

ANALISIS SENTIMEN TERHADAP PELAYANAN PT PLN DI JAKARTA PADA *TWITTER* DENGAN ALGORITMA *K-NEAREST NEIGHBOR (K-NN)*

M. Suyudi Alrajak, Iin Ernawati, Ika Nurlaili
Fakultas Ilmu Komputer
Universitas Pembangunan Nasional "Veteran" Jakarta
Jl. R.S Fatmawati, Pondok Labu, Jakarta Selatan, DKI Jakarta, 12450, Indonesia
m.suyudi.a@gmail.com

Abstrak. *Twitter* merupakan media sosial yang banyak digunakan masyarakat untuk berpendapat. Pendapat tersebut dapat berupa opini terhadap pelayanan perusahaan. Salah satu perusahaan yang menyediakan wadah opini tersebut, yaitu PT. PLN melalui akun @pln_123. Opini tersebut berupa laporan atau pertanyaan (sentimen netral), keluhan (sentimen negatif), dan dukungan (sentimen positif) perihal kelistrikan PLN yang dapat dijadikan acuan untuk meningkatkan kualitas pelayanan yang lebih baik lagi dengan cara analisis sentimen. Analisis sentimen dapat dilakukan melalui tahap *text preprocessing*, yaitu membersihkan kata yang tidak relevan dengan sentimen lalu memberikan bobot tiap kata dengan *Term Frequency-Invers Document Frequency (TF-IDF)* kemudian melakukan klasifikasi dengan algoritma *K-Nearest Neighbor (K-NN)* menggunakan *Euclidean Distance* dengan jarak antar tetangga berjumlah 3 atau $K = 3$. Total akurasi yang didapatkan sebesar 89,4% dengan hasil klasifikasi pada bulan Februari 2020 pada daerah DKI Jakarta dari total 500 tweets menghasilkan sejumlah sentimen netral sebanyak 426 (85,2%), sentimen negatif sebanyak 71 (14,2%), dan sentimen positif sebanyak 3 (0,6%).

Kata Kunci: Analisis Sentimen, K-NN, *Text Mining*, *Euclidean Distance*

1. Pendahuluan

1.1. Latar Belakang

PT. Perusahaan Listrik Negara (PLN) merupakan perusahaan pemerintah yang bertujuan untuk menyelenggarakan usaha penyediaan tenaga listrik bagi kepentingan umum dalam jumlah dan mutu yang memadai serta memupuk keuntungan. Salah satu misi dari PT. PLN adalah menjalankan bisnis kelistrikan dan bidang lain yang terkait, berorientasi pada kepuasan pelanggan. Untuk menjaga mutu kepuasan pelanggan, maka diperlukan opini publik terhadap pelayanan PT. PLN. Opini publik tersebut berupa keluhan masyarakat (opini negatif), dukungan masyarakat (opini positif), dan laporan masyarakat (opini netral). Pada era saat ini, sudah banyak platform media sosial yang bisa dijadikan wadah opini publik. Salah satu media sosial yang digunakan oleh PT. PLN sebagai wadah opini publik adalah *Twitter*. Pada media sosial ini, publik atau masyarakat bisa memberikan opininya terkait pelayanan kelistrikan oleh PT. PLN melalui akun *Twitter* resminya, yaitu @pln_123. Opini tersebut bisa berupa dukungan, keluhan, dan laporan terkait kelistrikan di lingkungannya. Salah satu cabang PLN yang banyak mengkonsumsi listrik ialah daerah DKI Jakarta karena terdapat total pelanggan sebanyak 4,4 juta pelanggan dan total konsumsi listrik sebesar 32.779 Giga Watt/Hour (Gwh).

Untuk itu diperlukan sebuah analisis sentimen terhadap pelayanan PT. PLN di DKI Jakarta agar mutu pelayanan meningkat sehingga kepuasan pelanggan terjaga. Dengan analisis sentimen bisa mendapatkan informasi yang berharga perihal pelayanan yang sudah diberikan kepada PT. PLN di DKI Jakarta. Untuk melakukan analisis sentimen diperlukan *text mining* agar bisa mengolah teks yang terdapat dalam opini menjadi sebuah informasi yang berharga untuk kepuasan pelanggan. Untuk melakukan *text mining* diperlukan sebuah metode atau algoritma yang berfungsi sebagai prosedur klasifikasi. Salah satu metode atau algoritma yang berfungsi untuk mengklasifikasikan setiap opini menjadi suatu sentimen positif, sentimen negatif, maupun hanyalah sentimen netral ialah *K-Nearest Neighbor (K-NN)*. Dan untuk membantu dalam proses algoritma tersebut diperlukan *text preprocessing* (praproses teks) dan *term weighting* (pembobotan kata).

