

BAB II

LANDASAN TEORI

2.1 Tinjauan Pustaka

Dalam pembuatan penelitian ini ada penelitian-penelitian sebelumnya yang sudah pernah dilakukan oleh orang lain yang mirip dan bahkan menjadi acuan dari penelitian ini. Adapun beberapa penelitian tersebut antara lain sebagai berikut :

1. Dedi Darwis, et al., (2020) dalam penelitiannya yang berjudul Penerapan Algoritma SVM Untuk Analisis Sentiment Pada Data *Twitter* Komisi Pemberantasan Korupsi Republik Indonesia menggunakan metode *Support Vector Machine*. Hasil dari klasifikasi menggunakan metode SVM dibagi menjadi tiga kelas, yaitu kelas positif sebanyak 8%, kelas negatif sebanyak 77%, dan kelas netral sebanyak 15%. Pengujian dari penelitian ini menggunakan Confusion Matrix, Akurasi dari hasil penelitiannya kecondongan sentimen negatif sebesar 77% dengan keakuratan hasil pengujian akurasi sebesar 82% dan pengujian precision sebesar 90%, serta recall sebesar 88% dan f1-score sebesar 89%.
2. Debby Alita, et al., (2020) pada penelitiannya Implementasi Algoritma Multiclass SVM Pada Opini Publik Berbahasa Indonesia Di Twitter. Total data twitter yang digunakan sebanyak 2.281 data tweet sentimen berbahasa Indonesia yang diperoleh dari hasil scraping data. dengan SVM One Against One dan SVM *One Against Rest* dengan hasil SVM *One Against One* lebih unggul untuk nilai presisi, recall dan F1Score, sedangkan untuk akurasi SVM *One Against Rest* lebih unggul dengan nilai perbedaan 0,06. Jika dibandingkan dengan metode lainnya yaitu

metode klasifikasi Naïve Bayes Classifier pada proses analisis sentimen metode multiclass SVM tetap memiliki nilai lebih unggul dan untuk teknik dataset yang dilakukan secara acak memiliki nilai yang lebih baik.

3. Styawati, et al., (2021) dalam penelitiannya yang berjudul Analisis Sentimen Masyarakat Terhadap Program Kartu Prakerja Pada Twitter Dengan Metode Support Vector Machine. Pada penelitian ini dilakukan perbandingan dua kernel yaitu linear dengan RBF. Hasil evaluasi yang dilakukan pada nilai akurasi kernel linear 98.67%, precision 98%, recall 99%, dan F1-Score 98%, sedangkan pada nilai akurasi kernel RBF 98.34%, precision 97%, recall 98%, F1-Score 98%, dapat disimpulkan bahwa sentimen masyarakat dari pengguna twitter terhadap program kartu prakerja dimasa pandemi lebih condong ke netral sebesar 98,34%. Berdasarkan hasil evaluasi yang dilakukan pada nilai akurasi kernel linear menghasilkan nilai akurasi 98.67%, sedangkan kernel RBF menghasilkan akurasi 98.34%. Maka dari sisi akurasi kernel linear lebih akurat dari pada kernel RBF.
4. Darmawan, et al., (2018) pada penelitiannya yang berjudul Implementasi Data Mining Menggunakan Model SVM Untuk Prediksi Kepuasan Pengunjung Taman Tabeuya. penelitian ini penulis mengumpulkan data yang diambil langsung melalui survei dari target lapangan dan parameter pertanyaan kuesioner tertentu. *Classification report* ditingkatkan dengan melakukan pengujian terhadap data sebanyak 3 dengan menghasilkan akurasi sebesar 86% dan nilai Area Under Curve (AUC) sebesar 0.947.

