

## Evaluasi Cluster Data Interkomparasi Anak Timbangan Dengan Algoritma Self Organizing Maps

### *Cluster Evaluation Weighing Intercomparison Data with Self Organizing Maps Algorithm*

Arif Fajar Solikin<sup>1)</sup>, Kusri<sup>2)</sup>, Ferry Wahyu Wibowo<sup>3)</sup>

<sup>1, 2,3)</sup> Magister Teknik Informatika Universitas AMIKOM Yogyakarta

Jl. Ring Road Utara, Ngringin, Condongcatu, Kec. Depok, Kabupaten Sleman, Daerah  
Istimewa Yogyakarta 55281

e-mail: [arif.1311@students.amikom.ac.id](mailto:arif.1311@students.amikom.ac.id)<sup>1)</sup>, [kusri@amikom.ac.id](mailto:kusri@amikom.ac.id)<sup>2)</sup>, [ferry.w@amikom.ac.id](mailto:ferry.w@amikom.ac.id)<sup>3)</sup>

#### **Abstrak**

*Interkomparasi laboratorium adalah salah satu metode untuk mengetahui kemampuan dan menilai unjuk kerja dari suatu laboratorium. Unjuk kerja laboratorium dapat diketahui dari evaluasi nilai rasio  $En$  yang merupakan perbandingan antara selisih nilai pengujian laboratorium peserta dengan laboratorium acuan dan selisih akar kuadrat dari nilai ketidakpastian laboratorium peserta dengan laboratorium acuan. Laboratorium dinyatakan setara jika nilai  $En$  berada pada rentang  $En \leq |1|$ . Evaluasi interkomparasi juga dapat dilakukan dengan memanfaatkan salah satu teknologi data mining berupa clustering. Clustering dilakukan dengan menggunakan algoritma self organizing maps yang merupakan algoritma unsupervised learning. Kelebihan clustering dalam mengevaluasi data interkomparasi terletak pada kemampuannya untuk mengelompokkan data ke beberapa cluster yang memiliki kedekatan atau kesamaan ciri / sifat / karakter, sehingga memudahkan penyelenggara interkomparasi dalam memberikan rekomendasi analisis perbaikan unjuk kerja laboratorium. Data interkomparasi dikelompokkan berdasar homogenitas antar anggota dalam satu cluster dan heterogenitas antar satu cluster dengan cluster lainnya. Untuk mendapatkan jumlah cluster terbaik dilakukan evaluasi melalui tiga metode pengujian, pseudo-F statistic, icdrate dan davies bouldin index. Dari beberapa percobaan diperoleh nilai pseudo-F statistik terbesar 167.53, nilai icdrate terkecil 0.071 dan nilai DBI terkecil 0.053 untuk artefak 1000 g. Sedangkan untuk artefak 200 g diperoleh nilai pseudo-F statistik terbesar 104.86, nilai icdrate terkecil 0.289 dan nilai DBI terkecil 0.306.*

**Kata kunci**— Cluster, Evaluasi, Interkomparasi

#### **Abstract**

*Laboratory intercomparison is one of method to determine the ability and assess the performance of a laboratory. Laboratory performance can be seen from the evaluation of the  $En$  ratio's value, which is a comparison between the difference in the value test of the participant's laboratory with reference's laboratory and the difference in the square root of the uncertainty value form participant's laboratory and reference's laboratory. The laboratory is declared equivalent if the  $En$  value is in the range of  $En \leq |1|$ . Intercomparisons evaluation can also be done by utilizing one of the data mining technologies in the form of clustering. Clustering is done by using self-organizing maps algorithm, which is an unsupervised learning algorithm. The advantage of clustering in evaluating intercomparison data lies in its ability to group data into several clusters that have closeness or similarity in characteristics / traits / characters of data, making it easier for intercomparison organizers to provide analytical recommendations for improving laboratory performance. Intercomparison data are grouped based on the homogeneity between members in one cluster and heterogeneity among the clusters. To get the*

*best number of clusters, evaluation is carried out through three testing methods, pseudo-F statistic, icdrate and davies bouldin index. From several experiments, the largest pseudo-F statistic value was 167.53, the smallest icdrate value was 0.071 and the smallest DBI value was 0.053 for the 1000 g artifact. As for the 200 g artifact, the largest pseudo-F statistic value was 104.86, the smallest icdrate value was 0.289 and the smallest DBI value was 0.306.*

**Keywords**— Cluster, Evaluation, Intercomparison

## 1. 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, diantaranya kuantitatif, kualitatif dan interpretatif [2]. 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. 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. 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.

Hasil pengukuran numerik dari laboratorium diolah secara statistik dengan menggunakan nilai rasio  $E_n$ . Nilai rasio  $E_n$  dihitung dengan rumus:

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

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%.

