

BAB II

KAJIAN TEORI

2.1 Analisis *Cluster*

Menurut Prasetyo (2012), analisis *cluster* juga pekerjaan pengelompokan data (obyek) yang didasarkan hanya pada informasi yang ditemukan dalam data yang menggambarkan obyek tersebut dan hubungan diantaranya. Tujuan pengelompokan adalah obyek-obyek yang bergabung dalam sebuah kelompok merupakan obyek-obyek yang mirip atau berhubungan satu sama lain dan berbeda dengan obyek dalam kelompok lain.

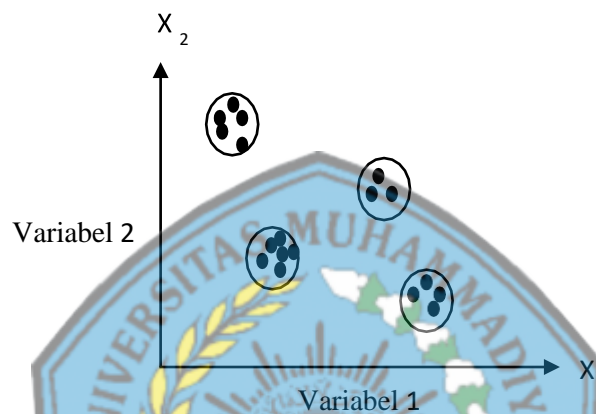
Untuk mendapatkan kelompok yang sehomogen mungkin, maka yang digunakan dasar untuk mengelompokkan adalah kesamaan skor nilai yang dianalisis. Semakin kecil besaran jarak suatu individu terhadap individu lain, maka semakin besar kemiripan individu tersebut. Data mengenai ukuran kesamaan tersebut kemudian dilakukan pengelompokan sehingga dapat ditentukan individu mana yang masuk kelompok mana (Gudono, 2014).

Ciri-ciri *cluster* yang baik yaitu mempunyai :

1. Homogenitas (*within-cluster*) yaitu kesamaan yang tinggi antara anggota dalam satu *cluster*.
2. Heterogenitas (*between-cluster*) yaitu perbedaan tinggi antara *cluster* yang satu dengan *cluster* yang lain.

Menurut Supranto (2004) analisis kelompok adalah metode yang digunakan untuk mengklasifikasi objek atau kasus (responden) ke dalam kelompok yang

relatif homogen, yang disebut *cluster* atau kelompok. Objek/ kasus dalam setiap kelompok cenderung mirip satu sama lain dan berbeda jauh (tidak sama) dengan objek dari kelompok lainnya. Selain itu, setiap objek hanya masuk ke dalam satu kelompok saja, tidak terjadi tumpang tindih (*overlapping* atau *interaction*), seperti pada gambar di bawah:



Gambar 1. Pengelompokan Ideal

(Sumber : *Analisis Multivariat, Arti dan Interpretasi*, Supranto, 2004)

Gambar 1 diatas menunjukkan hasil pengelompokan yang ideal, dimana setiap objek/ kasus hanya masuk atau menjadi anggota dari salah satu kelompok (tidak mungkin menjadi anggota dari dua kelompok atau lebih). Analisis kelompok terbagi menjadi dua, yaitu metode hierarki dan non hierarki. Berikut penjelasan untuk masing-masing jenis :

1. Hierarchical Methods (Metode Hierarki)

Metode ini biasa digunakan untuk individu yang tidak terlalu banyak, dan jumlah kelompok yang hendak dibentuk belum diketahui. Pengelompokan ini disajikan dalam bentuk dendogram, yang mirip dengan struktur diagram pohon atau *tree diagram* (Usman dan Sobari, 2013). Metode hierarki terbagi menjadi

dua, yaitu *Agglomerative* atau Metode Penggabungan dan *Divisive* atau Metode Pembagian. Metode *agglomerative* dimulai dengan setiap objek dalam satu kelompok yang terpisah. Kelompok dibentuk dengan mengelompokkan objek ke dalam kelompok yang semakin membesar. Proses ini dilanjutkan sampai semua objek menjadi anggota dari suatu kelompok tunggal (*a single cluster*). Sedangkan metode *divisive* dimulai dari semua objek dikelompokkan menjadi kelompok tunggal. Kemudian kelompok tersebut dibagi atau dipisah, sampai setiap objek berada dalam kelompok yang terpisah (Supranto, 2004).

