

6 Considerações Finais

Este capítulo apresenta as contribuições deste trabalho, bem como alguns pontos identificados, ao longo de seu desenvolvimento, como trabalhos futuros.

6.1. Contribuições

Atualmente, a principal forma de publicidade na Web é a publicidade de busca. Os anúncios exibidos nesse tipo de publicidade precisam ser adequadamente direcionados aos usuários, o que é feito através de sistemas de recomendação de anúncios. Na política dominante de ordenação de anúncios utilizada por esses sistemas, a qual se baseia no Leilão de Segundo Preço Generalizado (LSGP) e no *estimated Cost Per Impression* (eCPI), a predição do *Click-Through Rate* (CTR) ocupa um papel crucial.

Neste trabalho, propomos um método de predição do CTR usando filtragem colaborativa, que pode ser aplicado à recomendação de anúncios. Ao utilizarmos filtragem colaborativa, somos capazes de prever o CTR para anúncios associados a qualquer tipo de conteúdo, mesmo os que não são similares aos observados no passado.

Adicionalmente, apresentamos o LearnAds, um *framework* que oferece suporte ao emprego de técnicas de Aprendizado de Máquina na publicidade direcionada, tratando-a como um problema de recomendação de anúncios. Para tanto, descrevemos os requisitos atendidos pelo *framework*, bem como as especificações e decisões de projeto adotadas a fim de satisfazer tais requisitos.

Finalmente, conduzimos experimentos utilizando dados sintéticos, que servem não apenas para validar o método de predição do CTR proposto, como também para realizar uma primeira instanciação do *framework* LearnAds.

6.2. Trabalhos Futuros

A seguir serão descritos alguns pontos interessantes, identificados como trabalhos futuros ao longo do desenvolvimento deste trabalho.

Em virtude da indisponibilidade de dados reais, só foi possível validar o método proposto de predição do CTR, através de experimentos utilizando dados sintéticos. A fim de efetivamente avaliar o desempenho do preditor de CTR gerado, devem ser realizados novos experimentos, quando forem disponibilizados conjuntos de dados contendo CTR's reais.

Considerando os resultados obtidos nos experimentos, os quais indicam que os métodos de filtragem colaborativa são apropriados para a resolução do problema de predição do CTR, seria interessante avaliar, além do algoritmo baseado na técnica de fatoração de matrizes, outros algoritmos de filtragem colaborativa. Dentre aqueles para os quais a literatura indica bons resultados quando aplicados em sistemas de recomendação, vale citar KNN, *K-Nearest Neighbors* (Bell & Koren, 2007), PLSA, *Probabilistic Latent Semantic Analysis* (Hofmann, 2003), e RBM, *Restricted Boltzmann Machines* (Salakhutdinov et al., 2007), entre outros.

Finalmente, seria interessante combinar o método de predição do CTR proposto neste trabalho com a técnica de *ensemble models*, que consiste no aprendizado de vários modelos preditivos cujos resultados são combinados para gerar uma predição única. Essa técnica tem produzido bons resultados quando aplicada à filtragem colaborativa (DeCoste, 2006; Wu, 2007), e alguns exemplos de algoritmos que a implementam são *Bagging* (Breiman, 1996) e *Boosting* (Freund & Schapire, 1996).