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%. Data ini kemudian dilakukan perhitungan dengan menggunakan metode derajat kesetaraan (Degrees of Equivalent / DoE) atau yang lebih dikenal sebagai rasio  $E_n$  yang mengacu pada ISO/IEC 17043:2010 [2,3]. Hasilnya berupa pernyataan kesetaraan laboratorium peserta interkomparasi, laboratorium dinyatakan setara jika nilai  $E_n \leq 1$ .

Untuk mendapatkan analisis hasil interkomparasi berdasarkan kesamaan sumber masalahnya, dirancang satu penelitian dengan melakukan *clustering* data hasil interkomparasi menggunakan algoritma *self organizing maps*. *Clustering* atau pengelompokkan 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 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* juga didasarkan penelitian sebelumnya yang membandingkan beberapa metode *clustering*, antara lain penelitian yang dilakukan oleh Novendri Isra et al yang membandingkan metode K-Medoids dengan metode SOM dalam mengelompokkan bencana alam hidrometeorologi di Pulau Jawa. Hasil penelitian menunjukkan bahwa algoritma *self organizing maps* merupakan metode yang tepat karena memiliki nilai standar deviasi yang lebih kecil dibanding metode K-Medoids. Penelitian lain yang dilakukan oleh Marina Marsudi Putri yang membandingkan pengelompokan kabupaten/kota di Jawa Timur berdasarkan indeks kesehatan masyarakat menggunakan metode SOM dan K-Means menunjukkan bahwa algoritma *self organizing maps* menghasilkan jumlah optimum cluster dan tingkat homogenitas internal dan heterogenitas eksternal cluster yang lebih baik dibandingkan metode K-Means [11].

Penerapan algoritma *self organizing maps* telah dilakukan pada penelitian-penelitian sebelumnya, antara lain penelitian yang dilakukan oleh Ni Putu Nanik dengan algoritma *self organizing maps* dan k means dengan  $k=2$  dimana bobot awal yang ditentukan adalah sama untuk kedua metode telah menghasilkan ketepatan klasifikasi yang sama [5]. Proses clustering dilakukan dengan menentukan *vector node* yang dipilih untuk selanjutnya ditentukan BMU (*best matching unit*) nya dengan *node* lain. Penelitian lainnya oleh Purbasari et al, diawali 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 (indeks pembangunan manusia) Aceh 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 (bahan bakar minyak) berdasar data manuver pengemudi kendaraan dengan menggunakan perluasan algoritma SOM yaitu *super organizing maps*, dimana data input dibedakan menjadi 4 (empat) layer, masing-masing layer kemudian dilakukan proses pengelompokan [9]. 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. Hasil pengelompokan akhir disimpulkan dari *cluster neuron* yang terbentuk dengan mengganti setiap *neuron* dengan poin data di dalamnya [10]. Penelitian-penelitian tersebut telah menerapkan algoritma *self organizing maps* untuk pengelompokan data dengan tujuan yang berbeda-beda. Pada penelitian ini dilakukan *clustering* data interkomparasi. Data interkomparasi satu laboratorium dengan laboratorium yang lainnya dikelompokkan dengan menggunakan algoritma SOM. Hasilnya kemudian dievaluasi menggunakan tiga metode uji (pseudo-F Statistic, icdrate dan Davies Bouldin Index) untuk menentukan jumlah *cluster* terbaik. Dari evaluasi tersebut selanjutnya akan dilakukan analisis permasalahan laboratorium peserta interkomparasi berdasar sumber ketidakpastiannya (repeatability, drift standar dan standar yang digunakan, koreksi udara/bouyancy, dan resolusi timbangan).

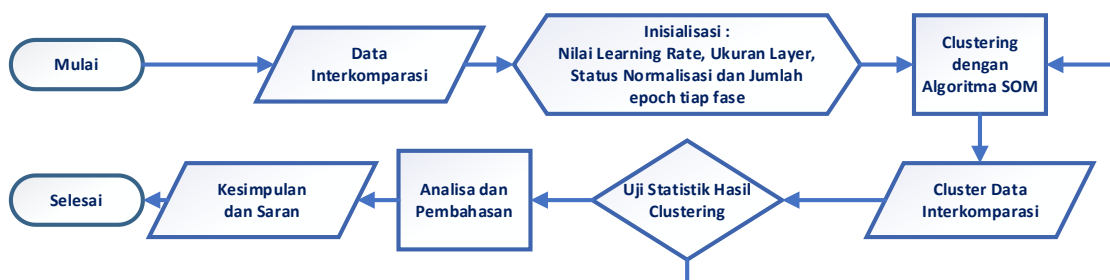
## 2. METODE PENELITIAN

### 2.1 Alur Penelitian

Penelitian ini merupakan penelitian eksperimen dengan pendekatan kuantitatif, dimana data penelitian berupa data numerik hasil dari pengujian artefak interkomparasi yang dianalisa dengan metode statistik. Data interkomparasi anak timbangan terlebih dahulu dihitung nilai rasio En nya sebelum dilakukan *clustering* dengan algoritma *self organizing maps*. Adapun tahapan – tahapan penelitian yang akan dilakukan dijelaskan dalam alur penelitian sebagai berikut:

Pada alur penelitian seperti pada gambar 1, setelah dilakukan literature review untuk mengumpulkan bahan referensi dan tinjauan pustaka yang bersumber dari jurnal internasional dan jurnal nasional, maka selanjutnya dilakukan tahapan sebagai berikut:

- 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 target 36 laboratorium, saat penelitian ini dilakukan baru terlaksana interkomparasi di 12 laboratorium, sehingga data yang digunakan dalam proses *clustering* dan evaluasi dibatasi sebanyak 24 data yang terbagi ke dua jenis artefak, artefak 1 kg sebanyak 12 data dan artefak 200 g sebanyak 12 data. Data yang terkumpul kemudian dilakukan perhitungan nilai rasio En nya. Data nilai rasio En dan data *budget uncertainty* dari laboratorium peserta interkomparasi dilakukan proses pengelompokkan dengan menggunakan algoritma SOM.
- Sebelum *clustering* dilakukan, terlebih dahulu ditentukan nilai parameter dari *learning rate*, jumlah *epoch* pada fase order dan fase konvergen, ukuran tinggi lebarnya *lattice / layer* dan status normalisasi datanya.
- Setelah inialisasi, selanjutnya dilakukan proses *clustering* dengan algoritma SOM. Proses *clustering* dilakukan dengan menggunakan platform *KNIME analytic*. Hasil *clustering* kemudian dievaluasi secara statistik dengan menghitung nilai *pseudo-F statistic*, nilai *internal cluster dispersion (icdrate)*, dan nilai DBI. Nilai yang dicari adalah nilai *icdrate* dan nilai DBI yang mendekati nol tapi tidak kurang sama dengan nol ( $>=0$ ) dan nilai *pseudo-F* terbesar. Jika nilai *icdrate* dan DBI masih terlalu besar maka dilakukan inialisasi ulang nilai parameter dan dilakukan *clustering* kembali.
- Setelah didapatkan hasil *clustering* dan hasil evaluasi kemudian dilakukan analisa dan pembahasan hasil.
- Tahapan terakhir dalam penelitian ini adalah menarik kesimpulan yang diperoleh dari eksperimen dan memberikan saran untuk penelitian selanjutnya.



Gambar 1. Alur Penelitian

### 2.2 Evaluasi Jumlah Cluster

Untuk mengetahui jumlah kelompok optimum dapat digunakan kriteria nilai Pseudo F-statistics. Berikut adalah persamaan yang digunakan untuk menghitung nilai Pseudo F-statistics [11]:

$$Pseudo\ F\ Statistic = \frac{\left(\frac{R^2}{k-1}\right)}{\left(\frac{1-R^2}{n-k}\right)} \quad (2)$$

Dimana:

$$R^2 = \frac{(SST-SSW)}{SST} \quad (3)$$

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

$$SSW = \sum_{i=1}^n \sum_{j=1}^c \sum_{k=1}^p (X_{ijk} - \bar{X}_{jk})^2 \quad (5)$$

Keterangan:

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

SSW (Sum Square Within): Total jumlah dari kuadrat jarak sampel terhadap rata-rata kelompoknya

n: banyaknya sampel

c: banyaknya variabel

p: banyaknya kelompok

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

$x_j$ : rata-rata seluruh sampel pada variabel ke-j

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

Nilai Pseudo F-statistics tertinggi menunjukkan bahwa jumlah kelompok yang digunakan untuk memartisi data telah optimal. Dimana keragaman dalam kelompok sangat homogen sedangkan antar kelompok sangat heterogen.

### 2.3 Evaluasi Cluster terbaik

Klaster terbaik untuk mengelompokkan obyek memiliki nilai homogenitas antar anggota dalam satu klaster yang tinggi dan memiliki nilai heterogenitas antar klaster yang tinggi. Dengan kata lain variasi antar anggota dalam satu klaster harus rendah sedangkan variasi antar klaster harus tinggi. Untuk menentukan kriteria klaster terbaik dapat digunakan 2 cara, pertama menggunakan nilai *internal cluster dispersion* (icdrate), dan kedua menggunakan nilai Davis Bouldin Index (DBI).