Dengan melakukan analisis sentimen tersebut dapat menghasilkan informasi terhadap pelayanan PT. PLN di DKI Jakarta berdasarkan keluhan, dukungan serta laporan berdasarkan kategori waktu, pelayanan, dan daerah apa saja yang mengalami permasalahan. Hasil tersebut dapat dijadikan rekomendasi kepada PT. PLN untuk mempertimbangkan pelayanan yang lebih baik lagi kedepannya.

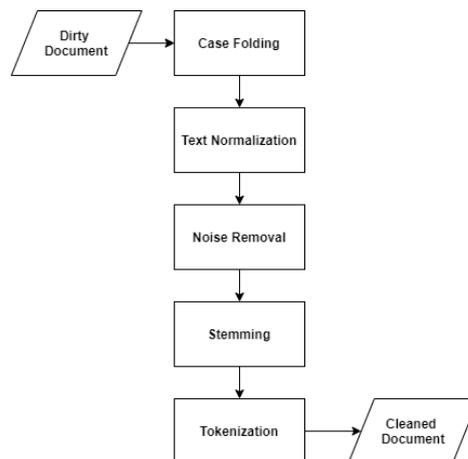
2. Landasan Teori

2.1 Text Mining

Text mining adalah suatu proses untuk mengekstrak informasi menarik, pengetahuan atau pola dari dokumen tidak terstruktur yang berasal dari sumber yang berbeda [10]. *Text mining* dapat dikatakan gabungan dari *text analysis* dan data *mining* karena *text mining* bertujuan untuk mendapatkan representasi dari suatu dokumen atau teks dengan teknik aspek-aspek yang ada di data *mining*. Sebelum melakukan *text mining*, seluruh dokumen akan dilakukan praproses teks terlebih dahulu agar dokumen yang didapatkan lebih mudah diklasifikasi.

2.2 Text Preprocessing

Text preprocessing atau praproses teks adalah suatu proses sebelum melakukan *text mining* dengan tujuan untuk mendapatkan fitur-fitur utama atau istilah-istilah utama dari dokumen teks dan untuk meningkatkan relevansi antara kata dan dokumen maupun relevansi antara kata dan kategori [9]. Praproses teks juga berfungsi untuk membersihkan teks yang sudah dikumpulkan dari *noise*, seperti memilah kata mana yang penting untuk diklasifikasi, menghilangkan *stopword*, dan sebagainya. Praproses sangatlah berpengaruh pada hasil analisa dan juga akurasi ketepatan *text mining* [3]. Berikut gambar *flowchart* untuk alur praproses teks :



Gambar 2. Flowchart untuk melakukan *Text Preprocessing*

2.2.1 Case Folding

Case Folding adalah proses mengubah semua huruf dalam dokumen menjadi modal kecil (a ke z). [8]. Fungsi utama dengan melakukan *case folding* supaya tidak ada kata yang memiliki makna yang berbeda meskipun huruf paling awal kapital.

2.2.2 Text Normalization

Text Normalization atau normalisasi teks adalah cara untuk mengubah dari tulisan representasi menjadi representasi sebagaimana teks tersebut diucapkan [5]. Tulisan representasi yang dimaksud ialah sebuah tulisan yang memiliki makna tetapi kata-katanya disingkat maupun ditambahkan beberapa huruf. Tulisan representasi juga bisa sebuah *emoticon* atau *emoji*, yaitu sebuah gambar yang merepresentasikan emosi manusia, seperti senang, marah, sedih, dan sebagainya.

2.2.3 Noise Removal

Noise adalah setiap bagian teks yang tidak relevan dengan konteks data dan hasil akhirnya, termasuk *stop words*, kata alfanumerik, dan tanda baca [7]. Contoh *stop words* atau kata-kata berhenti, yaitu “dan”, “lalu”, “kemudian”, dan sebagainya. Contoh alfanumerik, yaitu “@username123”, “#hashtag123”, dan sebagainya. Contoh tanda baca, yaitu “,”, “!”, “?”, dan sebagainya. Jadi, secara umum *noise removal* dalam praproses teks adalah proses menghilangkan kata atau tanda baca yang tidak relevan dengan konteks yang ada.

2.2.4 Stemming

Stemming adalah salah satu fitur praproses teks yang digunakan dalam pemrosesan bahasa alami dan penambangan teks. Tujuan utama dari proses *stemming* adalah untuk mengurangi kata infleksional atau turunan ke dalam bentuk dasarnya [2]. Dengan fitur ini dimensi teks menjadi semakin sedikit sehingga semakin mudah untuk dikelompokkan berdasarkan kata dasar yang terdapat dalam Kamus Besar Bahasa Indonesia (KBBI).

