

BAB 2

TINJAUAN PUSTAKA

2.1 Pembatasan Sosial Berskala Besar (PSBB)

PSBB adalah singkatan dari Pembatasan Sosial Berskala Besar, PSBB dilakukan sebagai upaya yang harus dilakukan untuk melawan pandemi Covid-19 [14]. PSBB diterbitkan oleh Kementerian Kesehatan (Kemenkes) dalam rangka Percepatan Penanganan COVID-19 agar bisa segera dilaksanakan di berbagai daerah. Aturan PSBB tercatat dalam Peraturan Menteri Kesehatan (Permenkes) RI Nomor 9 Tahun 2020 tentang Pedoman Pembatasan Sosial Berskala Besar Dalam Rangka Percepatan Penanganan Corona Virus Disease 2019 (Covid-19) [15]. Di Indonesia PSBB mulai dilakukan sejak awal Maret 2020. PSBB merupakan sebuah penyelenggaraan pembatasan kegiatan-kegiatan di tempat umum dan mengkarantinakan diri sendiri didalam rumah. Pembatasan kegiatan yang dilakukan antara lain peliburan sekolah dan tempat kerja, pembatasan keagamaan dan pembatasan kegiatan-kegiatan lainnya di tempat umum. Tujuan dari PSBB yaitu untuk mencegah meluasnya penyebaran virus COVID-19 yang sedang terjadi saat ini [16].

2.2 Text Mining

Text mining merupakan bidang baru yang sedang berkembang yang digunakan untuk mengumpulkan informasi yang memiliki arti dari teks bahasa alami [17]. Text mining adalah bagian dari penelitian ilmu pengetahuan komputer yang mencoba memecahkan krisis dari muatan informasi dengan mengkombinasikan teknik dari data mining, machine learning, natural language processing, information retrieval dan knowledge management [18]. Proses kerja Text Mining hampir sama dengan Data Mining namun yang membedakan pada Text Mining data sumber yang digunakan sebagai document collection tidak memiliki pola yang terstruktur secara tekstual dan tidak diformulasikan di database, Sehingga dalam text mining diperlukan pengubahan data tidak terstruktur menjadi data yang terstruktur dan disajikan dalam bentuk numerik. Text mining biasanya berkaitan dengan teks yang memiliki fungsi untuk

komunikasi dari informasi yang faktual atau opini, dan keinginan untuk mencoba mengekstrak informasi dari sebuah teks secara otomatis merupakan hal yang menarik meskipun tingkat keberhasilan yang diperoleh hanyalah sebagian. Sehingga dalam text mining diperlukan perubahan data tidak terstruktur menjadi data yang terstruktur dan disajikan dalam bentuk numerik. Salah satu bentuk penggunaan text mining adalah untuk Analisis Sentimen.

2.3 Teknik Pengambilan Data

Pada penelitian ini, akan dilakukan implementasi teknik crawling untuk mengumpulkan data yang berasal dari Twitter. Crawling adalah teknik yang digunakan untuk mengumpulkan informasi di web. Crawling bekerja secara otomatis, dimana informasi yang dikumpulkan berdasarkan pada kata kunci yang disediakan oleh pengguna.

Crawler adalah alat yang digunakan untuk crawling. Crawler berbentuk program yang diprogram dengan algoritma tertentu, sehingga dapat dilakukan memindai ke halaman web, sesuai dengan alamat web atau kata kunci yang ditetapkan pengguna. Ketika melakukan pemindaian, crawler akan membaca teks yang ada, hyperlink dan berbagai tag yang digunakan pada halaman situs web. Berdasarkan informasi tersebut, crawler akan mengindeks informasi atau menyimpan informasi ke dalam file atau ke database. Hasil dari crawling ini dapat dimanfaatkan untuk analisis serta ekstraksi informasi [19].