#### 2.3.1 Icdrate

Icdrate (*internal cluster dispersion*) menggambarkan tingkat dispersi atau perbedaan dalam klaster. Nilai icdrate yang semakin kecil menunjukkan bahwa klaster tersebut semakin baik sebab antara anggota dalam satu klaster memiliki perbedaan yang rendah atau memiliki variasi yang kecil [11].

Nilai *icdrate* dapat diperoleh dengan menggunakan persamaan [11]:

$$icdrate = 1 - \frac{SSB}{SST} \quad (6)$$

Dimana:

$$SSB = \sum_{j=1}^c \sum_{k=1}^p (\bar{X}_{jk} - \bar{X}_j)^2 \quad (7)$$

Keterangan:

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

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

$x_j$ : rata-rata sampel pada variabel ke-j

c: banyaknya variabel

p: banyaknya kelompok

### 2.3.2 Davies Bouldin Index

*Davies-Bouldin Index* (DBI) merupakan metode yang digunakan untuk mengevaluasi cluster. Evaluasi dilakukan melalui skema perhitungan jarak internal cluster, dimana jarak internal terbaik merupakan kuantitas dan kedekatan terhadap titik pusat cluster dari cluster yang diikuti. Sedangkan jarak antar cluster didasarkan pada jarak antar titik pusat cluster ke  $i$  terhadap titik pusat cluster ke  $j$ . Prinsip yang digunakan pada Davies-Bouldin Index ini jarak inter-cluster antara cluster  $C_i$  dan  $C_j$  dimaksimalkan dan pada waktu yang sama jarak antar titik dalam sebuah cluster diminimalkan. Jika jarak inter-cluster maksimal, berarti kesamaan karakteristik antar-masing-masing cluster sedikit sehingga perbedaan antar-cluster terlihat lebih jelas. Jika jarak intra-cluster minimal berarti masing-masing objek dalam cluster tersebut memiliki tingkat kesamaan karakteristik yang tinggi (Wani & Riyaz 2017). Tahapan dari perhitungan Davies-Bouldin Index adalah sebagai berikut [12]:

a. *Sum of Square Within-cluster* (SSW)

Untuk mengetahui kohesi dalam sebuah cluster ke- $i$  adalah dengan menghitung nilai dari *Sum of Square Within-cluster* (SSW). Kohesi didefinisikan sebagai jumlah dari kedekatan data terhadap titik pusat cluster dari sebuah cluster yang diikuti. Persamaan yang digunakan untuk memperoleh nilai Sum of Square Within cluster adalah sebagai berikut:

$$SSW_i = \frac{1}{m_i} \sum_{j=i}^{m_i} d(x_j, c_i) \quad (8)$$

dimana  $m$  = jumlah anggota dalam cluster

b. *Sum of Square Between-cluster* (SSB)

Perhitungan *Sum of Square Between-cluster* (SSB) bertujuan untuk mengetahui separasi antar cluster. Persamaan yang digunakan untuk menghitung nilai *Sum of Square Between cluster* adalah sebagai berikut:

$$SSB_{i,j} = d(c_i, c_j) \quad (9)$$

c. *Ratio* (Rasio)

Bertujuan untuk mengetahui nilai perbandingan antara cluster ke- $i$  dan cluster ke- $j$ . Untuk menghitung nilai rasio yang dimiliki oleh masing-masing cluster, digunakan persamaan berikut:

$$R_{i,j} = \frac{SSW_i + SSW_j}{SSB_{i,j}} \quad (10)$$

d. *Davies Bouldin Index*

Nilai rasio yang diperoleh dari persamaan (10) digunakan untuk mencari nilai *Davies-Bouldin Index* (DBI) dengan menggunakan persamaan berikut:

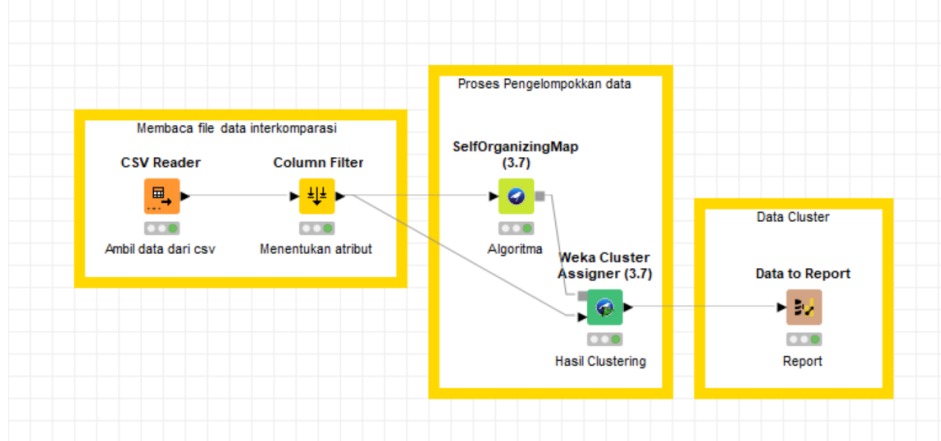
$$DBI = \frac{1}{k} \sum_{i=1}^k \max_{i \neq j} (R_{i,j}) \quad (11)$$

