

基于生成对抗网络的长短兴趣推荐模型

康嘉钰, 苏凡军

(上海理工大学 光电信息与计算机工程学院, 上海 200093)

摘要:传统的推荐系统中,用户的兴趣被认为是稳定不变的,而事实上,用户的兴趣会因为各种因素产生变化。为了更加有利地跟踪用户兴趣偏好变化进行内容推荐,提出了一种基于生成对抗网络的推荐算法 L-GAN (long short-term memory via generative adversarial networks),利用长期和短期的兴趣偏好,通过生成对抗的训练策略来训练推荐模型,使推荐模型产生的推荐列表更加准确。在对抗训练过程中,将数据分为多个行为周期,按照时间顺序依次输入每个行为周期内的用户-项目评价矩阵,生成器模型产生推荐列表,而判断器模型则区分输入的推荐列表是否与真实历史记录的特征相似。最终,通过在两个公开的数据集上与多个推荐模型进行对比实验,结果表明在不同稀疏度的数据集上,L-GAN 算法在推荐精度方面有较明显的提高,更善于挖掘数据的隐层特征。

关键词:推荐算法;生成对抗网络;循环神经网络;孪生网络;对比损失函数

中图分类号:TP391

文献标识码:A

文章编号:1673-629X(2020)06-0035-05

doi:10.3969/j.issn.1673-629X.2020.06.007

A Long-short-term Interests Recommendation Model Based on Generative Adversarial Networks

KANG Jia-yu, SU Fan-jun

(School of Optical-electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: In the traditional recommendation system, users' interests are considered to be stable and unchanged, but in fact, they will change due to various factors. In order to track the changes of users' interests and preferences more advantageously for content recommendation, we propose a recommendation algorithm L-GAN based on generating antagonistic network, which takes advantage of long-term and short-term interest preference to train the recommendation model by generating antagonistic training strategies, so that the recommendation list generated by the recommendation model can be more accurate. In the course of confrontation training, the data is divided into several action cycles, and the user-project evaluation matrix is input in time sequence in each action cycle. The generator model generates the recommendation list, while the judge model distinguishes whether the input recommendation list is similar to the characteristics of the real history record. Finally, by comparing the two open datasets with several recommendation models, the experimental results show that the L-GAN algorithm improves the recommendation accuracy significantly in different sparse datasets and is better at mining hidden features of data.

Key words: recommendation algorithm; generative adversarial networks; recurrent neural network; siamese network; contrastive loss function

0 引言

目前在推荐算法领域,数据为驱动的推荐系统受到越来越多的关注。这些系统会引导用户从大量可能的选项中发现与用户兴趣相关度高的产品或服务^[1-2]。随着用户对推荐技术依赖的加强,推荐系统如何为用户提供精准的推荐成为亟待解决的重点,在

许多算法中往往都会忽视用户的兴趣漂移问题^[3]。比如一部电影的受欢迎程度会随时间变化而变化,用户喜欢的电影类型也会受到短期的流行影响而变化。因此,在推荐系统中如何利用长短期兴趣变化达到精准推荐显得尤为重要。

针对推荐系统的长短兴趣问题,文献[4]描述了

收稿日期:2019-08-06

修回日期:2019-12-08

基金项目:国家自然科学基金(61703278)

作者简介:康嘉钰(1995-),男,硕士研究生,研究方向为推荐系统、深度学习;苏凡军,讲师,博士,研究方向为计算机网络、下一代网络 QoS 技术、深度学习。

基于长短期兴趣的协同过滤方法的优点,并介绍了一种基于循环神经网络(recurrent neural network, RNN)的长短期兴趣预测方法。文献[5]将 MF 模型与 RNN 模型相结合来进行推荐,其通过 MF 模型来挖掘用户长期兴趣特征,利用 RNN 模型来挖掘用户一段时间内的兴趣变化,同时考虑到了用户长短期的变化。文献[3]提出了一种使用 RNN 来负责短期兴趣,前馈神经网络负责长期兴趣的推荐模型。这些模型均采用一般的训练方法训练,Szegedy 等人^[6]发现在模型训练中添加一些轻微的干扰就可以轻易改变模型的预测结果。深度学习模型遭遇干扰时所表现的脆弱性,给推荐系统带来了极大的风险。并且会使模型对历史信息的利用不充分,对隐层特征的挖掘不精确。

