

Abstrak

Tugas akhir ini menganalisis metode *n-gram* dalam mengenali bahasa suku bangsa Indonesia berbasis teks. Untuk menganalisis akurasi dari metode *n-gram* dilakukan pengujian dengan menggunakan panjang n yang berbeda dari *n-gram*, panjang rangking berbeda dari model *n-gram* bahasa, dan pengujian untuk menganalisis pengaruh banyaknya kata di dalam dokumen yang ingin dikenali bahasa daerahnya. Proses pelatihan dilakukan guna membentuk model *n-gram* bahasa dari masing-masing bahasa daerah. Sistem yang dibuat menggunakan metode *n-gram* untuk pemodelan bahasa daerah dan teknik rank-order-statistic untuk pengklasifikasian bahasa daerahnya. Dari seluruh pengujian yang dilakukan didapatkan bahwa untuk akurasi pengenalan bahasa daerah Sunda dan Jawa dapat digunakan panjang minimum $rank=100$ dan panjang n dari *n-gram* yaitu $n=3$, $n=4$, $n=5$, dengan akurasi pengenalan pada penggunaan panjang $rank=100$ sebesar 100% untuk $n=3$, 98,75% untuk $n=4$, 97,50% untuk $n=5$. Sedangkan rasio antara panjang $rank$ dengan banyaknya kata di dalam dokumen yang ingin dikenali bahasanya yaitu $pjg_rank : jml_kata = 100 : 40$, dengan penggunaan panjang minimum $rank=100$ dan banyak kata minimum di dalam dokumen yang ingin dikenali = 40 kata.

Kata kunci: n-gram, performansi, akurasi, rank-order-statistic.