dimana  $k$  adalah jumlah cluster. Semakin kecil nilai *Davies Bouldin Index* (DBI) yang diperoleh (non-negatif  $\geq 0$ ), maka semakin baik *cluster* yang diperoleh dari pengelompokan.

## 3. HASIL DAN PEMBAHASAN

Data interkomparasi dikelompokkan berdasar nilai  $E_n$  dan sumber ketidakpastiannya dengan menggunakan platform “KNIME”. Seperti pada gambar 2, KNIME atau Konstanz Information Miner, adalah 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. Dari gambar 2 terdapat 5 hub dalam KNIME yang merupakan rangkaian dari proses *clustering*. *Clustering* diawali dengan membaca data pada file dengan format .csv pada hub *csv reader*. Data tersebut kemudian dilakukan *filtering* pada hub *column filter* untuk menentukan atribut/variabel yang menjadi masukan pada proses *clustering*. Selanjutnya pada hub *Self Organizing Maps* dilakukan pengaturan nilai parameter yang terdiri dari nilai *learning rate*, tinggi dan lebar *lattice*, jumlah *epoch* untuk fase *ordering* dan fase *convergence* dan status normalisasi data. Terdapat dua status normalisasi, *true* jika data dilakukan normalisasi dan *false* jika data tidak dilakukan normalisasi. Normalisasi data dilakukan untuk

menskalakan nilai atribut dari data sehingga bisa terbentuk data pada range tertentu di setiap atribut. Normalisasi data dilakukan dengan metode *min-max* dimana data pada atribut yang sama dibagi dengan nilai maksimum pada atribut tersebut. Untuk mengetahui berapa jumlah *cluster* terbentuk dan rincian anggotanya digunakan hub *weka cluster assigner*. Dari hub ini, data kemudian ditampilkan dalam bentuk *image* menggunakan hub *data to report*.



Gambar 2. Clustering dengan algoritma SOM menggunakan platform KNIME

Tahapan selanjutnya ada inisialisasi parameter dengan menentukan 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 <sub>o</sub>	Epoch <sub>c</sub>	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

Parameter seperti tabel 1 di atas dapat dijelaskan sebagai berikut:

- *Normalize attributes*: Ini akan menormalkan atribut, di set pilihan *true* atau *false*.
- *Ordering epochs*: Jumlah epoch dalam fase pemesanan / pengorganisasian, di set pada nilai 6000
- *Convergen epochs*: Jumlah epoch dalam fase konvergensi, di set pada nilai 2000
- *calcStats*: Ini akan menghitung statistik untuk setiap *cluster* setelah proses pengelompokkan selesai, di set pilihan *true*
- *height*: tinggi layer, di set sesuai kebutuhan
- *learningRate*: Jumlah awal bobot diperbarui, di set sama untuk semua di 0.8
- *width*: lebar layer, di set sesuai kebutuhan

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 aretfak 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 12 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 seperti pada gambar 3 berikut :



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	0.0000222
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	0.0009300	200.0015	0.0011	0.3743	0.000300	0.000400	0.000300	0.000000	0.000930
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	0.001008	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

Gambar 3. Data interkomparasi anak timbangan

Data pada gambar 3 di atas 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:

- Ketidaktepatan repeatability timbangan ( $U_r$ ).
- Ketidaktepatan akibat daya baca / resolusi timbangan ( $U_d$ ).
- Ketidaktepatan anak timbangan standar yang digunakan ( $U_{std}$ ).
- Ketidaktepatan drift atau pergeseran nilai dari anak timbangan standar ( $U_{drift}$ ).
- Ketidaktepatan akibat bouyancy udara ( $U_b$ ).

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

Row ID	S Kode	D En 1k	D Ur	D Ud	D Ustd	D Udrif	D Ub	D Cluster0	D Cluster1	D Cluster2	D Cluster3	D Cluster4	D Cluster5	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

Gambar 4. Hasil clustering percobaan ke-1

Pada gambar 4 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. Hasil clustering pada gambar 4 adalah data yang dilakukan normalisasi dengan pilihan *true* pada konfigurasi algoritmanya. Perlakuan data yang tidak dinormalisasi ditunjukkan pada gambar 5 percobaan ke-5, dimana terdapat 6 cluster terbentuk dan masing-masing cluster memiliki anggota.