2.4 Analisis Sentimen

Analisis sentimen atau disebut juga opinion mining adalah bidang studi untuk menganalisis pendapat, sentimen, evaluasi, penilaian sikap dan emosi terhadap entitas seperti produk, jasa, organisasi, individu, peristiwa dan atribut lainnya. Analisis sentimen berfokus kepada opini yang mengekspresikan sentimen positif, negatif atau netral [20]. Terdapat tiga tahapan umum dalam proses analisis sentimen, yaitu pengambilan data dari sumber data atau yang biasa disebut crawling yang mana mengumpulkan *tweets*, lalu memisahkan menjadi tiga kategori yaitu positif, negatif dan netral, selanjutnya mencari kata kunci yang terkait dengan sekumpulan tweet positif, negatif dan netral. Kata kunci ini

terutama untuk menggambarkan aspek apa yang mendapat opini, selanjutnya tahap training dan testing dengan menggunakan

2.5 Analisis Sentimen Berdasarkan Aspek

Analisis sentiment berdasarkan level aspek dapat melakukan analisis sentimen secara lebih dalam dari suatu teks ulasan. Level aspek berguna untuk mengetahui aspek apa yang ada dalam setiap ulasan. Analisis sentimen berbasis aspek dari opini berbasis teks mengacu pada entitas yang spesifik dan aspek yang dibahasnya. Penggunaan level aspek bertujuan untuk mendeteksi polaritas teks tertulis berdasarkan aspek tertentu.

Penelitian aspect-based sentiment analysis (ABSA) secara umum terdiri dari 2 task yaitu Aspect Extraction dan Aspect Sentiment Orientation Classification [20].

2.5.1 Aspect Extraction

Pada tahap ini mengekstrak aspek yang sudah ditentukan sebelumnya. Misalnya, dalam kalimat “Pemberlakuan belajar jarak jauh atau belajar daring selama masa pandemi Covid-19 membuat beberapa pelajar atau siswa di Indonesia kesulitan mengakses pelajaran yang diberikan.”, aspeknya adalah “Belajar Daring” entitasnya “Mengakses pelajaran”. Pada kata “Mengakses pelajaran” tidak menunjukkan aspek umum karena evaluasi bukan tentang mengakses pelajaran secara keseluruhan tetapi hanya tentang “Belajar Daring”.

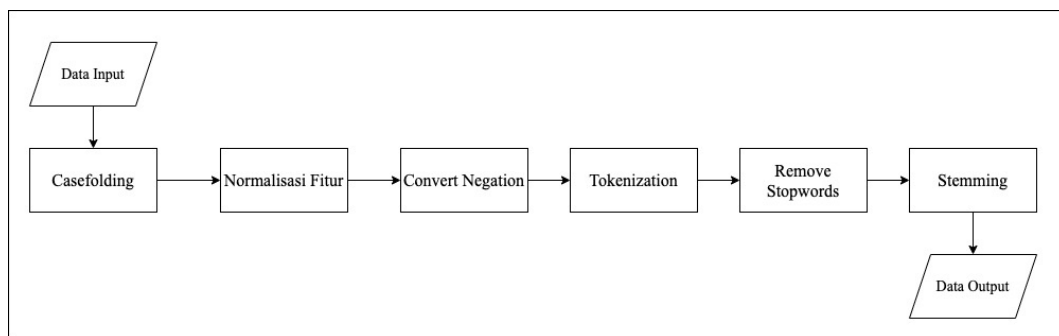
2.5.2 Aspect Sentiment Orientation Classification

Pada tahap ini menentukan apakah pendapat dari berbagai aspek kedalam sentimen positif, atau negatif. Pada contoh kalimat “Meski lebaran dan larangan mudik sudah berlalu, kita juga harus kooperatif. Jangan mudik dulu di saat seperti ini”. Sentimen dari aspek “Larangan Mudik” adalah positif.

Pemilihan Aspek dan Pelabelan dataset Berdasarkan observasi terhadap data ulasan yang diperoleh dari *Twitter* didapatkan 4 aspek yang dimiliki, yakni aspek Kesehatan, Ekonomi, Pendidikan, Transportasi. Tahap perancangan dataset meliputi tahap manualisasi pelabelan data yang dilakukan terhadap data teks uraian opini pelanggan untuk setiap aspek.