最近,文献[7]将对抗训练策略应用于图片解读任务中,效果十分优秀。文献[8]提出了一种基于生成对抗网络的序列生成方法,使用强化学习的策略梯度来实现序列数据生成。文献[9]提出了基于 IRGAN 框架的新生成检索模型和判断模型,使 IRGAN 在搜索项目、推荐项目方面得到了较大的提升。文献[10]提出了一种 GAN 框架的流式推荐模型。由此可见,生成对抗网络在各种任务中都具有有效性,且在推荐系统中同样具有有效性。对于提升深度学习模型对干扰的鲁棒性,使用对抗生成网络也是行之有效的解决方法。

基于上述综述,文中提出了一种基于生成对抗框架(GAN)的 Top-N 推荐模型 L-GAN。采用对抗训练的策略优化 LSTM 推荐模型,重点考虑用户和项目之间的兴趣漂移问题。L-GAN 模型使用生成器产生推荐列表,并用判断器区别推荐列表与真实数据,通过判断器与生成器不断对抗训练,使生成器最终产生的推荐列表与真实数据极为相似。提出的基于生成对抗网络的 L-GAN 推荐算法,主要有几点贡献:

- (1) 使用对抗训练策略来训练 LSTM 推荐模型,使用用户行为周期数据作为输入,由生成器生成推荐列表,判断器来识别推荐列表是否合理;
- (2) 在判断器中使用孪生神经网络来判断生成列表的合理性;
- (3) 通过将数据分割为行为周期数据,同时考虑了数据长期与短期的兴趣偏好变化,使数据的隐层特征获取更加准确。

1 LSTM 模型

提出的模型主要使用 LSTM 模型来有效利用长短期兴趣漂移变化。LSTM 模型是一种改进的时间循环神经网络,可以学习时间序列长短期依赖信息,由于神经网络包含时间记忆单元,比较适合于对时间序列

中的间隔和延迟事件进行处理和预测^[11]。每一个时刻 t 的 LSTM 单元由输入门 i_t 、遗忘门 f_t 、输出门 o_t 、细胞记忆单元 c_t 和隐层状态 h_t 组成。这些门是根据先前的隐藏状态 h_{t-1} 和时刻 t 的输入 x_t 计算出来的。

$$i_t = \text{sigmoid}(W[h_{t-1}, x_t]) \quad (1)$$

$$f_t = \text{sigmoid}(W[h_{t-1}, x_t]) \quad (2)$$

$$o_t = \text{sigmoid}(W[h_{t-1}, x_t]) \quad (3)$$

通过遗忘部分存在的细胞记忆和增加新的细胞记忆内容来更新时刻 t 的细胞记忆。可以用公式(4)表示遗忘过程,公式(5)表示细胞记忆更新过程。

$$I_t = \tanh(W[h_{t-1}, x_t]) \quad (4)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot I_t \quad (5)$$

当更新完 LSTM 单元的记忆内容后,时刻 t 的隐层状态为:

$$h_t = o_t \odot \tanh(c_t) \quad (6)$$

每一个 LSTM 单元的更新可以由简式 $h_t = \text{LSTM}(h_{t-1}, x_t)$ 表示。在利用长短期兴趣做预测时,输入量 x_t 应该来自于用户时刻 t 的行为周期,行为周期可以理解为一时间内用户评价项目的评价记录合集。

2 L-GAN 推荐模型框架

假设行为周期中的矩阵 R 为用户-项目评价矩阵,由用户集 U 与项目评分集 M 组成,使用符号 $r_{ij,t}$ 来表示时刻 t 时,用户 i 对项目 j 的评价。 $r_{ij,t}$ 的数值越大,表示用户 i 对项目 j 的兴趣越大。文中提出的 L-GAN 模型主要是将 LSTM 模型应用于 GAN 的框架中。

