

基于门控循环单元神经网络的广告点击率预估

陈巧红,董雯,孙麒,贾宇波

(浙江理工大学信息学院,杭州 310018)

摘要:为提高在线广告的投放效果,改善用户广告体验度,增加广告收益,提出了一种基于门控循环单元神经网络模型的广告点击率预估方法。该方法结合了门控循环单元网络特有的门控单元结构和广告数据时序性特点,利用按时间反向传播算法训练网络模型;提出一种门控循环单元神经网络训练步长改进算法,使得训练时间更少,模型更加精确。实验表明,与逻辑斯特回归、随机森林、朴素贝叶斯和循环神经网络模型相比,提出的方法在广告点击率预估的概率上更准确,有助于广告主、媒体和目标受众用户三方博弈,实现共赢。

关键词: 在线广告;门控循环单元;点击率;按时间反向传播;三方博弈

中图分类号: TP181

文献标志码: A

文章编号: 1673-3851(2018)09-0587-06

0 引言

计算广告学是一门新兴的综合性学科,涉及统计学、信息科学、计算机科学和微观经济等相关领域。点击率(Click through rate, CTR)预估是计算广告技术的核心之一^[1]。广告点击率预估通常根据历史广告点击数据,通过机器学习模型,预测特定用户在特定广告位对特定广告的点击概率。常见的互联网广告商业计费模式^[2]有四种:按展现付费(Cost per mille, CPM)、按点击付费(Cost per click, CPC)、按转化付费(Cost per action, CPA)和按投资收益率付费(Return on investment, ROI)。市场上的付费模式大多采用CPC,即广告被用户每点击一次,广告主应给媒体付的价格,媒体网站的收入是点击价格和点击总数的乘积。在点击价格不变的情况下,提高点击次数,即提高点击广告的概率是提高广告收益的关键因素。

广告点击率预估主要分为四个步骤:数据清洗、特征工程、模型选择和训练、模型评估。Dave等^[3]提出了基于梯度提升决策树(Gradient boosting decision tree, GBDT)的预估方法,主要思想是通过弱决策器迭代生成强决策器,并自动选择和生成特

征。但是该方法在大规模稀疏的数据集情况下,准确率难以得到保证且训练时间成本过高。Oentaryo等^[4]提出了利用因式分解机(Factorization machine, FM)模型挖掘非线性特征的方法。该方法通过对二项式矩阵做矩阵分解,将高维稀疏的特征向量映射到低维连续向量空间,能够有效地解决大规模数据稀疏型的问题,然而该方法由于需要特征矩阵作分解和特征高低维映射的原因,导致处理特征的工作量巨大。Zhu等^[5]提出了一种基于模型融合最大化的方法,该方法只考虑对点击率有关键作用的特征进行哈希变换,一定程度上忽视了特征的整体性和多样性。Chapelle等^[6]提出一种基于贝叶斯网络(Naive bayes networks, NB)模型的方法,通过模拟登陆页面的相关性以及搜索结果页面可感知的相关性进行广告点击率预估,但是贝叶斯网络模型必须先验概率且属性之间必须是相互独立的。Zhang等^[7]提出了利用循环神经网络(Recurrent neural networks, RNN)模型进行点击率预估的方法,利用按时间反向传播(Back propagation through time, BPTT)算法来训练RNN,其实验结果表明,相比于GBDT、FM以及传统的神经网络模型,RNN在准确率上有一定的提升。然而RNN在使用梯度下降优化

算法时,造成梯度爆炸问题^[8],影响模型的准确度。

为了解决循环神经网络梯度爆炸的问题,本文采用基于门控单元(Gated recurrent unit, GRU)改进的循环神经网络,即门控循环单元神经网络(Gated recurrent unit neural networks, GRUs)。该方法利用 GRUs 特殊的门控单元结构,通过对当前隐藏层状态的影响因子不同作加权处理,同时对模型训练产生的误差进行更新,避免在学习轮数增加的情况下发生梯度爆炸的问题,进而提高模型的准确性。本文进一步对该模型的训练算法进行改进,提出一种步长改进算法,通过步长改进算法可使得训练迭代次数更少,预估结果更加精确,以提高广告点击率的预估能力。

1 门控循环单元神经网络模型和算法改进

1.1 门控循环单元神经网络模型

GRUs 是对 RNN 的改进,使用不同的函数去计算隐藏层状态(hidden state),主要体现在两个方面^[9]:a)序列中不同的位置信息对当前的隐藏层状态的影响不同,越靠前的权重影响越小,具体表现为历史状态对当前的状态进行加权,距离越远,权值越小。b)误差的产生是由一个或多个信息造成,隐藏层状态只针对相应的序列信息权重进行更新。相对于 RNN,GRUs 结构增加了更新门(update gate)和重置门(reset gate)^[10-11]。更新门产生新的状态值,重置门控制之前状态的输入值,根据当前输入以及前一个隐藏层状态输出的更新门和重置门值,结合重置门、当前输入和前一个隐藏层状态输出,计算得出新记忆单元(new memory)值,新记忆单元忽略之前的所有状态,最终的记忆状态(final memory)是之前的隐藏层状态与新记忆单元值的结合。GRUs 原理如图 1 所示。其中:input 表示特征输入, z_t 表示更新门结构, h_t 表示隐藏层结构, r_t 表示重置门结构, \tilde{h}_t 表示记忆单元结构。




