

# 方言

微信 : Suffoquer-fang · (+86) 186-0559-9008 · fangy21@mails.tsinghua.edu.cn

## 教育经历

清华大学, 计算机科学与技术, 工学学士, GPA 3.88, 11/205 (Top 5%) 2017.09 - 2021.07

清华大学, 计算机科学与技术, 工学硕士, GPA 3.89, 12/64 2021.09 - 2024.07

## 会议论文

- **Yan Fang**, Jintao Zhan, Jiaxin Mao and Yiqun Liu. *Joint Optimization of Multi-vector Representation with Product Quantization*. Natural Language Processing and Chinese Computing (NLPC 2022 Oral Presentation)
  - 用多个向量来表示查询和文档能带来更好的检索性能, 但是其巨大的存储开销阻碍了实际应用。
  - 我们使用乘积量化方法进行索引压缩, 并且设计了联合优化方法同时优化压缩索引和查询编码器。
  - 实验结果表明, 我们的方法能有超过 10 倍的存储压缩, 同时避免检索性能显著下降。
- Jia Chen, Yiqun Liu, **Yan Fang**, Jiaxin Mao, Hui Fang, Shenghao Yang, Xiaohui Xie, Min Zhang, Shaoping Ma. *Axiomatically Regularized Pre-training for Ad hoc Search*. Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval (SIGIR 2022)
  - IR 公理通过数学形式确定一系列排序准则来指导排序模型设计, 可以提高模型的有效性和可解释性。
  - 我们提出新的预训练方法, 将一系列公理进行组织从而生成大量预训练样本。
  - 实验结果表明, 我们的方法能够显著提升模型在低资源设定和大量资源情况下的排序性能。
  - 主要负责预训练样本设计, 模型预训练和在多个数据集上微调。
- **Yan Fang**, Qingyao Ai, Jintao Zhan, Yiqun Liu, Zheng Liu and Zhao Cao. *Combining Multiple Supervision for Robust Zero-shot Dense Retrieval* (under review)
  - 稠密向量检索需要大量监督信号进行训练, 而在迁移场景下获取标注信号成本很高。
  - 预训练-微调范式可能出现潜在的过拟合问题, 导致迁移性能不稳定。
  - 针对这一问题, 我们将弱监督信号与标注信号融入共同训练框架来缓解过拟合问题, 并且设计了 Soft Prompt 解耦不同领域和不同任务。
  - 实验结果表明, 我们的方法能取得迁移性能上的提升, 同时针对训练过程更加鲁棒。
- Qi Zhu, Zheng Zhang, **Yan Fang**, Xiang Li, Ryuichi Takanobu, Jinchao Li, Baolin Peng, Jianfeng Gao, Xiaoyan Zhu, Minlie Huang. *ConvLab-2: An Open-Source Toolkit for Building, Evaluating, and Diagnosing Dialogue Systems*. In Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. (ACL 2020)
  - 参与设计对话系统的评测指标, 分析其出错模式, 例如槽位出错, 陷入死循环等。
  - 对话系统的使用者和算法开发者需要灵活获取对话系统失效出错的相关场景和信息。
  - 针对这些评测指标, 为任务导向型对话系统开发了对应的评测模块, 自动整合相关信息, 并进行可视化。

## 实习经历

字节跳动 Data | 推荐算法实习生 2021.01 - 2021.04

- 利用抖音-头条共同用户建立留存预估模型, 对抖音用户进行预测, 依据人群聚类构建拉新流程。
- 实现数据库 UDF, 对新用户 (7 日) 和老用户展现的类别分布进行分析, 协助新用户冷启动过程。

Disney-Hotstar | 暑期实习生 2020.06 - 2020.08

- 基于 Scrapy 实现爬虫, 爬取 Hotstar 的印地语, 中文和英文的电视剧信息, 进行数据清洗和预处理。
- 构建搜索系统, 支持同一语言内匹配。使用 Vue.js 实现前端, Django+ElasticSearch+MySQL 实现后端。

## 项目经历

DeeCamp 人工智能训练营 | 暑期学员 2020.06 - 2020.08

- 使用人工智能技术在量化交易和投资中进行决策辅助, 主要负责数据建模。
- 利用傅里叶级数和差值等方法处理时序数据, 使用 LSTM 结合外部特征训练模型预测未来时刻的数据。
- 使用对未来预测的结果构建强化学习模型, 进行合理的投资决策辅助。

基于路径追踪的真实感渲染器 | PathTracer, 独立完成 2021.04 - 2021.07

- 使用 C++ 实现路径追踪算法, 构建三维场景下的真实感渲染器。实现纹理贴图, 景深等高级特性。
- 利用 BVH 树实现  $O(\log N)$  级别的射线检测算法, 支持数百万面片数量的复杂模型渲染。
- 利用 OpenMP 利用多线程进行并行加速, 利用 CUDA 使用 GPU 并行加速, 将渲染时间缩短至原先的 1/20。

RISC-V 架构操作系统 | xv6, 独立完成 2022.11 - 2023.02

- 使用 C++ 实现了系统调用, 中断, 页表, 进程调度, Copy-On-Write, mmap, 硬盘 IO 缓存等操作系统功能。
- 实现了一个简易的文件系统, 成功在 QEMU 上运行了用户态终端, 并且可以正确执行 shell 命令。

## 基于 C++ 的单线程关系型数据库 | StupidDB, 独立完成

2021.01 - 2021.04

- 使用 C++ 实现基于 B+ 树的高效非簇索引，支持联合索引。并且使用内存池的思想提高节点分配效率。
- 利用空闲链表的思想构建数据管理模块，实现数据表层面和数据库层面的管理系统。
- 利用 Flex 和 Bison 进行 SQL 语言解析，可以正确执行 SQL 命令。

## 专业技能

---

编程语言: Python, C/C++, Golang

系统、工具、框架等: PyTorch, Linux, Git, Docker, Django, Vue.js

## 奖励和荣誉

---

中国计算机学会计算机软件能力认证 (CCF CSP 认证) : 前 2%	2022.10
董氏东方奖学金 (学业成绩前 5%)	2019.10
清华之友——竞技世界奖学金 (学业成绩前 5%)	2018.10
清华大学新生奖学金	2017.09
NeurIPS 2018-Pommerman 强化学习 AI 比赛 (第 9 名)	2018.11