

## BAB V

### SIMPULAN DAN SARAN

#### 5.1 Simpulan

Berdasarkan penelitian yang telah dilakukan pada data ulasan aplikasi *seller center* Tokopedia dan Tiktok Shop untuk untuk *topic modeling* dan *sentiment analysis*, ditemukan lima aspek utama yang sering muncul dalam ulasan pengguna aplikasi *seller center* Tokopedia dan Tiktok shop yaitu Produk, Keuangan, Performa Toko, Pendaftaran dan Pengaturan Akun, dan Pesanan & Pengiriman yang diperoleh dari hasil memetakan distribusi kata pada topik dominan yang dihasilkan oleh model terbaik dengan fitur aspek.

Setiap aspek dilakukan *sentiment analysis* untuk memperoleh sentimen positif dan negatif pada tiap aspek. Klasifikasi biner mempermudah pengambilan keputusan karena sentimen negatif dan positif pada aspek memberikan wawasan yang bisa ditindaklanjuti (*actionable insight*) oleh pemegang keputusan. Model yang dibangun dengan klasifikasi biner akan lebih kuat untuk membedakan kepuasan dan ketidakpuasan pengguna aplikasi. Aspek Pendaftaran dan Pengaturan Akun memperoleh 68.18% sentimen negatif dan 31.82% sentimen positif dengan *f1-score* 0.729, Produk memperoleh 52.77% sentimen negatif dan 47.23% sentimen positif dengan *f1-score* 0.689, Pesanan Pengiriman memperoleh 51.81% sentimen negatif dan 48.19% sentimen positif dengan *f1-score* 0.748, Keuangan memperoleh 48.21% sentimen negatif dan 51.79% sentimen positif dengan *f1-score* 0.668, serta Performa Toko memperoleh 40% sentimen negatif dan 60% sentimen positif dengan *f1-score* 0.719. Keseluruhan hasil *sentimen analysis* menunjukan Aspek Pendaftaran dan Pengaturan Akun memiliki sentimen negatif paling besar sedangkan aspek Performa Toko memiliki sentimen positif paling besar. *Sentiment analysis* menggunakan SMOTE untuk menyeimbangkan data namun tidak selalu menghasilkan performa yang lebih baik.

Pemodelan topik dengan model NMF menghasilkan nilai koherensi yang lebih tinggi dibandingkan dengan model LDA. Nilai coherence NMF 0.503110—0.742449 (TFIDF) dan 0.631439—0.734241 (Count Vectorizer) sedangkan

*coherence c\_v* LDA menggunakan TFIDF dan CountVect lebih rendah dari NMF dengan rentang nilai *coherence* LDA 0.415862—0.504810 (TFIDF) dan 0.549520—0.617491 (Count Vectorizer). Ketika tahap preprocessing menggunakan pos tagging, hasil *coherence c\_v* LDA menggunakan TFIDF dan Count Vectorizer juga lebih rendah dari NMF dengan rentang nilai *coherence* LDA 0.424310—0.516026 (TFIDF) dan 0.530519—0.598437 (Count Vectorizer) sedangkan rentang nilai *coherence* NMF 0.607189—0.747502 (TFIDF) dan 0.610915—0.744763 (Count Vectorizer).

Hasil pemodelan topik diimplementasikan pada tahap *deployment* dengan membuat *web dashboard* yang dapat diakses secara lokal melalui aplikasi Streamlit dan bahasa pemrograman Python. Pengguna aplikasi dapat memasukkan ulasan untuk memperoleh hasil klasifikasi aspek dominan dan sentimen ulasan dalam satu tombol. Selain itu, *web dashboard* berisi visualisasi distribusi sentimen positif dan negatif terhadap aspek untuk memberikan wawasan yaitu aspek/fitur/layanan yang membutuhkan prioritas tertinggi atau fitur yang sentimen positifnya tinggi sehingga perlu dipertahankan kinerjanya.

## 5.2 Saran

Saran yang dapat diterapkan pada penelitian selanjutnya adalah:

1. Meningkatkan hasil *preprocessing* data pada data ulasan yang mengandung banyak kata slang atau kata singkatan yang sering digunakan saat berselancar di internet dengan membuat atau menggunakan kamus normasilisasi berisi kata koreksi.
2. Meningkatkan hasil pemodelan topik dengan *setting* parameter yang berbeda pada *topic modeling* untuk menemukan kinerja model yang lebih optimal.
3. Menggunakan algoritma pemodelan topik seperti BERTopic yang berbasis *transformer embedding* untuk meningkatkan representasi semantik dan meningkatkan interpretasi hasil topik.