图 1 GRUs 原理

1.2 模型训练和算法改进

基于 GRUs 模型预估广告点击率,目的是准确

地对广告特征输入序列进行分类,依靠误差反向传播和梯度下降来实现^[12]。GRUs 训练比较困难,主要是因为隐藏层参数 \mathbf{W} ,无论在前向传播过程还是在反向传播过程中都会乘上多次,这样就会导致前向传播某个小于 1 的值乘上多次,对输出影响变小,使得反向传播时出现梯度爆炸的问题。在传统神经网络中,大都采用反向传播(Back propagation, BP)算法来训练,RNN 以及改进网络中使用按时间反向传播 BPTT 算法^[13]。按时间传播表示一系列完全定义的有序计算,根据时间依次连接,其参数在所有的层之间共享,因此当前层的梯度值除了要基于当前的这一步计算,还有依赖于之前的时间步。BPTT 采用链式法则求解参数梯度。

图 2 描述了 BPTT 算法在一个 t 时间的存储和处理操作。历史缓存每经过一个 t 时间,就会增加一层的数据(包括该 t 时间所有的输入和输出值)。




图 2 按时间反向传播操作

图 2 中 x 表示当前时间的特征输入, O 表示当前时间的特征输出, S 表示激活函数。图 2 中的实线箭头表示当前隐藏层节点的输出值是由上一刻的输入输出值确定,虚线表示反向传播,计算 $t+1$ 到 $t-1$ 时间的误差。每一个时间都产生一个输出,节点输出每经过一个时间 t ,就会增加之前所有时间的信息状态值。GRUs 的结构在时间 t 的隐藏层输入可以用公式表示为:

$$a_h^t = \sum_{i=1}^I w_{ih} x_i^t + \sum_{h'=1}^H w_{h'h} b_{h'}^{t-1}.$$

在 t 时间的广告特征输出 b_h^t 用公式表示为:

$$b_h^t = g_h(a_h^t),$$

其中: x_i^t 为 t 时间的特征值输入, $b_{h'}^{t-1}$ 为 $t-1$ 时间的输出, i 和 I 表示节点, h' 和 H 表示隐藏层, w_{ih} 为输入层与隐藏层之间的权重, $w_{h'h}$ 为广告特征在上一时间隐藏层与当前隐藏层之间的权重, g_h 为隐藏层的激励函数。

GRUs 在输出层 t 时间的输入 a_k^t 用公式表示为:

$$a_k^t = \sum_{h=1}^H w_{hk} b_h^t.$$

t 时间的输出 y_k^t 用公式表示为:

$$y_k^t = g_k(a_k^t),$$

其中: w_{hk} 为隐藏层与输出层之间的权重, g_k 为输出层的激励函数。

在训练神经网络反向传播时, t 时间输出层的误差 δ_k^t 公式表示为:

$$\delta_k^t = y_k^t - z_k^t.$$

隐藏层误差 δ_h^t 用公式表示为:

$$\delta_h^t = g_h'(a_h^t) \left(\sum_{k=1}^K \delta_k^t w_{hk} + \sum_{h'=1}^H \delta_{h'}^{t+1} w_{hh'} \right).$$

t 时间的隐藏状态的梯度函数用公式表示为:

$$\delta_j^t = \frac{\partial E}{\partial a_j^t},$$

其中: z_k^t 为 x_k^t 的标签, E 为误差函数, ∂E 表示 E 的偏导函数, a_j^t 表示隐藏层在 t 时间 j 节点的输入, ∂a_j^t 表示 a_j^t 的偏导函数。对各个梯度权重求偏导函数计算公式可以表示为:

$$\nabla E(w_{ij}) = \frac{\partial E}{\partial w_{ij}} = \sum_{t=1}^T \frac{\partial E}{\partial a_j^t} \frac{\partial a_j^t}{\partial w_{ij}} = \sum_{t=1}^T \delta_j^t b_i^t.$$

至此,由梯度下降法求出权重的更新函数用公式表示为:

$$w_{ij} = w_{ij} - \alpha \nabla E(w_{ij}).$$

对 GRUs 采用梯度下降法来训练时,需要提前设置步长和迭代轮次。本文提出一种改进步长的梯度下降方法来训练 GRUs,改进步长算法的流程为:先设置一个大的步长快速寻找全局近似最优点,再利用较小的步长通过指数迭代衰减,进而找到局部最优。

