

Analisis Sentimen Pemindahan Ibu Kota Indonesia Dengan Pembobotan Term BM25 Dan Klasifikasi *Neighbor Weighted K-Nearest Neighbor*

Marinda Ika Dewi Sakariana¹, Indriati², Candra Dewi³

Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Brawijaya
Email: ¹marindaikads@gmail.com, ²indriati.tif@ub.ac.id, ³dewi_candra@ub.ac.id

Abstrak

Pemindahan Ibu Kota Indonesia merupakan salah satu kebijakan yang sedang gencar dibicarakan saat ini. Dengan adanya kebijakan mengenai pemindahan Ibu Kota dari Jakarta ke Kalimantan tentu menimbulkan beragam komentar dari masyarakat yang dapat ditemukan di media sosial Twitter. Komentar yang ada dapat dibedakan menjadi komentar positif dan negatif. Untuk mengetahui suatu komentar bernilai positif atau negatif maka perlu dilakukan analisis sentimen seperti pada penelitian ini. Dalam penelitian ini, ada beberapa tahapan yang harus dilakukan untuk mendapatkan hasil akhir. Tahapan tersebut yaitu *pre-processing* data, pembobotan term serta pemeringkatan dengan algoritme BM25, dan klasifikasi hasil akhir twit dengan algoritme *Neighbor Weighted K-Nearest Neighbor* (NWKNN). Penelitian ini menggunakan 480 data latih dan 120 data uji yang terbagi ke dalam sentimen positif dan negatif. Nilai akurasi tertinggi yang diperoleh adalah 93,33% dengan nilai *precision* sebesar 92,45%, *recall* sebesar 94,67% dan *f-measure* sebesar 93,55% dengan K yaitu 25, $K_1=1,2$ dan $b=0,65$ serta nilai E sebesar 4.

Kata kunci: analisis sentimen, pemindahan ibu kota, twitter, BM25, NWKNN

Abstract

The relocation of Indonesia capital city is one of the policies that is being intensively discussed at this time. With the policy regarding the relocation of the capital city from Jakarta to Kalimantan, it will certainly cause various reactions or comments from the community that can be found on social media, Twitter. Types of reactions can be divided into positive and negative comments. To find out a comment has a positive or negative value, sentiment analysis is needed as in this study. In this study, there are several steps that must be done to get the final results. These stages are pre-processing data, term weighting and ranking with the BM25 algorithm, and classifying the final results of tweets with Neighbor Weighted K-Nearest Neighbor (NWKNN) algorithm. This study uses 480 training data and 120 test data divided into positive and negative sentiments. The highest accuracy value obtained was 93.33% with a precision value of 92.45%, a recall of 94.67% and an f-measure of 93.55% with a K value of 25, $K_1=1,2$ and $b=0,65$ also an E value of 4.

Keywords: sentiment analysis, moving capital, twitter, BM25, NWKNN

1. PENDAHULUAN

Pemindahan Ibu Kota Negara Indonesia menjadi berita terpopuler di pertengahan tahun 2019. Dikutip dari The Jakarta Post (2019), bahwa Ibu Kota Negara Kesatuan Republik Indonesia akan dipindahkan dari DKI Jakarta ke Penajam Pasar Utara dan Kutai Kartanegara, Kalimantan Timur. Alasan pemindahan ini terjadi karena beban Jakarta sebagai pusat pemerintahan, ekonomi, dan politik sudah semakin tinggi sehingga sulit untuk

dikendalikan. Jakarta dianggap sudah tidak layak untuk menjadi ibu kota negara. Dengan adanya pemindahan tersebut diharapkan mampu mengurangi permasalahan kependudukan yang terpusat di Jakarta, kemacetan, kesenjangan sosial, dan lingkungan.

Keputusan mengenai pemindahan ibu kota sudah jelas akan menimbulkan berbagai macam reaksi dari masyarakat. Reaksi yang bersifat setuju akan keputusan itu dan juga reaksi yang menentang adanya pemindahan. Reaksi inilah yang akan dianalisis supaya dapat digunakan

pemerintah sebagai bahan evaluasi dan pembelajaran dalam mengambil keputusan untuk permasalahan yang sama. Dapat pula digunakan untuk lembaga penyuluhan untuk membantu memberi pengertian pada masyarakat akan dampak dan manfaat yang dapat diambil dengan adanya kebijakan pemindahan tersebut, Sebelum digunakan sebagai bahan evaluasi, perlu dilakukan analisis sentimen supaya mengetahui berapa banyak reaksi yang setuju dan tidak setuju.

