

Principais componentes na ordenação de anúncios: um experimento em ambiente real de publicidade computacional

André Casimiro, Marcos Broinizi, João Eduardo Ferreira

¹ Departamento de Ciências de Computação
Universidade de São Paulo (USP) – São Paulo, SP – Brasil

{casimiro,mbroinizi,jef}@ime.usp.br

Abstract. *Computational Advertising is a multibillion dollar market that promotes the web's development. A major challenge is to simultaneously optimize the interests of users, advertisers and publishers, which depends on the order of ads retrieved. Many research papers explored different factors to solve the problem of ad ordering, such as page context, ad historical performance, maximum cost per click, and user's related data. However, there is a knowledge gap regarding the evaluation of these factors in a real environment. To reduce this gap, we present an experiment of computational advertising in the largest Brazilian news portal. More concretely, in this paper, we evaluated the correlation and how each one of these factors affects system performance. According to our results, these aspects complement each other, and when used together, they are able to optimize the interests of users, advertisers and publishers.*

Resumo. *Publicidade computacional é um mercado multibilionário que proporciona o desenvolvimento da Internet. Um dos grandes desafios é otimizar simultaneamente os interesses dos usuários, anunciantes e publicadores, o que depende da ordem dos anúncios recuperados. Muitos trabalhos exploram diferentes fatores para resolver o problema de ordenação de anúncios, tais como o contexto da página, o desempenho histórico do anúncio, o valor máximo de um clique e os dados do usuário. Entretanto, há uma lacuna de entendimento com relação a avaliação desses fatores em um ambiente real. Para reduzi-la, apresentamos um experimento de publicidade computacional no maior portal brasileiro de notícias. Mais concretamente, avaliamos a correlação e como cada um desses fatores afeta o desempenho do sistema de anúncios. De acordo com nossos resultados esses aspectos são complementares e, quando usados em conjunto, otimizam os interesses dos usuários, anunciantes e publicadores.*

1. Introdução

Na Internet, é impossível não notar a presença de anúncios publicitários, eles estão presentes em sites de busca, portais de informação, notícias, redes sociais e até mesmo blogs pessoais. A exibição de publicidade é um mercado multibilionário [IAB 2013] que estimulou o desenvolvimento da Internet, pois permite que produtores de conteúdo e desenvolvedores de aplicativos rentabilizassem seus negócios. Nesse cenário, os modelos e os contratos de publicidade desenvolveram-se muito nos últimos anos. Iniciando com a alocação de anúncios visuais (*banners*) por um valor fixo, seguida pela busca patrocinada em máquinas de busca e, posteriormente, pelas redes de anúncios (*ad networks*) expandindo a veiculação de conteúdo publicitário a qualquer página da Internet.

Os sistemas de publicidade computacional possuem um repositório de anúncios e de anunciantes. Cada requisição feita por um navegador para exibição do conteúdo de um site gera também uma requisição ao sistema de anúncios. Os anúncios são recuperados, ordenados e devolvidos para exibição. Essa ordenação depende de diversos fatores e visa balancear os interesses das partes envolvidas, a saber: o usuário, o anunciante e o publicador (que é o site no qual os anúncios são veiculados). O equilíbrio desses interesses é essencial para a continuidade do sistema, pois a participação de cada um depende da atuação dos outros. Por exemplo, uma ordenação que favorecesse o interesse financeiro do publicador aumentaria o lucro mas, a longo prazo, provavelmente menos usuários se interessariam pelos anúncios veiculados, uma vez que os mesmos seriam pouco relacionados ao conteúdo da página, o que implicaria na degradação da efetividade do sistema de publicidade. A definição de uma ordenação que equilibre os interesses se torna ainda mais desafiadora ao considerar o fato de que a quantidade de espaço publicitário em cada página comporta poucos anúncios, enquanto existem milhares disponíveis para exibição.

A seleção e ordenação de anúncios é frequentemente modelada como um problema de recuperação de informação [Wang et al. 2009] e leilões de segundo preço [Edelman et al. 2005]. Alguns trabalhos têm utilizado técnicas de aprendizado de máquina para resolver esse problema, indo desde regressões lineares [Bendersky et al. 2010] e logísticas [Agarwal et al. 2009] até técnicas mais avançadas como programação genética [Lacerda et al. 2006] e SVM [Broder et al. 2007]. Bons resultados tem sido alcançados com esses modelos, por outro lado seu uso enfrenta algumas restrições quando aplicados a um sistema real. Uma das principais restrições é a manutenção do sistema conforme o ambiente evolui, devido à sua complexidade o desenvolvimento e implantação de novos modelos pode não acompanhar as constantes mudanças a que o sistema está submetido.

