data yang bersifat opensource. KNIME menyatukan berbagai komponen dalam bidang machine learning dan data mining dengan konsep alur data yang modular seperti pada gambar 1.



Gambar 1. Clustering dengan platform KNIME

Uji Homogenitas dan Heterogenitas Cluster

Hasil clustering selanjutnya dilakukan evaluasi dengan menguji nilai homogenitas dan heterogenitas cluster yang terbentuk. Kluster terbaik untuk mengelompokkan obyek memiliki nilai homogenitas antar anggota dalam satu kluster yang tinggi dan memiliki nilai heterogenitas antar kluster yang tinggi. Dengan kata lain variasi antar anggota dalam satu kluster harus rendah sedangkan variasi antar kluster harus tinggi. Untuk menentukan kriteria kluster terbaik dapat digunakan nilai icdrate. Icdrate (internal cluster dispersion) menggambarkan tingkat dispersi atau perbedaan dalam kluster[11]. Nilai icdrate yang semakin kecil menunjukkan bahwa kluster tersebut semakin baik sebab antara anggota dalam satu kluster memiliki perbedaan yang rendah atau memiliki variasi yang kecil.

Nilai icdrate dapat diperoleh dengan menggunakan persamaan:

$$icdrate = 1 - \frac{SSB}{SST} \quad (2)$$

$$SSB = \sum_{j=1}^c \sum_{k=1}^p (\bar{X}_{jk} - \bar{X}_j)^2 \quad (3)$$

$$SST = \sum_{i=1}^n \sum_{j=1}^c \sum_{k=1}^p (X_{ijk} - \bar{X}_j)^2 \quad (4)$$

Dimana :

SSB (Sum Square Between) : Total jumlah dari kuadrat jarak variabel terhadap rata-rata keseluruhan

SST (Sum Square Total) : Total jumlah dari kuadrat jarak sampel terhadap rata-rata keseluruhan

