

低资源下的 智能对话和推荐技术探索及实践

报告人：平安寿险 尹曦



目录

CONTENTS

- 01 背景介绍
- 02 知识图谱辅助的口语表述实体链接
- 03 基于蒙特卡洛树搜索的多轮对话策略学习
- 04 知识增强信息流推荐

01

背景介绍

中国平安人寿保险

- 主营 **人身保险** 业务，产品多为保障期限长、保障范围全面的复杂保险
- 拥有 **2亿+** 用户， **120万+** 代理人
- 重视科技赋能，积极转型为 **科技型** 寿险公司

寿险AI技术领域



深度学习、智能推荐



计算机视觉



NLP、知识图谱、
对话式机器人

平安人寿保险智能化布局：对话式机器人

中国平安人寿保险

应用场景

招聘

培训

销售

服务

管理

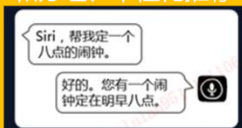
风控

资管

.....

文本语音机器人

寒暄闲聊、业务咨询
和办理、个性化推荐



电话外呼机器人

结合智能语音、电话
平台和对话系统技术



视频机器人

多模态合成，拟真视
频形象交互



技术创新

国际竞赛冠军

🏆 7项

DSTC8, SemEval2020, SQuAd 2.0 ..

顶级会议论文

📄 20篇 +

IJCAI, ICME, CIKM ..

发明专利申请

👤 300个 +

算法\开发\产品\等全技术领域 ..

应用产出

20+

对话机器人

10+

技术平台

100+

上线场景

一站式多模态对话式机器人应用平台

- 创新销售模式，为**代理人**提供职业体系培养及展业工具：



- 优化服务流程，为**客户**提供简单、便捷、友善、安心的保险服务体验：



行业首个支持代理人**远程展业**并提供
销售实战辅导的智能应用
基于保险讲解场景构建线上**“AI会客厅”**
拓宽代理人线上服务边界

- **线上一键会客讲解** | 方案同步共享、小工具辅助讲解
- **智能助手全程陪访** | 识别问题，辅导解答，预测提问
- **AI辅助素材创作** | 辅助生成保险知识、案例等

对话智能问答

智能预测

实时对话辅助

内容生成



行业首款**个性化场景化实战模拟的**
人机对练式培训机器人
提供**全天候**培训辅助、**个性化**培训规划

- 全面覆盖 120万+ 代理人
- 7*24 小时专属“AI训练助理”
- 支持“学练考评”全流程陪练

人机对话

语义识别

拟人展示

AI生成

个性化方案

拟真动画演示

场景化演练

智能学习分析



02

**知识图谱辅助的
口语表述实体链接**

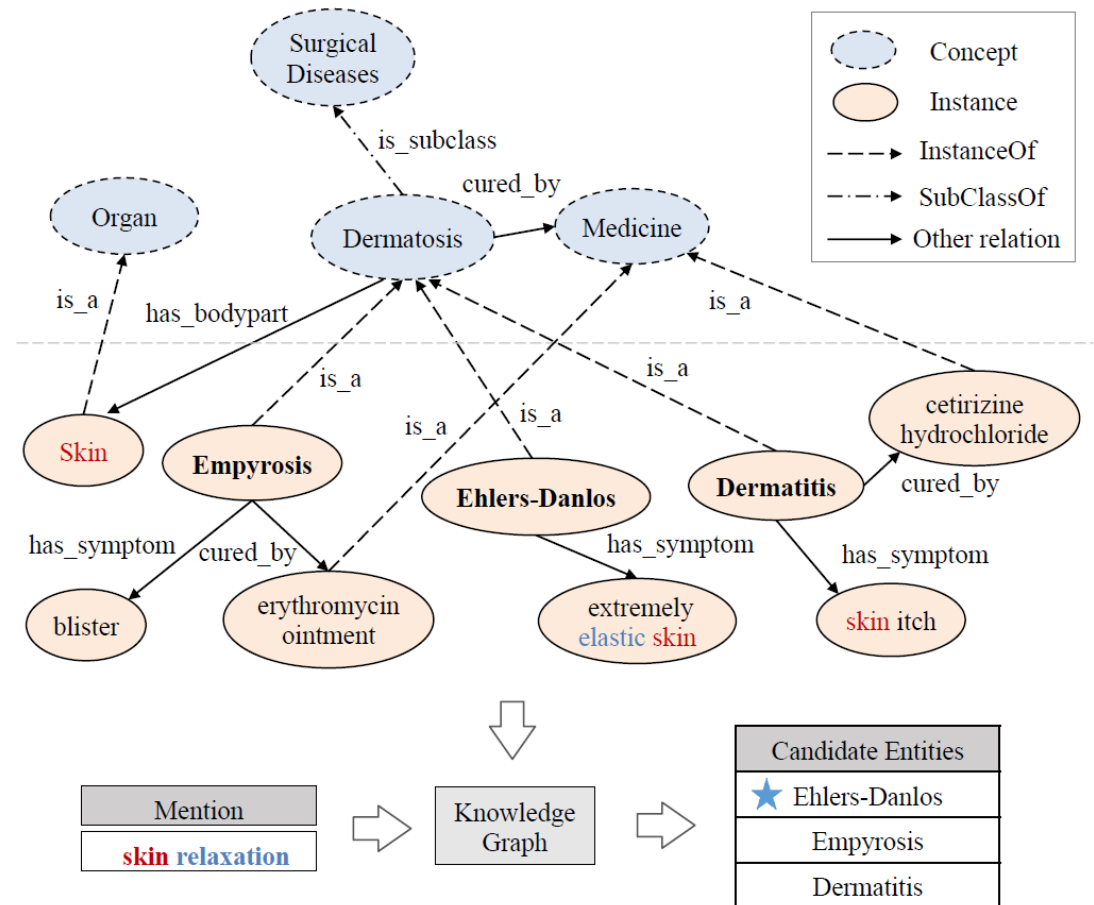
QA example:

User query: Am I qualified for the new insurance policy as I suffer from **skin relaxation** recently?