Os sistemas de anúncios têm restrições de escala da ordem de bilhões de requisições por hora e milhões de usuários únicos por mês. Para satisfazê-las, são construídos semelhantes a sistemas de busca, realizando ações como *crawling* da página destino, indexação dos anúncios cadastrados, recuperação, ordenação e exibição dos anúncios recuperados. Nosso trabalho é baseado em um sistema de anúncios que neste modelo. Ele atende às restrições de escala e possui uma estratégia de mercado para ordenação de anúncios que utiliza quatro variáveis principais: a aposta, ou o valor máximo pago por um anunciante por um clique em seu anúncio (BID), a taxa histórica de clique do anúncio (CTR, ou *Click Through Rate*), o *score* de relevância com o contexto da página (CTX) e o *score* de relevância com o usuário (BTU, ou *behavioral targeted user*). Podemos descrever os interesses de cada participante em termos dessas variáveis como segue:

- o usuário acessa a Internet com a intenção de obter informações (CTX), esperando ter uma boa experiência pessoal (BTU) e tem potencial de adquirir algo (CTR);
- o anunciante disponibiliza informação sobre um bem ou serviço que deseja oferecer a um usuário e possui recursos para investir em publicidade, esperando receber acessos e vendas (ou conversões) advindos dessa publicidade (CTR);
- o publicador exerce papel de intermediário, possui alta audiência e deseja aumentar a receita exibindo publicidade (BID) e a audiência atraindo usuários (CTR).

No melhor de nossa pesquisa, nenhum estudo foi ainda conduzido para analisar a importância e a contribuição dessas variáveis individualmente. Nosso trabalho traz na

seção 2 uma descrição dos principais trabalhos relacionados ao desenvolvimento da publicidade computacional nos últimos anos. Para análise das variáveis, foram realizados dois experimentos no ambiente de produção do maior portal de conteúdo da Internet brasileira. A descrição do ambiente é feita na seção 3, seguida pela descrição dos experimentos e seus resultados na seção 4. Por fim, as conclusões e trabalhos futuros estão na seção 5.

2. Trabalhos relacionados

A história da publicidade computacional nos remete a própria história da Internet. Conforme a Internet foi crescendo e se consolidando como parte integrante da vida das pessoas, maior a atração de se colocar conteúdo publicitário em suas páginas. Logo, naturalmente, quanto mais recursos foram investidos, maior o desenvolvimento da área. Ao longo dos anos, surgiram novos modelos e formatos de publicidade, enriquecendo a experiência do usuário e satisfazendo melhor suas necessidades de consumo [Oberoi 2013].

O primeiro modelo de publicidade computacional foi fortemente baseado na publicidade tradicional vinda de outras mídias. Nele um anunciante paga por um espaço publicitário fixo em um site que julgue ser relevante para o público que deseja alcançar. Esse modelo é utilizado até hoje e geralmente o custo é fixado por tempo ou por milhares de exibições/impressões, também conhecido como CPM (*cost per mille*). O grande divisor de águas para a publicidade computacional foi o surgimento da busca patrocinada (*sponsored search*), em que usuários de máquinas de busca são expostos a publicidade relacionada à consulta que realizaram. Os anunciantes apostam em palavras e concorrem em um leilão de segundo preço para conseguirem as melhores posições de exibição [Edelman et al. 2005]. Além de CPM, o modelo de pagamento também pode ser por clique no anúncio, que é conhecido como CPC (*cost per click*). Em 1998, a Overture, uma das empresas pioneiras em publicidade computacional que foi comprada pelo Yahoo em 2003, utilizava apenas a variável BID para ordenação dos anúncios. Assim, quem pagava mais aparecia nas melhores posições. O Google, que era conhecida por fornecer os resultados de busca mais relevantes, usou a mesma estratégia para ordenação dos anúncios e acrescentou uma variável de qualidade, introduzindo o conceito de recomendação de anúncios. Em fevereiro de 2002, essa variável nada mais era do que o CTR do anúncio, hoje certamente a qualidade inclui diversos outros fatores [Google 2002].

