

7

Conclusão

Nesta dissertação investigamos métodos de aprendizado de máquina para *Sentiment Analysis*. Apresentamos alguns modelos de representação de documentos como saco de palavras e N-grama. Testamos os classificadores SVM (Máquina de Vetores Suporte) e Naive Bayes com diferentes modelos de representação textual e comparamos seus desempenhos.

Apresentamos o conceito de filtro de subjetividade visando remover dos documentos frases que não emitem opiniões e geram ruído no processo de classificação de sentimento.

O filtro de subjetividade se mostrou eficaz para o classificador Naive Bayes, porém não gerou melhoria no desempenho do classificador SVM. Isto sugere que o modelo de aprendizado do classificador SVM é robusto suficientemente para filtrar este ruído.

Pré-processar os documentos aplicando *part of speech tagging* gerou uma variação desprezível na precisão. Concluimos que isso se deve ao fato de que a grande maioria das palavras pertencem sempre à mesma classe gramatical.

Utilizamos um critério guloso de seleção de variáveis baseado na Informação Mútua Média (IMM). Analisamos a evolução do desempenho dos classificadores em função do número de *features* consideradas. Os experimentos sugeriram que, uma vez consideradas as 1000 *features* mais informativas, as outras podem ser desprezadas sem perda de desempenho (ou com mínima perda).

Os modelos e classificadores apresentaram desempenhos muito parecidos (82% o pior e 87.8% o melhor). Portanto, não é possível ter conclusões definitivas sobre qual é o melhor modelo para a tarefa de classificação de sentimento. Além disso, o corpus utilizado é razoavelmente pequeno (2000 textos) e limitado a um domínio e fonte específicos. Portanto, os experimentos não trazem conclusões definitivas quanto aos melhores modelos para o problema.

Uma linha de pesquisa em aberto na área é estudar o desempenho de algoritmos semi-supervisionados (máquinas que continuam aprendendo

durante a fase de classificação) visto que tais métodos apresentam bons resultados em classificação por tópico (04). Porém, acreditamos que o *movie review data set* seja muito pequeno para se validar este tipo de técnica.

Uma outra questão que fica em aberto é se métodos heurísticos e estatísticos de seleção de *features* automáticos podem trazer melhores resultados.

Neste trabalho, *Sentiment Anaysis* foi tratado como um problemas de categorização de texto partindo da premissa de que cada documento está associado à uma classe positiva ou à negativa. Porém, na prática, é comum querermos extrair o *sentimento* com relação a uma organização ou produto em textos que não necessariamente emitem opiniões exclusivamente de um tema.

Considere o seguinte exemplo:

“A ACME é uma empresa muito interessante e criativa, já a XPTO é devagar e burocrática.”

Neste exemplo, desejamos detectar um sentimento positivo com relação à ACME e um negativo com relação à XPTO. Uma abordagem ingênua para este problema é considerar termos que ocorrem na “vizinhança” do termo a ser classificado. Porém, é obvio que existem problemas com esta abordagem.

Portanto, é importante que os estudos em *Sentiment Analysis* passem a tratar as classificações como “orientadas a entidades” ao invés de se concentrar em classificação de sentimentos associados a documentos.