System reply: Unfortunately, based on the policy, you may fall into the terms of **Ehlers-Danlos**, which may exclude your protection. Please contact our agents for more details.

Motivation

- **Medical entity synonyms discovery** aims to accurately map the mention to synonymous medical entity in knowledge graphs
- Challenges
 - different semantic spaces: oral vs. professional
 - **some entities rarely appear in existing mention-entity pairs**
- Existing methods via *matching of syntactic strings or lexical embeddings* **cannot** capture **external knowledge** well



Problem Definition: Medical entity synonyms discovery

• Inputs

- mention-to-entity pairs $\mathcal{D} = \{(q_i, t_i)\}_{i=1}^N$
 - e.g., (bow legs, knee varus), (high blood pressure, hypertension), ...
 - N is the number of annotated pairs
- a cross-domain knowledge graph $\text{KG} = \{\text{C}, \text{I}, \text{R}, \text{S}\}$
 - C: Concept; I: Instance
 - R: relation set; S: triple set

• Output

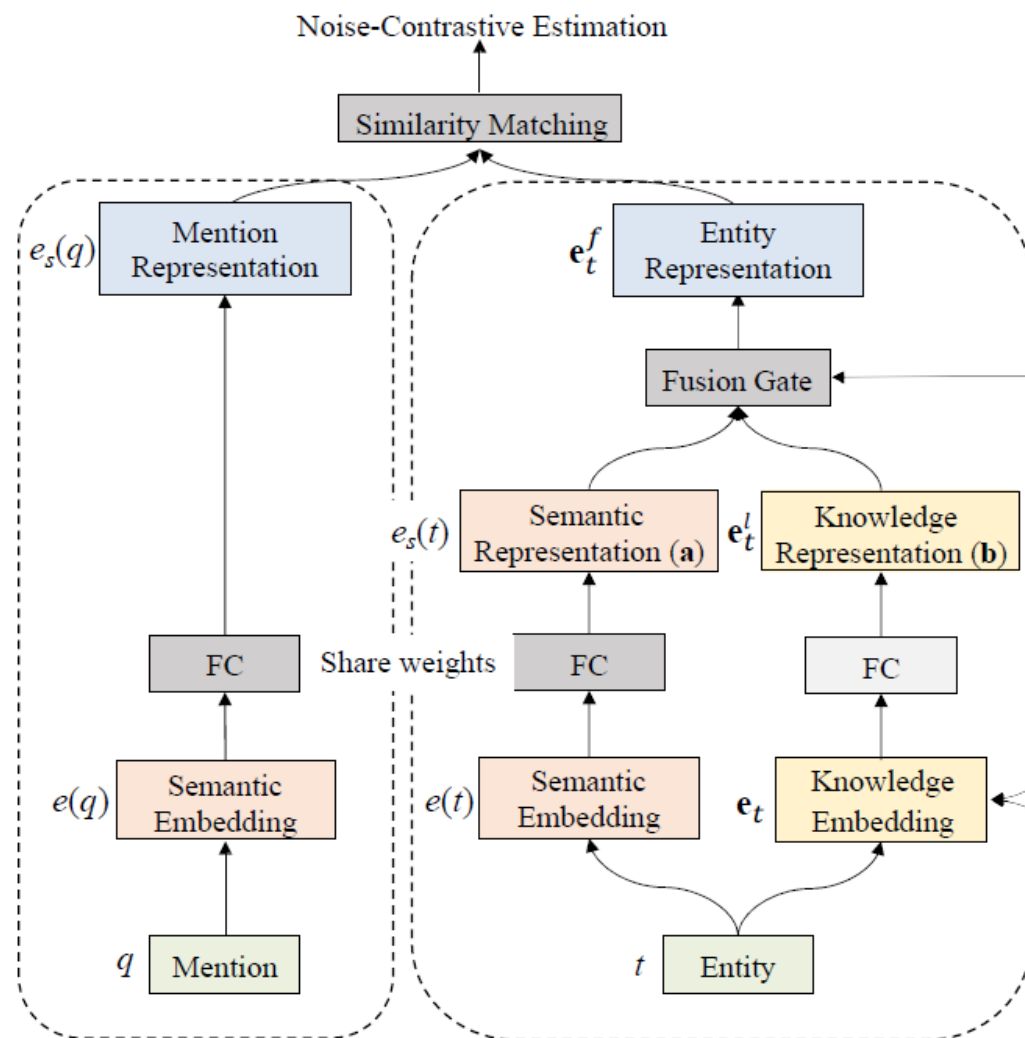
- determine a list of synonymous entities for the disease mention
 - e.g., skin relaxation -> Ehlers-Danlos

Our Proposal

1. Input representations
 - Char embeddings (semantic information)

$$e(q) = \frac{1}{|q|} \sum_{k=1}^{|q|} e(q_k), \quad e(t) = \frac{1}{|t|} \sum_{k=1}^{|t|} e(t_k).$$

- Entity knowledge embedding
 - Joint TransC-TransE learning
2. Semantic space alignment
 - Shared weights in FC
3. Fusion of Entity's Semantic and Knowledge Representations
4. Similarity Matching: *noise-contrastive estimation*