Há uma generalização teórica dessa variável de qualidade que é usada para o problema de ordenação de anúncios e que modela o equilíbrio de interesses que citamos anteriormente. Podemos definir a fórmula de ordenação de anúncios apenas em função de dois valores, a aposta do anunciante (BID) e a probabilidade de se atingir o objetivo esperado com a veiculação do anúncio.

$$rank = BID * Pr(sucesso)$$

No modelo de CPM, o objetivo é simplesmente a impressão do anúncio na tela. Como não há risco de o anúncio não ser exibido, temos que $Pr(impr) = 1$ e logo:

$$rank_{CPM} = BID * Pr(impressao) = BID$$

Para o modelo CPC, a probabilidade de um usuário clicar em um anúncio depende de diversos fatores e sua fórmula de rank seria então:

$$rank_{CPC} = BID * Pr(clique)$$

Há ainda o modelo CPA (*cost per action*), em que o anunciante só paga quando o usuário, após clicar no anúncio, faz determinada ação em seu site, como por exemplo comprar um produto ou preencher um formulário. Podemos representar sua fórmula como:

$$rank_{CPA} = BID * Pr(\text{clique}) * Pr(\text{acao})$$

A taxa de usuários que clica em um anúncio exibido geralmente é menor do que 1% e a proporção desses que também realizam uma ação (e.g. compram um produto) é menor ainda. Como a escala da web é de milhões de usuários, esse funil de conversão ainda é atrativo para os anunciantes. O trabalho de Bagherjeiran et al. explora uma abordagem de otimização para o modelo de CPA [Bagherjeiran et al. 2010]. Há inúmeros aspectos que podem ser considerados para estimar $Pr(\text{clique})$ e $Pr(\text{acao})$ com relação ao usuário e o que o influencia em seu engajamento com conteúdo publicitário. Algumas das questões que buscaram ser analisadas são: o anúncio é relevante com o interesse do usuário naquele momento? [Agarwal et al. 2009] A exibição excessiva de anúncios irrita o usuário? [Broder et al. 2008] O aspecto visual do anúncio está adequado? [Azimi et al. 2012]

As páginas de busca são bons pontos de partida para navegação na Internet, mas o tempo que o usuário gasta navegando nelas é pequeno se comparado ao tempo gasto consumindo conteúdo na página alvo de sua busca. Para suprir essa demanda de exibição de publicidade surgiu o que chamamos de publicidade contextualizada (*contextual advertising*), que é a exibição de anúncios relacionados em qualquer página da Internet. Uma solução em escala para esse problema foram as redes de anúncios (*ad networks*) que agregaram em uma única plataforma anunciantes e publicadores. Qualquer anunciante pode cadastrar um anúncio e qualquer publicador pode integrar seu site para exibição de publicidade. Quando um usuário requisita uma página do site do publicador, os anúncios são requisitados ao servidor de anúncios e inseridos na área reservada a publicidade.

O problema de publicidade contextualizada é uma generalização do problema de busca patrocinada no sentido que estende o desafio de contextualização dos anúncios a qualquer página da Internet, não somente a resultados de buscas. Além do significativo aumento de tráfego, a maior dificuldade está em estimar $Pr(\text{clique})$ e $Pr(\text{acao})$ com precisão. Na busca patrocinada temos uma informação precisa do interesse do usuário naquele instante: a consulta que acabou de realizar. Em publicidade contextualizada não temos isto, precisamos inferir tal informação a partir do contexto, como o conteúdo da página e o comportamento do usuário. A variável CTX que apresentamos é uma forma de capturar a relevância de um anúncio com relação ao conteúdo da página e é obtida no processo de recuperação de anúncio. As redes de anúncios são estruturadas de forma semelhantes às máquinas de busca, fazem *crawling* das páginas dos publicadores e indexação dos anúncios em um índice invertido. Quando um usuário acessa a página de um publicador, é feita uma requisição ao sistema de anúncios identificada pela url da página e uma consulta é feita ao índice de anúncios utilizando palavras extraídas da página pelo crawler. O CTX é o *score* obtido na recuperação dos anúncios. Os trabalhos de Agarwal et al. mostram como utilizar o CTX para estimar $Pr(\text{clique})$ [Agarwal et al. 2009] e também para obter maior eficiência computacional e precisão semântica [Agarwal and Gurevich 2012]. O trabalho de Bendersky melhora eficiência da recuperação dos anúncios propondo um modelo de dados organizado por campanhas publicitárias [Bendersky et al. 2010] e o trabalho de Ribeiro-Neto usa métodos de expansão de consulta para evitar falta de correspondência entre o vocabulário das páginas e dos anúncios [Ribeiro-Neto et al. 2005].