Row ID	S Kode	D En 1k	D Ur	D Ud	D Ustd	D Udrif	D Ub	D Cluster0	D Cluster1	D Cluster2	D Cluster3	D Cluster4	D Cluster5	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

Gambar 5. Hasil clustering percobaan ke-5

Dengan menggunakan persamaan 2,6,11 untuk hasil clustering percobaan ke-1 diperoleh nilai pseudo-F statistic sebesar 0,027, nilai icdrate sebesar 0.830 dan nilai DBI sebesar 2,212. Nilai pseudo-F statistic masih terlalu kecil sementara nilai icdrate dan nilai DBI masih terlalu besar. Nilai yang dikehendaki untuk pseudo-F statistic adalah nilai terbesar, yang menunjukkan jumlah cluster optimum. Sementara nilai icdrate dan nilai DBI yang dikehendaki adalah nilai terkecil yang menunjukkan cluster terbaik, dimana tingkat homogenitas intercluster tinggi dan tingkat heterogenitas intracluster tinggi.



## Evaluasi Cluster Data Interkomparasi Anak Timbangan Dengan Algoritma Self Organizing Maps

Pada gambar 6 berikut ini, konfigurasi ukuran tinggi dan lebar layer diatur pada ketinggian 1 dan lebarnya 3, menghasilkan jumlah cluster yang lebih sedikit dibandingkan dengan ukuran dimensi layer yang lebih besar pada percobaan ke-1 (ukuran layer 2 x 3). Pada gambar 7 dengan konfigurasi ukuran layer yang sama, namun dengan pilihan status normalisasi yang berbeda, dimana pada percobaan ke-2 status normalisasinya *true*, sedangkan pada percobaan ke-6 status normalisasinya *false* menghasilkan konfigurasi anggota cluster yang berbeda. Data yang tidak dinormalisasi masing-masing *cluster* memiliki anggota, sementara data yang dinormalisasi terdapat satu *cluster* yang sama sekali tidak memiliki anggota.

Row ID	S Kode	D En 1k	D Ur	D Ud	D Ustd	D Udrif	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

Gambar 6. Hasil *clustering* percobaan ke-2

Row ID	S Kode	D En 1k	D Ur	D Ud	D Ustd	D Udrif	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

Gambar 7. Hasil *clustering* percobaan ke-6

Dari keseluruhan eksperimen yang telah dilakukan mulai dari percobaan ke-1 hingga percobaan ke-8, kemudian dihitung nilai pseudo-F statistic dengan menggunakan persamaan (2), nilai icdrate dengan menggunakan persamaan (6) dan nilai DBI dengan menggunakan persamaan (11).

Dari perhitungan *pseudo-F statistic* untuk artefak 1 kg diperoleh *cluster* optimum pada percobaan ke-8 dengan nilai *pseudo-F* terbesar 4.029. *Setting* parameter pada percobaan ke-8 ini antara lain: nilai *learning rate* 0.8, tinggi *lattice* 2, lebar *lattice* 2, jumlah *epoch* order 6000, jumlah *epoch convergen* 2000, *setting* normalisasi *false* dan jumlah *cluster* optimum 4.

Sedangkan *cluster* terbaik diperoleh pada percobaan ke-5 dengan nilai icdrate terkecil sebesar 0.075. *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 untuk nilai DBI terkecil diperoleh pada percobaan ke-7 dengan nilai DBI sebesar 0.053. *Setting* parameter pada percobaan ke-7 ini antara lain: nilai *learning rate* 0.8, tinggi *lattice* 1, lebar *lattice* 2, jumlah *epoch* order 6000, jumlah *epoch convergen* 2000, *setting* normalisasi *false* dan jumlah *cluster* terbaik 2. Adapun hasilnya seperti pada tabel 2 berikut:

Tabel 2. Hasil evaluasi *clustering* pada artefak 1 kg

Percobaan ke	Normalisasi	Jumlah Cluster	Nilai Pseudo F	Nilai icdrate	Nilai DBI
1	True	6	0.027	0.830	2.212

2	True	3	0.037	0.925	1.185
3	True	2	0.037	0.925	0.278
4	True	4	0.017	0.895	1.590
5	False	6	0.007	0.075	2.673
6	False	3	1.776	0.118	0.612
7	False	2	1.756	0.126	0.053
8	False	4	4.029	0.105	0.665

Tabel 3. Hasil evaluasi clustering pada artefak 200 g

Percobaan ke	Normalisasi	Jumlah Cluster	Nilai Pseudo F	Nilai icdrate
1	True	6	0.063	6.832
2	True	3	0.019	1.308
3	True	2	0.019	1.308
4	True	4	0.016	4.790
5	False	6	8.198	0.306
6	False	3	0.325	0.651
7	False	2	0.149	0.691
8	False	4	1.546	0.243

Untuk artefak 200 g, hasil evaluasi seperti pada tabel 3, dimana jumlah *cluster* optimum diperoleh pada percobaan ke-5 dengan nilai *pseudo-F* terbesar 8.198. *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* optimum 6.