Analisis sentimen adalah studi untuk mengkaji opini, penilaian, atau sentimen terhadap sebuah topik ataupun produk (Liu, 2012). Analisis sentimen biasanya menggunakan sentimen pada media sosial untuk dijadikan sumber data. Mengingat banyaknya jumlah data dari media sosial itulah yang menyebabkan sentimen sulit dianalisis secara manual dan perlu dibuat sebuah program. Hasil akhir dari proses analisis sentimen nantinya akan mengelompokkan opini menjadi entitas positif dan negatif. Dimana, entitas positif akan merepresentasikan reaksi yang setuju dan negatif menggambarkan reaksi yang menentang pemindahan ibu kota negara.

Opini mengenai pemindahan ibu kota negara Indonesia banyak ditemukan pada berbagai sosial media, salah satunya pada Twitter. Menurut Rajadesingan, et al., (2015), Twitter dianggap sangat membantu karena memberikan informasi secara *real time*, tidak jarang jika Twitter digunakan untuk pemasaran dan penyebaran berita. Pengguna twitter biasa memberikan pendapat terkait segala hal yang ingin ditanggapi. Tetapi tweet mereka belum bisa dilabelkan ke opini positif maupun negatif untuk itu perlu dilakukan analisis sentimen.

Untuk dapat melabelkan opini seseorang yang ada pada Twitter dibutuhkan suatu metode perhitungan untuk pengklasifikasian suatu tweet. Analisis sentimen memiliki beberapa rangkaian tahapan yang perlu dilakukan antara lain pre-processing, pembobotan term, pencarian nilai kemiripan antar dokumen, dan proses klasifikasi. Ketika mencari nilai pembobotan untuk melakukan pengurutan hasil kecocokan terhadap dokumen dapat dicari dengan berbagai metode seperti BM25. Penelitian oleh Sixto, et al., (2016) menyatakan bahwa BM25 dapat digunakan pada analisis sentimen untuk pemeringkatan setiap tweet dari dataset yang ada dan kemudian digunakan untuk proses pengklasifikasian otomatis. Pada penelitian tersebut menghasilkan nilai evaluasi maksimal

jika menggunakan nilai $b = 0,6$ dan $k_1 = 35$ untuk 1000 dataset dan nilai $b = 0,7$ dan $k_1 = 40$ untuk keseluruhan dataset.

Setelah mendapatkan nilai bobot dan urutan kemiripan, dilanjutkan dengan klasifikasi. Untuk melakukan klasifikasi ada beberapa pilihan metode yang bisa dilakukan, namun tidak semua metode akan menghasilkan hasil klasifikasi yang tepat jika data yang digunakan jumlahnya tidak seimbang. Pada penelitian Tan (2005) ditemukan kesimpulan bahwa ketika membandingkan hasil *recall*, *precision*, dan *f-measure* metode *Neighbor Weighted K-Nearest Neighbor* (NWKNN) lebih baik dari metode KNN apabila komposisi data yang digunakan tidak seimbang. Penelitian lainnya yang memperkuat pernyataan bahwa NWKNN cocok digunakan untuk komposisi data yang tidak seimbang yaitu Ridok & Latifah (2015), didapatkan bahwa algoritma KNN menunjukkan nilai *recall* dan *f-measure* NWKNN masing-masing lebih tinggi sebesar 6.9% dan 2.6% daripada nilai *recall* dan *f-measure* KNN untuk klasifikasi dokumen berita.

Berdasarkan penjelasan di atas, maka akan dibuat penelitian analisis sentimen mengenai pemindahan Ibu kota Indonesia dengan menggunakan metode BM25 untuk perhitungan nilai bobot dan pemeringkatan serta NWKNN untuk klasifikasi dengan data bersumber dari Twitter.

2. DASAR TEORI

2.1 Analisis Sentimen

Menurut Liu (2002), analisis sentimen merupakan suatu proses pembelajaran yang berkaitan dengan pengolahan pendapat. Tujuan dari analisis sentimen yaitu untuk membantu proses identifikasi topik tertentu dan juga untuk evaluasi supaya terus mendapatkan opini bagus dari masyarakat. Fokus utama analisis sentimen yaitu mengkaji sentimen suatu individu pada hal tertentu seperti produk, masalah terkini, dan lain sebagainya. Hasil yang didapat pada analisis sentimen akan digolongkan menjadi sentimen positif dan negatif.