Uma tendência mais recente da área de publicidade computacional tem sido a de melhorar seu conhecimento sobre o usuário que está navegando, não de forma generalista, mas individualizada. Conhecer o perfil do usuário (sexo, faixa etária, região geográfica, interesses pessoais, etc...) permite que a recomendação de publicidade seja mais precisa, fornecendo ao usuário anúncios de seu interesse e melhorando o retorno obtido pelos anunciantes. A obtenção desse tipo de dado pode ser feita por meio de redes sociais, requisitando ao usuário acesso aos dados; ou por rastreamento de comportamento (*behavioral tracking* ou *behavioral targeting*), área que utiliza aprendizado de máquina para analisar padrões de navegação e classificar usuários em perfis. Essa é uma área promissora, que tem obtido melhorias significativas no engajamento do usuário [Tang et al. 2011]. A variável BTU que utilizamos em nossos experimentos representa essa dimensão.

3. Ambiente

Nesta seção descrevemos o sistema de publicidade computacional utilizado para realização de nosso experimento, bem como características da fonte de coleta de dados e o processo de obtenção de cada variável. Nosso experimento foi realizado na rede de anúncios do maior portal de conteúdo da Internet brasileira, responsável por 5 bilhões de requisições de anúncios por mês. Há três tipos principais de publicadores de anúncios, os canais, os parceiros e os afiliados. Os canais são seções do portal de conteúdo específico como notícias, esporte, entretenimento, etc.; os parceiros são sites de nicho que possuem parceria de tráfego de usuários; e os afiliados são quaisquer sites que integraram às suas páginas uma seção para exibição de conteúdo publicitário por meio da rede. Essa gama de sites que exibem os anúncios atrai anunciantes dos mais variados, empresas de pequeno, médio e grande porte de todos os ramos de atuação.

3.1. Sistema de anúncios

O principal objetivo do sistema de anúncios utilizado é exibir a um usuário que está visitando uma das páginas dos publicadores os melhores anúncios dentre os disponíveis. O conceito de melhor anúncio é implementado como critérios de ordenação, ou *ranking*, para selecionar uma pequena quantidade de anúncios dentre o grande volume disponível. Esses critérios usualmente são representados por fórmulas ou funções que utilizam valores mensuráveis, como as quatro variáveis já descritas. A ordenação busca atender simultaneamente os interesses dos usuários, anunciantes e publicadores. Além disso, o sistema está submetido a fortes restrições de desempenho, como volume de requisições e tempo de resposta.

Para atender ao seu objetivo e respeitar as restrições impostas, o sistema de anúncios em estudo foi concebido em duas fases. A primeira utiliza recuperação de informação para selecionar anúncios em um índice, no qual anúncios são tratados como documentos a serem recuperados. Uma consulta de anúncios é construída com os termos e assuntos da página visitada, os assuntos de interesse do usuário, os dados demográficos, a geo-localização do usuário, entre outros. A consulta é submetida e os anúncios mais relevantes ou similares são recuperados, utilizando uma ordenação tradicional de recuperação de informação no modelo vetorial, com ponderação de frequência e raridade, *tf-idf*. Essa etapa calcula os valores das variáveis CTX e BTU.

A segunda fase é chamada de estratégia de reordenação e reordena os anúncios selecionados na etapa inicial utilizando uma fórmula que combina as variáveis BID,

CTX, BTU e CTR e exibe os anúncios mais bem posicionados. Exploramos apenas essa segunda fase, testando o desempenho de diferentes estratégias sobre a plataforma de experimentação descrita em mais detalhes por Broinizi e Ferreira [Broinizi et al. 2014].

4. Análise de dados

Nesta seção descrevemos a análise de dados conduzida para determinar quais são os fatores mais relevantes na ordenação de anúncios e como sua combinação pode contribuir para os interesses do usuário, do anunciante e do publicador. Realizamos dois experimentos em ambiente de produção para comparação do desempenho de diferentes estratégias de reordenação de anúncios; também, fizemos uma análise de componentes principais para entender o relacionamento entre as variáveis disponíveis: BID, CTR, CTX e BTU.