5. Andi Nurkholis, et al., (2021), melakukan penelitian yang berjudul *Optimasi Parameter Support Vector Machine Berbasis Algoritma Firefly Pada Data*. Data set yang digunakan dalam penelitian ini adalah data opini masyarakat terhadap beberapa film. Label kelas yang digunakan dalam klasifikasi data yaitu label kelas positif dan label kelas negatif. Banyaknya data yang digunakan dalam penelitian ini yaitu 2179 data, dengan pembagian data sebanyak 436 sebagai data pengujian dan 1743 data sebagai data pelatihan. Berdasarkan data tersebut dilakukan proses evaluasi terhadap *Firefly Algorithm-Support Vector Machine (FA-SVM)*. Hasil penelitian ini menunjukkan bahwa Algoritma Firefly mampu mendapatkan kombinasi parameter SVM yang optimal berdasarkan akurasi, sehingga tidak diperlukan cara trial and error untuk mendapatkan nilai tersebut. Hal ini dibuktikan dengan hasil evaluasi FA-SVM menggunakan rentang nilai $C=1.0-3.0$ dan $=0.1-1.0$ menghasilkan akurasi tertinggi yaitu 87.84%. Evaluasi berikutnya menggunakan rentang nilai $C=1.0-3.0$ dan $=1.0-2.0$ menghasilkan akurasi tertinggi 87.15%.

2.2 Sentimen Analisis

Sentimen Analisis adalah sentiment dari teks subjektif tersebut menganalisis, memproses, meringkas dan proses inferensial. Sentiment analisis saat ini dibagi menjadi penggunaan klasifikasi pembelajaran mesin dan metode klasifikasi berdasarkan aturan, metode pembelajaran mesin menggunakan kata kata emosi sebagai klasifikasi fitur, dan kamus emosi dapat digunakan untuk mewujudkan pemilihan karakteristik sentiment dengan cepat dan efisien (Aulia Rahman Isnain, et al., 2021). Hasil sentimen tersebut diambil dengan menganalisa tiap kata pada

sebuah kalimat baik dari pendapat, ulasan, paragraph dan sebuah topik berkaitan dengan konteks. Analisis sentimen dilakukan berdasarkan aspek masalah yang dimiliki dan akan menentukan hasil yang berniali positif, negatif atau netral (Desi B. Tabuan 2021).

Tugas utama dalam analisis sentiment dengan mengelompokkan teks yang ada didalam sebuah kalimat atau dokumen dengan memastikan pendapat yang dikemukakan di dalam kalimat atau dokumen tersebut, apakah bersifat positif, negatif atau netral (Pudjajana dan Manongga 2018). Sentimen analisis juga dapat mengungkapkan perasaan emosional sedih, bahagia atau marah (Rusdian dan Rosiyadi 2019). Berdasarkan penelitian yang telah dilakukan sebelumnya, pada klasifikasi sentimen terdapat 2 bentuk jenis kelas, pertama 2 kelas yaitu positif dan negatif dan 3 kelas yaitu positif, negatif dan netral. Namun jenis kelas tersebut dapat berubah sesuai dengan kebutuhan analisis.

2.3 Text Mining

Text mining merupakan bagian dari data mining, yaitu proses untuk memperoleh suatu pengetahuan menggunakan seperangkat alat analisis dimana pengguna berinteraksi dengan sekumpulan dokumen dari waktu ke waktu (Aulia Rahman Isnain, et al., 2021). Proses utama dalam *text mining* yaitu dengan menemukan kalimat yang dapat mewakili isi dari dokumen yang kemudian akan dianalisis keterkaitan antar dokumen menggunakan metode statistik seperti analisis kelompok (*clustering*), klasifikasi (*classification*) dan informasi retrieval (Rusdian dan Rosiyadi 2019).