2.2.5 Tokenization

Tokenization atau tokenisasi adalah suatu proses untuk membagi dokumen menjadi kata-kata / istilah, membangun vektor kata, yang dikenal sebagai *bag-of-words*. Tokenisasi terdiri dari berbagai pemotongan unit kata yang ingin dibuat. N-gram merupakan salah satu metode dari tokenisasi tersebut. N-gram adalah alternatif untuk kata tunggal dalam proses *tokenization*, dimana urutan kata berurutan dengan panjang N menjadi sebuah unit kata [3].

2.3 Term Frequency-Invers Document Frequency (TF-IDF)

Term Frequency-Invers Document Frequency (TF-IDF) adalah statistik numerik yang menunjukkan relevansi kata kunci dengan beberapa dokumen tertentu atau dapat dikatakan bahwa ia menyediakan kata kunci tersebut, dengan begitu beberapa dokumen tertentu dapat diidentifikasi atau dikategorikan [6]. TF-IDF terdapat dua perhitungan, yaitu *Term Frequency* (TF) dan *Invers Document Frequency* (IDF). Berikut masing-masing perhitungan TF dan IDF :

$$TF = \begin{cases} 1 + \log_{10}(tf_{t,d}), & \text{if } tf_{t,d} > 0 \\ 0, & \text{if } tf_{t,d} = 0 \end{cases} \quad (1)$$

$$IDF = \log\left(\frac{N}{df_t}\right) \quad (2)$$

Keterangan :

$tf_{t,d}$: jumlah kemunculan *term* (t) pada dokumen (d), jika tidak ada term atau $t=0$, maka TF menjadi 0.

N : jumlah dokumen teks.

df_t : jumlah dokumen yang mengandung *term*(t).

Perkalian dari perhitungan TF dan IDF dapat menghasilkan bobot kata yang disebut TF-IDF, yaitu dengan perhitungan berikut :

$$W_{t,d} = TF \times IDF \quad (3)$$

2.4 K-Nearest Neighbor (K-NN)

Algoritma K-Nearest Neighbor adalah sejenis classifier centroid terdekat. Ide utama algoritma K-NN pertama, hitung jarak atau kesamaan antara sampel uji dan semua sampel pelatihan, dan temukan tetangga terdekat K dari sampel uji dalam sampel pelatihan; kemudian sesuai dengan kategori tetangga ini untuk menentukan kategori sampel uji. Seperti yang kita ketahui, salah satu tugas utama dalam algoritma K-Nearest Neighbor adalah mengukur kesamaan atau jarak. Metrik jarak yang umum digunakan adalah Euclidean Distance (atau Hamming Distance, dll.) [1]. Dalam algoritma ini, metode yang umum digunakan untuk mengukur jarak perhitungan antar tetangga dokumen terdekat untuk klasifikasi teks adalah Euclidean Distance.

$$\text{Euclidean Distance}(A, B) = \sum_{i=1}^t \sqrt{(A - B)^2} \quad (4)$$

Keterangan :

- A : dokumen *testing* atau uji
- B : dokumen *training* atau latih
- t : jumlah *term* atau kata

2.5 Analisis Sentimen

Analisis sentimen adalah sebuah studi komputasional atas opini, penilaian, sikap, dan emosi orang terhadap entitas, individu, masalah, peristiwa, topik, dan atribut mereka [4]. Analisis tersebut bertujuan untuk mendapatkan sentimen sekumpulan orang terhadap produk yang dibuat ataupun pelayanan yang dilakukan oleh suatu organisasi, kelompok, maupun personal. Dengan hasil analisis berupa data positif, negatif, dan netral yang bisa dijadikan acuan untuk evaluasi dari hal yang dianalisis.

2.6 Evaluasi

Evaluasi dilakukan untuk mengetahui seberapa tepat pemodelan klasifikasi yang sudah dilakukan untuk mengkategorikan menjadi beberapa model/kelas. Evaluasi terhadap data *mining* ataupun *text mining* biasanya berkaitan dengan *confusion matrix*, yaitu ukuran penting untuk mengevaluasi keakuratan model penilaian kredit [11]. Berikut gambar pemodelan *confusion matrix* :

		Actual		
		Positive	Neutral	Negative
Prediction	Positive	True Positive	False Positive	False Positive
	Neutral	False Neutral	True Neutral	False Neutral
	Negative	False Negative	False Negative	True Negative