Sedangkan untuk *cluster* terbaik diperoleh pada percobaan ke-8 dengan nilai *icdrate* terkecil sebesar 0.243. *Setting* parameter pada percobaan ke-8 ini antara lain: nilai *learning rate* 0.8, tinggi *lattice* 2, lebar *lattice* 2, jumlah *epoch* order 6000, jumlah *epoch convergen* 2000, *setting* normalisasi *false* dan jumlah *cluster* terbaik 4.

Sedangkan untuk nilai DBI terkecil diperoleh pada percobaan ke-5 dengan nilai DBI terkecil sebesar 0.306. *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 5, hal ini dikarenakan ada 1 dari 6 *cluster* yang tidak memiliki anggota.

Dari hasil evaluasi, sesuai tabel 2 untuk artefak 1 kg *cluster* terbaik diperoleh pada percobaan ke-8. Hal ini dikarenakan nilai *pseudo-F* nya paling besar, sementara selisih nilai *icdrate* nya tidak terlalu jauh ( $\Delta$  0.03) dengan nilai *icdrate* terkecil, meskipun nilai DBI terkecil diperoleh pada percobaan ke-7. Seperti terlihat pada gambar 8 percobaan ke-7 terbentuk 2 *cluster*, dimana satu *cluster* memiliki 1 anggota yang jika dilihat dari data dan perhitungan *En* nya masuk kategori *outlier*.

Row ID	S Kode	D En 1k	D Ur	D Ud	D Ustd	D Udrif	D Ub	D Cluster0	D Cluster1	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		1	
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		0	
Kota Semarang	A7	0.31	0	0.004	0.001	0.002	0		1	
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	0.059		1	
Kab Kuningan	B4	0.259	0.003	0.004	0	0.001	0.001		1	
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		1	
Kab Kudus	B7	0.286	0.002	0.004	0.001	0.001	0.001		1	

Gambar 8. Hasil clustering percobaan ke-7

Selanjutnya dari hasil evaluasi sesuai tabel 3 untuk artefak 200 g, *cluster* terbaik diperoleh pada percobaan ke-5. Hal ini dikarenakan pada percobaan ke-5 memiliki nilai *pseudo-F* terbesar dan nilai DBI terkecil. Meskipun nilai *icdrate* terkecil ada di percobaan ke-8 namun selisihnya tidak terlalu jauh ( $\Delta$  0.093).

Dari proses clustering dan evaluasi yang telah dilakukan, laboratorium peserta interkomparasi tahun 2021 untuk artefak 1 kg dapat dikelompokkan seperti pada tabel 4 berikut:

Tabel 4 Kelompok terbaik artefak 1 kg

Artefak 1 kg		Anggota	Keterangan
Jumlah cluster terbaik		4	
Cluster ke-1	Kota: Cimahi		Outlier, perlu diverifikasi ulang standar AT 1 kg
Cluster ke-2	Kab.: Kediri, Demak		Memiliki kesamaan pada bouyancy nya
Cluster ke-3	Kab.: Temanggung, Kuningan, Pekalongan, Kudus		Memiliki kesamaan pada resolusi timbangan, drift standar dan bouyancy
Cluster ke-4	Kab.: Semarang, Banyumas, Bojonegoro Kota: Magelang, Semarang		Sebagian besar memiliki kesamaan pada drift standar

Sedangkan untuk artefak 200 g dapat dikelompokkan seperti pada tabel 5 berikut:

Tabel 5 Kelompok terbaik artefak 1 kg

Artefak 200 g		Anggota	Keterangan
Jumlah cluster terbaik		5	
Cluster ke-1	Kota: Cimahi		Nilai En terbesar di antara peserta lain, namun masih setara ( <i>inlier</i> )
Cluster ke-2	Kab.: Banyumas		Nilai bouyancy paling tinggi diantara lainnya
Cluster ke-3	Kab.: Kediri, Semarang, Temanggung		Memiliki kesamaan pada bouyancy dan repeat timbangan.
Cluster ke-4	Kab.: Kuningan, Pekalongan, Bojonegoro, Kudus Kota: Semarang		Sebagian besar memiliki rentang nilai En yang mendekati nol dan memiliki deviasi nilai standar dan bouyancy paling kecil
Cluster ke-5	Kab. Demak, Kota Magelang		Memiliki kesamaan pada nilai bouyancy dan drift standar