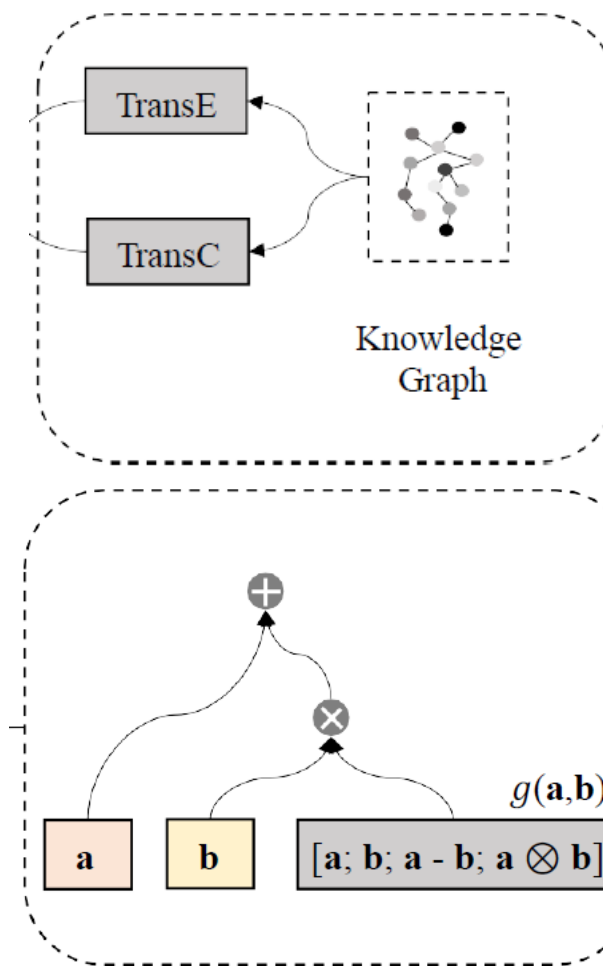
Properties: Adding External Knowledge

- Hybrid knowledge embedding
 - represent learning via joint TransC-TransE learning

$$\mathcal{L}_k = \sum_{(i,r_e,c) \in \mathcal{S}_e} f_e(i,c) + \sum_{(c_i,r_c,c_j) \in \mathcal{S}_c} f_c(c_i,c_j) + \sum_{(i,r_{ij},j) \in \mathcal{S}_l} f_l(i,r_{ij},j) + \sum_{(i,r_{ic},c) \in \mathcal{S}_{IC}} f_{IC}(i,r_{ic},c) + \sum_{(c_i,r_{c_i c_j},c_j) \in \mathcal{S}_{CC}} f_{CC}(c_i,r_{c_i c_j},c_j). \quad (7)$$

- **Fusion gate** to adaptively incorporate knowledge with learned semantic features

$$e_t^f = e_s(t) + e_t^l \otimes g(e_s(t), e_t^l).$$



Knowledge Graph (KG) and Dataset

- A heterogeneous KG with entities collected from three categories: **insurance products, occupation, and medicine**

Knowledge Graph	All Insurance	Occupation	Medicine	Cross Domain	
# Entities	75,153	1,409	2,587	71,157	0
# E_type	17	2	2	13	0
# Relations	1,120,792	2,827	2,580	1,098,280	17,105
# R_type	20	2	2	13	4
# Mention-entity pairs in Train/Dev/Test				45,500/5,896/5,743	
# Regular cases/# Difficult cases				5,303/440	

Results

Methods	hits@3			hits@5			hits@10		
	All	Regular	Difficult	All	Regular	Difficult	All	Regular	Difficult
JACCARD [26]	52.28%	56.61%	0.00%	58.03%	62.83%	0.00%	63.76%	69.04%	0.00%
Word2Vec [4]	47.00%	50.88%	0.00%	52.28%	56.59%	2.30%	58.31%	63.10%	4.60%
CNN [24]	51.76%	55.69%	4.33%	57.75%	61.98%	6.38%	65.13%	69.72%	9.34%
BERT [6]	54.60%	58.87%	2.96%	60.41%	65.02%	4.78%	66.50%	71.39%	7.52%
DNorm [17]	56.23%	59.78%	12.76%	63.79%	67.58%	17.77%	71.89%	75.64%	26.42%
SurfCon [36]	58.29%	62.02%	12.98%	66.27%	70.11%	19.59%	75.20%	79.03%	28.93%
MedSynNet	66.84%	70.81%	18.91%	73.09%	77.13%	24.37%	79.41%	83.35%	31.89%
–Knowledge Embedding	64.91%	69.07%	14.58%	71.56%	75.77%	20.73%	79.12%	83.14%	30.52%
–TransC (TransE only)	65.80%	69.92%	15.95%	71.44%	75.79%	18.91%	78.94%	83.18%	27.80%
→Direct Addition	63.51%	67.19%	19.13%	70.85%	74.47%	27.10%	78.13%	81.77%	34.17%
→Ernie Fusion	61.98%	65.85%	15.26%	68.63%	72.54%	21.41%	76.28%	80.29%	27.79%

- MedSynNet beats all baselines
- Knowledge embedding plays a significant role in improving performance

Summary

- **MedSynNet** to tackle the task of medical entity synonyms discovery in
 - resolving OOV by newly learned character embeddings and map them into the same space
 - learning knowledge information by TransC-TransE model
 - designing a fusion gate to adaptively include knowledge information into the semantic features
- The **first health insurance benchmark** consists of
 - a large-scale Chinese health insurance related knowledge graph in multiple domains
 - a dataset of annotated mention-to-entity pairs of diseases