Gambar 3. Model Confusion Matrix

Terdapat dua nilai dari evaluasi *confusion matrix* yang digunakan untuk sebuah evaluasi yang optimal, yaitu *Total Accuracy* (TA) dan *Error Rate* (ER). Pertama, TA biasanya digunakan untuk mengevaluasi kinerja algoritma *machine learning* (Jin, 2017). Selain itu, untuk tujuan mengevaluasi kinerja terkait kesalahan dalam klasifikasi, ER dihitung sebagai jumlah semua prediksi yang salah dibagi dengan jumlah total dataset. Misalkan dalam tugas klasifikasi biner, enam variabel, TP, TNeu, TNeg, FP, FNeu, dan FNeg, masing-masing mewakili *True Positive* (TP), *True Neutral* (TNeu), *True Negative* (TNeg), *False Positive* (FP), *False Neutral* (FNeu), dan *False Negative* (FNeg) Berikut rumus untuk menghitung TA dan ER *score* berturut-turut :

$$TA = \frac{TP+TNeu+TNeg}{TP+TNeu+TNeg+FP+FNeu+FNeg} \quad (5)$$

$$ER = \frac{FP+FNeu+FNeg}{TP+TNeu+TNeg+FP+FNeu+FNeg} \quad (6)$$

Keterangan :

TA : total akurasi

ER : rasio error

TP : data yang diprediksi positif dan benar

FP : data yang diprediksi positif tetapi salah

TNeu : data yang diprediksi netral dan benar

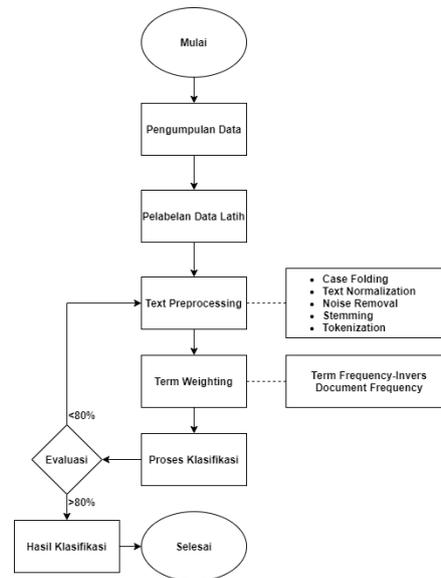
FNeu : data yang diprediksi netral tetapi salah

TNeg : data yang diprediksi negatif dan benar

FNeg : data yang diprediksi negatif tetapi salah

3. Metodologi Penelitian

Dalam melakukan klasifikasi akan dilakukan tahapan penelitian sebagai berikut :



Gambar 4. Flowchart Tahapan Penelitian

3.1 Pengumpulan Data

Tahap pengumpulan data dilakukan dengan cara *crawling tweet* pada akun *twitter* resmi PT. PLN (@pln_123) dan terdapat kata “Jakarta” untuk melakukan proses klasifikasi analisis sentimen pada penelitian ini.

3.2 Pelabelan Data Latih

Tahap pelabelan data latih dilakukan dengan cara memberikan label pada data latih dengan memberikan justifikasi terhadap sentimen positif, netral, dan negatif pada suatu *tweet* yang ada pada data latih.

3.3 Text Preprocessing

Text preprocessing dilakukan untuk membersihkan dan menyaring data yang belum terstruktur menjadi data yang lebih terstruktur dan bersih dari *noise*.

3.4 Term Weighting

Term weighting dilakukan untuk memberikan bobot kata di tiap dokumen atau *tweets* menggunakan TF-IDF agar memiliki nilai yang bisa membantu proses klasifikasi dengan perhitungan yang ada pada rumus (3).

3.5 Proses Klasifikasi

Proses klasifikasi menggunakan algoritma K-NN dengan cara :

- Persamaan rumus (4) untuk menghitung nilai jarak antar dokumen (*tweets*) uji dengan dokumen latih.
- Jarak antar dokumen tetangga terdekat sejumlah $K = 3$.
- Jumlah dokumen latih sebesar 500 *tweets* dan jumlah dokumen uji sebesar 500 *tweets*.
- Setelah klasifikasi sentimen akan dilakukan klasifikasi dari masing-masing kategori, yaitu tanggal, pelayanan, dan daerah.

3.6 Evaluasi

Evaluasi akan dilakukan dengan metode *confusion matrix* dengan data yang diuji sebesar 500 dokumen (*tweets*). Jika akurasi yang dihasilkan lebih kecil dari 80% maka praproses teks akan diubah skemanya.

3.7 Hasil Klasifikasi

Hasil klasifikasi berupa banyaknya dukungan (sentimen positif), keluhan (sentimen negatif), dan laporan (netral) berdasarkan kategori tanggal, pelayanan dan daerah terhadap PT. PLN di DKI Jakarta. Hasil ini akan divisualisasikan dalam bentuk *chart* atau grafik agar lebih mudah dipahami. Hasil tersebut akan dijadikan saran untuk rekomendasi peningkatan pelayanan kepada PT. PLN.