n : banyaknya sampel

x_{jk} : rata-rata sampel pada variabel ke-j dan kelompok ke-k

x_j : rata-rata sampel pada variabel ke-j

x_{ijk} : sampel ke-i pada variabel ke-j kelompok ke-k

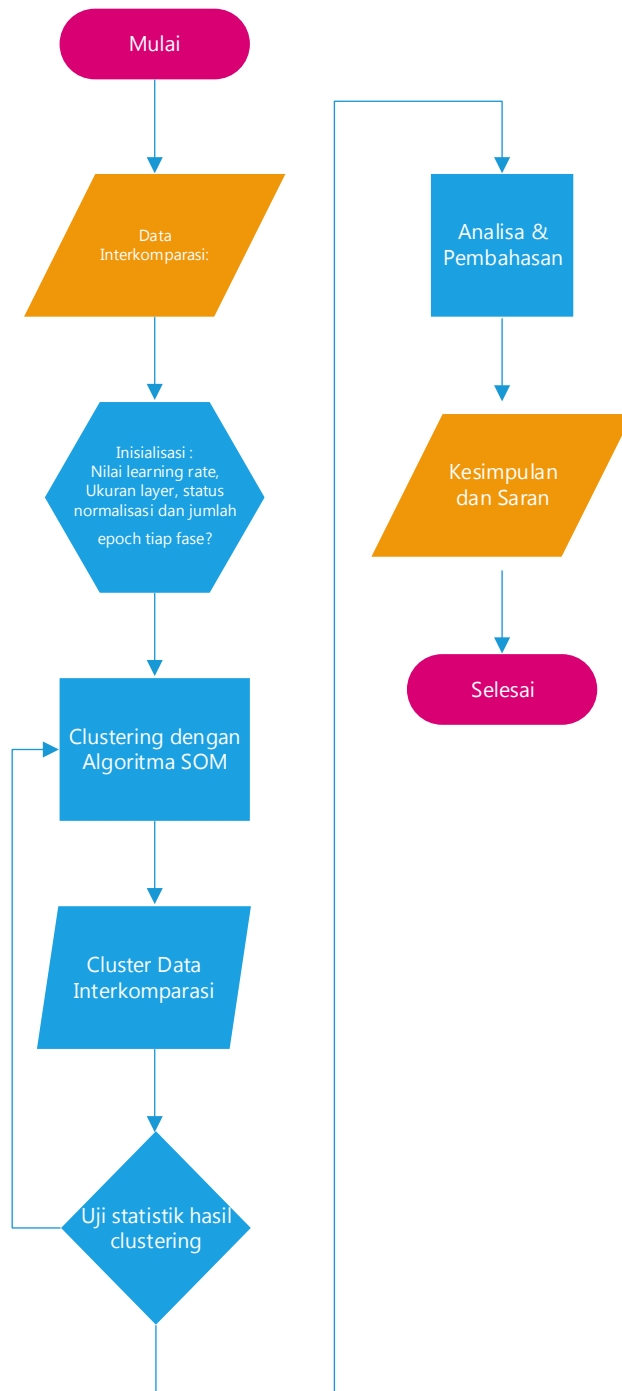
c : banyaknya variabel

p : banyaknya kelompok

Metode yang digunakan dapat dijelaskan dalam alur penelitian sebagai berikut:

1. Tahap pengumpulan data interkomparasi anak timbangan. Data ini diperoleh dari kegiatan interkomparasi tahun 2021 yang diselenggarakan oleh Balai Standardisasi Metrologi Regional II dengan jumlah peserta sebanyak 36 laboratorium. Data berupa nilai massa konvensional anak timbangan dan nilai budget uncertainty untuk artefak 1 kg dan artefak 200 g, sehingga akan terkumpul sebanyak 72 data. Dari data yang terkumpul kemudian dilakukan perhitungan nilai rasio EN nya. Data Nilai rasio EN dan data budget uncertainty dari laboratorium peserta interkomparasi akan dilakukan proses pengelompokan data dengan menggunakan algoritma SOM.
2. Sebelum clustering dilakukan terlebih dahulu ditentukan nilai parameter dari learning rate, jumlah epoch pada fase order dan fase konvergen, dan ukuran tinggi lebarnya lattice / layer.
3. Setelah inisialisasi, selanjutnya dilakukan proses clustering dengan algoritma SOM. Proses clustering dilakukan dengan menggunakan platform KNIME analytic. Hasil clustering kemudian dievaluasi secara statistik dengan menghitung nilai internal cluster dispersion (icdrate). Nilai yang dicari adalah nilai icdrate yang mendekati nol tapi tidak kurang sama dengan nol ($> \neq 0$). Jika nilai icdrate masih terlalu besar maka

- dilakukan inialisasi ulang nilai parameter dan dilakukan clustering kembali.
4. Setelah didapatkan hasil clustering dan hasil evaluasi kemudian dilakukan analisa dan pembahasan hasil.
 5. Tahapan terakhir dalam penelitian ini adalah menarik kesimpulan yang diperoleh dari eksperimen dan memberikan saran untuk penelitian selanjutnya.



Gambar 2 Alur Penelitian

HASIL DAN PEMBAHASAN

Pada gambar 1 clustering dilakukan dengan menggunakan platform KNIME, data interkomparasi disimpan dalam format .csv kemudian dibaca melalui hub csv reader, selanjutnya dilakukan filtering pada kolom data. Proses selanjutnya pada hub *self organizing maps*, diberikan inialisasi awal nilai parameter nilai dari *learning rate*, tinggi dan lebar *lattice* serta jumlah *epoch* untuk fase *ordering* dan fase *convergence* seperti tabel 1 berikut:

Tabel 1. Nilai Parameter Percobaan Clustering dengan Algoritma SOM

Percobaan ke	learning rate	tinggi lattice	lebar lattice	Epoch _o	Epoch _c	Normalisasi
1	0,8	2	3	6000	2000	True
2	0,8	1	3	6000	2000	True
3	0,8	1	2	6000	2000	True
4	0,8	2	2	6000	2000	True
5	0,8	2	3	6000	2000	False
6	0,8	1	3	6000	2000	False
7	0,8	1	2	6000	2000	False
8	0,8	2	2	6000	2000	False

Artefak yang digunakan dalam kegiatan interkomparasi berupa artefak anak timbangan kelas M_1 dengan massa nominal 1 kg sebanyak 2 unit yang dibedakan identitasnya dalam artefak 1 kg A dan artefak 1 kg B, serta artefak anak timbangan kelas M_2 dengan massa nominal 200 g sebanyak 2 unit yang dibedakan identitasnya dalam artefak 200 g A dan artefak 200 g B. Interkomparasi diikuti oleh 36 kabupaten / kota di pulau Jawa, dimana masing-masing kabupaten / kota diberikan inisial kode peserta A yang menandakan penggunaan artefak A dan inisial kode B yang menandakan penggunaan artefak B. Dari kegiatan interkomparasi loop I (diikuti oleh 12 kabupaten / kota) diperoleh data sebagai berikut :