2. Pengklasteran Sekatan (*Partitioning*) atau Non Hierarki

Pengklasteran berbasis *partitioning* menghasilkan partisi dari data sehingga objek dalam klaster lebih mirip satu sama lain daripada objek yang ada dalam klaster lain (Triyanto, 2015). Berbeda dengan pengklasteran hierarki, prosedur pengklasteran sekatan tidak dilakukan secara bertahap, dan jumlah klasternya juga ditentukan terlebih dahulu (Machfudhoh dan Wahyuningsih, 2013). Beberapa metode pengklasteran sekatan yang digunakan dalam penelitian ini antara lain.

a. *K-Means Clustering*

K-Means cluster adalah salah satu metode yang membutuhkan jumlah cluster yang ditentukan terlebih dahulu sebagai k , dan kemudian membagi n objek kedalam k cluster. Kemiripan antara anggota dalam satu cluster sangat tinggi sedangkan kemiripan antar anggota dengan cluster yang lain sangat rendah. Kemiripan anggota pada cluster diukur dengan nilai kedekatan objek terhadap mean pada cluster atau centroid cluster (Muzakir, 2014).

K-Means merupakan salah satu metode pengklasteran data nonhierarki (sekatan) yang berusaha mempartisi data yang ada ke dalam bentuk dua atau lebih klaster. Metode ini mempartisi data ke dalam klaster sehingga data berkarakteristik berbeda diklasterkan ke dalam klaster yang lain. Adapun tujuan pengklasteran data ini adalah untuk meminimalkan fungsi objektif yang diset dalam proses pengklasteran, yang pada umumnya berusaha meminimalkan fungsi objektif yang diset dalam proses pengklasteran, yang pada umumnya berusaha meminimalkan variasi di dalam suatu klaster dan memaksimalkan variasi antar klaster. Adapun langkah-langkah untuk *K-Means Clustering* adalah sebagai berikut (Prasetyo,2012):

1. Inisialisasi: tentukan nilai k sebagai jumlah klaster yang diinginkan dan matriks jarak yang diinginkan.
2. Pilih k data dari set data X sebagai *centroid*. Nilai *centroid* merupakan rata-rata objek dalam *cluster* tersebut.

$$C_{ij} = \frac{i}{n_i} \sum_{k=1}^{n_i} x_{jk} \quad (2.1)$$

dengan:

C_{ij} : pusat *cluster* ke- i pada variabel ke- j

x_{jk} : nilai pengamatan pada objek ke- k pada variabel ke- j

n_i : jumlah peubah yang menjadi anggota *cluster* ke- j

3. Alokasikan semua data ke *centroid* terdekat dengan matriks jarak yang sudah ditetapkan (memperbarui klaster *ID* pada setiap data).

4. Hitung kembali centroid berdasarkan data yang mengikuti kluster masing-masing.
5. Ulangi langkah 3 dan 4 hingga kondisi konvergen tercapai, yaitu tidak ada data yang berpindahkluster.

K-Means Clustering digunakan sebagai alternatif metode kluster untuk data dengan ukuran yang besar karena memiliki kecepatan yang lebih tinggi dibandingkan dengan metode hierarki (Sitepu dkk, 2011).

b. *K-Medoids Clustering*

K-Medoids Clustering, juga dikenal sebagai *Partitioning Around Medoids (PAM)*, adalah varian dari metode *K-Means*. Hal ini didasarkan pada penggunaan *medoids* bukan dari pengamatan *mean* yang dimiliki oleh setiap kluster, dengan tujuan mengurangi sensitivitas dari partisi sehubungan dengan nilai ekstrim yang ada dalam dataset (Vercellis, 2009).