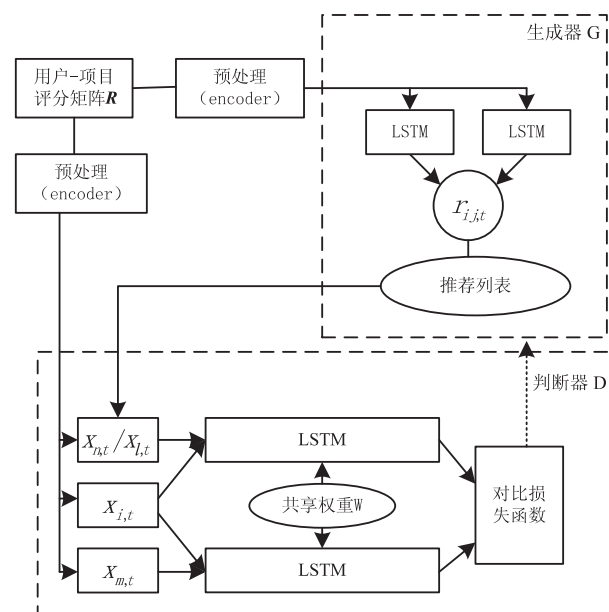


图 1 L-GAN 模型结构

GAN^[12]是由生成器 G 和判断器 D 构成的。文中模型中的判断器 D 用来区分训练集中的真实高分项目与生成器 G 预测的高评分项目或推荐列表;生成

器 G 使用预测出的高评分项目或推荐列表来欺骗判断器 D 。生成对抗训练策略的目的是,通过生成出的推荐列表不断地与用户真实历史评价对抗训练,使推荐列表中的项目与用户历史喜欢的项目特征达到高度接近或重合。结构如图 1 所示。

具体的目标可以用如下公式表示:

$$\min_G \max_D V(D, G) = E_{x \sim p_{\text{true}}(x)} [\log D(x)] + E_{z \sim p(z)} [\log(1 - D(G(z)))] \quad (7)$$

其中, x 为来自训练集的真实数据, $G(z)$ 表示由生成器生成的高评价项目或推荐列表, z 也是来自训练集的真实数据。为了使生成器 G 产生更加真实的推荐列表且判断器 D 的判断结果更加准确,将 LSTM 模型运用于生成器 G 与判断器 D 中,加强对数据长短期兴趣偏好的敏感度,以提高对隐层特征的挖掘。

2.1 生成器 G

生成器将一个行为周期的用户-项目评价矩阵 R 作为输入,生成用户 i 的推荐列表。但是用户-项目评价矩阵一般为高维稀疏的,不利于模型的训练。可以先通过矩阵分解降维的方法预处理矩阵 R 。文中使用具有自编码器的编码网络对矩阵进行预处理^[13],将其降维拆分为向量 $x_{i,t}$ 和向量 $x_{j,t}$, $x_{i,t}$ 为用户 i 在一定时间内对所有评价过的项目的评价向量, $x_{j,t}$ 为在一定时间内所有评价过项目 j 的用户对项目 j 的评价向量。在时刻 t , 评分 $r_{ij,t}$ 取决于用户时间状态 $h_{i,t}$ 和项目时间状态 $h_{j,t}$ 。因为用户的时间状态变化依赖于用户评价向量的变化,同理项目的时间状态变化也是由项目评价向量变化决定的。所以可以使用两个 LSTM 模型分别输入两个向量,分别得到用户时间状态 $h_{i,t}$ 和项目时间状态 $h_{j,t}$ 。为了同时考虑用户与项目的变化,文中将它们的内积作为预测时刻 t 用户 i 对项目 j 的评分 $r_{ij,t}$ 。

$$x_{i,t}, x_{j,t} = \text{Encoder}(R) \quad (8)$$

$$h_{i,t} = \text{LSTM}(h_{i,t-1}, x_{i,t}) \quad (9)$$

$$h_{j,t} = \text{LSTM}(h_{j,t-1}, x_{j,t}) \quad (10)$$

$$r_{ij,t} = h_{i,t} \odot h_{j,t} \quad (11)$$

通过这样的方法,按照时间戳的顺序,依次将行为周期的评价矩阵输入,对一定时间段内用户 i 没有评价过的项目进行预测评分,预测评分最高的前几个项目按预测评分从高到低排序,即可视为生成出的推荐列表。生成器的模型如图 1 所示。生成器的目标函数可以表示为:

$$\min_G \frac{1}{M} \sum_{j=1}^M \log(1 - D(x_{i,t}, x_{m,t}, x_{n,t})) \quad (12)$$

其中, M 为项目集, $D(x_{i,t}, x_{m,t}, x_{n,t})$ 为判断器的模型, $x_{n,t}$ 为生成器产生的推荐列表中的高评分项目向量。训练生成器是为了与判断器对抗,从而使判断器无法

区分出推荐结果与真实数据,即使 $G(z)$ 产生的结果更接近真实数据,则目标是使判断器判断的相似度 $D(G(z))$ 最大,为了便于计算可求得 $\log(1 - D(x_{i,t}, x_{m,t}, x_{n,t}))$ 最小化结果。

