

BAB V

HASIL DAN PEMBAHASAN

5.1 Pendahuluan

Pada bab ini akan dibahas hasil dari penelitian mengenai analisis sentimen pada media sosial twitter terhadap penggunaan kendaraan listrik dengan menggunakan metode *naive bayes classifier* dan *information gain* dan mengukur kinerja dari hasil klasifikasi.

5.2 Data Hasil Pengujian

Disini akan dijelaskan mengenai data hasil pengujian sistem yang berfungsi untuk mengetahui kinerja program dalam proses klasifikasi. Pengujian dilakukan untuk menguji *accuracy*, *precision*, *recall*, dan *f1-score* dengan metode *naive bayes* dan *naive bayes* dengan *information gain*.

Dalam melakukan pengujian ini, akan dilakukan skenario dimana skenario ini akan dibagi berdasarkan data latih dan data uji. Dari total data sebanyak 4174 akan dibagi untuk beberapa skenario. Untuk rincian skenario dapat dilihat dalam tabel V-1

Tabel V- 1 Rincian data Pengujian

Pembagian	Data Latih	Data Uji
50 : 50	2087	2087
60 : 40	2504	1670
70 : 30	2922	1252
80 : 20	3339	835
90 : 10	3757	417

Pengujian dilakukan 2 kali, dimana pengujian pertama hanya menggunakan *naive bayes* dan pada penelitian yang kedua menggunakan seleksi fitur *information gain* dan *naive bayes*. Pengujian ini dilakukan untuk melihat perbandingan

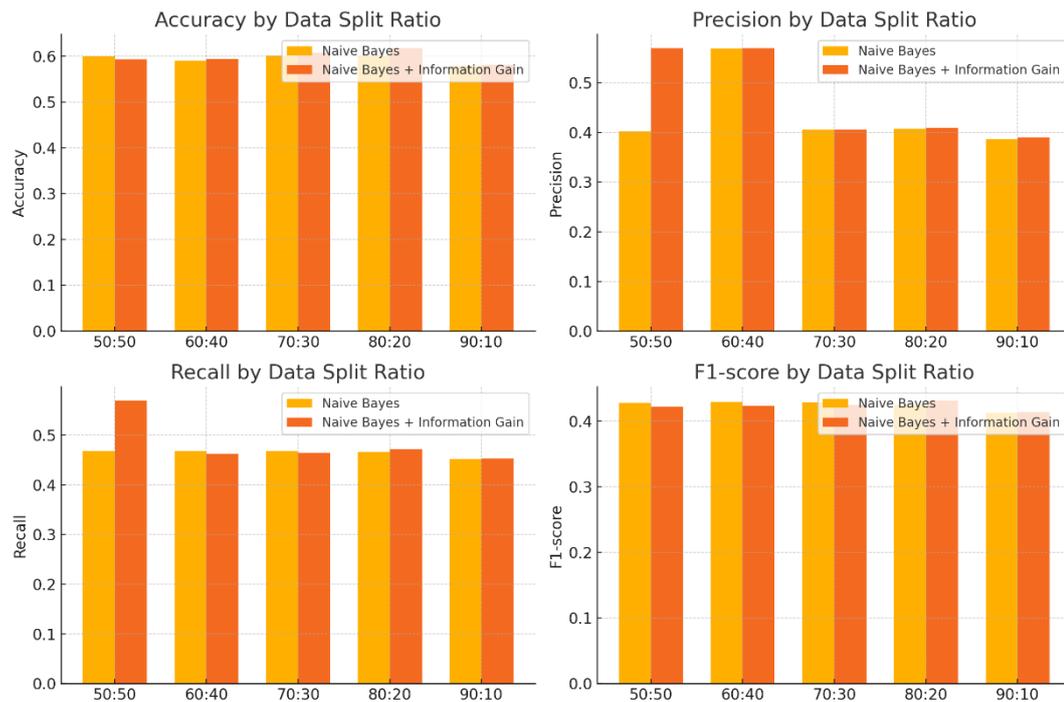
accuracy, precision, recall, dan f1-score.

Pengujian pertama, metode yang digunakan adalah *naive bayes*. Pengujian berikutnya, metode yang digunakan adalah *information gain* dan *naive bayes classifier*. Dalam pengujian ini untuk melakukan seleksi fitur, diberikan sebuah *threshold* sebesar 0.0002 untuk membatasi jumlah dari fitur berdasarkan skor dari *information gain*. Hasil dari penelitian ini akan menampilkan hasil dan menampilkan jumlah fitur yang digunakan jumlah fitur yang digunakan. Dari pengujian didapatkan data seperti berikut.