2.2 Pemindahan Ibu Kota

Ibu Kota Negara merupakan pusat segala kegiatan yang berhubungan dengan kenegaraan dan diatur oleh perundang-undangan. Ibu kota

negara sebagai pusat dari berbagai macam aktivitas tentunya tidak lepas dari permasalahan. Permasalahan kompleks yang terjadi pada ibu kota Negara Indonesia yaitu masalah demografi karena penduduk terbanyak ada di Jakarta kisaran 10.277.628 jiwa dikutip dari Bappenas (2019), kemacetan, dan kondisi lingkungan yang kian memburuk disertai banjir tahunan. Masalah yang ada pada Jakarta sekarang sudah sesuai dengan kriteria yang mendasari pemindahan ibu kota menurut Agassi (2013) yaitu masalah sosial, ekonomi, politik, dan lingkungan. Permasalahan terus menumpuk tanpa sejalan dengan penanggulangannya menyebabkan diambil keputusan sulit untuk memindahkan ibu kota negara dari Jakarta ke Kalimantan Timur.

2.3 Pre-Processing

Text Preprocessing berfungsi untuk mengubah representasi data yang tidak terstruktur menjadi terstruktur (Feldman & Sanger, 2007). Pada penelitian ini, *text preprocessing* yang digunakan yaitu *cleaning*, *case folding*, *tokenizing*, *filtering*, dan *stemming*.

2.3.1 Cleaning

Tahapan *cleaning* fungsinya untuk menghilangkan karakter selain huruf dan angka. Contoh dari karakter yang harus dihilangkan berupa tanda baca, tanda hubung, tagar, dsb.

2.3.2 Case Folding

Tahapan *case folding* fungsinya untuk menyetarakan besar kecilnya huruf yang ada pada kata. Caranya dengan mengganti semua huruf kapital menjadi huruf kecil.

2.3.3 Tokenizing

Tahapan *tokenizing* adalah tahap memisahkan seluruh kata yang terdapat pada dokumen menjadi suku kata tunggal (Feldman & Sanger, 2007). Hasil akhir dari *tokenizing* disebut juga token. Token dipisahkan dengan bantuan karakter spasi.

2.3.4 Filtering

Tahapan *filtering* adalah tahapan untuk menghilangkan kata yang ada pada *stopwords* Tala. Kata yang terdapat pada *stopwords* didefinisikan sebagai kata yang kerap muncul tetapi tidak memiliki makna khusus

2.3.5 Stemming

Tahapan *stemming* adalah proses menguraikan kata menjadi kata dasarnya. Kata dasar yang dimaksud adalah kata tanpa semua imbuhan, baik di awal atau akhir kata. Hasil dari tahap ini berupa term.

2.4 Metode BM25

BM25 menghasilkan keefektifan dan ketepatan yang tinggi untuk menghitung kesamaan antara *query* dan dokumen menurut (Pardede, et al., 2015). Ada beberapa faktor yang memengaruhi kesuksesan BM25 yaitu TF (*Term Frequency*), IDF (*Inverse Document Frequency of term*), dan panjang dokumen. Ketiga faktor tersebut digunakan dalam perhitungan bobot term kemudian hasil perhitungannya akan diperingkat untuk menentukan kemiripan. Persamaan perhitungan metode BM25 dapat dilihat pada persamaan (1) dan persamaan (2).

$$BM25 = \sum_{i=1}^n IDF(q_i) \cdot \frac{f(q_i, D) \cdot (k_1 + 1)}{f(q_i, D) + k_1 \cdot (1 - b + b \cdot \frac{|D|}{avgdl})} \quad (1)$$

$$IDF(q_i) = \log \frac{N - n(q_i) + 0.5}{n(q_i) + 0.5} \quad (2)$$

Keterangan:

| | |
|-------------|---|
| $f(q_i, D)$ | = Frekuensi term pada dokumen d |
| k_1 | = konstanta, biasanya 1,20 |
| b | = konstanta, biasanya 0,75 |
| $ D $ | = Panjang dokumen |
| $avgdl$ | = Rata-rata panjang dari kumpulan dokumen |
| N | = Total data latih yang digunakan |
| $n(q_i)$ | = banyak q_i yang terkandung pada dokumen |

2.5 Neighbor Weighted K-Nearest Neighbor (NWKNN)

Data yang digunakan pada suatu penelitian tentu jumlahnya tidak selalu seimbang untuk tiap kategori kelas. NWKNN hadir untuk mengatasi permasalahan data yang tidak seimbang jumlahnya dalam tiap kategori kelas yang ada (Tan, 2005). Dalam mengatasi ketidakseimbangan jumlah data, maka diantisipasi dengan proses pembobotan kategori kelas. Kelas dengan jumlah data yang lebih sedikit akan memperoleh bobot yang lebih besar (Widyaswari, et al., 2019).