2.6 Preprocessing

Sebelum dilakukan proses klasifikasi, diperlukan proses preprocessing terhadap data mentah yang digunakan akan sebagai materi untuk klasifikasi nantinya. Tujuan preprocessing adalah mentransformasikan data ke dalam suatu format data yang lebih mudah untuk diproses sesuai dengan kebutuhan penelitian [21]. Berikut langkah-langkah preprocessing pada penelitian ini:



Gambar 2.1 Tahapan Preprocessing

1. Casefolding pada data tweet dilakukan proses perubahan dari huruf besar menjadi huruf kecil dan menghilangkan seluruh tanda baca pada kalimat.
2. Normalisasi Fitur merupakan proses menghilangkan atau menghapus komponen-komponen khas yang terdapat pada tweet seperti username, url, rt.
3. Convert Negation, pada tahap ini setiap *tweets* yang mengandung kata-kata yang bersifat negasi akan diubah nilai sentimennya
4. Tokenization pada data tweet setiap kata akan dipisahkan berdasarkan spasi yang ditemukan. Proses memisahkan atau memotong semua kata yang ada pada suatu kalimat dan mengubahnya menjadi kumpulan token atau term.
5. Remove Stopwords adalah proses menghilangkan kata yang sering muncul, bersifat umum dan dianggap sebagai kata yang tidak memiliki makna.
6. Stemming yaitu pengubahan kata berimbuhan menjadi kata dasar atau kata asli pada data tweet.

Proses ini bertujuan untuk mengoptimasi pencocokan sehingga hasil yang dicari dapat lebih akurat.

2.7 *Term Frequency (TF)*

Term Frequency (TF) adalah algoritma pembobotan heuristik yang menentukan bobot dokumen berdasarkan kemunculan term. Bobot dari suatu kata, t dalam suatu dokumen, d dan dilambangkan dengan tfd . Pendekatan paling sederhana dari konsep ini adalah dengan menyatakan bobot suatu kata t sebagai jumlah kemunculannya pada dokumen d . Jika suatu dokumen muncul sebanyak 5 kali kata plagiat, maka nilai TFnya adalah 5. Semakin sering sebuah istilah muncul, semakin tinggi bobot dokumen untuk istilah tersebut, dan sebaliknya.

Konsep term frequency memandang suatu dokumen sebagai kantong kata di mana urutan dari kemunculan suatu kata diabaikan dan hanya jumlah kemunculan dari kata itu saja yang penting. Konsep term frequency memiliki kelemahan yaitu semua kata dianggap setara. Hal ini mengakibatkan relevansi suatu kata menjadi sangat tinggi jika kata itu sering muncul dalam suatu kumpulan dokumen. Padahal tingginya frekuensi kemunculan suatu kata tidak selalu menyatakan bahwa kata tersebut penting.

Terdapat empat buah algoritma untuk mendapatkan nilai TF yaitu: [22]

- a. Raw Tf Nilai Tf sebuah term dihitung berdasarkan kemunculan term tersebut dalam dokumen.
- b. Logarithmic Tf Dalam memperoleh nilai Tf, cara ini menggunakan fungsi logaritmik dalam matematika. $TF = 1 + \log (TF)$
- c. Binnary Tf Cara ini menghasilkan nilai Boolean berdasarkan kemunculan term pada dokumen tersebut. Akan bernilai 0 apabila term tidak ada pada sebuah dokumen, dan bernilai 1 apabila term tersebut ada dalam dokumen. Sehingga banyaknya kemunculan term pada dokumen tidak berpengaruh.
- d. Augmented Tf $TF = 0.5 + 0.5 \times TF_{max} (TF)$

Dalam penelitian ini digunakan algoritma Raw TF. Raw TF diperoleh dari perhitungan frekuensi kemunculan suatu istilah pada dokumen.

2.8 Naive Bayes Classification

Naive Bayes Classification pertama kali ditemukan oleh Thomas Bayes pada abad ke-18. Pengklasifikasi bayes merupakan salah satu pengklasifikasi statistik, dimana pengklasifikasi ini dapat memprediksi probabilitas keanggotaan kelas suatu data tuple yang akan masuk ke dalam kelas tertentu, sesuai dengan perhitungan probabilitas. Naive Bayes classifier menunjukkan akurasi dan kecepatan yang tinggi bila diterapkan pada database yang besar [23]. Metode ini sering digunakan dalam menyelesaikan masalah dalam bidang mesin pembelajaran karena metode ini dikenal memiliki tingkat akurasi yang tinggi dengan perhitungan sederhana [23].

Teorema *Bayes* berawal dari persamaan (2-1), yaitu.

$$P(A|B) = \frac{P(B|A) \times P(A)}{P(B)} \quad (2-1)$$

Dari persamaan dapat dijelaskan sebagai berikut.