K-Medoids Clustering hadir untuk mengatasi kelemahan *K-Means Clustering* yang sensitif terhadap *outlier* karena suatu objek dengan suatu nilai yang besar mungkin secara substansial menyimpang dari distribusi data (Han dan Kamber, 2006).

K-Medoids Clustering menggunakan metode pengklasteran partisi untuk mengklusterkan sekumpulan n objek menjadi sejumlah k kluster. Algoritma ini menggunakan objek pada kumpulan objek yang mewakili sebuah kluster. Objek yang mewakili sebuah kluster disebut dengan *medoids*. Kluster dibangun dengan menghitung kedekatan yang dimiliki antara *medoids* dengan objek *non medoids* (Setyawati, 2017).

Menurut Han dan Kamber (2006), tahapan *K-Medoids Clustering* adalah sebagai berikut.

- a. Secara acak pilih k objek pada sekumpulan n objek sebagai *medoids*.
- b. Ulangi.
- c. Tempatkan objek *non medoids* ke dalam klaster yang paling dekat dengan *medoids*.
- d. Secara acak pilih O_{random} (sebuah objek *non medoids*).
- e. Hitung total *cost*, S , dari pertukaran *medoids* O_j dengan O_{random} .

$$S = \text{total cost baru} - \text{total cost lama} \quad (2.2)$$

dengan

S : selisih

Total *cost* baru : total *cost* baru untuk *non medoids*

Total *cost* lama : total *cost* lama untuk *medoids*

- f. Jika $S < 0$ maka ukar O_j dengan O_{random} , untuk membentuk sekumpulan k objek baru sebagai *medoids*.
- g. Hingga tidak adaperubahan

2.2 Penentuan Jumlah Cluster dengan Metode Silhouette

Hingga saat ini telah banyak metode validasi clustering yang dikembangkan, baik menggunakan kriteria internal, eksternal, dan relatif. Validasi dengan kriteria internal merupakan uji akursi data klaster yang diperoleh dengan data itu sendiri, data yang digunakan untuk proses klaster dan validasi sama. Pendekatan rata-rata nilai metode *silhouette* untuk menduga kualitas dari klaster yang

terbentuk. Semakin tinggi nilai rata-ratanya maka akan semakin baik. (Ahmad, 2018).

Silhouette digunakan untuk melihat kualitas dan kekuatan cluster, seberapa baik suatu objek ditempatkan dalam suatu cluster. Metode ini merupakan gabungan dari metode *cohesion* dan *separation*. Tahapan perhitungan *silhouette* adalah sebagai berikut:

1. Hitunglah rata-rata dari suatu dokumen misalkan i dengan semua dokumen lain yang berada dalam satu cluster (Al- Zoubi,2018)

$$a(i) = \frac{1}{|A|-1} \sum_{j \in A, j \neq i} d(i, j)$$

dengan j adalah dokumen lain dalam suatu cluster A dan $d(i, j)$ adalah jarak antara dokumen i dengan j .

2. Hitunglah rata-rata dari dokumen i tersebut dengan semua dokumen di cluster lain, dan diambil nilai terkecilnya. (Al- Zoubi,2018)

$$d(i, C) = \frac{1}{|A|-1} \sum_{j \in A, j \neq i} d(i, j)$$

dengan $d(i, C)$ adalah jarak rata-rata dokumen i dengan semua objek pada cluster lain C dimana $A \neq C$. (Han,2012)

$$b(i) = \min_{C \neq A} d(i, C)$$

3. Nilai *silhouette* nya adalah: (Han,2012)

$$s(i) = \frac{b(i)-a(i)}{\max(b(i), a(i))}$$

2.3 Ukuran Jarak dalam Pengklasteran

Berdasarkan tujuan pengklasteran yang telah dijelaskan, maka menurut Supranto (2004) terdapat beberapa ukuran diperlukan untuk mengakses seberapa

mirip atau berbeda objek-objek yang diklasterkan. Pendekatan yang paling biasa ialah mengukur kemiripan dinyatakan dengan jarak (*distance*) antara pasangan objek. Objek dengan jarak lebih pendek antara mereka akan lebih mirip satu sama lain dibandingkan dengan pasangan dengan jarak antara dua objek.