03

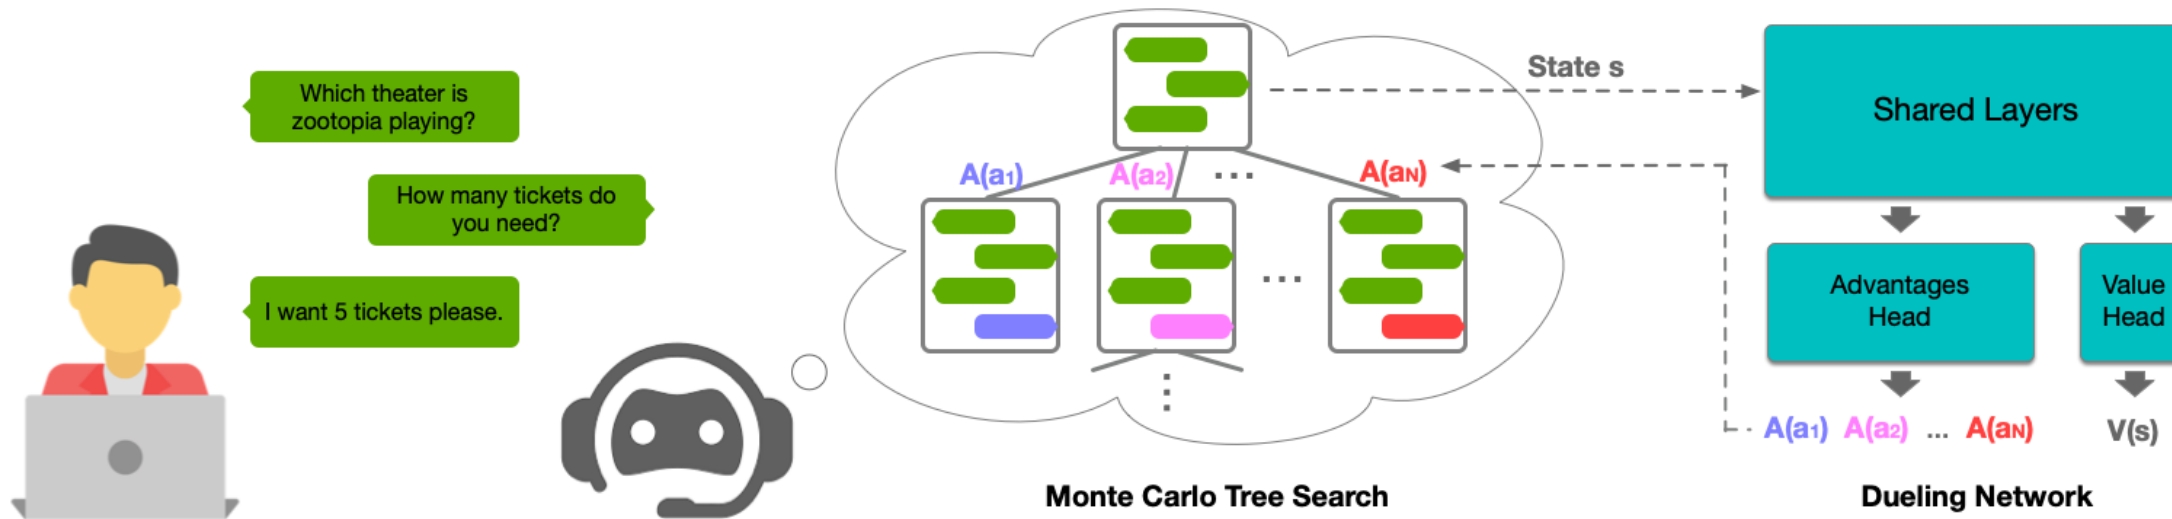
基于蒙特卡洛树搜索 的多轮对话策略学习

Motivation

- 寿险实际业务中存在大量多轮对话机器人的应用场景，如在线保单办理、在线理赔等。
- 采用传统的基于规则和有监督学习来进行多轮对话策略的训练会面临诸多难点：
 - 对话结构复杂，标注成本高且准确率不高，缺乏大量优质标注数据。
 - 忽略多轮对话中存在的序列化结构，对话策略的训练更注重单轮的拟合效果。

Our Proposal

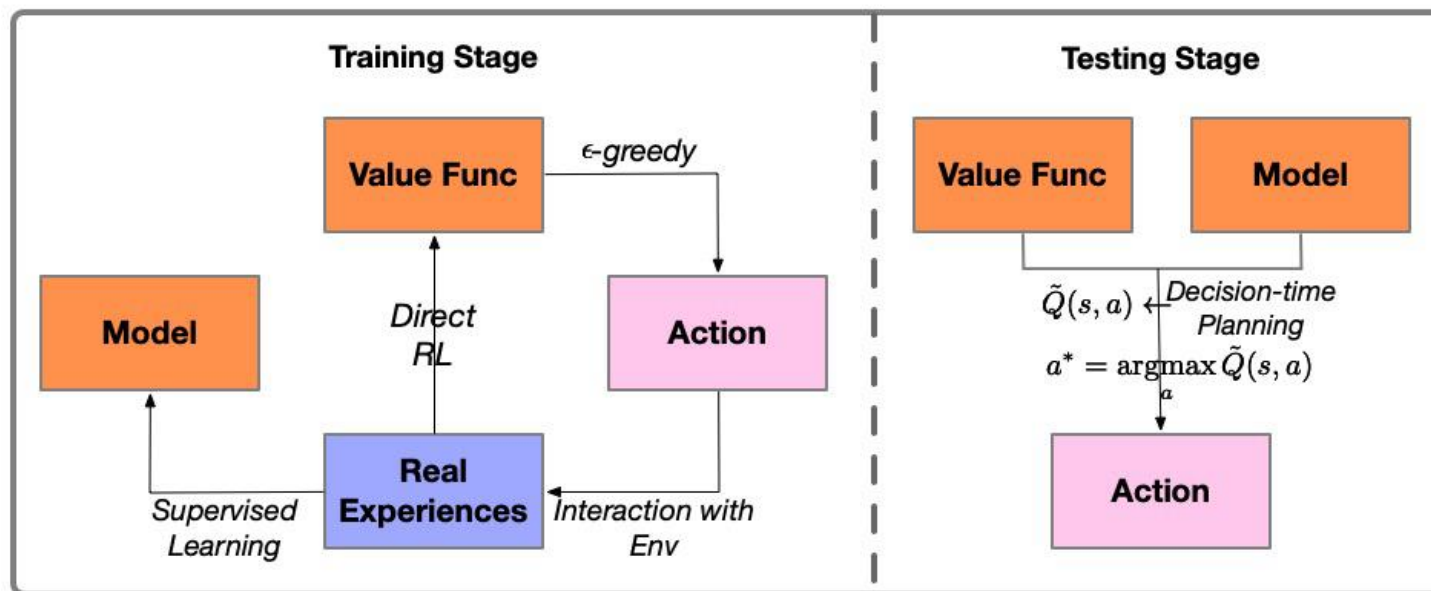
- 首次将蒙特卡洛树搜索(Monte Carlo Tree Search, MCTS)作为强化学习中的决策时规划的算法，结合Dueling Network来对多轮对话策略学习进行优化。



