

面向服务可靠性预测的逆扩散表征学习与对抗双向混合注意力交互方法研究

学生：杜冠辰，计算机科学与技术专业（2022级）， 指导教师：许建龙

汕头大学，数学与计算机学院，计算机系

摘要

现有服务计算方法多采用图神经网络（如 GCN、GAT）学习用户与服务节点的嵌入表示，但其依赖二分图建模的范式限制了模型的可扩展性；同时，真实网络环境中普遍存在噪声，如何实现鲁棒的 QoS 预测仍是一项重大挑战。

为此，本文提出 *QoSDiff*：通过逆扩散概率模型学习用户与服务嵌入，提升模型的可扩展性；并在交互阶段引入对抗网络对噪声进行分布正则化，从而消除其干扰。在大规模真实数据集上的实验表明，所提方法在非功能属性预测任务中均取得了优异的性能。



图1 *QoSDiff* (左) vs. 传统基于图的方法 (右)。

模型架构

实验如图2所示，*QoSDiff*由两个核心模块组成:基于逆扩散的嵌入学习模块与基于对抗注意力的交互模块。




图2. 提出的*QoSDiff*方法架构

1. **基于逆扩散的嵌入学习模块**将用户与服务上下文映射到共享隐空间,并把随机初始化的嵌入视为施加一步前向扩散后的含噪结果。通过面向离散嵌入空间的自注意力噪声预测网络估计并减去噪声,以单步逆扩散恢复出鲁棒的嵌入,无需显式构图。

2. **基于对抗注意力的交互模块**把去噪嵌入经拼接或采样后构造真实与合成两类交互表示,送入生成器—判别器的对抗框架。生成器使用双向混合注意力机制,同时建模"用户"与"服务"的双向影响以输出预测 $\hat{y}$;对抗过程兼具特征对齐与二次去噪作用,提升高阶交互建模能力与抗噪性。

以对抗损失与回归损失联合优化,并用系数 λ 平衡二者损失,从而在稀疏且含噪条件下实现准确鲁棒的缺失 QoS 预测。



扫码或访问 qosdiff.demohub.live,
体验在线演示并查看完整实验结果

实验结果

为验证*QoSDiff*的有效性，本文选取协同过滤方法（UPCC、IPCC、UIPCC）、矩阵分解方法（PMF、BiasMF）、深度学习方法（CSMF、NFMF、NCRL）以及图学习方法（GraphMF、PMP、RIGCN、QoSFNN）作为**对比基线**，并在四种矩阵密度设置下进行系统评估。

Model	Density=2.5%	Density=5%	Density=7.5%	Density=10%
UPCC	0.709 ± 0.007	0.640 ± 0.021	0.588 ± 0.030	0.556 ± 0.030
IPCC	0.755 ± 0.006	0.637 ± 0.001	0.615 ± 0.020	0.596 ± 0.020
UIPCC	0.737 ± 0.006	0.628 ± 0.010	0.604 ± 0.020	0.584 ± 0.020
PMF	0.712 ± 0.004	0.570 ± 0.001	0.561 ± 0.040	0.487 ± 0.020
BiasMF	0.689 ± 0.002	0.600 ± 0.014	0.544 ± 0.020	0.516 ± 0.003
CSMF	0.649 ± 0.003	0.550 ± 0.001	0.497 ± 0.002	0.453 ± 0.001
NFMF	0.524 ± 0.004	0.447 ± 0.005	0.426 ± 0.001	0.413 ± 0.003
NCRL	0.561 ± 0.005	0.546 ± 0.002	0.542 ± 0.004	0.537 ± 0.004
GraphMF	0.448 ± 0.005	0.399 ± 0.007	0.378 ± 0.005	0.367 ± 0.003
PMP	0.538 ± 0.003	0.465 ± 0.002	0.436 ± 0.004	0.418 ± 0.002
RIGCN	0.497 ± 0.001	0.435 ± 0.009	0.419 ± 0.012	0.395 ± 0.001
QoSFNN	0.431 ± 0.005	0.377 ± 0.006	0.353 ± 0.004	0.345 ± 0.004
QoSDiff	0.402 ± 0.004	0.358 ± 0.006	0.337 ± 0.001	0.324 ± 0.001
imp.	6.73%	5.04%	4.53%	6.09%

图3.不同密度下响应时间预测的MAE对比

实验结果表明，*QoSDiff* 在不同数据密度下均取得了最低的MAE，验证了其在稀疏QoS预测任务中的有效性；进一步地，为分析各模块的贡献，本文开展了**消融实验**。




图4. 不同密度下响应时间预测任务中的消融实验结果

消融实验表明，引入逆扩散嵌入学习后，模型在四种数据密度下的MAE均明显降低，说明该模块能够有效提升用户与服务表示学习能力；同时，对抗注意力（AAIM）交互模块相比 矩阵分解（MF）交互和 协同过滤（CF）交互取得更优结果，验证了其在建模用户—服务复杂交互关系中的有效性。

作者简介



杜冠辰，汕头大学数学与计算机学院计算机科学与技术系 2022 级本科生。本科期间多次获得校级综合奖学金，主要研究方向包括深度学习、服务计算与QoS预测。已申请多项发明专利并发表多篇SCI论文，现推免至南京理工大学IMAG课题组。