Ukuran jarak yang paling banyak digunakan adalah *Euclidean* dan *Mahattan*. *Euclidean* digunakan ketika ingin memberikan jarak terpendek antara dua titik (jarak lurus), sedangkan *Mahattan* memberikan jarak terjauh pada dua data. *Mahattan* juga sering digunakan karena kemampuannya dalam mendeteksi keadaan khusus dengan lebih baik (Augusta, 2005 dalam Prasetyo, 2012).

a. Jarak *Euclidean*

Jarak *Euclidean* ialah akar dari jumlah kuadrat perbedaan/deviasi di dalam nilai untuk setiap variabel (Supranto, 2004). Jarak *Euclidean* juga biasa disebut sebagai metode perhitungan jarak yang didasarkan pada ruang berdimensi terbatas bernilai riil (Kumari dan Bhagat, 2013). Adapun persamaan untuk menghitung jarak *Euclidean* adalah sebagai berikut (Prasetyo, 2012):

$$d_{ij} = \sqrt{\sum_{k=1}^p (x_{ik} - x_{jk})^2} \quad (2.3)$$

dengan :

d_{ij} : jarak antara objek ke-i dan objek ke-j

p : jumlah variabel *cluster*

x_{ik} : data dari subjek ke-i pada variabel ke-k

x_{jk} : data dari subjek ke-j pada variabel ke-k

k : 1,2,3, ... , p

i : 1,2,3, ... , n

$j : 1,2,3, \dots , n$

b. Jarak Mahattan

Jarak Mahattan atau *the city block distance* merupakan jarak antara dua objek yang merupakan jumlah perbedaan mutlak/absolut di dalam nilai untuk setiap variabel (Supranto, 2004). Adapun persamaan untuk jarak Mahattan adalah sebagai berikut (Prasetyo, 2012):

$$d_{ij} = \sum_{k=1}^p |x_{ik} - x_{jk}| \quad (2.4)$$

dengan :

d_{ij} : jarak antara objek ke-i dan objek ke-j

p : jumlah variabel *cluster*

x_{ik} : data dari subjek ke-i pada variabel ke-k

x_{jk} : data dari subjek ke-j pada variabel ke-k

$k : 1,2,3, \dots , p$

$i : 1,2,3, \dots , n$

$j : 1,2,3, \dots , n$

2.4 Standarisasi/Pembakuan Data

Menurut Hair,*et al.* (2006),pembakuan data adalah proses mengkonversi nilai masing-masing variabel awal menjadi nilai standar dengan rata-rata 0 dan standar deviasi 1 untuk menghilangkan bias yang disebabkan karena perbedaan skala dari beberapa variabel yang digunakan dalam analisis. Nilai standar untuk x_{ij} adalah:

$$Z_{ij} = \frac{x_{ij} - m_j}{s_j} \quad (2.5)$$

dengan:

x_{ij} = nilai objek ke- i pada variabel ke- j

$i = 1, 2, 3, \dots, n$

Z_{ij} = data x_{ij} yang sudah terstandarkan

S_j = simpangan baku dari variabel ke- j

m_j = rata-rata dari variabel ke- j

Menurut Simamora (2006), jika variabel menggunakan satuan berbeda, variabel perlu distandarkan terlebih dahulu baru dilakukan analisis cluster.

2.5 Asumsi Analisis kelompok /Cluster

Menurut Hair, dkk., (1998) terdapat dua asumsi dalam analisis kelompok yaitu sampel yang representatif dan tidak ada multikolinieritas.

1. Sampel Representatif

Penggunaan sampel dalam penelitian harus dapat mewakili populasi atau representatif. Penggunaan sampel yang representatif akan memberikan hasil yang maksimal dan sesuai dengan kondisi populasi yang ada. Namun apabila penelitian menggunakan populasi maka dapat disimpulkan bahwa asumsi representatif terpenuhi. (Hair, dkk.,1998).