$P(A|B)$ adalah peluang A (kata) pada data uji jika diketahui keadaan B (kelas) positif dan negatif.

Algoritma pembelajaran *Bayes* menghitung probabilitas eksplisit untuk menggambarkan hipotesa yang dicari. Sistem dilatih menggunakan data latihan lengkap berupa nilai-nilai atribut dan nilai target kemudian sistem akan diberikan sebuah data baru dalam bentuk $\langle a_1, a_2, a_3, \dots, a_n \rangle$ dan sistem diberi tugas untuk menebak nilai fungsi target tersebut dari data hasil pelatihan.

Naive Bayes memberi nilai target kepada data baru menggunakan nilai V_{map} , yaitu nilai kemungkinan tertinggi dari seluruh anggota himpunan set domain V yang ditunjukkan pada persamaan (2-2).

$$C_{\text{map}} = \underset{V_j \in V}{\text{argmax}} P(V_j | a_1, a_2, a_3, \dots, a_n) \quad (2-2)$$

Dimana

a = kata dalam dokumen

V_j = Kategori ke j

$j = 1, 2, 3$

V_1 = Kategori Positif

V_2 = Kategori Negatif

Teori *Bayes* kemudian digunakan untuk menulis ulang persamaan (2-2) menjadi persamaan (2-3)

$$C_{\text{map}} = \underset{V_j \in V}{\text{argmax}} \frac{P(a_1, a_2, a_3, \dots, a_n | V_j)P(V_j)}{P(a_1, a_2, a_3, \dots, a_n)} \quad (2-3)$$

Karena $P(a_1, a_2, a_3, \dots, a_n)$ nilainya konstan untuk semua V_j sehingga persamaan 2.5 dapat ditulis dengan persamaan (2-4).

$$C_{\text{map}} = \underset{V_j \in V}{\text{argmax}} P(a_1, a_2, a_3, \dots, a_n | V_j)P(V_j) \quad (2-4)$$

Tingkat kesulitan menghitung $P(a_1, a_2, a_3, \dots, a_n | V_j)P(V_j)$ menjadi tinggi karena jumlah kata $P(a_1, a_2, a_3, \dots, a_n | V_j)P(V_j)$ bisa menjadi sangat besar. Ini disebabkan jumlah kata tersebut sama dengan jumlah kombinasi posisi kata dikali dengan jumlah kategori. Metode klasifikasi Naive Bayes menyederhanakan hal ini dengan bekerja dengan asumsi bahwa atribut-atribut yang digunakan bersifat conditionally independent antara satu dan yang lainnya, dengan kata lain dalam setiap kategori, setiap kata independent satu sama lain. Sehingga menjadi persamaan

$$C_{\text{map}} = \underset{V_j \in V}{\text{argmax}} P(V_j) \prod_{i=1}^n P(a_i | V_j) \quad (2-5)$$

Substitusi persamaan (2-5) dengan persamaan (2-4) menjadi persamaan (2-6).

$$C_{\text{map}} = \underset{V_j \in V}{\text{argmax}} P(V_j) \prod_{i=1}^n P(a_i | V_j) \quad (2-6)$$

C_{map} adalah nilai probabilitas hasil perhitungan Naive Bayes. Untuk nilai fungsi target yang bersangkutan. Frekuensi kemunculan kata menjadi dasar perhitungan nilai dari $P(V_j)$ dan $P(a_i | V_j)$. Himpunan set dari nilai-nilai probabilitas 15 ini berkorespondensi dengan hipotesa yang ingin dipelajari. Hipotesa kemudian digunakan untuk mengklasifikasikan data-data baru. Pada pengklasifikasikan teks, perhitungan persamaan (2-6) dapat didefinisikan:

$$P(V_j) = \frac{\text{docs}_j}{|D|} \quad (2-7)$$

$$P(w_k | V_j) = \frac{n_k + 1}{n + |\text{kata}|} \quad (2-8)$$

Keterangan:

V_j = Kategori ke j

docs_j = Kumpulan dokumen yang memiliki kategori v_j .

$|D|$ = Jumlah dokumen yang digunakan dalam pelatihan (kumpulan data latih).

$P(w_k | c_i)$ = peluang kemunculan w_k pada kategori c_i

n_k = Jumlah kemunculan kata w_k pada semua data tekstual yang memiliki nilai fungsi target yang sesuai.

n = jumlah total kata yang terdapat di dalam kata tekstual yang memiliki nilai fungsi target yang sesuai.