A avaliação das estratégias com relação à sua utilidade para os participantes foi feita por meio do desempenho em duas métricas chave:

- o CTR (*click through rate*), que é o número de cliques dividido pelo número de impressões, representa os interesses do usuário e do publicador;
- e o ECPM (*estimated cost per mille*), que é o valor financeiro arrecadado a cada mil impressões, representa o interesse do publicador;

Vale notar que gostaríamos de utilizar como métrica específica para o anunciante o ROI (*return over investment*), ou seja o retorno recebido pelo que foi investido em publicidade, mas esse dado pertence ao anunciante e nem sempre está disponível. Entretanto, o CTR também é uma métrica de interesse do anunciante uma vez que indica que o mesmo atraiu a atenção do usuário para seu produto ou site.

4.1. Experimento 1: comparação de estratégias puras

O primeiro experimento avaliou cinco estratégias de reordenação de anúncios: stRND, stBID, stCTR, stCTX e stBTU. A estratégia stRND é uma reordenação aleatória dos anúncios e será utilizada como *baseline*. Todas as outras estratégias representam uma ordenação pura pela variável que as descreve, ou seja, stBID reordena os anúncios apenas pela variável BID, stCTR apenas por CTR, e assim por diante. As cinco estratégias foram avaliadas simultaneamente ao longo de uma semana, todas receberam uma amostra aleatória e de mesmo tamanho de todas as requisições feitas ao sistema de anúncios, totalizando mais de 300 milhões de anúncios exibidos. Uma limitação de nossa plataforma que pretendemos aprimorar futuramente é o fato de não isolar as estratégias por grupos de usuários, assim o mesmo usuário é exposto a várias estratégias diferentes.

A Figura 1 apresenta o gráfico normalizado do desempenho diário de cada estratégia em relação às métricas de CTR e ECPM. A estratégia com a melhor taxa de clique foi stCTR e a que gerou mais retorno financeiro foi stBID. A alta taxa de clique em stCTR a fez superar o patamar de retorno financeiro de stRND, em contrapartida, mesmo stBID tendo a pior taxa de clique, excedeu em muito as outras estratégias em termos de ECPM. Enquanto a estratégia stCTX obteve resultado levemente superior a stRND tanto em CTR quanto em ECPM, stBTU se mostrou bem semelhante: em termos de CTR sem um padrão definido; e em termos de ECPM equiparados em um patamar baixo.

O fato de stCTR desempenhar tão bem em CTR indica que podemos olhar para o problema de exibição de publicidade do ponto de vista de recomendação, no qual usuários recomendam anúncios para outros que tenham comportamento semelhante, o que corrobora com a tendência apontada por Garcia-Molina [Garcia-Molina et al. 2011].

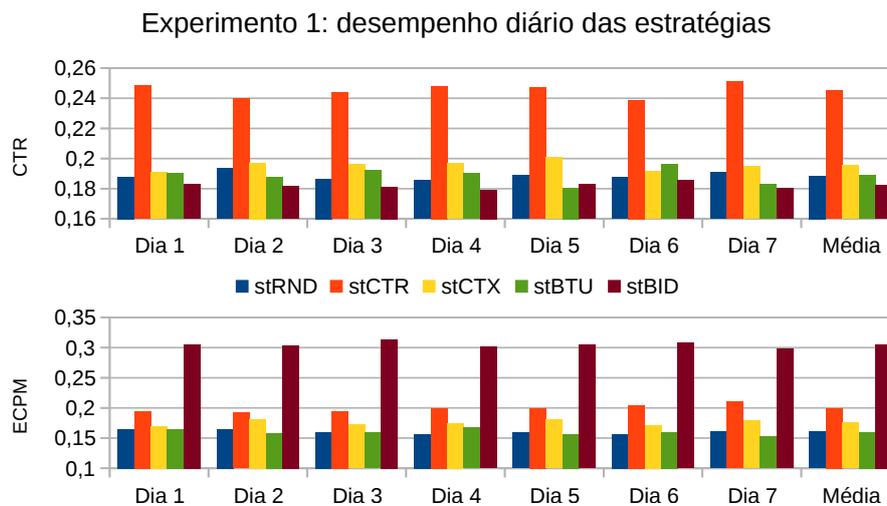


Figura 1. Desempenho diário das estratégias do experimento 1 em termos de CTR e ECPM normalizados. A média de todos os dias é apresentada à direita.