Tujuan dari *text mining* adalah untuk memperoleh informasi yang bermanfaat dari sekumpulan dokumen. Jadi, sumber data yang digunakan dalam *text mining* adalah sekumpulan teks dengan memiliki format yang belum terstruktur atau minimal semi terstruktur. Adapun tugas umum dari *text mining* yaitu pengelompokkan teks (Rusdianan dan Rosiyadi 2019). Konsep *teks mining* yang digunakan dalam klasifikasi yaitu dokumen tekstual dengan tujuan untuk mengklasifikasi dokumen yang sesuai dengan topik pembahasan. Perbedaan antara *data mining* dan *text mining* terletak pada *preprocessing*, pada *data mining* *preprocessing* berfokus pada penomoran (*indexing*) dan normalisasi data, sedangkan *text mining* berfokus pada identifikasi dan ekstraksi fitur (Aulia Rahman Isnain, et al., 2021).

2.4 *Machine Learning*

Machine learning merupakan suatu ilmu yang membuat sistem dapat secara otomatis belajar sendiri tanpa harus berulang kali diprogram oleh manusia. *Machine Learning* sendiri merupakan salah satu disiplin ilmu dalam kecerdasan buatan atau yang sering biasa dikenal dengan *Artificial Intelligent (AI)*. *Machine Learning* juga sering disebut dengan *Artificial Intelligent (AI)* konvensional karena merupakan kumpulan metode-metode yang digunakan dalam penerapannya. *Machine Learning* berfokus pada pengembangan program komputer yang dapat mengakses data dan menggunakannya untuk belajar sendiri. Sebelum *Machine Learning* bisa bekerja, maka ia membutuhkan data untuk *training* (latihan) kemudian hasil dari *training* tersebut akan diuji atau di test dengan data yang sama atau bertolak belakang (Ali Imron, 2019).

2.5 *Twitter*

Twitter didirikan oleh Jack Dorsey pada bulan Maret 2006 dengan situs jejaring sosialnya diluncurkan pada bulan Juli yang dioperasikan oleh *Twitter, Inc.* *Twitter* adalah media sosial gratis dan terpopuler serta menyediakan layanan jaringan yang memungkinkan pengguna untuk berbagi pendapat melalui pesan singkat atau sering dikenal dengan tweet (D.K. Zala 2018).

Tweet dapat dilihat secara publik, namun penggunaanya dapat menentukan pengiriman pesan kesiapa saja dan pengguna dapat melihat *tweet* pengguna lainnya yang biasa dikenal sebagai pengikut (*followers*). Pengguna *twitter* juga dapat menulis pesan berdasarkan topik dengan menggunakan simbol # (*hashtag*). Sedangkan untuk menyebutkan nama atau membalas pesan dari pengguna lain dapat menggunakan simbol @ (Ari Yanti Ramadhani 2021). Fitur yang terdapat didalam *Twitter* antara lain:

1. Laman Utama (*Home*)

Pada halaman utama pengguna dapat mengetahui *tweet* yang dikirimkan oleh pengguna lain yang telah menjadi teman kita atau *following*. Halaman utama biasa disebut sebagai *timeline*. *Timeline* ini menampilkan sebuah aliran *tweet* yang telah tersusun sesuai dengan waktu *tweet* dikirim.

2. Profil (*Profile*)

Halaman ini yang akan dilihat oleh semua pengguna *Twitter* mengenai profil atau data diri serta *tweet* yang telah sempat dibuat.

3. Pengikut (*Followers*)

Pengikut adalah pengguna lain yang ingin menjadikan kita sebagai temannya. Ketika pengguna lain sudah menjadi pengikut akun seseorang, maka *tweet* seseorang yang telah diikuti tersebut akan muncul pada halaman utama.

4. Mengikuti (*Following*)

Mengikuti kebalikan dari pengikut, mengikuti adalah akun seseorang yang sudah mengikuti akun pengguna lain agar *tweet* yang dikirim oleh pengguna yang diikuti tersebut dapat muncul pada halaman utama.

5. *Mentions*

Biasanya konten ini merupakan balasan dari percakapan agar sesama pengguna bisa langsung menandai orang yang akan diajak bicara.