2.2 判断器 D

判断器使用孪生神经网络框架 (siamese network framework)。孪生神经网络可以很好地区分隐层特征,常用于特征之间的对比任务。该框架分为特征提取网络和相似度计算两个部分^[14]。为了更精准地识别项目间基于长短兴趣偏好的隐层特征的区别,孪生神经网络框架中的特征提取网络使用类似于生成器中 LSTM 模型的用法,这时的输入应该使用用户向量 $x_{i,t}$, 用户历史评价高分项目向量 $x_{m,t}$ 和生成器预测的高分项目向量 $x_{n,t}$, 如图 1 所示。通过对比时刻 t 用户评价过的高分项目与推荐出的项目状态的相似度来判断生成器推荐是否准确。特征提取网络的公式可表示为:

$$x_{i,t}, x_{m,t} = \text{Encoder}(R) \quad (13)$$

$$r_{im,t} = \text{LSTM}(h_{i,t-1}, x_{i,t}) \odot \text{LSTM}(h_{m,t-1}, x_{m,t}) \quad (14)$$

$$r_{in,t} = \text{LSTM}(h_{i,t-1}, x_{i,t}) \odot \text{LSTM}(h_{n,t-1}, x_{n,t}) \quad (15)$$

在孪生网络内特征提取网络中使用的权重是共享的^[15]。文中模型选用了对比损失函数 (contrastive loss)^[16] 作为求得相似度的方法。根据其计算出的相似度,可以判断生成器预测结果是否准确。判断器模型可以表示为:

$$D(x_{i,t}, x_{m,t}, x_{n,t}) = \frac{y \cdot d^2}{2} + (1 - y) \cdot \max(1 - d, 0)^2 \quad (16)$$

$$d = \|r_{im,t} - r_{in,t}\|_2 \quad (17)$$

其中, d 为对比样本的欧氏距离, y 表示两个样本是否相似, y 为 1 时表示两个样本相似,为 0 则表示不相似。需要注意的是,在训练优化判断器的阶段,需要使用用户评价过的其他项目向量 $x_{l,t}$ 代替预测项目向量 $x_{n,t}$ 。目的是为了用真实的数据来更新优化判断模型中的共享权重。因此判断器的目标函数表示为:

$$\max_D \frac{1}{U} \sum_{i=1}^U [\log D(x_{i,t}, x_{m,t}, x_{l,t}) + \log(1 - D(x_{i,t}, x_{m,t}, x_{n,t}))] \quad (18)$$

其中, U 为用户集。公式中的第一项,来源均为真实数据,得到的相似度概率 $D(x)$ 越大越好。而第二项是判断生成器的推荐列表与真实数据的相似度,判断器的作用是鉴别它们的区别,所以其鉴别的相似度结果 $D(G(z))$ 应越小越好,为了统一形式方便计算,第二项改为 $1 - D(G(z))$,这样整个公式不会出现矛盾。

2.3 训练算法流程

算法训练流程总结如下 (在训练模型的时候,判

断器与生成器通过对抗训练的策略交替进行更新优化):

算法:算法训练流程。

输入:训练集 S

初始化:使用随机数来初始化生成器 G 与判断器 D 的权重,预处理训练集 S

训练生成器 G :

(a)生成时刻 t 用户 i 的项目推荐列表

(b)从推荐列表中选出预测高分项目样本集 N

(c)for $n \in \{1, 2, \dots, N\}$:

用户 i 的历史高分项目 m 来自训练集 S

使用判断器 D 来区分 k, m

End for

(d)通过生成器的目标函数(12)来更新生成器 G
训练判断器 D :

(a)用户 i 的历史高分项目 m 与评价过的其他项目 l 均来自训练集 S

(b)判断器 D 判断 m, l 的相似度

(c)通过判断器的目标函数(18)来更新判断器 D

until 两个模型均收敛

3 实验

3.1 实验数据集

为了验证文中算法的推荐效果,选择了两个公开的数据集(MovieLens-100K(<http://grouplens.org/datasets/movielens>)和Netflix-3M(<https://www.kaggle.com/netflix-inc/netflix-prize-data>))进行实验。这两个数据集均有用户对电影的评级,评价等级为从1到5,5为最高评分。并且它们还提供了电影的发行时间以及详细的用户信息。对每个数据集,去掉没有明显信息的用户及电影,按照时间戳粒度随机分为若干个训练集与测试集。其中MovieLens-100K的时间戳粒度设为5天,Netflix-3M的时间戳粒度设为1天。两个数据集的详细信息如表1所示。