4. Hasil dan Pembahasan

Data yang dikumpulkan menjadi 2 bagian, yaitu data latih dan data uji. Data latih dikumpulkan sebanyak 500 *tweets* berdasarkan pencarian dengan *username* @pln_123 saja sedangkan data uji dikumpulkan sebanyak 500 *tweets* berdasarkan pencarian dengan *username* @pln_123 dan memuat informasi tentang Jakarta. Berikut tabel sampel data sebelum dan sesudah praproses teks :

Tabel 1. Sampel Data

Dokumen	Sampel Sebelum Praproses Teks	Sampel Sesudah Praproses Teks	Label
D1	@pln_123 listrik gak nyala2 Udah 2 jam saya lapor ke twitter. Pln lama sekali responnya sudah telfon 123 perlayannya gimana ini ya??	['listrik', 'nyala', 'jam', 'lapor', 'twitter', 'pln', 'lama', 'sekali', 'responnya', 'telfon', 'layan', 'bagaimana']	Negatif
D2	Terima kasih @pln_123 aduan kami dilayani dg baik. Petugas teknis datang dan listrik sdh menyala kembali. 👍👍 https://t.co/3IcevQ5Uax	['terimakasih', 'adu', 'layan', 'baik', 'tugas', 'teknis', 'datang', 'listrik', 'nyala']	Positif
D3	@pln_123 Mohon info min, jam 12.00 ada pemadaman di area kramat raya jakarta pusat. Itu dikarenakan apa ya?	['mohon', 'info', 'admin', 'jam', 'padam', 'area', 'kramat', 'raya', 'jakpus', 'karena', 'apa']	Netral
D4	@pln_123 mohon infonya min, di wilayah Duren Sawit, Jakarta Timur kok mati lampu?	['mohon', 'info', 'admin', 'wilayah', 'duren', 'sawit', 'jaktim', 'kok', 'mati', 'lampu']	Netral
D5	@pln_123 Mohon info utk wilayah Cempaka Baru Jakarta Pusat nyala kapan kah?	['mohon', 'info', 'wilayah', 'cempaka', 'baru', 'jakpus', 'nyala', 'kapan']	Netral

Dari hasil sampel sesudah praproses teks tersebut akan dijadikan sebuah kamus kata-kata yang akan dijadikan perhitungan nilai. Berikut tabel sampel nilai TF-IDF per-kata :

Tabel II. Nilai TF-IDF :

Kata	TF-IDF				
	D1	D2	D3	D4	D5
admin	0	0	0.397940	0.397940	0
adu	0	0.698970	0	0	0
apa	0	0	0.698970	0	0
area	0	0	0.698970	0	0
bagaimana	0.698970	0	0	0	0
baik	0	0.698970	0	0	0
baru	0	0	0	0	0.698970
cempaka	0	0	0	0	0.698970
datang	0	0.698970	0	0	0
duren	0	0	0	0.698970	0
info	0	0	0.221849	0.221849	0.221849
jakpus	0	0	0.397940	0	0.397940
jaktim	0	0	0	0.698970	0
jam	0.397940	0	0.397940	0	0
kapan	0	0	0	0	0.698970
karena	0	0	0.698970	0	0
kok	0	0	0	0.698970	0
kramat	0	0	0.698970	0	0
lama	0.698970	0	0	0	0
lampu	0	0	0	0.698970	0
lapor	0.698970	0	0	0	0
layan	0.397940	0.397940	0	0	0
listrik	0.397940	0.397940	0	0	0
mati	0	0	0	0.698970	0
mohon	0	0	0.221849	0.221849	0.221849
nyala	0.221849	0.221849	0	0	0.221849
padam	0	0	0.698970	0	0
pln	0.698970	0	0	0	0
raya	0	0	0.698970	0	0

responnya	0.698970	0	0	0	0
sawit	0	0	0	0.698970	0
sekali	0.698970	0	0	0	0
teknis	0	0.698970	0	0	0
telfon	0.698970	0	0	0	0
terimakasih	0	0.698970	0	0	0
tugas	0	0.698970	0	0	0
twitter	0.698970	0	0	0	0
wilayah	0	0	0	0.397940	0.397940

Perhitungan TF-IDF di atas didapatkan dengan rumus (3) melalui perkalian rumus (1) dan rumus (2). Berikut contoh perhitungan sampel pada kata “wilayah” pada D4 dan D5.

Rumus (1) :

$$TF_{D4}(\text{wilayah}) = 1 + \log_{10}(1) = 1 + 0 = 1$$

$$TF_{D5}(\text{wilayah}) = 1 + \log_{10}(1) = 1 + 0 = 1$$

Nilai $tf_{t,d}$ didapatkan berdasarkan jumlah kata yang terdapat dalam kalimat pada masing-masing dokumen.

