

A New Risk-Sensitive Deep Learning Optimization Function for Ranking Tasks

Pedro H. S. Rodrigues¹, Daniel X. de Sousa², Marcos A. Gonçalves¹

¹ Departamento de Ciência da Computação – Universidade Federal de Minas Gerais (UFMG)
Belo Horizonte – MG - Brazil

²Instituto Federal de Goiás (IFG)
Anápolis – GO - Brazil

{silvapedro,mgoncalv}@dcc.ufmg.br, daniel.sousa@ifg.edu.br

Abstract. *This master thesis proposes the RiskLoss function to deal with the (hard) problem of incorporating risk-sensitiveness measures into Deep Neural Networks (DNNs), by including two adaptations for neural network ranking in ad-hoc retrieval and Recommender Systems (RSs): a differentiable loss function and the use of networks' sub-portions, obtained via dropout, as baseline systems for optimizing risk sensitiveness. We empirically demonstrate significant achievements of the RiskLoss functions when used with recent DNN methods. For ad-hoc retrieval, RiskLoss presents the most consistent risk sensitiveness behavior, reducing by 28% the losses over the best evaluated baselines and significantly improving over the risk-sensitive state-of-the-art non-DNN method (by up to 13%) while keeping (or even increasing) overall effectiveness. In RSs, RiskLoss reduced the number of bad recommendations by over 11% for “hard-to-recommend” users. This dissertation produced a full paper in the most important worldwide Information Retrieval (IR) conference (ACM SIGIR Conference on Research and Development in IR 2022, Qualis A1) and a journal paper submitted to Elsevier’s Information Processing & Management (Qualis A1), currently in the second round of revisions.*

Resumo. *Esta dissertação de mestrado propõe a função RiskLoss para lidar com o problema de incorporar medidas de sensibilidade ao risco em Redes Neurais Profundas (RNPs), incluindo duas adaptações para a modelos de ranqueamento em redes neurais, considerando busca ad-hoc e Sistemas de Recomendação (RSs): uma função de perda diferenciável e o uso de subporções de redes, obtidas via dropout, como sistemas de referência para otimizar a sensibilidade ao risco. Demonstramos empiricamente conquistas significativas das funções RiskLoss quando usadas com métodos recentes de RNPs. No caso da busca ad-hoc, RiskLoss apresenta um comportamento bastante consistente de sensibilidade ao risco, reduzindo em 28% as perdas em relação às melhores referências avaliadas e melhorando significativamente em relação ao estado da arte não-RNP sensível ao risco (em até 13%), mantendo (ou até aumentando) a eficácia geral. Nos RSs, RiskLoss pôde reduzir o número de recomendações ruins em mais de 11% para usuários “difíceis de recomendar”. Esta dissertação produziu um artigo completo na mais importante conferência de Recuperação de Informação do mundo (ACM SIGIR Conference on Research*

and Development in IR 2022, Qualis A1) e um artigo de revista submetido ao Information Processing & Management da Elsevier (Qualis A1), atualmente na segunda fase de revisão .

1. Dados da Dissertação Defendida

- Data da Defesa: 31/03/2023
- Programa de Pós-Graduação: Programa de Pós-Graduação em Ciência da Computação, Departamento de Ciência da Computação, Universidade Federal de Minas Gerais
- Categoria: mestrado
- Membros da Banca: Rodrygo Luis Teodoro Santos (Universidade Federal de Minas Gerais), André Luiz da Costa Carvalho (Universidade Federal do Amazonas)

2. Contexto e problema

Sistemas de Recuperação de Informação (RI) modernos empregam modelos de aprendizado de máquina capazes de selecionar conteúdos relevantes usando como entrada expressões que descrevem as preferências e interesses dos usuários [Li 2011]. Para obter modelos de aprendizado de máquina efetivos, técnicas de aprendizado de ranqueamento (AR) têm sido exploradas pelos sistemas de RI. Métodos AR de ponta são produzidos por Redes Neurais Profundas (RNP), especialmente arquiteturas transformers, que usam mecanismos de self-attention com a capacidade de aprender e explorar fatores latentes não lineares [Pobrotyn et al. 2020]. Para uso dos métodos de RNP para ranqueamento, alguns estudos propuseram funções de perda (loss functions) adaptadas com o objetivo de aproximar as medidas de avaliação de RI. Essa adaptação é necessária, pois as RNP realizam otimização baseada em gradientes, usando funções de perda contínuas, diferentemente das métricas NDCG e MAP que são descontínuas e não suaves [Qin et al. 2010].