表1 数据集信息

指标	MovieLens-100K	Netflix-3M
用户数	933	326 668
电影数	17 956	17 751
训练集时间	9/97-3/98	9/05-11/05
训练集评分数	75 498	13 675 402
测试集时间	3/98-5/98	12/05
测试集评分数	20 632	2 405 578
稀疏性	6.3%	0.3%

3.2 实验评估标准

为了对推荐效果进行定量的评价,使用推荐精度(precision)、NDCG、MRR作为推荐算法的度量标准。

这些评价指标的值越大,推荐算法的效果越好^[17-18]。

推荐精度可以表示用户喜欢项目在推荐列表中的比例,对于推荐列表大小为 k 的推荐精度公式为:

$$\text{Precision@}k = \frac{T(k)}{R(k)} \quad (19)$$

其中, $R(k)$ 为生成推荐列表的数量, $T(k)$ 为实现正确推荐的推荐列表数量。

NDCG(normalized discounted cumulative gain)广泛作为对Top-N推荐系统的推荐列表的评价指标。用公式可以表示为:

$$\text{NDCG@}k = \frac{\text{DCG@}k}{\text{IDCG@}k} \quad (20)$$

$$\text{DCG@}k = \sum_{i=1}^k \frac{\text{rel}_i}{\log_2(1+i)} \quad (21)$$

其中, rel_i 为推荐列表位置 i 的推荐结果的相关性。如果排名 i 的项目相关性好, $\text{rel}_i = 1$, 否则等于0。IDCG为理想情况下的DCG,即为DCG的最大值。

MRR(mean reciprocal rank)是将推荐列表中一个预测准确的结果的位置的倒数作为准确度,再对所有准确度求平均值。

$$\text{MRR} = \frac{\sum_{q=1}^Q \frac{1}{\text{rank}_q}}{Q} \quad (22)$$

其中, Q 为推荐项目的数量, rank_q 为第 q 个推荐项目第一次出现在推荐列表中的位置。

3.3 实验对比模型

实验选用TimeSVD++^[19]、R-RNN^[20]和IRGAN^[9]模型进行对比。TimeSVD++推荐算法是一种对于静态的基于矩阵分解技术的推荐算法的改进算法。R-RNN模型采用与文中生成器类似的推荐算法,并通过Adam算法对其参数进行优化。IRGAN用于信息检索领域,可以生成出按偏好相关的推荐列表。

3.4 实验结果

在实验中进行Top-N推荐时,对推荐列表长度 k 取不同值分别进行实验,以 k 为3、6、9时的实验结果作为样本,各项实验结果如表2和表3所示。

实验结果表明,文中提出的L-GAN模型相对于对比模型在推荐精度和准确度上都有较明显的提升。TimeSVD++推荐算法和R-RNN模型推荐效果明显低于使用GAN训练的模型,证明通过生成对抗训练可以更好地获取隐层特征。L-GAN虽采用与R-RNN模型类似的推荐列表生成方式,但在训练时通过判断器的反馈会提升推荐列表的精度。L-GAN在各个指标对比中均略微高于IRGAN,显示了L-GAN较好的推荐效果。这是因为L-GAN模型的优势在于能够考虑用户和电影之间短期和长期联系,尤其是模型中LSTM部分明确考虑了用户行为的动态性。在实验结

果中,当推荐列表容量大小增加时,三个模型的推荐效果均呈现不同程度的下降。

表2 推荐结果(MovieLens-100K)

评估标准	TimeSVD++	R-RNN	IRGAN	L-GAN
Precision@3	0.286	0.276	0.281	0.289
Precision@6	0.271	0.261	0.269	0.272
Precision@9	0.252	0.253	0.260	0.264
NDCG@3	0.301	0.295	0.312	0.318
NDCG@6	0.286	0.276	0.294	0.306
NDCG@9	0.251	0.256	0.279	0.297
MRR	0.455	0.442	0.458	0.466

表3 推荐结果(Netflix-3M)

评估标准	TimeSVD++	R-RNN	IRGAN	L-GAN
Precision@3	0.268	0.267	0.275	0.290
Precision@6	0.247	0.254	0.271	0.279
Precision@9	0.241	0.240	0.267	0.271
NDCG@3	0.263	0.265	0.268	0.273
NDCG@6	0.249	0.257	0.269	0.272
NDCG@9	0.242	0.246	0.263	0.267
MRR	0.376	0.382	0.386	0.393