Rumus (2) :

$$IDF_{D4}(\text{wilayah}) = \log\left(\frac{5}{2}\right) = 0.397940$$

$$IDF_{D5}(\text{wilayah}) = \log\left(\frac{5}{2}\right) = 0.397940$$

Nilai N didapatkan berdasarkan banyaknya jumlah dokumen dan nilai df_t didapatkan berdasarkan banyaknya kata “wilayah” pada semua dokumen.

Rumus (3) :

$$TF-IDF_{D4}(\text{wilayah}) = 1 \times 0.397940 = 0.397940$$

$$TF-IDF_{D5}(\text{wilayah}) = 1 \times 0.397940 = 0.397940$$

Setelah mendapatkan nilai TF-IDF dari setiap kata yang ada pada dokumen kemudian menghitung jarak *Euclidean Distance* antar dokumen dengan rumus (4) berdasarkan nilai TF-IDF yang ada pada tabel TF-IDF. Perhitungan jarak dimulai dari kata “admin” hingga kata “wilayah” yang hanya memiliki nilai TF-IDF antara D4 atau D5 . Perhitungan dilakukan dengan cara nilai TF-IDF pada kata D5 dikurangi nilai TF-IDF pada D4 kemudian dikuadratkan lalu dijumlahkan semua kata-kata yang sudah dikuadratkan dan terakhir jumlah tersebut dihitung akarnya. Berikut contoh perhitungan jarak antar D4 dan D5 :

$$Euclidean\ Distance\ (D5-D4) = \sqrt{(0-0.397940)^2 + (0.698970-0)^2 + (0.698970-0)^2 + (0-0.698970)^2 + (0.221849-0.221849)^2 + (0.397940-0)^2 + (0-0.698970)^2 + (0.698970-0)^2 + (0-0.698970)^2 + (0-0.698970)^2 + (0-0.698970)^2 + (0.221849-0.221849)^2 + (0.221849-0)^2 + (0-0.698970)^2 + (0.397940-0.397940)^2}$$

$$Euclidean\ Distance\ (D5-D4) = 2,2184021$$

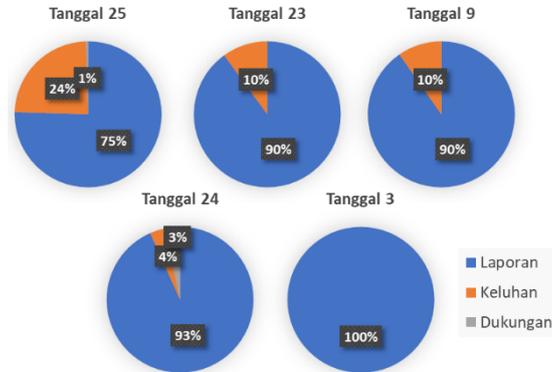
Nilai *Euclidean Distance* tersebut dilakukan dengan cara yang sama dengan dokumen lainnya yang tujuannya untuk mengetahui label dari D5. Tiga label data dari nilai *Euclidean Distance* terkecil akan dijadikan acuan untuk memilih label untuk D5. Pemilihan label dilakukan dengan cara menghitung paling banyak label yang terdapat pada urutan tiga terkecil. Jika pada urutan tiga terkecil tersebut ternyata didominasi oleh netral maka label pada D5 merupakan begitupun untuk label yang lainnya juga.

Hasil yang didapatkan dari proses klasifikasi sentimen tersebut, yaitu dari 500 data uji pada bulan Februari 2020 terdapat 426 label netral (laporan), 71 label negatif (keluhan), dan 3 label positif (dukungan). Berikut hasilnya dalam bentuk *pie chart* :



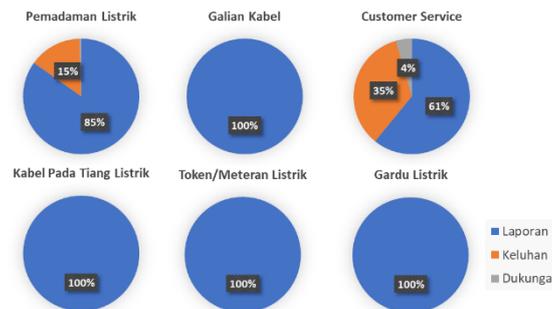
Gambar 5. Hasil Analisa *Pie Chart* Sentimen Masyarakat DKI Jakarta

Berikut hasil analisa *Pie Chart* berdasarkan kategori tanggal dengan urutan 5 tanggal yang paling banyak keluhan:



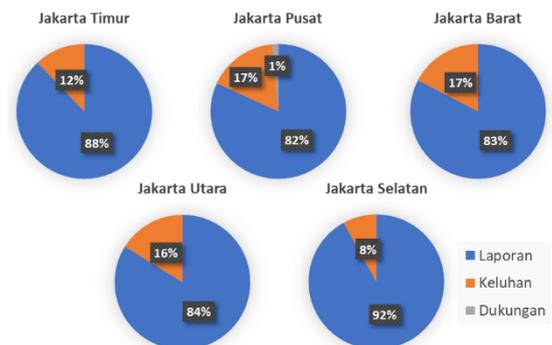
Gambar 6. Hasil Analisa *Pie Chart* Laporan, Keluhan, dan Dukungan Berdasarkan bulan Februari

Berikut hasil analisa *Pie Chart* berdasarkan kategori pelayanan :



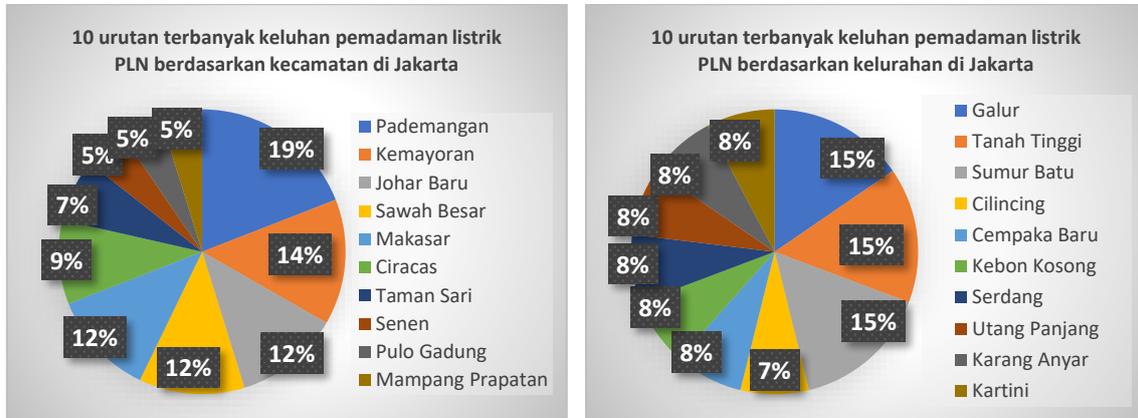
Gambar 7. Hasil Analisa *Pie Chart* Laporan, Keluhan, dan Dukungan Berdasarkan Pelayanan

Berikut hasil analisa *Pie Chart* berdasarkan kategori kotamadya :



Gambar 8. Hasil Analisa *Pie Chart* Laporan, Keluhan, dan Dukungan Berdasarkan Kotamadya

Berikut hasil analisa *Pie Chart* berdasarkan kategori kecamatan dan kelurahan dengan keluhan terhadap pelayanan pemadaman listrik :



Gambar 9. Hasil Analisa *Pie Chart* Berdasarkan Kecamatan (kiri) dan Kelurahan (kanan) Dengan Keluhan Pemadaman Listrik PLN

Evaluasi dilakukan untuk mengetahui seberapa besar akurasi dan rasio error yang dalam klasifikasi sentimen menggunakan model *confusion matrix*.

Tabel III. Hasil Evaluasi *Confusion Matrix* :

		Actual		
		Positif	Netral	Negatif
Prediksi	Positif	3	0	0
	Netral	1	417	8
	Negatif	0	44	27

True Positif (TP), yaitu prediksi positif yang tepat sesuai dengan data sebenarnya sebanyak 3, True Netral (TNeu), yaitu prediksi netral yang tepat sesuai dengan data sebenarnya sebanyak 417, True Negatif (TNeg), yaitu prediksi negatif yang tepat sesuai dengan data sebenarnya sebanyak 27, False Positif (FP), yaitu prediksi positif yang tidak sesuai dengan data sebenarnya sebanyak 1, False Netral (FNeu), yaitu prediksi netral yang tidak sesuai dengan data sebenarnya sebanyak 8, dan False Negatif (FNeg), yaitu prediksi negatif yang tidak sesuai dengan data sebenarnya sebanyak 44.