Tabel 2. Data Interkomparasi Anak Timbangan Loop I Tahun 2021

Kode	Mc 1kg	Uc 1kg	En	Ur	Ud	Ustd	Udrif	Ub	Mc 200g	Uc 200g	En	Ur	Ud	Ustd	Udrif	Ub
A1 (acuan)	1000.0053	0.0031		0.0000416	0.0000408	0.0008	0.000739	0.0011085	200.00062	0.00057		0.0000415	0.0000041	0.00025	0.0001386	0.0000222
A2	999.99	0.0087	1.2966	0.000000	0.004083	0.000800	0.000739	0.001109	200.0000	0.0082	0.0308	0.000000	0.004083	0.000250	0.000139	0.000222
A3	1000.0170	0.012	0.7748	0.004082	0.002300	0.010607	0.000000	0.001109	200.0030	0.010	0.3094	0.000408	0.000500	0.002475	0.000000	0.000222
A4	1000.0025	0.011	0.1947	0.002850	0.004080	0.002300	0.000740	0.001110	199.9999	0.0032	0.0455	0.000040	0.000040	0.001500	0.000460	0.000220
A5	1000.0039	0.0090	0.1157	0.001300	0.004100	0.000800	0.000200	0.001100	200.00015	0.00067	0.3387	0.000000	0.000000	0.000300	0.000000	0.000200
A6	1000.0394	0.0030	5.5902	0.000200	0.000400	0.000600	0.000700	0.001100	200.001	0.0010	0.8089	0.000000	0.000400	0.000200	0.000100	0.000200
A7	1000.0013	0.0098	0.3101	0.000000	0.004080	0.001480	0.002310	0.000069	199.9993	0.0028	0.1276	0.000047	0.000041	0.000255	0.001390	0.000069
B1 (acuan)	1000.0037	0.0031		0.000042	0.000041	0.000800	0.000739	0.001109	200.00101	0.00057		0.000012	0.000004	0.000250	0.000139	0.000022
B2	1000.0006	0.0087	0.2585	0.000000	0.004100	0.000800	0.000800	0.001100	200.00005	0.0083	0.0932	0.000000	0.004100	0.000300	0.000500	0.000200
B3	1000.0036	0.0091	0.0041	0.001900	0.004100	0.000800	0.000200	0.001100	200.0015	0.0011	0.3743	0.000300	0.000400	0.000300	0.000000	0.000200
B4	1000	0.011	0.2589	0.003350	0.004082	0.000145	0.000739	0.001109	200.0024	0.009200	0.1561	0.002134	0.004082	0.000050	0.000139	0.000222
B5	999.996	0.010	0.5840	0.002500	0.004100	0.000600	0.000700	0.001100	200.003	0.010	0.2010	0.002500	0.004100	0.000200	0.000100	0.000200
B6	1000.0031	0.003300	0.0859	0.000342	0.000408	0.000800	0.000739	0.001108	200.00105	0.000740	0.1336	0.000052	0.000041	0.000250	0.000139	0.000222
B7	1000.0072	0.009300	0.2863	0.001670	0.004080	0.000800	0.000740	0.001110	200.00114	0.000720	0.2054	0.000030	0.000040	0.000250	0.000140	0.000220

Data – data tersebut kemudian dikelompokkan dengan menggunakan algoritma *self organizing maps* sesuai dengan nilai parameter pada tabel 1. Data yang dikelompokkan berupa nilai En dan budget uncertainty yang terdiri dari :

1. Ketidakpastian repeatability timbangan (U_r);
2. Ketidakpastian akibat daya baca / resolusi timbangan (U_d);
3. Ketidakpastian anak timbangan standar yang digunakan (U_{std});
4. Ketidakpastian drift atau pergeseran nilai dari anak timbangan standar (U_{drift});
5. Ketidakpastian akibat bouyancy udara (U_b).

Berikut hasil clustering data interkomparasi artefak 1 kg menggunakan algoritma *self organizing maps* :