Tahapan dari metode NWKNN yaitu:

1. Hitung bobot untuk mendapatkan nilai kemiripan, kemudian diurutkan dari yang terbesar.
2. Tentukan bobot per kategori kelas, dengan Persamaan (3).

$$Weight_i =$$

$$\frac{1}{(Num(C_i^d) / \text{Min}\{Num(C_l^d) | l=1, \dots, K^*\})^{1/Exponent}} \quad (3)$$

Keterangan:

$Weight_i$ = Bobot kelas ke - i

$Num(C_i^d)$ = Jumlah data latih pada kelas ke -i

$Num(C_l^d)$ = Jumlah data latih d pada kelas l, dimana l disesuaikan dengan jumlah kategori kelasnya

$Exponent$ = Eksponen, dimana nilainya >1

3. Hitung skor untuk mendapatkan hasil klasifikasi, skor dapat dihitung dengan Persamaan (4).

$$score(d, c_i) = Weight_i *$$

$$(\sum_{d_j \in KNN(x)} Sim(d, d_j) * \delta(d_j, c_i)) \quad (4)$$

Keterangan:

$score(d, c_i)$ = Hasil perhitungan skor dari data uji d pada kelas c_i

$d_j \in KNN(x)$ = Data latih d_j termasuk di kumpulan tetangga terdekat dari data uji.

$Sim(d, d_j)$ = Similaritas antara data uji dan data latih.

$\delta(d_j, c_i)$ = Jika data latih termasuk anggota c_i maka nilainya 1 dan apabila bukan anggota c_i bernilai 0

2.6 Pengujian

2.6.1 K-Fold Cross Validation

K-Fold Cross Validation berfungsi untuk mengevaluasi rata rata keberhasilan dari program. Menurut Kohavi (1995), cara kerja pengujian ini yaitu mengulang perhitungan sejumlah k bagian dengan penggunaan dataset yang berbeda sehingga sistem akan teruji. Kemudian hitung rata-rata akurasi keseluruhan data.

2.6.2 Confusion Matrix

Pengujian *confusion matrix* dibuat dengan menghitung perbandingan hasil klasifikasi dari pakar dengan hasil prediksi keluaran dari program. Penjelasan mengenai *confusion matrix* dapat dilihat pada Tabel 1.

Tabel 1. Confusion Matrix

| | Kelas Positif (Prediksi) | Kelas Negatif (Prediksi) |
|--------------------------|-----------------------------|-----------------------------|
| Kelas Positif (Pakar) | True Positive (TP) | False Negative (FN) |
| Kelas Negatif (Pakar) | False Positive (FP) | True Negative (TN) |

Keterangan:

TP = Data positif yang terprediksi dengan benar

FP = Data prediksi yang

seharusnya masuk kelas negatif

FN = Data prediksi yang

seharusnya masuk kelas positif

TN = Data negatif yang terprediksi dengan benar

Perhitungan yang diperoleh dari *confusion matrix* antara lain:

1. Akurasi

Akurasi yaitu perbandingan antara jumlah prediksi yang benar dengan total percobaan. Didapat dari Persamaan (5)

$$Akurasi = \frac{TP+TN}{TP+FP+TN+FN} \quad (5)$$

2. Precision

Precision merupakan ketepatan informasi yang diminta oleh user dengan jawaban dari sistem. Didapat dari Persamaan (6).

$$Precision = \frac{TP}{FP+TP} \quad (6)$$

3. Recall

Recall merupakan jumlah kesesuaian informasi yang didapatkan dari hasil percobaan. Didapat dari Persamaan (7).

$$Recall = \frac{TP}{TP+FN} \quad (7)$$

4. F-Measure

Pengukuran untuk mencari nilai rata-rata harmonik antara *precision* dan *recall*. Didapat dari Persamaan (8).