6. *Favorite*

Favorite yaitu cara untuk menyimpan sebuah *tweet* yang dianggap menarik dengan memandainya sehingga *tweet* tersebut dapat dibaca lagi suatu saat dan tidak hilang oleh halaman sebelumnya.

7. Pesan Langsung (*Direct Message*)

Pesan langsung sering dikenal dengan sebutan DM. DM sejenis *Inbox* pada *Twitter* yang langsung tertuju ke pembuat *tweet* itu sendiri.

8. Tagar (*Hashtag*)

Hashtag “#” adalah simbol yang ditulis sebelum topik tertentu, yang digunakan agar pengguna lain dapat mencari topik yang serupa yang ditulis oleh pengguna lain juga.

9. List Pengguna

Twitter dapat mengelompokkan satu kelompok sehingga mempermudah untuk dapat melihat secara keseluruhan para daftar nama pengguna (*username*) yang mereka ikuti (*follow*).

10. Topik Hangat (*Trending Topic*)

Topik yang sedang banyak dibicarakan oleh pengguna *Twitter* dalam waktu yang bersamaan. Topik ini dapat membantu penggunanya untuk dapat mengerti apa yang sedang terjadi pada dunia.

11. *Replay*

Replay sebuah balasan atas suatu *tweet* yang mengarah langsung pada si pembuat *tweet* itu.

2.6 Preprocessing Data

Data yang didapatkan dari hasil pengumpulan data belum bisa langsung diklasifikasikan karena data tersebut masih terdapat banyak simbol dan kata-kata yang tidak diperlukan, karena itu diperlukan preprocessing agar data lebih terstruktur dan bersih sehingga bisa diklasifikasikan (Aprilia Rizki Adiati, et., al 2009). Adapun tahapan didalam preprocessing terdapat yaitu *Tokenising*, *Case Folding*, *Stopword*, *Stemming*. Dalam penelitian ini, menerapkan beberapa pre-processing sebagai berikut :

1. *Cleansing*

yaitu proses membersihkan dokumen dan menyeleksi kata yang tidak diperlukan seperti html, emoticon, hashtag, mention dan url.

2. *Case Folding*

Case folding merupakan proses merubah kalimat data teks menjadi seragam.

3. *Tokenizing*

merupakan proses seleksi pemotongan kata dalam kalimat. Diberikan pemisah seperti tanda koma (,), titik (.), dan tanda pemisah lainnya.

4. *Stopword*

stopword adalah proses untuk memfilter kata yang sering digunakan seperti mereka, kenapa, jika, seperti, untuk, ke, dan.

5. *Stemming*

Stemming merupakan proses penyerdehanaan kata dalam kalimat, kata yang berimbuah akan diubah menjadi kata dasar dalam dokumen.

2.7 Pembobotan Data

Pembobotan TF-IDF (*Term Frequency-Inverse Document Frequency*) merupakan proses pembobotan fitur kata pada tweet, TF IDF merupakan gabungan dari Term Frequency (TF) dan Invers Document Frequency (IDF) yang digunakan dalam menghitung bobot setiap kata (term) pada setiap dokumen (Debby Alita, et al., 2020). TF-IDF merupakan sebuah ukuran *statistic* yang digunakan untuk mengevaluasi seberapa penting sebuah kata pada dokumen yang diberikan menunjukkan seberapa penting kata itu dalam tiap dokumen tersebut. DF merupakan frekuensi dokumen yang mengandung kata tersebut menunjukkan seberapa umum kata tersebut. IDF merupakan *inverse* dari nilai DF (Septian 2019).

Hasil dari pembobotan kata menggunakan TF-IDF ini adalah hasil perkalian dari TF dikalikan dengan IDF. Bobot kata semakin besar kata sering muncul pada


suatu dokumen dan semakin kecil jika muncul dalam banyak dokumen. Tujuan dari pembobotan adalah untuk mendapatkan label/sentimen dari setiap kata/term yang ada pada dokumen (Ni'mah dan Arifin 2020).