$|kata|$ = Jumlah kata yang berbeda yang muncul dalam seluruh data tekstual yang digunakan.

2.9 K-Fold Cross Validation

K-fold cross validation adalah teknik yang dapat digunakan apabila memiliki jumlah data yang terbatas (jumlah instance tidak banyak) [24]. K-fold cross validation merupakan salah satu metode yang digunakan untuk mengetahui rata-rata keberhasilan dari suatu sistem dengan cara melakukan perulangan dengan mengacak atribut masukan sehingga sistem tersebut teruji untuk beberapa atribut input yang acak. K-fold cross validation diawali dengan membagi data sejumlah n fold yang diinginkan. Dalam proses cross validation data akan dibagi dalam n buah partisi dengan ukuran yang sama $D_1, D_2, D_3, \dots, D_n$ selanjutnya proses testing dan training dilakukan sebanyak n kali. Dalam iterasi ke- i partisi D_i akan menjadi data testing dan sisanya akan menjadi data training. Untuk penggunaan jumlah fold terbaik untuk uji validitas, dianjurkan menggunakan 10-fold cross validation dalam model [25].

Skenario pengujian merupakan tahap penentuan pengujian yang dilakukan. Pengujian dilakukan menggunakan metode k-cross validation dengan nilai k sebanyak 10-fold, pengujian ini bertujuan untuk mengetahui akurasi metode naïve bayes classifier yang diterapkan pada analisis sentimen jika diuji dengan data training dan data testing yang berbeda. Penggunaan 10-fold ini dianjurkan karena merupakan jumlah fold terbaik untuk uji validitas [26]. Tahap pengujian dengan menggunakan metode 10-fold cross validation membagi dataset yang awalnya berjumlah 1500 data akan dibagi menjadi 10 subset (bagian) masing-masing subset berjumlah 150 data. Pada fold pertama terdapat kombinasi 9 subset yang berbeda digabung dan digunakan sebagai data training, sedangkan 1 subset (sisa) digunakan sebagai data testing, selanjutnya proses training dan testing dilakukan sampai fold kesepuluh.

2.10 Klasifikasi multi-label

Klasifikasi Multi-label menjadi perhatian bagi peran penelitian dalam mengembangkan dan menerapkan di dalam machine learning. Pendekatan dalam metode klasifikasi multi-label dibagi menjadi dua kategori utama, yaitu Problem Transformation Methods dan Algorithm Adaptation Methods [26].

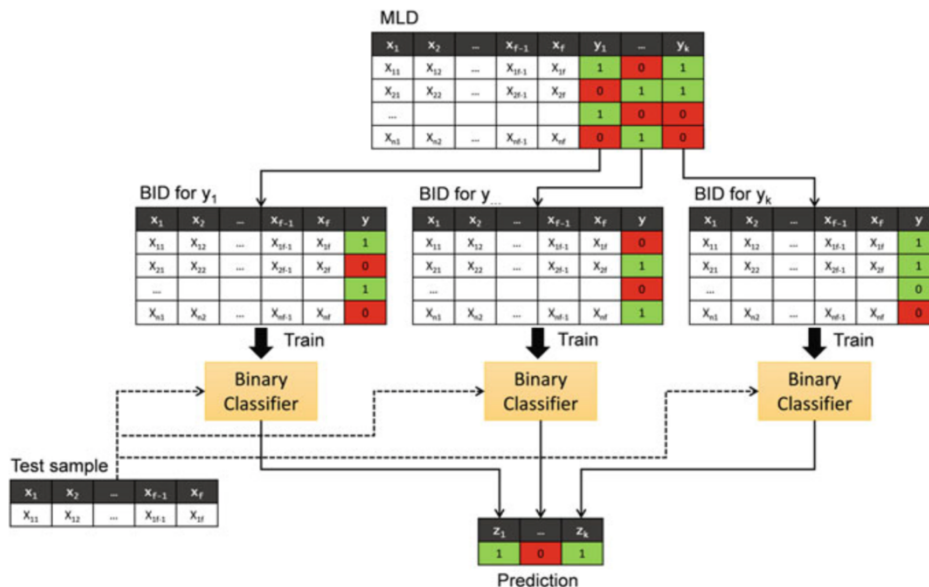
Klasifikasi teks adalah bagian dari supervised learning yang mana memiliki tujuan untuk mengklasifikasikan data berdasarkan labelnya. Setiap data dapat dikelompokkan dalam satu label, beberapa label atau tanpa label. Ada dua jenis model klasifikasi yaitu single-label hanya memiliki panjang label = 1 dan multi-label, yang memiliki lebih banyak dari dua panjang label yang menjadi fokus penelitian ini.