Total akurasi dihitung berdasarkan rumus (5),

$$\text{Total Akurasi} = (3 + 417 + 27) / (3 + 1 + 417 + 8 + 27 + 44) = 0,894 = 89,4\%$$

Rasio error dihitung berdasarkan rumus (6),

$$\text{Rasio Error} = (1 + 8 + 44) / (3 + 1 + 417 + 8 + 27 + 44) = 0,106 = 10,6\%$$

5. Penutup

5.1 Kesimpulan

1. Algoritma K-NN dapat digunakan untuk analisis sentimen khususnya pelayanan suatu perusahaan.
2. Algoritma K-NN pada klasifikasi sentimen berjalan baik dengan hasil total akurasi sebesar 89,4% dan rasio error sebesar 10,6% dengan menggunakan *confusion matrix* berdasarkan data uji yang diambil selama bulan Februari 2020.
3. Hasil analisis sentimen mendapatkan 426 laporan (sentimen netral), 71 keluhan (sentimen negatif), dan 3 dukungan (sentimen positif). Dari 500 *tweets*, hanya terdapat 71 keluhan atau sekitar 14,2% dari total seluruh opini. Maka, dapat disimpulkan pelayanan PLN di Jakarta pada bulan Februari 2020 sudah cukup baik.
4. Rekomendasi untuk pelayanan PLN ke depannya khususnya di Jakarta diharapkan bisa memberikan informasi secara berkala perihal pemadaman listrik pada daerah yang mendapatkan keluhan banyak, seperti di kecamatan Pademangan dan Kemayoran. Lalu tersedianya 24 jam *call center* PLN sehingga masyarakat bisa lebih mudah mendapatkan informasi perihal kelistrikan.

5.2 Saran

1. Tambahkan lebih banyak data lagi untuk normalisasi dapat mengubah kata yang tidak ada di dalam KBBI, khususnya kata gaul, kata/frasa yang sering disingkat-singkat, dan kata tidak baku.
2. Tambahkan lebih banyak data latih yang lebih berkualitas khususnya dalam hal kosakata dalam *tweets*.
3. Kombinasikan 4 variabel, yaitu sentimen, waktu, pelayanan, dan daerah dalam satu visualisasi *chart* untuk menunjukkan banyaknya opini dengan keterkaitan antara 4 variabel tersebut.
4. Menggunakan algoritma lainnya untuk membandingkan dengan algoritma yang sudah diterapkan.
5. Menambahkan data lainnya pada periode waktu selanjutnya untuk dapat dibandingkan dengan bulan Februari 2020.
6. Melakukan prediksi keluhan menggunakan *time series* untuk periode waktu selanjutnya berdasarkan data tiap bulan sehingga mampu untuk prediksi keluhan yang akan datang.

Referensi

- [1] Chen, Qiuxing, Lixiu Yao, dan Jie Yang. 2016. Short Text Classification Based On Lda Topic Model. International Conference on Audio, Language and Image Processing (ICALIP), Shanghai, pp. 749-753.
- [2] Ismailov, A., M. M. A. Jalil, Z. Abdullah, dan N. H. A. Rahim. 2016. A comparative study of stemming algorithms for use with the Uzbek language. International Conference on Computer and Information Sciences (ICCOINS), Kuala Lumpur, 3, pp. 7-12.
- [3] Krouska, Akriki, Christos Troussas, dan Maria Virvou. 2016. The effect of preprocessing techniques on Twitter Sentiment Analysis. International Conference on Information, Intelligence, Systems & Applications (IISA), pp. 144.
- [4] Liu, Bing dan Lei Zhang. 2012. A Survey of Opinion Mining and Sentiment Analysis. Mining Text Data(1), pp. 415-463.
- [5] Ng, Axel H., Kyle Gorman, dan Richard Sproat. 2017. Minimally Supervised Written-To-Spoken Text Normalization. IEEE Automatic Speech Recognition and Understanding Workshop (ASRU), pp. 665-670.
- [6] Qaiser, Shahzad dan Ramsha Ali. 2018. Text Mining: Use of TF-IDF to Examine the Relevance of Words to Documents. International Journal of Computer Applications (0975 - 8887), 181, pp. 25-29
- [7] Ruskanda, Fariska Zakhralativa. 2019. Study on the Effect of Pre-processing Methods for Spam Email Detection. Indonesia Journal on Computing, 4(1), pp. 109-118.
- [8] Slamet, C., A. R. Atmadja, D. S. Maylawati, R. S. Lestari, W. Darmalaksana, dan M. A. Ramdhani. 2018. Automated Text Summarization for Indonesian Article Using Vector Space Model. IOP Conference Series: Materials Science and Engineering, 288, pp. 1-6.
- [9] Srividhya, V. dan R. Anitha. 2010. Evaluating Preprocessing Techniques in Text Categorization. International Journal of Computer Science and Application Issue, pp. 49-51.
- [10] Vijayarani, S. dan R. Janani. 2016. Text Mining: Open Source Tokenization Tools - An Analysis. Advanced Computational Intelligence: An International Journal (ACII), 3(1), pp. 37-4.
- [11] Zeng, Guoping. 2018. On the confusion matrix in credit scoring and its analytical properties. Communications in Statistics - Theory and Methods. Vol. 49, pp. 2080-2093.