Tabel 3. Percobaan ke-1

Row ID	S Kode	D En Ik	D Ur	D Ud	D Ustd	D Udri	D Ub	D Cluster0	D Cluster1	D Cluster2	D Cluster3	D Cluster4	D Cluster5	I Winner ...
Kab Kediri	A2	1.297	0	0.004	0.001	0.001	0.001							0
Kab Demak	A3	0.775	0.004	0.002	0.011	0	0.001							5
Kab Semarang	A4	0.195	0.003	0.004	0.002	0.001	0.001							3
Kota Magelang	A5	0.116	0.001	0.004	0.001	0	0.001							3
Kota Cimahi	A6	5.59	0	0	0.001	0.001	0.001							2
Kota Semarang	A7	0.31	0	0.004	0.001	0.002	0							0
Kab Temang...	B2	0.258	0	0.004	0.001	0.001	0.001							0
Kab Banyumas	B3	0.004	0.002	0.004	0.001	0	0.069							3
Kab Kuningan	B4	0.259	0.003	0.004	0	0.001	0.001							3
Kab Pekalongan	B5	0.584	0.003	0.004	0.001	0.001	0.001							3
Kab Bojonegoro	B6	0.086	0	0	0.008	0.001	0.001							2
Kab Kudus	B7	0.286	0.002	0.004	0.001	0.001	0.001							3

Pada percobaan ke-1 terdapat 6 cluster terbentuk dimana 2 cluster diantaranya tidak mempunyai anggota. Cluster yang tidak mempunyai anggota disebabkan oleh 2 hal, ukuran dimensi layer dan perlakuan datanya (dinormalisasi atau tidak). Tujuan data dinormalisasi adalah untuk mendapatkan data dengan ukuran yang lebih kecil namun masih mewakili data aslinya. Data interkomparasi memiliki rentang nilai yang tidak terlalu besar, sehingga data asli tidak perlu dilakukan normalisasi.

Tabel 4. Percobaan ke-5 (tidak dinormalisasi)

Row ID	S Kode	D En Ik	D Ur	D Ud	D Ustd	D Udri	D Ub	D Cluster0	D Cluster1	D Cluster2	D Cluster3	D Cluster4	D Cluster5	I Winner ...
Kab Kediri	A2	1.297	0	0.004	0.001	0.001	0.001							2
Kab Demak	A3	0.775	0.004	0.002	0.011	0	0.001							4
Kab Semarang	A4	0.195	0.003	0.004	0.002	0.001	0.001							0
Kota Magelang	A5	0.116	0.001	0.004	0.001	0	0.001							1
Kota Cimahi	A6	5.59	0	0	0.001	0.001	0.001							5
Kota Semarang	A7	0.31	0	0.004	0.001	0.002	0							4
Kab Temang...	B2	0.258	0	0.004	0.001	0.001	0.001							1
Kab Banyumas	B3	0.004	0.002	0.004	0.001	0	0.069							3
Kab Kuningan	B4	0.259	0.003	0.004	0	0.001	0.001							3
Kab Pekalongan	B5	0.584	0.003	0.004	0.001	0.001	0.001							4
Kab Bojonegoro	B6	0.086	0	0	0.008	0.001	0.001							1
Kab Kudus	B7	0.286	0.002	0.004	0.001	0.001	0.001							3

Perlakuan data yang tidak dinormalisasi ditunjukkan pada tabel 4 percobaan ke-5, dimana terdapat 6 cluster terbentuk dan masing-masing cluster memiliki anggota. Demikian juga hasil percobaan yang ditunjukkan pada tabel 5 dan tabel 6 berikut.

Tabel 5. Percobaan ke-2

Row ID	S Kode	D En Ik	D Ur	D Ud	D Ustd	D Udri	D Ub	D Cluster0	D Cluster1	D Cluster2	I Winner ...
Kab Kediri	A2	1.297	0	0.004	0.001	0.001	0.001				0
Kab Demak	A3	0.775	0.004	0.002	0.011	0	0.001				2
Kab Semarang	A4	0.195	0.003	0.004	0.002	0.001	0.001				0
Kota Magelang	A5	0.116	0.001	0.004	0.001	0	0.001				0
Kota Cimahi	A6	5.59	0	0	0.001	0.001	0.001				2
Kota Semarang	A7	0.31	0	0.004	0.001	0.002	0				0
Kab Temang...	B2	0.258	0	0.004	0.001	0.001	0.001				0
Kab Banyumas	B3	0.004	0.002	0.004	0.001	0	0.069				0
Kab Kuningan	B4	0.259	0.003	0.004	0	0.001	0.001				0
Kab Pekalongan	B5	0.584	0.003	0.004	0.001	0.001	0.001				0
Kab Bojonegoro	B6	0.086	0	0	0.008	0.001	0.001				2
Kab Kudus	B7	0.286	0.002	0.004	0.001	0.001	0.001				0

Perubahan ukuran dimensi layer yang lebih kecil menghasilkan jumlah cluster yang lebih sedikit dibandingkan dengan ukuran dimensi layer yang lebih besar. Pada percobaan ke-2 dan percobaan ke-6 ukuran layernya diatur pada ketinggian 1 dan lebar 3