2.8 Support Vektor Machine

Support Vector Machine (SVM) adalah suatu teknik untuk melakukan prediksi pada kasus klasifikasi maupun regresi. Dalam teknik *Support Vector Machine* bertujuan untuk menemukan fungsi pemisah (*klasifier*) terbaik di antara fungsi tidak terbatas jumlahnya untuk memisahkan dua macam obyek (Budi Santosa & Ardian Umam 2018). Secara sederhana, SVM merupakan metode data mining yang masuk dalam kelas *supervised learning*. Tujuan utama dari teknik ini adalah mencari *hyperplane* terbaik dari beberapa *hyperplane* yang ada (Andi Nurkholis, et al., 2021).

Pada SVM dua dimensi terdapat sumbu x^1 dan x^2 . Secara teori, jarak antara dua garis $ax_1 + bx_2 = c_1$ dengan garis dapat $ax_1 + bx_2 = c_2$ dihitung dengan:

$$\text{Jarak antara 2 garis} = \frac{|c_2 - c_1|}{\sqrt{a^2 + b^2}} \quad (2.1)$$



Gambar 2.1 SVM Dua Kelas dengan Hyperplane Terbaik
(Budi Santosa & Ardian Umam , 2018)

Untuk menghitung margin dapat dengan menghitung jarak antara hyperline $w^T x + b = 1$ dengan *hyperline* $w^T x + b = -1$. *Hyperline* ini dapat di bawa kebentuk $w^T x = 1 - b$ dan $w^T x = -1 - b$, dimana $w^T x$ di sini adalah perkalian matriks yang setara dengan $w_1 x_1 + w_2 x_2$ jika dalam dua dimensi. Dengan menggunakan persamaan (2.1), *margin* dapat dihitung dengan :

$$\begin{aligned} \text{margin} &= \frac{1}{2} * \text{jarak antar dua garis} \\ \text{margin} &= \frac{1}{2} * \frac{|(-1-b)-(1-b)|}{2a\sqrt{w_1^2+w_2^2}} \\ \text{margin} &= \frac{1}{2} * \frac{2}{\|w\|} = \frac{1}{\|w\|} \end{aligned} \quad (2.2)$$

Sehingga proses optimasi SVM yang mana ingin memaksimalkan nilai margin dapat dilakukan dengan meminimalkan pembaginya, yaitu $\|w\|$ atau dapat kita tulis format sebagai berikut:

$$\begin{aligned} &\text{minimize } \frac{1}{2} \|w\| \\ &\text{subject to:} \\ &y_1(wx_1 + b) \geq 1, i = 1, 2, \dots, 1, \end{aligned} \quad (2.3)$$

Dengan x_1 adalah input y_1 , adalah output, dan w, b adalah parameter yang ingin di cari nilainya.

Hyperplane dapat dilihat pada gambar 2.1. dengan menentukan nilai pola terdekat garis *hyperplane* dengan *input space* akan diberi dengan tanda lingkaran positif dan negatif. Namun ketika nilai *input space* berdekatan dengan *support vektori* proses identifikasi lebih sulit karena memiliki nilai berdekatan dan *overlap* terhadap kelas lain, namun dalam proses penentuan *hyperplane* merupakan faktor

paling krusial dalam proses *supervised learning* dalam SVM (Desi B. Tabunan 2021).

2.8.1 Support Vektor Machine One Against One

Dengan metode ini perlu menemukan $k(k-1)/2$ fungsi pemisah dimana setiap fungsi dilatih dengan data dari dua kelas. Dalam metode ini diambil contoh kasus yang telah melalui tahap pembobotan TF-IDF. Nilai x pada tabel akan digunakan untuk perhitungan kernel. Selanjutnya dilakukan kernelisasi pada set data dari fitur dimensi lama sehingga mendapatkan set data dengan fitur baru dimensi tinggi. Dengan kernel $K(x,xi) = \exp(-\gamma \|x - y\|^2)$, $\gamma > 0$, dan set data berdimensi $N \times 1$ maka akan didapatkan dimensi baru $N \times N$, dimana N adalah banyaknya data (Debby Alita, et., al 2020).