4.2. Experimento 2: comparação de estratégias tradicionais

O segundo experimento é semelhante ao primeiro e analisou comparativamente as seguintes estratégias: stCTR, stBID, stTRAD, stUSER, stMKT. As estratégias stCTR e stBID são as mesmas do experimento 1; stTRAD é a fórmula tradicional de reordenação criada pelo Google em 2002 e nada mais é que uma multiplicação de CTR e BID; stUSER é a soma dos valores normalizados das variáveis relevantes apenas para o usuário (CTR, CTX, BTU); e stMKT é uma solução comercial que combina as variáveis disponíveis. A coleta de dados durou sete dias e mais de 300 milhões de anúncios foram exibidos.

A Figura 2 apresenta o gráfico normalizado do desempenho diário de cada estratégia em relação às métricas de CTR e ECPM. A estratégia stUSER obteve resultado levemente inferior ao de stCTR com relação à taxa de clique e equivalente em ECPM, o que valida que as variáveis CTR, CTX e BTU impactam diretamente no interesse do usuário. A estratégia stTRAD se mostrou a mais equilibrada com relação às duas métricas de desempenho. A estratégia stMKT obteve o melhor resultado em ECPM, superando stBID não somente em desempenho financeiro, mas também em taxa de clique (quase duas vezes superior). Isso ratifica que a reordenação de anúncios baseado nessas variáveis pode produzir ganhos para cada um dos participantes simultaneamente.

4.3. Análise de componentes principais (PCA)

O PCA é uma técnica estatística usada em análise multivariada que realiza uma mudança de base do espaço analisado, de modo que os vetores da nova base (componentes principais) estejam alinhados com os eixos de maior dispersão dos dados [Shlens 2014]. Para entender a correlação entre as variáveis analisadas, realizamos a análise de componentes principais com uma amostra de dados coletada durante os experimentos. Utilizamos apenas dados de anúncios que foram clicados, ou que foram exibidos junto a algum outro clicado. Essa heurística visa aumentar a qualidade dos dados, removendo anúncios que possivelmente não foram nem vistos pelos usuários, e foi necessária para obtermos uma análise conclusiva. A Figura 3 apresenta a projeção dos vetores da base original (BID, CTR, CTX e BTU) em dois planos definidos pela nova base (PC1, PC2, PC3 e PC4).

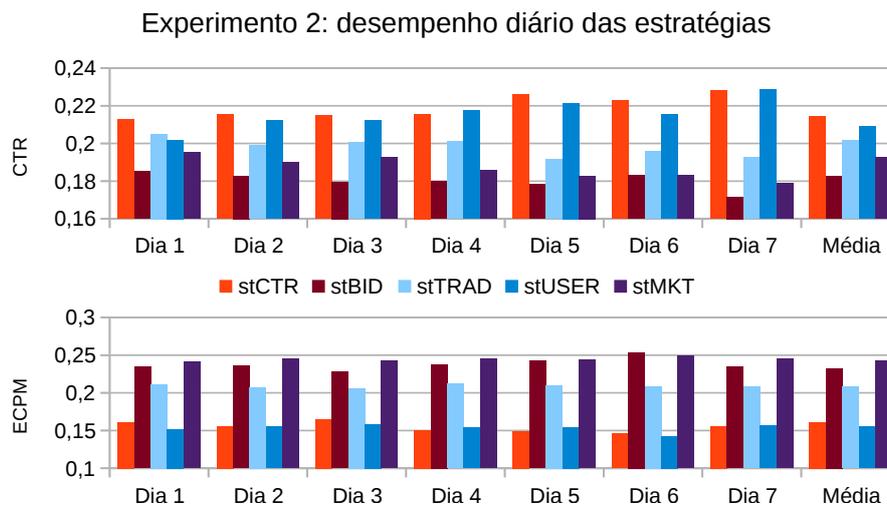


Figura 2. Desempenho diário das estratégias do experimento 2 em termos de CTR e ECPM normalizados. A média de todos os dias está a direita.