Tabel 6. Percobaan ke-6 (tidak dinormalisasi)

Row ID	S Kode	D En Ik	D Ur	D Ud	D Ustd	D Udri	D Ub	D Cluster0	D Cluster1	D Cluster2	I Winner ...
Kab Kediri	A2	1.297	0	0.004	0.001	0.001	0.001				1
Kab Demak	A3	0.775	0.004	0.002	0.011	0	0.001				1
Kab Semarang	A4	0.195	0.003	0.004	0.002	0.001	0.001				0
Kota Magelang	A5	0.116	0.001	0.004	0.001	0	0.001				1
Kota Cimahi	A6	5.59	0	0	0.001	0.001	0.001				2
Kota Semarang	A7	0.31	0	0.004	0.001	0.002	0				0
Kab Temang...	B2	0.258	0	0.004	0.001	0.001	0.001				0
Kab Banyumas	B3	0.004	0.002	0.004	0.001	0	0.069				0
Kab Kuningan	B4	0.259	0.003	0.004	0	0.001	0.001				0
Kab Pekalongan	B5	0.584	0.003	0.004	0.001	0.001	0.001				1
Kab Bojonegoro	B6	0.086	0	0	0.008	0.001	0.001				0
Kab Kudus	B7	0.286	0.002	0.004	0.001	0.001	0.001				0

Dari percobaan yang sudah dilakukan kemudian dihitung nilai icdrate dengan menggunakan rumus (2) untuk mendapatkan jumlah cluster optimum dengan hasil sebagai berikut:

Tabel 7. Perhitungan nilai icdrate artefak 1 kg

Percobaan ke	Normalisasi	Jumlah Cluster	Nilai icdrate
1	True	6	0.745696732
2	True	3	0.874853676
3	True	2	0.874853676
4	True	4	0.863299004
5	False	6	0.07132414
6	False	3	0.114728143
7	False	2	0.124806003
8	False	4	0.096350675

Dari perhitungan nilai icdrate terkecil diperoleh pada percobaan ke-5 dengan nilai icdrate sebesar 0.0713. Setting parameter pada percobaan ke-5 ini antara lain: nilai learning rate 0.8, tinggi lattice 2, lebar lattice 3, jumlah epoch order 6000, jumlah epoch convergen 2000, setting normalisasi false dan jumlah cluster terbaik 6. Sedangkan pada percobaan ke-1 inisialisasi parameter relatif sama hanya berbeda pada status normalisasi data, namun menunjukkan nilai icdrate sebesar 0.7457 (hampir sepuluh kali lipat dari nilai icdrate percobaan ke-5). Sementara untuk nilai icdrate terkecil kedua diperoleh pada percobaan ke-8 dimana jumlah cluster terbentuk 4 dengan inisialisasi parameter dimensi layer 2 x 2. Pada status normalisasi true, semua percobaan menunjukkan nilai icdrate yang mendekati 1, sementara yang status normalisasinya false semua percobaan menunjukkan nilai icdrate yang mendekati 0, ini disebabkan data interkomparasi berada pada range data yang hampir seragam sehingga tidak perlu dilakukannya normalisasi data.

Demikian juga untuk artefak anak timbangan 200 g, nilai icdrate dari beberapa percobaan ditampilkan pada tabel 8 berikut ini:

Tabel 8. Perhitungan nilai icdrate artefak 200 g

Percobaan ke	Normalisasi	Jumlah Cluster	Nilai icdrate
1	True	6	0.706020386
2	True	3	0.916757618
3	True	2	0.916757618
4	True	4	0.995156222
5	False	6	0.288953334
6	False	3	0.353372631
7	False	2	0.808731814
8	False	4	0.993541629

Dari perhitungan nilai icdrate terkecil diperoleh pada percobaan ke-5 dengan nilai icdrate sebesar 0.2889. Setting parameter pada percobaan ke-5 ini antara lain: nilai learning rate 0.8, tinggi lattice 2, lebar lattice 3, jumlah epoch order 6000, jumlah epoch convergen 2000, setting normalisasi false dan jumlah cluster terbaik 6. Sedangkan pada percobaan ke-1 inisialisasi parameter relatif sama hanya berbeda pada status normalisasi