$$UCT_D(s, a) = \frac{Q_c(s, a)}{N(s, a)} + c \cdot A(s, a) \cdot \sqrt{\frac{2 \ln N(s)}{N(s, a)}}$$

- ▶ Advantage function: branch exploration priority
- ▶ Rollout evaluation (Simulation): state value function as depth-wise summary

- 训练阶段：
 - 通过Dueling Network结构的对话策略模块来拟合优势函数和状态价值函数
 - 通过监督学习拟合用户的潜在回答习惯，得到拟合环境
- 测试或实时决策阶段：
 - 通过拟合环境模块来构建未来多轮对话的状态树，并借助优势函数和状态价值函数对树进行高效的搜索，从而对各个候选的对话策略进行打分，学习到最优的对话策略。



Experimental Setup and Results

Task Description

- ▶ Movie-ticket booking, 280 user goals, 11 intents, 16 slots
- ▶ Agenda-based user simulator
- ▶ Evaluation metrics: success rate, cumulative rewards, dialogue turns

Agent	Episodes100			Episodes200			Episodes300		
	Success	Return	Turns	Success	Return	Turns	Success	Return	Turns
DQN ²	.2867	-17.35	25.51	.6733	32.48	18.64	.7667	46.87	12.27
DDQ(5) ¹	.6056	20.35	26.65	.7128	36.76	19.55	.7372	39.97	18.99
DDQ(5) ²	.6200	25.42	19.96	.7733	45.45	16.69	.7467	43.22	14.76
DDQ(5) ³	.6456	28.48	21.83	.6394	29.96	17.28	.6344	28.34	18.92
DDQ(10) ¹	.6624	28.18	24.62	.7664	42.46	21.01	.7840	45.11	19.94
DDQ(10) ²	.6800	34.42	16.36	.6000	24.20	17.60	.3733	-2.11	15.81
DDQ(10) ³	.6254	25.71	22.59	.6759	31.99	19.61	.7209	39.24	17.92
DDQ(20) ²	.3333	-13.88	29.76	.4467	5.39	18.41	.3800	-1.75	16.69
DDQ(20) ³	.7076	45.73	16.15	.8182	51.33	16.15	.7968	48.37	15.65
Switch-DDQ ²	.5200	15.48	15.84	.8533	56.63	13.53	.7800	48.49	12.21
DDU	.4675	14.15	24.01	.7611	33.89	17.41	.8562	43.07	15.69
MCTS-DDU	.7312	46.63	19.77	.9090	57.26	12.79	.9314	55.87	12.13

- 在微软提出的对话系统任务中，对比先前的SOTA方案，此方法取得了任务成功率从86%到93%的巨大性能提升。

Summary

- 整体采用强化学习框架避免了传统监督学习需要大量优质标注数据的局限
- 通过和用户模拟器进行交互训练，降低了训练成本。
- 同时具备和真实用户进行实时线上学习的能力
- 强化学习能够挖掘出多轮对话间存在的序列化依赖和影响，避免了局部过拟合，实现了全局上的策略最优。

04

知识增强信息流推荐

外部知识增强信息流推荐的应用场景

展E宝资讯推荐



金管家资讯推荐



应用于两个主要的资讯信息流业务:

1.金管家的资讯发现场景。

2.E行销的展E宝中的精选资讯的推荐场景。

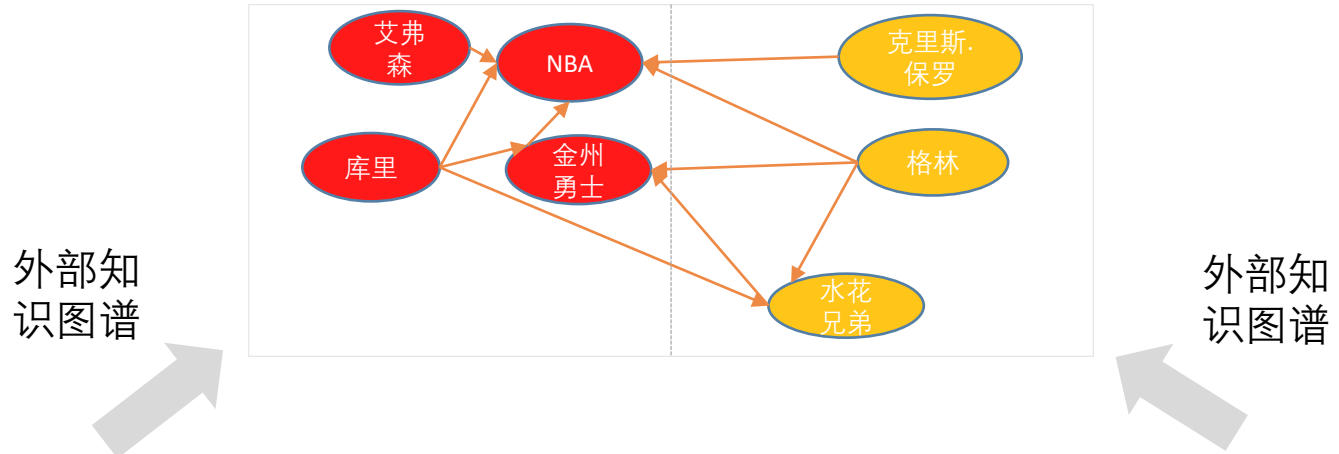
知识增强资讯推荐的特性和示例

◆ 算法目标

通过外部图谱知识结合预训练语言模型，增强低资源下的资讯文本内容表示，提升信息流推荐效果。

◆ 低资源体现

1. 利用离线的外部知识图谱，无需针对性的训练资源。
2. 利用在大规模语料上预训练过的语言模型，降低稀疏用户行为数据下进行推荐的训练样本需求。



库里强于艾弗森?

美媒评NBA历史最佳阵容，库里2阵，AI仅4。近日，美国媒体评选了NBA历史最佳阵容，其中，金州勇士的库里被排在了历史最佳阵容的2阵中，而艾弗森被排在了4阵中，这引起了很多球迷的不满，认为库里的历史地位不应该那么高，艾弗森的历史地位也不应该那么低！先看最佳阵容第5阵，.....

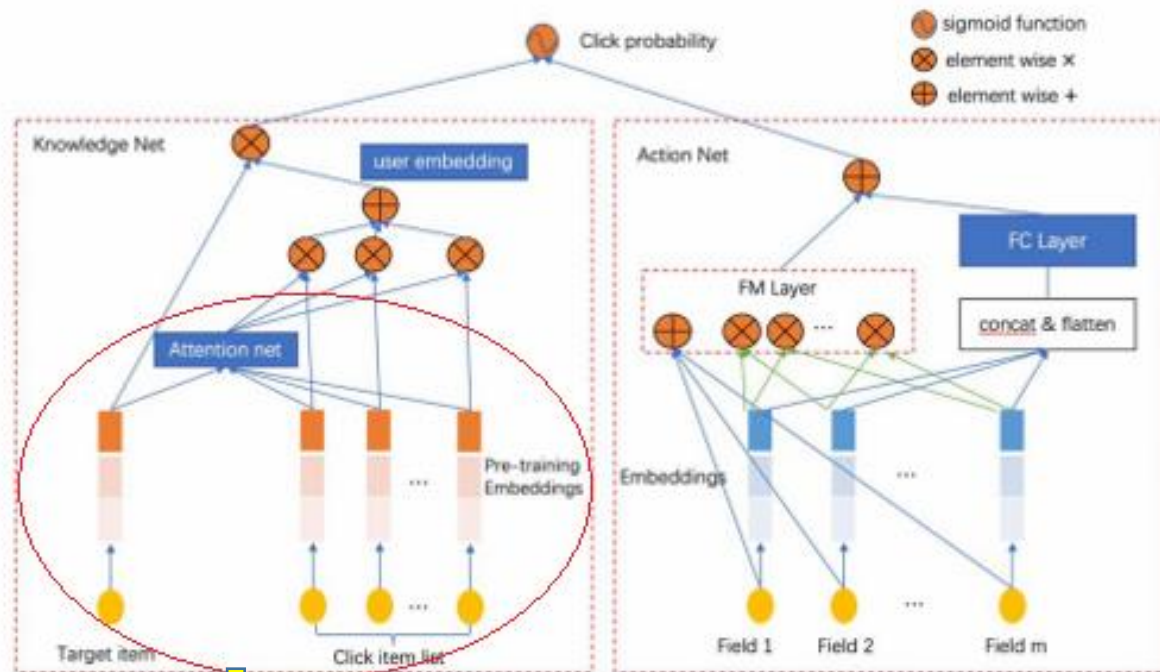
难以直接建立关联

六一儿童节特刊 | 球星童年萌照，和本尊一模一样!

今天是六一儿童节，愿所有的朋友都有一颗童年的心，在这个普天同庆的快乐日子里，小编精选出了几位特殊篮球明星的童年萌照，他们的特殊之处就在于几十年过去了，他们的容貌几乎没有任何变化。一看到小时候的照片你就会发现，这和现在的本尊简直是一模一样啊。1、克里斯·保罗2、追梦格林3、勇士水花兄弟4、神龟-威少5、勒布朗·詹姆斯.....

1. 以上两篇文章的标签分别是（NBA，最佳阵容）和（儿童节，明星）。文章的标签风格有很大的差异，文章表面的相似度也比较有限，但事实上喜欢NBA球星库里的球员会同时关注这两篇文章（ps: 库里是水花兄弟之一）。
2. 通过关联外部知识图谱，两篇文章的几个核心实体词之间建立了较为直接的关联，同时利用在大规模语料上预训练好的语言模型提取资讯的文本向量，使得经过知识和语义增强的两篇文章向量间有了较强的相似性，这样促使具有内在共同点的文章得到关注，提升了相应的推荐质量和用户体验。