Selanjutnya dilakukan kernelisasi pada set data dari fitur dimensi lama sehingga mendapatkan set data dengan fitur baru dimensi tinggi. Dengan kernel $K(x,xi) = \exp(-\gamma \|x - y\|^2)$, $\gamma > 0$, dan set data berdimensi $N \times 1$ maka akan didapatkan dimensi baru $N \times N$, dimana N adalah banyaknya data. Prinsip dari metode ini yaitu dibangun $(k-1)2$ buah model klasifikasi biner (k adalah jumlah kelas). Setiap model klasifikasi dilatih pada data dari dua kelas.

2.8.2 Support Vektor Machine One Against Rest

Pada proses klasifikasi k -kelas, ditemukan k fungsi pemisah dimana k adalah banyaknya kelas. Misalkan ada fungsi pemisah dengan nama p . Dalam metode ini, p_i dilatih dengan semua data dari kelas ke- i dengan label $+1$ dan semua data dari kelas lain dengan label -1 . Dalam tahap ini diambil contoh kasus yang telah melalui tahap preprocessing dan pembobotan TF-IDF.

Formulasi yang digunakan adalah dualitas Lagrange multiplier yang sudah dimodifikasi untuk x dengan fungsi kernelnya, menjadi $w = \sum_{i=1}^n \alpha_i y_i \phi(x_i)$ dengan keterangan W = vector bobot, $\alpha_i = 0,5$ (konstanta), y_i = kelas data, x_i = data latih. Pada dasarnya prinsip dari metode ini adalah dibangun k buah model SVM biner (k adalah jumlah kelas). Setiap model klasifikasi ke- i dilatih dengan menggunakan keseluruhan data, untuk mencari solusi permasalahan (Debby Alita, et., al 2020).

Formulasi yang digunakan adalah dualitas Lagrange multiplier yang sudah dimodifikasi untuk x dengan fungsi kernelnya, menjadi $w = \sum_{i=1}^n \alpha_i y_i \phi(x_i)$ dengan keterangan W = vector bobot, $\alpha_i = 0,5$ (konstanta), y_i = kelas data, x_i = data latih.


Selanjutnya harus dilakukan kernelisasi pada set data dari fitur dimensi lama sehingga mendapatkan set data dengan fitur baru dimensi tinggi. Dengan kernel $K(x,y) = \exp(-\gamma \|x - y\|^2)$, $\gamma \gg 0$, dan set data berdimensi $N \times 1$ maka akan didapatkan dimensi baru $N \times N$, dimana N adalah banyaknya data.

Pada dasarnya prinsip dari metode ini adalah dibangun k buah model SVM biner (k adalah jumlah kelas). Setiap model klasifikasi ke- i dilatih dengan menggunakan keseluruhan data, untuk mencari solusi permasalahan. Contohnya, terdapat permasalahan klasifikasi dengan 3 buah kelas. Untuk pelatihan digunakan 3 buah SVM biner.

2.9 Metode Kernel

Banyak teknik data mining atau *machine learning* yang dikembangkan dengan asumsi kelinieran. Sehingga algoritma yang dihasilkan terbatas untuk kasus-kasus yang linier. Umumnya kasus-kasus yang terjadi di dunia nyata bukanlah kasus yang tidak linier. Untuk mengatasi sifat yang tidak linier tersebut dapat menggunakan metode kernel (Ari Yanti Ramadhani 2021).