$$F - Measure = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (8)$$

3. METODOLOGI

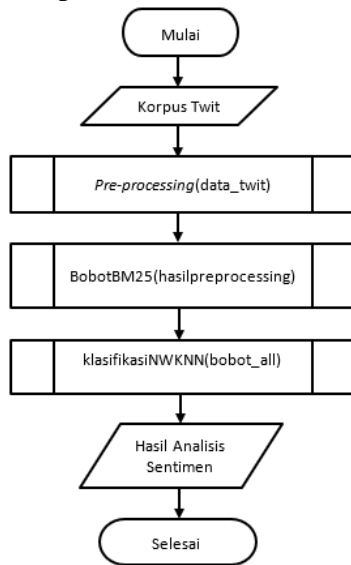
3.1 Data Penelitian

Teknik pengumpulan data pada penelitian

ini dengan pengamatan tweet secara langsung pada Twitter dan dicari dengan kata kunci pemindahan ibu kota. Data diambil secara manual. Total data yang digunakan sebanyak 600 data, dengan 375 data dengan sentimen positif dan 225 data dengan sentimen negatif.

3.2 Perancangan

Gambaran proses pada penelitian ini ditampilkan pada Gambar 1.



Gambar 1. Alur Proses

Dari Gambar 1, dapat dibuat penjabaran sebagai berikut.

1. Data berupa tweet pemindahan Ibu Kota Indonesia dijadikan masukan.
2. Setiap tweet akan dihitung bobotnya sekaligus diperingkat sehingga mengetahui nilai kemiripannya menggunakan metode BM25.
3. Selanjutnya tweet yang sudah diperingkat akan diklasifikasikan dengan metode klasifikasi *Neighbor Weighted K-Nearest Neighbor*.
4. Keluaran berupa kelas positif atau negatif.

4. HASIL PENGUJIAN DAN ANALISIS

Pengujian pada penelitian ini dilakukan dengan menguji parameter nilai K, eksponen, nilai K_1 dan b , serta penggunaan *stopwords* dan bagaimana pengaruhnya terhadap nilai akurasi, *precision*, *recall*, dan *f-measure*.

4.1 Pengujian K-Fold Cross Validation

Pada pengujian *K-Fold Cross Validation* akan membagi dataset sebanyak 600 data menjadi 5 *fold*. Berdasarkan penelitian oleh (James, et al., 2013), saat melakukan *k-fold Cross-Validation* menggunakan $k\text{-fold} = 5$ atau $k\text{-fold} = 10$, karena nilai ini telah terbukti menghasilkan perkiraan tingkat kesalahan yang cukup baik. Tiap *fold* memiliki data uji sebanyak 120 dan data latihan berjumlah 480 data.

Tabel 1. Pengujian K-Fold Cross Validation

| K-Fold = 5 | Hasil Pengujian | | | |
|------------------|-----------------|--------------|--------------|--------------|
| | Precision | Recall | F-Measure | Akurasi |
| Fold 1 | 86,17 | 79,84 | 82,88 | 84,17 |
| Fold 2 | 67,22 | 63,78 | 65,45 | 69,17 |
| Fold 3 | 91,57 | 93,56 | 92,55 | 92,5 |
| Fold 4 | 81,11 | 75,12 | 78 | 80 |
| Fold 5 | 72,63 | 70,89 | 71,75 | 74,17 |
| Rata-rata | 79,74 | 76,64 | 78,13 | 80,00 |

Berdasarkan hasil pengujian yang tertera pada Tabel 1 menghasilkan rata-rata akurasi keseluruhan *k-fold* sebesar 80%. Hasil akurasi tertinggi didapat apabila kita menggunakan dataset pada *fold 3*. Perbedaan hasil evaluasi tiap *fold* terjadi karena adanya perbedaan data latihan dan data uji yang digunakan sehingga memungkinkan terjadinya kenaikan atau pengurangan nilai akurasi dari program. Data latihan yang digunakan memiliki pengaruh besar pada hasil evaluasi karena apabila mengandung kata yang sering muncul tapi justru tidak muncul di data uji maka akan memengaruhi hasil klasifikasi.

4.2 Pengujian Parameter K_1 dan b

Cara kerja dari pengujian ini yaitu dengan mengganti K_1 dengan nilai 1,2 hingga 2. Dan mengganti b dengan 0,5 hingga 0,8 sesuai dengan teori dari (Robertson & Zaragoza, 2009).