data, namun menunjukkan nilai icdrate sebesar 0.7060 (hampir sepuluh kali lipat dari nilai icdrate percobaan ke-5). Sementara untuk nilai icdrate terkecil kedua diperoleh pada percobaan ke-6 dimana jumlah cluster terbentuk 3 dengan inisialisasi parameter dimensi layer 1 x 3. Pada status normalisasi true, semua percobaan menunjukkan nilai icdrate yang mendekati 1, sementara yang status normalisasinya false hanya percobaan ke-5 dan ke-6 yang menunjukkan nilai icdrate yang mendekati 0, sementara percobaan ke-7 dan ke-8 menunjukkan icdrate yang mendekati 0. Hal ini disebabkan data interkomparasi pada artefak 200 g terdapat beberapa perbedaan digit nilai massa konvensional ataupun digit nilai uncertainty akibat dari penggunaan timbangan elektronik dengan resolusi yang berbeda.

KESIMPULAN

Setelah dilakukan analisis terhadap hasil clustering data interkomparasi dengan algoritma self organizing maps, dapat disimpulkan bahwa :

1. Nilai icdrate terkecil diperoleh pada percobaan ke-5 untuk artefak 1 kg sebesar 0,0713. Sementara untuk nilai icdrate pada artefak 200 g diperoleh pada percobaan ke-5 dengan nilai 0,2889.
2. Normalisasi data mempengaruhi homogenitas dan heterogenitas cluster. Untuk data dengan rentang yang hampir seragam tidak perlu dilakukan normalisasi data.
3. Hasil clustering algoritma self organizing maps pada ukuran layer 2 x 3 pada percobaan ke-5 memiliki nilai homogenitas cluster yang baik dan nilai heterogenitas atau jarak antar cluster terbaik.

SARAN

Saran untuk penelitian lebih lanjut dapat dilakukan dengan melakukan perbandingan metode evaluasi cluster dengan xie beni inde maupun davies bouldin index.

DAFTAR PUSTAKA

- [1] ISO/IEC, 2010, *Conformity assessment - General requirements for proficiency testing*, first edition.
- [2] [R.M. Voiculescu, M. C. Olteanu, V.M. Nistor, 2013, Design And Operation Of An Interlaboratory Comparison Scheme, *Nuclear Fusion Journal*, 2013.
- [3] Tim Penyusun, 2021, Program Interkomparasi Standar Massa - Protokol Interkomparasi, BSML Regional II, 2021
- [4] Edy Irwansyah, M Faisal, 2015, *Advanced Clustering Teori dan Aplikasi*, edisi 1, Deepublish, Yogyakarta.
- [5] Hendayanti Ni Putu Nanik; Putri Gusti Ayu Made Arna; Nurhida Maulida, 2018, Ketepatan Klasifikasi Penerima Beasiswa Stimik Stikom Bali Dengan Hybrid Self Organizing Maps Dan Algoritma K-Means, *Jurnal Varian*, Vol.2 No.1 Oktober 2018.
- [6] Purbasari I Y; Puspaningrum E Y; Putra A B S, 2019, Using Self-Organizing Map (SOM) for Clustering and Visualization of New Students based on Grades, *Journal of Physics: Conference Series*, IOP Publishing, 2020.

- [7] Kania Siti; Rachmatin Dewi; Dahlan Jarnawi Afgani, 2019, Program Aplikasi Pengelompokan Objek Dengan Metode Self Organizing Map Menggunakan Bahasa R, *Jurnal EurekaMatika*, Vol.7 No.2, 2019.
- [8] Firmansyah Dese Narfa; Adinugroho Sigit; Rahayudi Bayu, 2019, Pengelompokan Wilayah Berdasarkan Kesejahteraan Sosial Menggunakan Algo-ritme Self-Organizing Maps Dengan Perbaikan Missing Value K-Nearest Neighbors, *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer* e-ISSN: 2548-964X Universitas Brawijaya Vol. 3, No. 7, Juli 2019, hlm. 7205-7213.
- [9] Lakshminarayanan Sivakkumaran, 2020, Application of Self-Organizing Maps on Time Series Data for identifying interpretable Driving Manoeuvres, *SpringerOpen Jurnal*, Germany.
- [10] TIAN Jin; GU Mengyi, 2019, Subspace Clustering Based on Self-Organizing Map, *ResearchGate*, 2019.
- [11] Putri Marina M, 2015, Pengelompokan Kabupaten/Kota Di Provinsi Jawa Timur Berdasarkan Indikator Kesehatan Masyarakat Menggunakan Metode Kohonen Som Dan K-Means, *Skripsi*, Jurusan Statistika Fakultas MIPA, ITS, Surabaya.