Penelitian telah dilakukan oleh Min-Ling Zhang tentang multi-label [27]. Pendekatan yang digunakan dalam kasus multi-label adalah salah satu masalah transformasi. Pendekatan transformasi masalah menangani masalah multi-label menjadi satu label dengan menggambarkan masalah pembelajaran multi-label ke dalam klasifikasi biner independent masalah, di mana setiap masalah klasifikasi biner sesuai dengan label yang mungkin diberi label sebagai relevansi biner [27].

Pada penelitian ini akan menggunakan metode berdasarkan klasifikasi biner yang dilakukan dengan mengambil satu label dari keseluruhan label, dan mengklasifikasikan masing-masing label secara terpisah. Terdapat dua teknik terkenal untuk menghadapi klasifikasi multiclass melalui ansambel pengklasifikasi biner yaitu pendekatan OVO dan OVA [28].

OVA (*one-versus-one*) juga dikenal sebagai OVR(One vs the rest / Satu vs yang lain), didasarkan pada pelatihan pengklasifikasi individu untuk setiap kelas terhadap semua orang lain. Teknik ini diperluas di bidang multilabel untuk dipertimbangkan memperhitungkan bahwa beberapa label dapat menjadi relevan sekaligus. Oleh karena itu, pengklasifikasi biner adalah dilatih untuk setiap label, seperti yang digambarkan pada Gambar, dan dan outputnya digabungkan untuk menghasilkan set label yang diprediksi. Di bidang multilabel, pendekatan ini bernama Binary Relevansi (BR).

Mengenai pendekatan OVO (*one-versus-All*), dalam klasifikasi multiclass, didasarkan pada pengklasifikasi untuk setiap pasangan kelas. Dengan cara ini model khusus untuk setiap pasangan diperoleh, meskipun dengan biaya koleksi pengklasifikasi yang lebih besar bila dibandingkan dengan OVA.



Gambar 2.2 Diagram Transformasi Relevansi Biner

Pada Gambar 2.2 Multilabel dataset (MLD) merupakan tabel keseluruhan dari dataset yang mana akan menghasilkan binary dataset (BID) sebanyak label yang ada pada dataset. Kemudian masing-masing BID akan dilakukan pelatihan untuk dapat mengklasifikasikan sesuai masing-masing label.[28]

2.11 Metode Performansi

Pada penelitian ini, metode performansi yang digunakan adalah *Hamming-Loss*. *Hamming loss* merupakan tingkat kesalahan antara label prediksi dengan label kebenaran. Nilai *hamming loss* yang lebih kecil menunjukkan performa yang lebih baik. Dalam metoda *Hamming-Loss*, perhitungan yang dilakukan adalah banyaknya kesalahan klasifikasi terhadap data yang diuji. Performansi dalam metode *Hamming-Loss* ditandai dengan representasi nilai dari $hloss(h)$. Semakin kecil nilai $hloss(h)$ maka berarti akurasi atau performansi dari sistem klasifikasi

yang dibangun semakin tinggi atau semakin baik. Persamaan untuk menghitung hloss(h) terlihat pada Persamaan 2.8[29].

$$H_{Loss} = \frac{1}{m} \sum_{i=1}^m \frac{H(X_i) \Delta Y_i}{|L|} \quad (2.8)$$

Accuracy adalah tingkat prediksi yang paling dekat dengan label sebenarnya. Nilai yang lebih tinggi dari accuracy menunjukkan performa yang lebih baik. Nilai kebenaran parameter ini dihitung dari diagram irisan prediksi dengan label kebenaran dibagi dengan diagram gabungan prediksi dengan label kebenaran dan jumlah data uji m. Evaluasi ini direpresentasikan persamaan 2.9.