Tabel 2. Pengujian Parameter K_1 dan b

| K_1 | b | Hasil | Hasil | Hasil F- | Hasil |
|-------|-------------|---------------|--------------|--------------|--------------|
| | | Precision (%) | Recall (%) | Measure (%) | Akurasi (%) |
| 1,2 | 0,5 | 90,91 | 93,33 | 92,1 | 91,67 |
| | 0,55 | 90,91 | 93,33 | 92,1 | 91,67 |
| | 0,6 | 91,67 | 94 | 92,82 | 92,5 |
| | 0,65 | 92,45 | 94,67 | 93,55 | 93,33 |
| | 0,7 | 91,57 | 93,56 | 92,55 | 92,5 |
| 0,75 | 0,75 | 91,57 | 93,56 | 92,55 | 92,5 |
| | 0,8 | 90,71 | 92,44 | 91,57 | 91,67 |
| | 1,3 | 90,91 | 93,33 | 92,1 | 91,67 |

| K_1 | b | Hasil Precision (%) | Hasil Recall (%) | Hasil F-Measure (%) | Hasil Akurasi (%) |
|-------|-------------|---------------------|------------------|---------------------|-------------------|
| | 0,55 | 90,91 | 93,33 | 92,1 | 91,67 |
| | 0,6 | 91,67 | 94 | 92,82 | 92,5 |
| | 0,65 | 92,45 | 94,67 | 93,55 | 93,33 |
| | 0,7 | 91,57 | 93,56 | 92,55 | 92,5 |
| | 0,75 | 90,71 | 92,44 | 91,57 | 91,67 |
| | 0,8 | 90,71 | 92,44 | 91,57 | 91,67 |
| ... | ... | ... | ... | ... | ... |
| 2 | 0,5 | 90,76 | 92,89 | 91,81 | 91,67 |
| | 0,55 | 90,76 | 92,89 | 91,81 | 91,67 |
| | 0,6 | 92,45 | 94,67 | 93,55 | 93,33 |
| | 0,65 | 89,86 | 91,33 | 90,59 | 90,83 |
| | 0,7 | 90,71 | 92,44 | 91,57 | 91,67 |
| | 0,75 | 90,71 | 92,44 | 91,57 | 91,67 |
| | 0,8 | 90,71 | 92,44 | 91,57 | 91,67 |

Berdasarkan Tabel 2 dapat dilihat bahwa parameter K_1 dan b tersebut menghasilkan hasil evaluasi yang cenderung sama. Dibuktikan bahwa kedua parameter tersebut tidak terlalu berpengaruh karena akan menghasilkan hasil evaluasi yang relatif sama. Nilai b yang paling menghasilkan hasil optimal yaitu 0,65 untuk K_1 sebesar 1,2 hingga 1,6. Kemudian untuk K_1 sebesar 1,7 hingga 2 nilai b yang menghasilkan hasil optimal sebesar 0,6. Dari kedua nilai b yang optimal tadi akan menghasilkan hasil evaluasi yang nilainya mirip. Nilai b ini akan digunakan dalam persamaan BM25 untuk membantu proses normalisasi TF.

4.3 Pengujian Paramater K

Tabel 3. Pengujian Parameter K

| K | Hasil Precision (%) | Hasil Recall (%) | Hasil F-Measure (%) | Hasil Akurasi (%) |
|-----------|---------------------|------------------|---------------------|-------------------|
| 2 | 81,81 | 83,78 | 82,78 | 80,83 |
| 3 | 79,69 | 81,11 | 80,39 | 80,83 |
| 5 | 80,4 | 81,33 | 80,86 | 81,67 |
| 10 | 87,8 | 90,22 | 88,99 | 88,33 |
| 15 | 90,91 | 93,33 | 92,1 | 91,67 |
| 20 | 89,98 | 92,22 | 91,09 | 90,83 |
| 25 | 91,57 | 93,56 | 92,55 | 92,5 |
| 30 | 89,98 | 92,22 | 91,09 | 90,83 |
| 35 | 87,3 | 88,89 | 88,09 | 88,33 |
| 40 | 88,18 | 90 | 89,08 | 89,17 |
| 45 | 85,59 | 87,11 | 86,34 | 86,67 |
| 50 | 87,3 | 88,44 | 87,87 | 88,33 |