Dengan metode kernel suatu data x *input space* di *mapping* ke *feature space* F dengan dimensi yang lebih tinggi melalui map φ sebagai berikut $\varphi: x \rightarrow \varphi(x)$. Karena itu data x di *input space* menjadi $\varphi(x)$ di *feature space*. Gambar 2.3 menunjukkan suatu contoh *feature mapping* dari ruang dua dimensi ke *feature space* dua dimensi. Dalam *input space*, data tidak bisa dipisahkan secara *linier*, tetapi dapat dipisahkan di *feature space*.



Gambar 2.2 Kernel Map Mengubah Persoalan Yang Tidak Linear Menjadi Linear Dalam Space Yang Baru (Suyanto 2018)

Adapun fungsi kernel yang biasanya digunakan dalam SVM :

$$\text{Kernel linear} : X^T X, \quad (2.4)$$

$$\text{Kernel polynomial} : (X^T X_i + 1)^p, \quad (2.5)$$

$$\text{Kernel Radial basis function} : \exp\left(-\frac{1}{2\sigma^2} \|x - x_1\|^2\right), \quad (2.6)$$

$$\text{Kernel tangent hyperbolic} : \tanh(\beta^T X_i + \beta_i), \quad (2.7)$$

2.10 Confusion Matrix

Confusion Matrix adalah teknik yang digunakan dalam melakukan evaluasi klasifikasi model berdasarkan objek yang diperkirakan dengan benar atau salah. Sebuah matriks dari prediksi akan dibandingkan dengan kelas asli yang berisi informasi aktual dan prediksi nilai klasifikasi. Setelah sistem berhasil melakukan klasifikasi *tweet*, dibutuhkan ukuran untuk menentukan seberapa valid atau tepat klasifikasi yang telah dibuat oleh sistem. Tabel 2.1 ini akan menunjukkan *confusion matrix* yang digunakan untuk membantu dalam perhitungan system evaluasi (Arsya Monica Pravina, Imam Cholissodin 2019).

Pengujian akurasi ini dilakukan menggunakan confusion matrix dengan melibatkan empat kondisi sebagai berikut:

Table 2.1 *Confusion Matrix*

Data Aktual	Data Prediksi		
	Negatif	Netral	Positif
Negatif	TNg	NgN	FN
Netral	NNg	TN	NP
Positif	FP	PN	TP

Multiclass Confusin Matrix memiliki elemen-elemen sebagai berikut :

1. TP : Kelas kata terprediksi benar bernilai positif
2. FN : Kelas positif terprediksi netral
3. FP : Kelas positif terprediksi negatif
4. NP : Kelas netral terprediksi sebagai kelas kata positif
5. TN : Kelas terprediksi netral
6. NNg : Kelas netral terprediksi negatif
7. FN : Kelas negatif terprediksi positif
8. NgN : Kelas negatif terprediksi netral
9. TNg : Kelas negatif terprediksi negative

Hasil dari pengujian *Confusion Matrix* dapat menghasilkan nilai *akurasi*, *recall*, *precision*. Akurasi merupakan nilai dari kemiripan antar nilai prediksi dan nilai sebenarnya. *Precision* merupakan tingkat dari kebenaran antar informasi yang diminta oleh pengguna dan informasi yang disediakan oleh sistem. *Recall* merupakan tingkat keberhasilan dalam menemukan kembali informasi. *F-measure* merupakan bentuk parameter gabungan dari *recall* dan presisi untuk ukuran keberhasilan *retrival*. Dengan menggunakan tabel *multiclass confusion matrix* 3x3, maka untuk menghitung tingkat akurasi, presisi dan recall di gunakan rumus:

$$Akurasi = \frac{TPos+TNeg+TNet}{TPos+FPosNeg+FPosNet+FNegPos+TNeg+FNegNet+FNetPos+FNetNeg+TNet} \quad (2.8)$$

$$Presisi = \frac{positif}{positif+negatif+netral} \quad (2.9)$$

$$Recall = \frac{positif}{positif+negatif+netral} \quad (2.10)$$

$$F - Measure = 2 * \frac{presisi*recall}{presisi+recall} \quad (2.11)$$