$$Accuracy = \frac{1}{m} \sum_{i=1}^m \frac{|H(X_i) \cap Y_i|}{|H(X_i) \cup Y_i|} \quad (2.9)$$

2.11 Twitter

Twitter adalah layanan jejaring sosial dan mikroblog daring yang memungkinkan penggunanya untuk mengirim dan membaca pesan berbasis teks hingga 140 karakter akan tetapi pada tanggal 07 November 2017 bertambah hingga 280 karakter yang dikenal dengan sebutan kicauan (tweet). *Twitter* didirikan pada bulan Maret 2006 oleh Jack Dorsey, dan situs jejaring sosialnya diluncurkan pada bulan Juli. Sejak diluncurkan, *Twitter* telah menjadi salah satu dari sepuluh situs yang paling sering dikunjungi di Internet, dan dijuluki dengan "pesan singkat dari Internet."



Gambar 2.2 Logo Twitter

Twitter mengalami pertumbuhan yang pesat dan dengan cepat meraih popularitas di seluruh dunia. Hingga bulan Januari 2013, terdapat lebih dari 500 juta pengguna terdaftar di *Twitter* per hari, dan *Twitter* menangani lebih dari 1,6 miliar permintaan pencarian per hari, 200 juta di antaranya adalah pengguna aktif. Lonjakan penggunaan *Twitter* umumnya berlangsung saat terjadinya peristiwa-peristiwa populer. Dikarenakan hal ini posisi *Twitter* naik ke peringkat kedua sebagai situs jejaring sosial yang paling sering dikunjungi di dunia, yang sebelumnya menempati peringkat dua puluh dua [30]

Tingginya popularitas *Twitter* menyebabkan layanan ini telah dimanfaatkan untuk berbagai keperluan dalam berbagai aspek, misalnya sebagai sarana protes, kampanye politik, sarana pembelajaran, dan sebagai media komunikasi darurat. *Twitter* juga dihadapkan pada berbagai masalah dan kontroversi seperti masalah keamanan dan privasi pengguna, gugatan hukum, dan penyensoran.

2.12 Twitter API

Twitter API merupakan sekumpulan URL yang mengambil parameter. URL ini mengizinkan pengguna mengakses fitur-fitur *Twitter*, seperti memposting tweet atau mencari tweet yang berisi suatu kata dan lain-lain [31]. *Twitter* API (Application Programming Interface) guna memudahkan para developer untuk mengambil data dari *Twitter* dan mengolahnnya. Pengumpulan data dari *Twitter* dapat digunakan untuk berbagai kebutuhan seperti.

1. Website yang membutuhkan login dengan *Twitter*.
2. Mendapatkan informasi akun, melihat *mention*, *retweets*, *favorites*, *followers*, *friends* dari akun *Twitter* tertentu yang terhubung dengan aplikasi.

3. Update status / *tweets* secara otomatis pada akun *Twitter* yang bersangkutan ketika melakukan aktivitas tertentu pada aplikasi.
4. Melihat home timeline, dan timeline pada akun *Twitter*.

2.13 Tools Pembangunan Perangkat Lunak

Dalam pembangun perangkat lunak digunakan beberapa tools untuk membangun perangkat lunak. Adapun tools yang digunakan yaitu.

2.13.2 Python

Python adalah bahasa pemrograman interpretative yang dianggap mudah dipelajari serta berfokus pada keterbacaan kode. Dengan kata lain, Python diklaim sebagai bahasa pemrograman yang memiliki kode-kode pemrograman yang sangat jelas, lengkap, dan mudah dipahami. Python secara umum berbentuk pemrograman berorientasi objek, pemrograman imperatif, dan pemrograman fungsional. Python dapat digunakan untuk berbagai keperluan perangkat lunak dan dapat berjalan diberbagai platform sistem operasi. Distribusi dalam aplikasi yang dibuat menggunakan python sangat luas dan multiplatform, diantaranya adalah Linux/Unix, Windows, Mac Os X, Java Virtual Machine, OS/2, Amiga, Palm, Symbian [32].

Bahasa python muncul pertama kali pada tahun 1991, dirancang oleh seorang bernama Guido van Rossum. Sampai saat ini Python masih dikembangkan oleh Python Software Foundation. Bahasa Python mendukung hampir semua sistem operasi, bahkan untuk sistem operasi Linux, hampir semua distronya sudah menyertakan Python di dalamnya [33].