No plano de $PC1 \times PC2$, vemos que as duas primeiras componentes principais são compostas por uma combinação de BID, CTX e BTU, e uma expressão menor de CTR. A diferença de direção entre BID, CTX e BTU revela que essas variáveis são pouco correlacionadas, já o alinhamento de CTR com BTU revela a utilidade da captura de interesses do usuário para atrair sua atenção. As duas primeiras componentes principais cobrem apenas 56,3% de toda a variância, portanto necessitamos analisar também as duas últimas. No plano de $PC3 \times PC4$, vemos que a terceira componente (PC3) é composta principalmente por CTR, o que, em conjunto com a diferença de direção de BID, CTX e BTU no plano de $PC1 \times PC2$, revela que as variáveis capturam aspectos diferentes do contexto e que, portanto, nenhuma delas deve ser descartada no problema de reordenação de anúncios. A quarta componente (PC4) está em uma direção de dispersão residual das variáveis BID, CTX e BTU, e revela a existência de uma relação direta entre o valor pago pelo anunciante (BID) e a contextualização entre o anúncio e a página (CTX).

5. Conclusão

A ordenação de anúncios para exibição de publicidade contextualizada é um problema de otimização com múltiplos interesses envolvidos. Muitos aspectos de contexto podem ser explorados, desde o conteúdo da página ao padrão de navegação do usuário. Nosso estudo sobre as variáveis BID, CTR, CTX e BTU mostrou que elas possuem impacto direto no desempenho do sistema de anúncios e validamos que a reordenação de anúncios por meio da combinação delas traz ganhos para o usuário, o anunciante e o publicador. Descobrimos também que há pouca correlação entre as variáveis e que usá-las em conjunto amplia o contexto capturado e as chances de recomendar anúncios melhores para o usuário. Pretendemos evoluir a plataforma de experimentação para permitir que grupos de usuários sejam expostos sempre à mesma estratégia, isso isolará a variável de usuário e viabilizará um estudo nos moldes estatísticos A/B, bem como nos permitirá analisar o efeito do tempo no desempenho das estratégias. Além disso, pretendemos estudar o efeito de sazonalidades, como feriados e datas comemorativas, em que o comércio é fortemente aquecido e a disposição do usuário para conteúdo publicitário é maior.

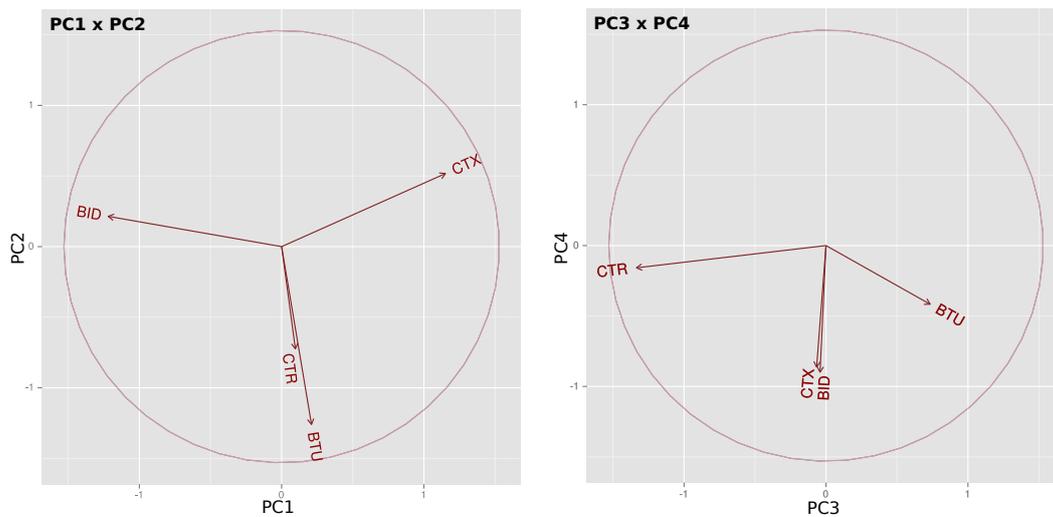


Figura 3. Loading plots das componentes principais. A preservação da variância original é de: 30.5% em PC1, 25.8% em PC2, 24.8% em PC3 e 18.6% em PC4.

Agradecimento

Este trabalho foi parcialmente financiado por UOL, Universo Online S.A. e também contou com o apoio institucional do CNPq, processo nro. 304150/2012-6.