4 结束语

在生成对抗网络框架的基础上,提出了一种 L-GAN 推荐模型,通过生成器产生推荐列表,判断器区分真伪评分项目的方法,准确挖掘数据基于长短期兴趣偏好变化的隐层特征,使推荐列表更加精准。在两个大型开源数据集上的实验,证明了该模型推荐效果的有效性与准确性,且对数据的隐层特征挖掘更精准。实验结果也显示了随着推荐列表增加,推荐效果出现降低的问题,因此今后会针对这一问题展开研究。

参考文献:

- [1] BOBADILLA J, ORTEGA F, HERNANDO A, et al. Recommender systems survey [J]. Knowledge - Based Systems, 2013, 46: 109-132.
- [2] 黄立威, 江碧涛, 吕守业, 等. 基于深度学习的推荐系统研究综述[J]. 计算机学报, 2018, 41(7): 1619-1647.
- [3] 冯永, 张备, 强保华, 等. MN-HDRM: 长短兴趣多神经网络混合动态推荐模型[J]. 计算机学报, 2019, 42(1): 16-28.
- [4] YU L, ZHANG W, WANG J, et al. SeqGAN: sequence generative adversarial nets with policy gradient [C]//Thirty-first AAAI conference on artificial intelligence. San Francisco: AAAI, 2017: 2852-2858.
- [5] DEVOOGHT R, BERSINI H. Long and short-term recommendations with recurrent neural networks [C]//Conference on User Modeling. Bratislava: ACM, 2017: 13-21.
- [6] SZEGEDY C, ZAREMBA W, SUTSKEVER I, et al. Intriguing properties of neural networks [C]//Proceedings of the international conference on learning representations. Banff: ICLR, 2014.
- [7] WU C, AHMED A, BEUTEL A, et al. Recurrent recommender networks [C]//Proceedings of the tenth ACM international conference on web search and data mining. Bratislava: ACM, 2017: 495-503.
- [8] CHEN T, LIAO Y, CHUANG C, et al. Show, adapt and tell: adversarial training of cross-domain image captioner [C]//2017 IEEE international conference on computer vision. Venice: IEEE, 2017: 521-530.
- [9] WANG J, YU L, ZHANG W, et al. IRGAN: a minimax game for unifying generative and discriminative information retrieval models [C]//The 40th international ACM SIGIR conference on research and development in information retrieval. Tokyo: ACM, 2017: 515-524.
- [10] WANG Q, YIN H, HU Z, et al. Neural memory streaming recommender networks with adversarial training [C]//The 24th ACM SIGKDD international conference on knowledge discovery & data mining. London: ACM, 2018.
- [11] WU C, AHMED A, BEUTEL A, et al. Joint training of ratings and reviews with recurrent recommender networks [C]//International conference on learning representations. San Juan: ICLR, 2016: 1-4.
- [12] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets [C]//Advances in neural information processing systems. Montreal: NIPS, 2014: 2672-2680.
- [13] ZENG D, LIU K, LAI S, et al. Relation classification via convolutional deep neural network [C]//Annual meeting of the association for computational linguistics. Baltimore: ACL, 2014: 2335-2344.
- [14] 沈雁, 王环, 戴瑜兴. 基于改进深度孪生网络的分类器及其应用[J]. 计算机工程与应用, 2018, 54(10): 19-25.
- [15] 李兰君, 周俊生, 顾颜慧, 等. 基于改进孪生网络结构的相似法律案例检索研究[J]. 北京大学学报: 自然科学版, 2019, 55(1): 84-90.
- [16] 白苗君. 平滑网络在人脸识别对比损失函数最优化中的应用[D]. 南京: 东南大学, 2018.
- [17] JOACHIMS T, LI H, LIU T, et al. Learning to rank for information retrieval [J]. ACM SIGIR Forum, 2007, 41(2): 58-62.
- [18] 刘春霞, 武玲梅, 谢小红. 推荐系统评估研究综述[J]. 现代计算机, 2018(24): 11-15.
- [19] RENDLE S, FREUDENTHALER C. Fast context-aware recommendations with factorization machines [C]//Proceeding of the international ACM SIGIR conference on research and development in information retrieval. Beijing: ACM, 2011: 635-644.
- [20] 高茂庭, 徐彬源. 基于循环神经网络的推荐算法[J]. 计算机工程, 2019, 45(8): 198-202.