#### 4. KESIMPULAN

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

- Clustering* data interkomparasi pada artefak 1 kg menghasilkan 4 *cluster* terbaik pada konfigurasi ukuran layer 2 x 2, status data tidak dinormalisasi dan nilai *learning rate* 0.8. Dengan hasil evaluasi nilai *pseudo-F* 4.029, nilai *icdrate* 0.105 dan nilai DBI 0.665. *Cluster* yang terbentuk sebagian besar memiliki kesamaan pada *drift standar* dan *bouyancy*.
- Clustering* data interkomparasi pada artefak 200 g menghasilkan 5 *cluster* terbaik pada konfigurasi ukuran layer 2 x 3, status data tidak dinormalisasi dan nilai *learning rate* 0.8. Dengan hasil evaluasi nilai *pseudo-F* 8.198, nilai *icdrate* 0.336 dan nilai DBI 0.306. *Cluster* yang terbentuk sebagian besar memiliki kesamaan pada *drift standar*, *bouyancy* dan *repeat* timbangan.

#### 5. SARAN

Dari hasil penelitian yang sudah dilakukan perlu adanya perbandingan evaluasi *cluster* dengan metode lain seperti *xie beni index*, metode *elbow* maupun metode *partition coefficient*. Evaluasi dengan beberapa metode tersebut perlu dilakukan untuk mengetahui efektifitas hasil pengujian terhadap *clustering*.

#### DAFTAR PUSTAKA

- ISO/IEC. (2010). Conformity assessment--General requirements for proficiency testing. *International Organization for Standardization Geneva*.
- Voiculescu, R. M., Olteanu, M. C., & Nistor, V. M. (2013). Design and operation of an interlaboratory comparison scheme. *Nuclear Fusion Journal*.
- Tim Penyusun (2021). Program Interkomparasi Standar Massa - Protokol Interkomparasi, BSML Regional II.
- Irwansyah, E., & Faisal, M. (2015). *Advanced Clustering: Teori dan Aplikasi*. Edisi 1. Deepublish: Yogyakarta

- [5]. Hendayanti, N. P. N., Putri, G. A. M. A., & Nurhidayati, M. (2018). Ketepatan Klasifikasi Penerima Beasiswa STMIK STIKOM Bali dengan Hybrid Self Organizing Maps dan Algoritma K-Mean. *Jurnal Varian*, 2(1), 1-7.
- [6]. Purbasari, I. Y., Puspaningrum, E. Y., & Putra, A. B. S. (2020, July). Using Self-Organizing Map (SOM) for Clustering and Visualization of New Students based on Grades. In *Journal of Physics: Conference Series* (Vol. 1569, No. 2, p. 022037). IOP Publishing.
- [7]. Kania, S., Rachmatin, D., & Dahlan, J. A. (2018). Program Aplikasi Pengelompokan Objek Dengan Metode Self Organizing Map Menggunakan Bahasa R. *Jurnal EurekaMatika*, 7(2), 17-29.
- [8]. Firmansyah Dese Narfa; Adinugroho Sigit; Rahayudi Bayu, 2019, Pengelompokan Wilayah Berdasarkan Kesejahteraan Sosial Menggunakan Algoritma 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, S. (2020). Application of self-organizing maps on time series data for identifying interpretable driving manoeuvres. *European transport research review*, 12(1), 1-11.
- [10]. Tian, J., & Gu, M. (2019). Subspace clustering based on self-organizing map. In *Proceeding of the 24th International Conference on Industrial Engineering and Engineering Management 2018* (pp. 151-159). Springer, Singapore.
- [11]. Putri, M. M. (2015). *Pengelompokan Kabupaten/Kota di Jawa Timur Berdasarkan Indikator Kesehatan Masyarakat Menggunakan Metode Kohonen SOM dan K-Means* (Skripsi, Jurusan Statistika Fakultas MIPA, Institut Technology Sepuluh Nopember).
- [12]. Sitompul, B. J. D. (2018). Peningkatan hasil evaluasi clustering davies-bouldin index dengan penentuan titik pusat cluster awal algoritma k-means. *Tesis*, S2 Teknik Informatika FIKTI USU, Medan.
- [13]. Asriny, N. I., Ramadhanty, D. R., Izzati, M. D., Putra, M. L. P., Shofura, A., Albi, C. U., & Widodo, E. (2021, February). Comparison of K-Medoids and Self Organizing Maps Algorithm in Grouping Hydrometeorological Natural Disasters in Java Island. In *IOP Conference Series: Materials Science and Engineering* (Vol. 1077, No. 1, p. 012008). IOP Publishing.