Apesar de obter melhorias na efetividade média, métodos de RNP para ranqueamento com funções de perda ainda herdam uma limitação intrínseca dos métodos de ranqueamento “antigos- eles não são capazes, sem intervenção explícita, de reduzir a alta variância de efetividade existente para diferentes consultas. Como resultado, modelos de ranqueamento otimizados podem às vezes produzir respostas “pobres” para alguns usuários/consultas importantes, enquanto ainda produzem um valor médio alto para a métrica global de efetividade otimizada.

Essa alta variância pode ter sérios impactos negativos na experiência do usuário com um sistema de RI, pois as falhas geralmente são muito mais notadas do que os vários resultados bem-sucedidos desses sistemas [Knijnenburg et al. 2012]. Embora exista uma área específica atenta a essas questões, denominada modelos Sensíveis ao Risco, até o nosso trabalho não existia nenhuma função de perda que pudesse otimizar o objetivo de sensibilidade ao risco em modelos RNP. Ou seja, a otimização baseada em gradientes e as medidas sensíveis ao risco eram até então incompatíveis, tornando o treinamento de RNPs sensíveis ao risco um problema não trivial e ignorado na literatura.

O recente interesse em Retrieval Augment Generation (RAG) [Lewis et al. 2020] como forma de personalizar Grandes Modelos de Linguagem (Large Language Models) [Yao et al. 2024] e resolver problemas associados a alucinações e atualizações desses

grandes modelos de linguagem, tornam ainda mais importante a busca por modelos robustos tolerante a falhas de recuperação de informação, tanto do ponto de vista acadêmico quanto industrial.

3. Objetivo

O principal objetivo da dissertação é fornecer evidências para validar a hipótese de que é possível construir uma função de custo derivável para otimização sensível ao risco em modelos de RNP. Desta forma, realizamos estudos e análises pertinentes à apresentação da RiskLoss, como uma função de custo capaz de permitir a otimização sensível ao risco em tarefas de ranqueamento e sistemas de recomendação.

4. Contribuição

A contribuição central da dissertação é a apresentação de uma função de perda inovadora, diferenciável e suave, capaz de otimizar o objetivo de sensibilidade ao risco na construção de modelos RNP em tarefa de recuperação de informação. Além de melhorar a redução de previsões errôneas, os modelos treinados com a função proposta (RiskLoss) também são capazes de melhorar a acurácia geral dos modelos, como um efeito colateral. Em resumo, a dissertação de mestrado fornece cinco contribuições inéditas:

- A primeira proposta na literatura a otimizar diretamente a sensibilidade ao risco de tarefas de ranqueamento em Redes Neurais Profundas.
- Uma nova função de perda original (RiskLoss) que incorpora características de RNP (por exemplo, regularização Dropout), para obter treinamentos autossuficientes e dinamicamente sensíveis ao risco.
- Uma extensa avaliação experimental comparando métodos de ranqueamento em RNP com e sem objetivo de sensibilidade ao risco e as melhores soluções sensíveis ao risco atualmente disponíveis em dois domínios – Algoritmos de Ranqueamento (AR) e Sistemas de Recomendação (SR) –, estabelecendo um novo patamar para o estado da arte na pesquisa de sensibilidade ao risco.
- A resposta a importantes questões de pesquisa sobre nossa solução, quanto a: i) sua generalização para diferentes domínios; ii) custos associados (em termos de tempo de execução); e iii) resiliência ao overfitting.
- Uma nova discussão sobre a relação entre “o viés da otimização média” versus a análise de Fairness com resultados experimentais mostrando que reduzir o viés pode promover resultados mais justos.