Tabel V- 2 Hasil pengujian

<i>Naive bayes</i>						
Rasio	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>	Waktu (s)	Fitur
50 : 50	0.6003	0.4028	0.4686	0.4280	0.0042	2493
60 : 40	0.5904	0.5693	0.4685	0.4297	0.0054	2633
70 : 30	0.6009	0.4058	0.4689	0.4286	0.0059	2685
80 : 20	0.6019	0.4075	0.4668	0.4255	0.0061	2827
90 : 10	0.5789	0.3861	0.4520	0.4130	0.0072	3022
<i>Naive bayes dan Information gain</i>						
Rasio	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>	Waktu (s)	fitur
50 : 50	0.5936	0.5697	0.5697	0.4220	0.0036	2262
60 : 40	0.5940	0.5697	0.4622	0.4231	0.0047	2379
70 : 30	0.6077	0.4065	0.4649	0.4243	0.005	2523
80 : 20	0.6177	0.4092	0.4718	0.4313	0.0054	2523
90 : 10	0.5813	0.3903	0.4528	0.4135	0.0066	2523

Perbandingan hasil evaluasi digambarkan pada diagram batang berikut :



Gambar V- 1 Diagram Perbandingan Hasil Evaluasi

5.3 Analisis Data Hasil Pengujian

Berdasarkan dari data penelitian pada tabel V-2 dan gambar V-1. Pada model *Naive bayes*, dengan pembagian data 50:50, akurasi tercatat sebesar 0.6003, dengan presisi 0.4028, recall 0.4686, dan F1-score 0.4280. Meskipun akurasi cukup moderat, presisi dan F1-score relatif rendah, sementara recall lebih tinggi dari presisi, menunjukkan model lebih baik dalam mengidentifikasi klasifikasi positif. Pada pembagian 60:40, presisi meningkat signifikan menjadi 0.5693, namun akurasi dan F1-score tetap hampir tidak berubah, yang menunjukkan bahwa model menjadi lebih baik dalam hal presisi tetapi masih kesulitan untuk menyeimbangkan presisi dan recall. Pada pembagian 70:30, metrik serupa dengan pembagian 50:50, menunjukkan kinerja yang konsisten. Pada pembagian 80:20, akurasi sedikit meningkat menjadi 0.6019, sementara presisi dan recall tetap serupa dengan

pembagian sebelumnya. Namun, pada pembagian 90:10, kinerja sedikit menurun dengan akurasi 0.5789 dan presisi 0.3861.

Untuk model *Naive bayes* dengan *Information gain*, pada pembagian 50:50, akurasi tercatat sebesar 0,5936 dengan presisi dan recall yang sama yaitu 0,5697, namun F1-score lebih rendah yaitu 0,4220. Penambahan *Information gain* meningkatkan presisi dan recall secara signifikan. Pada pembagian 60:40, presisi tetap tinggi tetapi recall sedikit menurun menjadi 0,4622, dengan F1-score hampir sama. Pada pembagian 70:30, presisi menurun signifikan menjadi 0.4065, namun recall tetap serupa, dan F1-score sedikit meningkat. Pada pembagian 80:20, akurasi mencapai nilai tertinggi 0.6177, dengan presisi 0.4092 dan recall 0.4718, serta F1-score 0.4313. Pada pembagian 90:10, kinerja menurun dengan akurasi 0.5813, tetapi presisi, recall, dan F1-score lebih tinggi dibandingkan model *Naive bayes* pada pembagian yang sama.

Secara keseluruhan, *Naive bayes* ataupun *Naive bayes* dengan *Information gain* menunjukkan kinerja yang konsisten pada berbagai pembagian data latih-uji, dengan sedikit perubahan dalam akurasi, presisi, recall, dan F1-score. Penambahan *Information gain* umumnya meningkatkan presisi dan recall dibandingkan dengan *Naive bayes* saja, yang menunjukkan bahwa *Information gain* membantu dalam meningkatkan kemampuan model untuk mengidentifikasi klasifikasi positif. Pembagian data 80:20 memberikan kinerja terbaik untuk kedua model, dengan akurasi tertinggi dan keseimbangan yang relatif baik antara presisi, recall, dan F1-score. Namun, seiring dengan penurunan ukuran data latih dari 90:10 ke 50:50, terdapat penurunan dalam kinerja untuk kedua model, yang menunjukkan bahwa kedua model mendapatkan manfaat dari lebih banyak data latih.

Penerapan *Information gain* sebagai metode seleksi fitur dalam model Naïve Bayes terbukti memberikan dampak positif terhadap kinerja model berdasarkan hasil evaluasi. Peningkatan akurasi terlihat jelas pada sebagian besar rasio data, menunjukkan bahwa *Information gain* membantu model lebih fokus pada fitur-fitur yang relevan, sehingga meningkatkan kualitas klasifikasi. Selain itu, *Information gain* secara signifikan meningkatkan precision, terutama pada rasio data 50:50 dan 60:40, yang berarti prediksi terhadap kelas positif menjadi lebih akurat dengan lebih sedikit kesalahan. Meskipun terdapat fluktuasi pada nilai recall, penurunan yang terjadi relatif kecil, sehingga *Information gain* tidak secara drastis mengurangi kemampuan model dalam mendeteksi kelas positif. Dari sisi F1-score, meskipun peningkatannya tidak selalu signifikan, *Information gain* tetap membantu menjaga keseimbangan antara precision dan recall. Secara keseluruhan, penggunaan *Information gain* memberikan peningkatan kinerja yang signifikan pada model *Naïve Bayes*, terutama dalam aspek akurasi dan precision, serta membuat model lebih efisien dengan mengurangi fitur yang tidak relevan.