Berdasarkan Tabel 3, dapat dilihat bahwa penggunaan nilai K yang beragam akan memengaruhi hasil evaluasi menjadi beragam juga. K yang paling optimal dalam penelitian ini yaitu 25. Ketika kita menggunakan nilai K dibawah 25 maka akan menghasilkan nilai evaluasi yang cenderung meningkat. Sedangkan

ketika nilai K yang digunakan lebih dari 25 hasilnya akan menurun. Hal ini terjadi karena nilai K akan selalu berpengaruh pada data yang diambil untuk perhitungan, jika terlalu kecil nilai K maka data yang diambil hanya bagian awal saja belum tentu data tersebut memiliki kelas yang sama dengan data uji. Sedangkan jika menggunakan nilai K yang tinggi maka ada data yang sebenarnya tidak diperlukan tetapi ikut terpakai ke proses perhitungan NWKNN.

4.4 Pengujian Nilai Eksponen

Pengujian terhadap eksponen digunakan guna mengetahui nilai eksponen yang paling optimal pada penelitian ini. Pengujian dilakukan dengan mengganti eksponen dengan nilai yang tertera pada Tabel 4.

Tabel 4. Pengujian Nilai Eksponen

| Eksponen | Hasil Precision (%) | Hasil Recall (%) | Hasil F-Measure (%) | Hasil Akurasi (%) |
|----------|---------------------|------------------|---------------------|-------------------|
| 2 | 90,91 | 93,33 | 92,1 | 91,67 |
| 3 | 89,98 | 92,22 | 91,09 | 90,83 |
| 4 | 91,57 | 93,56 | 92,55 | 92,5 |
| 5 | 91,57 | 93,56 | 92,55 | 92,5 |
| 6 | 91,57 | 93,56 | 92,55 | 92,5 |
| 7 | 89,02 | 90,22 | 89,62 | 90 |
| 8 | 89,02 | 90,22 | 89,62 | 90 |
| 9 | 89,02 | 90,22 | 89,62 | 90 |
| 10 | 89,02 | 90,22 | 89,62 | 90 |

Sesuai yang tertera pada Tabel 4, ketika dilakukan pengujian didapatkan perbedaan nilai eksponen menghasilkan perubahan nilai evaluasi pada data uji. Rentang nilai eksponen paling optimal yang digunakan pada penelitian ini yaitu 4 hingga 6. Ketika nilai eksponen digunakan semakin besar maka akan menyebabkan penurunan nilai evaluasi hal ini terjadi karena semakin besar nilai eksponen akan membuat bobot kedua kategori kelas perbedaannya semakin rendah. Jika perbedaannya semakin rendah maka NWKNN tidak akan berfungsi maksimal karena hanya akan mengandalkan parameter K untuk proses klasifikasi.

4.5 Pengujian Stopwords

Pengujian *stopwords* dilakukan dengan membandingkan antara hasil evaluasi *precision*, *recall*, *f-measure*, dan akurasi antara menggunakan keseluruhan *stopwords*, dengan tidak menggunakan *stopwords*, dan dengan modifikasi *stopwords* Tala.

Tabel 5. Pengujian Penggunaan *Stopwords*

| <i>Stopwords</i> | Hasil <i>Precision</i> (%) | Hasil <i>Recall</i> (%) | Hasil <i>F-Measure</i> (%) | Hasil <i>Akurasi</i> (%) |
|-------------------|----------------------------|-------------------------|----------------------------|--------------------------|
| Tanpa | 84,99 | 89,33 | 88,74 | 85,83 |
| Dengan | 86,46 | 87,33 | 86,89 | 87,5 |
| Modifikasi | 91,57 | 93,56 | 92,55 | 92,5 |

Perbedaan hasil evaluasi pada Tabel 5. terjadi karena *stopwords* juga memengaruhi hasil evaluasi. Ketika pengujian tanpa menggunakan *stopwords* akan muncul banyak kata, namun tidak semua kata akan bermakna dalam penelitian ini seperti kata penghubung. Kata-kata tersebut akan tetap masuk dalam perhitungan sehingga mempunyai bobot yang kemudian akan memengaruhi hasil pelabelan. Ketika menggunakan keseluruhan *stopwords* hasil evaluasinya juga kurang maksimal karena ada kata kunci sentimen yang ikut dihapus, contohnya kata negasi. Hasil evaluasi terbaik didapat apabila penelitian menggunakan modifikasi *stopwords*.