2. Tidak Ada Multikolinieritas

Multikolinieritas adalah suatu peristiwa dimana terjadi korelasi yang kuat antara dua atau lebih variabel kelompok. Multikolinieritas merupakan masalah yang perlu diperhatikan dalam analisis multivariat pada umumnya, karena pengaruhnya yang sangat besar dalam menghasilkan solusi, sehingga mengganggu proses analisis. Namun dalam analisis kelompok efeknya

berbeda, yaitu variabel-variabel yang terjadi multikolinieritas secara implisit dibobot lebih besar. Karena alasan ini peneliti dianjurkan untuk menguji variabelkelompok mana yang secara substansial menimbulkan multikolinieritas. (Hair, dkk., 1998).

Pengujian terhadap multikolinieritas dalam data salah satunya dengan menggunakan koefisien korelasi. Koefisien korelasi merupakan indeks atau bilangan yang digunakan untuk mengukur keeratan hubungan antar variabel. Perhitungan koefisien korelasi yang dapat digunakan untuk data dengan skala pengukuran interval dan rasio adalah koefisien korelasi *pearson*. (Hasan, 2002). Berikut adalah persamaan koefisien korelasi *pearson* :

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (2.6)$$

dengan:

r_{xy} : koefisien korelasi antara variabel x dan y

x_i, y_i : variabel bebas x dan y pada data ke- i

\bar{x}, \bar{y} : rata-rata data variabel x dan y

Beberapa hal yang dapat dilakukan apabila data mengandung multikolinieritas yaitu dapat mengurangi variabel dengan jumlah yang sama pada setiap set atau dapat menggunakan salah satu *distance measures*, seperti *Mahalanobis distance*. (Hair, dkk., 1998). Selain itu, menurut Supranto (2004) multikolinieritas juga dapat ditangani dengan menggunakan analisis komponen utama yang mereduksi variabel menjadi beberapa faktor sehingga tidak mengandung multikolinieritas.

2.6 Analisis Komponen Utama

Analisis faktor merupakan suatu analisis yang digunakan untuk mereduksi dan meringkas data. Faktor-faktor diekstraksi sehingga faktor pertama memberikan andil terbesar terhadap seluruh varian dari seluruh variabel asli, faktor kedua menyumbang terbesar kedua, faktor ketiga menyumbang terbesar ketiga, dan begitu seterusnya sehingga proses pencarian faktor dihentikan setelah sumbangan terhadap seluruh varian variabel mencapai 60% atau lebih. Dimungkinkan pula untuk mengekstraksi faktor sehingga faktor tidak berkorelasi sesamanya seperti di dalam Analisis Komponen Utama atau *Principal Component Analysis* (PCA). (Supranto, 2004).

2.7 Perbandingan Model Terbaik

Untuk mengetahui metode mana yang mempunyai kinerja terbaik, dapat digunakan rata-rata simpangan baku dalam *Cluster* (σ_w) dan simpangan baku antar *Cluster* (σ_k) (Bunkers, dkk. 1996 dalam Laeli, 2014).

Rumus rata-rata simpangan baku dalam *Cluster*:

$$(\sigma_w) = K^{-1} \sum_{k=1}^K \sigma_k \quad (2.7)$$

dengan:

K : Banyaknya *Cluster* yang terbentuk

σ_k : Simpangan baku *Cluster* ke- k

Rumus simpangan baku *Cluster* ke- k σ_k :

$$\sigma_k = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - \mu_k)^2} \quad (2.8)$$

dengan:

N : Jumlah Anggota dari setiap *Cluster*

μ_k : Rata-rata *Cluster* ke-k

X_i : Anggota *Cluster*, dari $I=1,2,\dots,N$

Rumus simpangan baku antar *Cluster* σ_B :

$$\sigma_B = [(K)^{-1} \sum_{k=1}^K (\mu_k - \mu)^2]^{1/2} \quad (2.9)$$

μ_k : Rata-rata *Cluster* ke-k

μ : Rata-rata keseluruhan *Cluster*

Rumus Rasio simpangan baku *Cluster* σ :

$$\sigma = \frac{\sigma_W}{\sigma_B} \times 100\% \quad (2.10)$$

dengan

σ_W : Simpangan Baku dalam *Cluster*

σ_B : Simpangan Baku antar *Cluster*

Metode yang mempunyai rasio terkecil merupakan metode terbaik. *Cluster* yang baik adalah *Cluster* yang mempunyai homogenitas (kesamaan) yang tinggi antar anggota dalam satu *Cluster* (within *Cluster*) dan heterogenitas yang tinggi antar *Cluster* yang satu dengan *Cluster* yang lain (between *Cluster*) (Santoso, 2007 dalam Laeli, 2014).

2.8 Pengertian Pendidikan

Pendidikan adalah suatu proses, tehnik, dan metode belajar mengajar dengan maksud mentransfer suatu pengetahuan dari seseorang kepada orang lain melalui prosedur yang sistematis dan terorganisir yang berlangsung dalam jangka waktu yang relative lama. Sedangkan menurut Pusat Bahasa Departemen Pendidikan Nasional (PBDPN), pendidikan adalah proses mengubah sikap dan tata cara

seseorang atau kelompok orang dalam usaha mendewasakan manusia melalui upaya pengajaran dan pelatihan. Pendidikan adalah usaha sadar dan terencana untuk mewujudkan suasana belajar dan proses pembelajaran agar peserta didik secara aktif mengembangkan potensi dirinya untuk memiliki kekuatan spiritual keagamaan, pengendalian diri, kepribadian, kecerdasan, akhlak mulia, serta keterampilan yang diperlukan dirinya, masyarakat, bangsa dan negara. (UU RI No. 20 Tahun 2003 tentang Sistem Pendidikan Nasional, pasal 1).

Pendidikan adalah proses perubahan sikap dan tatalaku seseorang atau kelompok orang dalam usaha mendewasakan manusia melalui upaya pengajaran dan pelatihan, proses, cara, perbuatan mendidik (Pusat Bahasa Departemen Pendidikan Nasional, 2002). Salah satu parameter keberhasilan pendidikan dapat dilihat dari indikator pendidikan di suatu wilayah. Indikator yaitu sesuatu yang dapat memberikan petunjuk besaran kuantitatif suatu konsep untuk mengukur masukan, proses, dan keluaran (Profil Pendidikan Dasar dan Menengah, 2016/2017). Indikator pendidikan merupakan besaran kuantitatif mengenai suatu konsep tertentu yang dapat digunakan untuk mengukur proses dan hasil pendidikan atau dampak dari suatu instrumen kebijakan pendidikan.

2.9 Indikator Pendidikan

Berdasarkan Profil Pendidikan Dasar dan Menengah tahun 2016/2017 pada Kementerian Pendidikan dan Kebudayaan tahun 2017, berikut dijelaskan mengenai 9 indikator pendidikan yaitu :

1. Angka Partisipasi Kasar (APK)

APK adalah perbandingan antara banyak siswa pada jenjang pendidikan tertentu dengan banyak penduduk usia sekolah sesuai jenjang pendidikan tersebut yang dinyatakan dalam persentase.

Rumus:

$$APK_j = \frac{\text{siswa } j}{\text{penduduk usia sekolah } j} \times 100\%$$

Semakin tinggi APK berarti makin banyak anak usia sekolah yang bersekolah di jenjang pendidikan tertentu atau banyak anak diluar usia sekolah. Kegunaan dari APK yaitu untuk mengetahui banyaknya siswa yang bersekolah sesuai dengan usia pada jenjang pendidikan tertentu.

2. Angka Partisipasi Murni

APM adalah perbandingan antara siswa usia sekolah tertentu pada jenjang pendidikan tertentu dengan penduduk usia yang sesuai pada jenjang pendidikan tersebut yang dinyatakan dalam persentase.