Referências

- Agarwal, D., Gabrilovich, E., Hall, R., Josifovski, V., and Khanna, R. (2009). Translating relevance scores to probabilities for contextual advertising. In Cheung, D. W.-L., Song, I.-Y., Chu, W. W., Hu, X., and Lin, J. J., editors, *CIKM*, pages 1899–1902. ACM.
- Agarwal, D. and Gurevich, M. (2012). Fast top-k retrieval for model based recommendation. In *Proceedings of the Fifth ACM International Conference on Web Search and Data Mining, WSDM '12*, pages 483–492, New York, NY, USA. ACM.
- Azimi, J., Zhang, R., Zhou, Y., Navalpakkam, V., Mao, J., and Fern, X. (2012). Visual appearance of display ads and its effect on click through rate. In *Proceedings of the 21st ACM International Conference on Information and Knowledge Management, CIKM '12*, pages 495–504, New York, NY, USA. ACM.
- Bagherjeiran, A., Hatch, A. O., and Ratnaparkhi, A. (2010). Ranking for the conversion funnel. In *Proceedings of the 33rd international ACM SIGIR conference on Research and development in information retrieval, SIGIR '10*, pages 146–153, New York, NY, USA. ACM.
- Bendersky, M., Gabrilovich, E., Josifovski, V., and Metzler, D. (2010). The anatomy of an ad: structured indexing and retrieval for sponsored search. In *Proceedings of the 19th international conference on World wide web, WWW '10*, pages 101–110, New York, NY, USA. ACM.
- Broder, A., Ciaramita, M., Fontoura, M., Gabrilovich, E., Josifovski, V., Metzler, D., Murdock, V., and Plachouras, V. (2008). To swing or not to swing: Learning when (not) to advertise. In *Proceedings of the 17th ACM Conference on Information and Knowledge Management, CIKM '08*, pages 1003–1012, New York, NY, USA. ACM.

- Broder, A., Fontoura, M., Josifovski, V., and Riedel, L. (2007). A semantic approach to contextual advertising. In *Proceedings of the 30th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval*, SIGIR '07, pages 559–566, New York, NY, USA. ACM.
- Broinizi, M., Mutti, D., and Ferreira, J. E. (2014). Application configuration repository for adaptive service-based systems: Overcoming challenges in an evolutionary online advertising environment. In *Proceedings of the 21th International Conference on Web Services*, ICWS '14.
- Edelman, B., Ostrovsky, M., Schwarz, M., Fudenberg, T. D., Kaplow, L., Lee, R., Milgrom, P., Niederle, M., and Pakes, A. (2005). Internet advertising and the generalized second price auction: Selling billions of dollars worth of keywords. *American Economic Review*, 97.
- Garcia-Molina, H., Koutrika, G., and Parameswaran, A. (2011). Information seeking: Convergence of search, recommendations, and advertising. *Commun. ACM*, 54(11):121–130.
- Google (2002). Google introduces new pricing for popular self-service online advertising program. <http://googlepress.blogspot.com.br/2002/02/google-introduces-new-pricing-for.html> , Fevereiro.
- IAB (2013). Internet advertising revenue report 2012 full year results. Technical report. http://www.iab.net/media/file/IAB_Internet_Advertising_Revenue_Report_FY_2012_rev.pdf , Abril.
- Lacerda, A., Cristo, M., Gonçalves, M. A., Fan, W., Ziviani, N., and Ribeiro-Neto, B. (2006). Learning to advertise. In *Proceedings of the 29th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval*, SIGIR '06, pages 549–556, New York, NY, USA. ACM.
- Oberoi, A. (2013). The history of online advertising. <http://www.adpushup.com/blog/the-history-of-online-advertising> , Julho.
- Ribeiro-Neto, B., Cristo, M., Golgher, P. B., and Silva de Moura, E. (2005). Impedance coupling in content-targeted advertising. In *Proceedings of the 28th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval*, SIGIR '05, pages 496–503, New York, NY, USA. ACM.
- Shlens, J. (2014). A tutorial on principal component analysis. *CoRR*, abs/1404.1100.
- Tang, J., Liu, N., Yan, J., Shen, Y., Guo, S., Gao, B., Yan, S., and Zhang, M. (2011). Learning to rank audience for behavioral targeting in display ads. In *Proceedings of the 20th ACM International Conference on Information and Knowledge Management*, CIKM '11, pages 605–610, New York, NY, USA. ACM.
- Wang, H., Liang, Y., Fu, L., Xue, G.-R., and Yu, Y. (2009). Efficient query expansion for advertisement search. In *Proceedings of the 32nd International ACM SIGIR Conference on Research and Development in Information Retrieval*, SIGIR '09, pages 51–58, New York, NY, USA. ACM.