5. KESIMPULAN

Setelah melakukan pengujian didapat kesimpulan bahwa pembobotan BM25 dan metode klasifikasi NWKNN dapat diterapkan pada penelitian berjudul Analisis Sentimen Pemandangan Ibu Kota Indonesia menggunakan 480 data latih dan 120 data uji. Pada penelitian ini, proses perhitungan dilakukan pada tiap kata pada keseluruhan data. Pertama dilakukan pre-processing *tweet*. Dilanjutkan dengan perhitungan bobot tiap term dihitung dengan menggunakan pembobotan TF dan IDF sesuai persamaan yang ada pada metode BM25. Kemudian, pemerinkatan kalimat *tweet* sesuai nilai kemiripan dari hasil BM25. Setelah itu, menentukan hasil klasifikasi dengan perhitungan NWKNN dimulai dengan menghitung bobot kategori kelas positif dan negatif keseluruhan data latih yang digunakan kemudian dihitung skornya menggunakan persamaan NWKNN. Skor tertinggi dari NWKNN inilah yang menjadi panduan untuk *tweet* digolongkan kelas positif atau negatif.

Hasil penelitian ini menghasilkan nilai tertinggi untuk *precision* sebesar 92,45%, *recall* sebesar 94,67%, *f-measure* sebesar 93,55% dan akurasi sebesar 93,33%. Nilai tertinggi didapat dengan menggunakan dataset dari *fold* ke-3, $K_1=1,2$ dan $b=0,65$, nilai $K=25$, dan nilai eksponen= 4.

6. DAFTAR PUSTAKA

Agassi, E., 2013. *Analisis Faktor-Faktor Yang Memengaruhi Pemandangan Ibukota Negara*, Bogor: Fakultas Ekonomi dan Manajemen Institut Pertanian Bogor.

Bappenas, K. P., 2019. *Dampak Ekonomi dan Skema Pembiayaan Ibu Kota Negara*. s.l., Kementrian PPN/ Bappenas.

Feldman, R. & Sanger, J., 2007. *Text Mining Handbook: Advanced Approaches in Analyzing Unstructured Data*. New York: Cambridge University Press.

James, G., Witten, D., Hastie, T. & Tibshirani, R., 2013. *An Introduction to Statistical Learning*. s.l.:s.n.

Kohavi, R., 1995. *A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection*. Stanford, International Joint Conference on Artificial Intelligence (IJCAI).

Liu, B., 2012. *Sentiment Analysis and Opinion Mining*. s.l.:Claypool Publishers.

Pardede, J., Husada, M. G. & Riensyah, R., 2015. *Implementasi dan Perbandingan Metode Okapi BM25 dan PLSA Pada Aplikasi Information Retrieval*, Bandung: Jurusan Teknik Informatika, Fakultas Teknik Industri, Itenas Bandung.

Rajadesingan, A., Zafarani, R. & Liu, H., 2015. *Sarcasm Detection on Twitter : A Behavioral Modeling Approach*. Shanghai, China, ACM, pp. 97-105.

Ridok, A. & Latifah, R., 2015. *Klasifikasi Teks Bahasa Indonesia Pada Corpus Tak Seimbang Menggunakan NWKNN*. Indonesia, Konferensi Nasional Sistem dan Informatika 2015.

Robertson, S. E. & Zaragoza, H., 2009. *The Probabilistic Relevance Framework: BM25 and Beyond. Foundations and Trends® in Information Retrieval*, Volume 3, pp. 333-389.

Sixto, J., Almeida, A. & L´opez-de-Ipi˜na, D., 2016. *Improving the Sentiment Analysis Process of Spanish Tweets with BM25*. Salford, UK, 21st International Conference on

- Applications of Natural Language to Information Systems.
- Tan, S., 2005. Neighbor Weighted K-Nearest Neighbor For Unbalanced Text Corpus. pp. 667-671.
- The Jakarta Post, 2019. *The Jakarta Post*. [Online]
Available at:
<https://www.thejakartapost.com/news/2019/08/26/breaking-jokowi-announces-east-kalimantan-as-site-of-new-capital.html>
[Accessed Sabtu November 2019].
- Widyaswari , P. A. V., I. & Perdana, R. S., 2019. Klasifikasi Kemacetan Lalu Lintas Kota Malang Melalui Media Twitter Menggunakan Metode Neighbor Weighted K-Nearest Neighbor (NW-KNN). *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer* , Volume 3, pp. 1464-1470 .