信息流推荐DAKUN框架



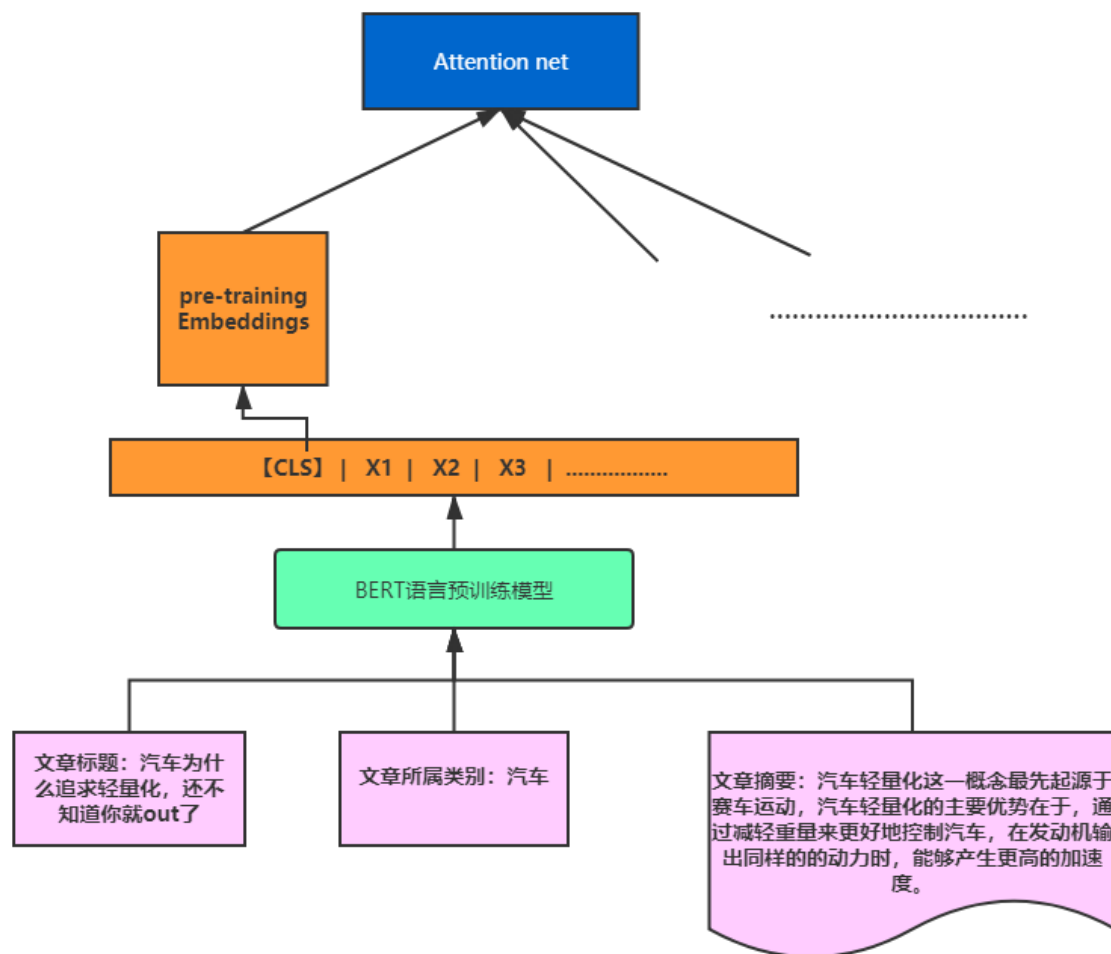
本工作针对红圈部分的向量表示进行优化

Knowledge-Net

DeepFM部分

- ◆ 传统的DeepFM利用用户和文章的基础特征和行为特征进行推荐。
- ◆ DAKUN在此基础上引入Knowledge-Net增加用户的历史文章点击序列表示
- ◆ 用户点击分享行为是稀疏的, 如何低资源训练向量的表达成为了一个关键问题。