Perubahan pada hasil evaluasi dari tiap percobaan disebabkan oleh beberapa faktor utama yang mempengaruhi kinerja model *Naive bayes* dan *Naive bayes* dengan *Information gain*. Pembagian data latih dan uji mempengaruhi hasil evaluasi. Jumlah data latih yang lebih besar biasanya memberikan model lebih banyak informasi untuk mempelajari pola dalam data, yang dapat meningkatkan akurasi dan kinerja secara keseluruhan, sementara data uji yang lebih besar memberikan evaluasi yang lebih komprehensif. Variabilitas data seperti keberagaman data dan kehadiran outliers atau noise dalam data latih atau uji dapat mempengaruhi presisi, recall, dan F1-score model. Model *Naive bayes* dengan

Information gain memilih fitur berdasarkan informasi yang paling relevan, yang dapat meningkatkan kemampuan model dalam mengidentifikasi pola penting dalam data dengan mengurangi kebisingan. Masalah *overfitting* dan *underfitting* juga dapat mempengaruhi hasil. Model yang terlalu fit pada data latih mungkin menunjukkan kinerja yang buruk pada data uji, sementara model yang tidak cukup fit pada data latih mungkin gagal mengenali pola yang relevan. Terakhir, sensitivitas model terhadap variasi dalam distribusi data dapat menyebabkan fluktuasi dalam metrik kinerja seperti presisi, recall, dan F1-score. Secara keseluruhan, model *Naive bayes* dengan *Information gain* cenderung menunjukkan kinerja yang lebih stabil dan konsisten dengan peningkatan presisi dan recall karena pemilihan fitur yang lebih relevan membantu dalam mengurangi kebisingan dan meningkatkan kemampuan model dalam mengidentifikasi pola penting dalam data.

Dari hasil pengujian menunjukkan bahwa jumlah fitur berpengaruh terhadap kinerja model *Naive bayes*, baik dengan maupun tanpa penerapan metode *Information gain*. Pada *Naive bayes* tanpa *Information gain*, jumlah fitur lebih tinggi, berkisar antara 2493 hingga 3022. Sebaliknya, ketika *Information gain* diterapkan, jumlah fitur yang dimiliki berkurang, menjadi 2262 hingga 2523. *Information gain* bekerja dengan menyaring fitur yang kurang relevan, sehingga selain mengurangi kompleksitas model, hal ini juga mempercepat waktu eksekusi, di mana waktu pemrosesan tanpa *Information gain* lebih lama, yaitu 0.0072 detik, sedangkan dengan *Information gain* waktu dapat ditekan hingga 0.0066 detik.

Penerapan *Information gain* menghasilkan peningkatan yang lebih konsisten, terutama pada rasio data 80:20 di mana akurasi mencapai 0.6177 dengan fitur 2523, dibandingkan dengan akurasi 0.6019 tanpa *Information gain* meski

menggunakan lebih banyak fitur 2827. Selain itu, precision, recall, dan F1-score juga cenderung lebih stabil saat *Information gain* diterapkan. Precision dan recall tanpa *Information gain* cenderung lebih fluktuatif, sementara dengan *Information gain*, keduanya menunjukkan peningkatan konsistensi pada setiap rasio data.

Berdasarkan waktu latih, penerapan *Information gain* mempercepat waktu komputasi dalam semua rasio data. Sebagai contoh, pada rasio 50:50, waktu eksekusi dengan *Information gain* adalah 0.0036 detik, sedangkan tanpa *Information gain* membutuhkan 0.0042 detik. Demikian pula untuk rasio lainnya, waktu dengan *Information gain* selalu lebih singkat dibandingkan tanpa *Information gain*.

5.4 Kesimpulan

Penelitian analisis sentimen pada media sosial *twitter* terhadap penggunaan kendaraan listrik dengan menggunakan metode *naïve bayes classifier* dan *information gain* dapat berhasil melakukan analisis sentimen. Sebanyak 4174 data *tweet* bahasa indonesia yang sudah diberikan label klasifikasi dengan 3 kelas, yaitu positif, negatif, dan netral. Hasil perhitungan evaluasi menunjukkan bahwa analisis sentimen dengan menggunakan seleksi fitur memberikan hasil kinerja yang lebih baik dibandingkan dengan metode *naive bayes* tanpa menggunakan seleksi fitur.