5. Avanço no estado da arte

A solução proposta neste trabalho para modelos sensíveis ao risco está atualmente no estado-da-arte das tarefas de Aprendizado de Ranqueamento e Sistemas de Recomendação, superando estratégias populares e eficazes tais como, GeoRisk [Dinçer et al. 2016] e URisk[Wang et al. 2012]. Até o presente momento os resultados reportados na dissertação não foram superados por nenhuma outra estratégia da literatura. Para os modelos de Sistemas de Recomendação, fomos pioneiros na otimização com objetivo em sensibilidade ao risco, com resultados extremamente promissores.

6. Avaliação

Avaliamos em profundidade nossa nova função de perda considerando diversos fatores: i) a generalidade da nossa solução aplicando e avaliando a RiskLoss em tarefas de sistemas de recomendação e métodos de recuperação ad-hoc, ambos com modelos de RNP ; ii) o fato da RiskLoss possuir um custo computacional (em tempo de execução) aceitável na fase de treinamento; iii) a compreensão das propriedades da RiskLoss para o treinamento de DNNs, incluindo uma avaliação experimental de sua resiliência ao overfitting; e iv) a relação da variância tratada pela RiskLoss e das medidas de Fairness, que também estão associadas à alta variabilidade nas recomendações de usuários [Fu et al. 2020]. Todos esses objetivos ajudaram a esclarecer o funcionamento interno da nossa solução e a explicar por que ela funciona tão bem. Os extensos experimentos realizados forneceram evidências suficientes para a validação da hipótese levantada.

7. Produção Científica, Técnica e Premiações

- Publicação:
Silva Rodrigues, P. H., Xavier Sousa, D., Couto Rosa, T., and Gonçalves, M. A. (2022). Risk-sensitive deep neural learning to rank. International ACM Special Interest Group on Information Retrieval Conference, ACM-SIGIR, Madrid, Spain. Qualis A1. h5-index 90
- Artigo em fase de submissão:
Silva Rodrigues, P. H., Xavier Sousa, D., Couto Rosa, T., and Gonçalves, M. A. (2024). Risk-sensitive optimization of neural deep learning ranking models with applications in ad-hoc retrieval and recommender systems. Information Processing & Management.

Referências

- Dinçer, B. T., Macdonald, C., and Ounis, I. (2016). Risk-sensitive evaluation and learning to rank using multiple baselines. SIGIR '16, New York, USA.
- Fu, Z., Xian, Y., Gao, R., Zhao, J., Huang, Q., Ge, Y., Xu, S., Geng, S., Shah, C., Zhang, Y., and de Melo, G. (2020). *Fairness-Aware Explainable Recommendation over Knowledge Graphs*.
- Knijnenburg, B. P., Willemsen, M. C., Gantner, Z., Soncu, H., and Newell, C. (2012). Explaining the user experience of recommender systems. *J. of User Mod. and User-Adapt. Inter.*
- Lewis, P., Perez, E., Piktus, A., Petroni, F., Karpukhin, V., Goyal, N., Küttler, H., Lewis, M., Yih, W.-t., Rocktäschel, T., Riedel, S., and Kiela, D. (2020). Retrieval-augmented generation for knowledge-intensive nlp tasks. In *Proceedings of the 34th International Conference on Neural Information Processing Systems*, NIPS '20, Red Hook, NY, USA. Curran Associates Inc.
- Li, H. (2011). *Learning to rank for information retrieval and natural language processing*. Morgan & Claypool Publishers.
- Pobrotyn, P., Bartczak, T., Synowiec, M., Bialobrzeski, R., and Bojar, J. (2020). Context-aware learning to rank with self-attention. In *Journal Computing Research Repository*.

- Qin, T., Liu, T.-Y., and Li, H. (2010). A general approximation framework for direct optimization of information retrieval measures. *In Journal of Information Retrieval*, 13(0).
- Wang, L., Bennett, P. N., and Collins-Thompson, K. (2012). Robust ranking models via risk-sensitive optimization. *In Proceedings of the 35th International Conference on Research and Development in Information Retrieval, SIGIR '12*, New York, USA.
- Yao, Y., Duan, J., Xu, K., Cai, Y., Sun, Z., and Zhang, Y. (2024). A survey on large language model (llm) security and privacy: The good, the bad, and the ugly. *High-Confidence Computing*, 4(2):100211.