资讯文本的深度语义理解模型



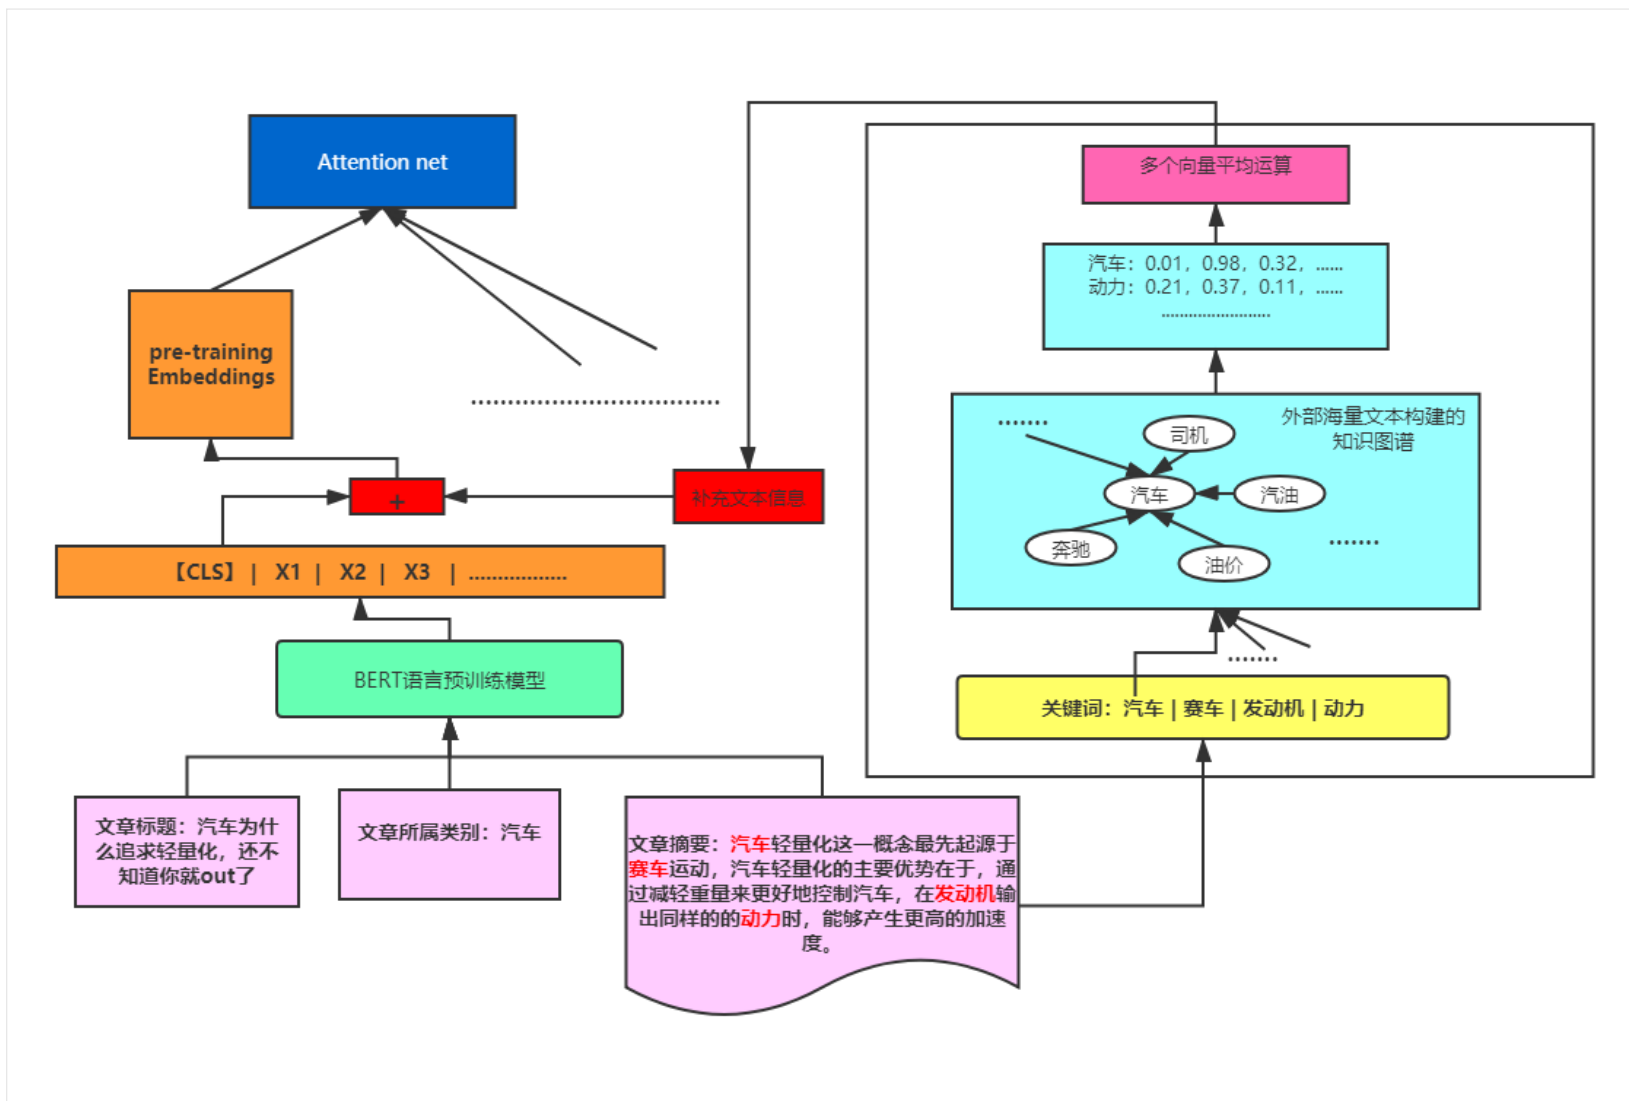
目的:

对资讯内容文本进行深度语义特征提取。

算法步骤:

1. 内容选择: 将文章标题, 类别, 截取内容一部分作为摘要, 进行拼接作为模型的输入。
2. 向量融合: 使用BERT语言与预训练模型对选择的内容进行向量的抽取, 将其输出的【CLS】位向量特征作为资讯文本的深度语义特征。

知识增强资讯推荐的KRED算法模型



目的:

将外部图谱中的知识有效引入推荐系统。

算法步骤:

1. 实体选择: 文章摘要中高频关键实体词进行提取。
2. 关联外部知识图谱: 实体与外界图谱知识进行关联。
3. 实体向量生成: transE的方法对实体在Xlore图谱中进行知识表示, 最终聚合所有关键词实体向量。
4. 知识增强的文章向量生成: 聚合后的实体向量与预训练模型输出的文本深度语义向量拼接生成知识增强的文章向量。

	第一次实验loss	第二次实验loss	Loss均值	第一次实验AUC	第二次实验AUC	AUC均值
DeepFM	0.344	0.341	0.342	0.719	0.718	0.718
DAKUN(DeepFM+文本信息)	0.332	0.332	0.332	0.741	0.742	0.741
DAKUN(知识优化版)	0.328	0.328	0.328	0.750	0.748	0.749

实验对比结果表

注：5.11-5.17 数据进行训练，使用5.18日数据进行预测，
曝光未分享为负样本，曝光分享为正样本
学习速率为0.001，epoch为5

从左表中可以总结得出：

1. 融入文本深度语义特征的DAKUN框架相对基础模型提升**2.3%(绝对值)**AUC值。

2. 在融合文本语义特征的基础上,进一步使用图谱知识增强, 进一步提升**~1%(绝对值)**的AUC值。

平安寿险人工智能研发团队

专注于人工智能研究以及前沿技术
在保险领域的落地应用

AI全栈队伍 寿险创新前沿主力军



THANKS

中国平安人寿保险