Rumus:

$$APM_j = \frac{\text{Siswa usia } j}{\text{Penduduk usia } j} \times 100\%$$

Semakin tinggi APM berarti makin banyak anak usia resmi di jenjang pendidikan tertentu. Nilai idealnya 100%. APM berguna untuk mengetahui banyaknya anak usia sekolah yang bersekolah pada jenjang yang sesuai.

3. Angka Partisipasi Sekolah (APS)

APS adalah Proporsi dari semua anak yang masih sekolah pada suatu kelompok umur tertentu terhadap penduduk dengan kelompok umur yang sesuai.

Rumus:

$$APS_j = \frac{\text{Jumlah penduduk usia } j \text{ yang masih bersekolah}}{\text{Jumlah penduduk usia } j} \times 100\%$$

Semakin tinggi APS semakin besar jumlah penduduk yang mengenyam pendidikan. APS digunakan untuk melihat akses penduduk pada fasilitas pendidikan khususnya bagi penduduk usia sekolah.

4. Rasio Siswa per Kelas (R-S/K)

Merupakan perbandingan antara jumlah siswa (S) dengan jumlah kelas/kel belajar (K).

Rumus:

$$R - S/K = S : K$$

Semakin tinggi rasio berarti makin padat siswa yang berada di kelas atau makin kurang jumlah ruang kelas. Berguna untuk mengetahui rata-rata besarnya kelas.

5. Angka Mengulang (AU)

AU merupakan perbandingan antara jumlah siswa mengulang (U_t) dengan jumlah siswa tahun ajaran sebelumnya (S_{t-1}), dinyatakan dalam persentase.

Rumus:

$$AU = \frac{U_t}{S_{t-1}} \times 100\%$$

Idealnya yaitu 0% berarti tidak ada siswa yang mengulang. Makin rendah nilainya berarti makin baik. AU digunakan untuk mengetahui banyaknya siswa mengulang sehingga dapat direncanakan program remedial.

6. Angka Putus Sekolah (APtS)

APtS merupakan perbandingan antara jumlah putus sekolah (PtS) dengan jumlah siswa tahun ajaran sebelumnya (S_{t-1}), dinyatakan dalam persentase

Rumus :

$$\text{APtS} = \frac{\text{PtS}}{S_{t-1}} \times 100\%$$

Idealnya yaitu 0% berarti tidak ada siswa yang putus sekolah. Makin rendah nilainya berarti makin baik. APtS digunakan untuk mengetahui banyaknya siswa putus sekolah sehingga dapat direncanakan program retrieval.

7. Rasio Siswa per Guru (R-S/G)

R-S/G adalah perbandingan antara jumlah siswa (S) dengan jumlah guru (G)

Rumus :

$$R - \frac{S}{G} = S : G$$

Semakin besar nilainya makin banyak guru melayani siswa atau makin kurang guru yang ada. R-S/G digunakan untuk mengetahui tambahan guru yang di perlukan.

8. Persentase Guru Layak (% GL)

Persentase Guru Layak (GL) adalah perbandingan antara jumlah guru layak mengajar (ijazah S1/Diploma 4 dan lebih tinggi) dengan jumlah guru seluruh (GS).

Rumus :

$$\% GL = \frac{GL}{GS} \times 100\%$$

Idealnya 100% berarti semua guru mengajar telah sesuai dengan ketentuan. UU No.14/2005. Makin tinggi % GL berarti makin baik digunakan untuk mengetahui banyaknya guru yang perlu disetarakan.

9. Persentase Ruang Kelas Baik (% Rkb)

Merupakan perbandingan antara jumlah ruang kelas baik (Rkb) dengan jumlah ruang kelas seluruhnya (RK) yang dinyatakan dalam persentase.

Rumus :

$$\% Rkb = \frac{Rkb}{RK} \times 100\%$$

Idealnya 100% berarti semua ruang kelas dalam kondisi baik. Makin tinggi nilainya berarti makin baik. Digunakan untuk mengetahui banyaknya ruang kelas yang rusak dan perlu rehabilitasi.