本文模型算法改进具体计算用公式表示为:

$$l = m + (n - m) \times e^{-\frac{p}{q}},$$

其中: l 表示每一轮优化时使用的步长, m 表示最小步长, n 表示最大步长, p 表示迭代轮次, q 表示在给定的步数下达到 n 。步长参数设置过大,会导致参数在极优值点的两侧来回移动,很难收敛到一个极值点;相反,如果步长参数过小,虽然可以保证收敛到一个近似极值点,但会大大降低优化速度,需要更多的迭代次数才能达到一个理想的优化效果。具体参数设置见表 1。

表 1 模型算法改进前后参数

模型	l	m	n	p	q
RNN	0.0010	—	—	200	—
GRUs	0.0010	—	—	200	—
本文模型	0.0010	0.0001	0.0030	200	10000

1.3 评价函数

由于本文的广告点击率预估问题是一个典型的二分类问题,所以采用 ROC (Receiver operating characteristic) 曲线和 AUC 值来评价模型的标准以

及预测的准确率^[14]。ROC 和 AUC 常被用来评价一个二值分类器(binary classifier)的优劣,在广告投放中,被点击的候选广告根据广告点击率值的大小,按概率由高到低排序,生成 ROC 曲线,AUC 代表 ROC 曲线下的面积,值越大,表示被点击的广告排序越靠前,即广告投放的效果越好,也就是广告点击率预测越准确。ROC 曲线横轴为假正率(False positive rate, FPR),表示划分实例中所有负例占有所有负例的比例;纵轴为真正率(True positive rate, TPR),表示正类覆盖率。AUC 的值 v_{AUC} 用公式表示为:

$$v_{AUC} = \frac{\sum_{positive} Rank_i - \frac{M(1+M)}{2}}{M \times N},$$

其中: M 表示正类样本的数目,即点击广告数据的数目; N 表示负类样本的数目,即广告数据未点击的数目。AUC 计算思想是统计总的正负样本对中,正样本的 score 大于负样本的 score。在广告点击率预估场景下,通常属于不平衡问题,AUC 对样本的数据比例有着良好的容忍性,在测试集的正负样本分布变化时,ROC 曲线能够保持不变,所以实验采用 AUC 值评价模型指标。

2 实验过程和结果分析

2.1 数据准备

本文实验中使用的数据集是 Kaggle 平台上的 10 天日志,该日志由移动广告 dsp 公司 Avazu 提供。由于涉及到用户隐私等问题,数据字段全部采用加密的形式给出。训练数据共四千多万条,24 个字段特征,其中 14 个为分类特征,10 个为数量特征。实验数据字段见表 2。

表 2 实验数据字段介绍

特征名	特征描述	特征类别	特征数目
id	广告 id	数量特征	8552
click	点击情况	分类特征	2
hour	时间	分类特征	240
banner_position	广告位	分类特征	7
site_id	站点 id	数量特征	4347
site_domain	站点域	数量特征	7745
site_category	站点分类	数量特征	26
app_id	Appid	数量特征	8552
app_domain	app 域	数量特征	559
app_category	app 分类	数量特征	36
device_id	设备 id	数量特征	2686408
device_ip	设备 ip	数量特征	6719482
device_model	设备型号	数量特征	8251
device_conn_type	联网方式	分类特征	4
device_type	设备类型	分类特征	5
c1,c14-c21	匿名信息	分类特征	3067

2.2 特征工程

首先划分训练集和测试集。由于作为原始数据中测试集的后两天数据没有类别标签,所以本实验只采用 8 天的训练集作为实验数据。把前 7 天的数据作为训练集,第 8 天的数据作为测试集。数据的日点击率情况见表 3。

表 3 数据的日点击率情况

天数	点击率	天数	点击率
21	0.174198	25	0.182402
22	0.157167	26	0.183049
23	0.182190	27	0.181594
24	0.174716	28	0.153325

从表 3 可以看出,各天的点击率基本维持在 0.17 上下,正负样本均衡,不需要进行采样处理。

针对时间“hour”特征,抽取增加出“day”和“hour”两个新特征。对特征缺失值进行处理。对不同特征类型的缺失值进行补全处理,其中缺失值为连续型的特征用该类别特征的均值代替,缺失值为离散型的特征用该类别特征的众数代替。进行频次转化,去除“id”、“day”和“hour”,其余特征强制转成“int”型整数格式作频次转化。进行频次转化的原因一条广告展示的次数过多会降低相同广告出现的概率,其次则为了数据类型的统一性。几个重要特征的转化情况见表 4。

表 4 几个重要特征的转化情况

特征名	原始形式	频次转化后形式
device_ip	f2ab42af	528412
site_domain	f3845767	4066
app_id	ecad2386	4539
device_id	a99f214a	334587

分类处理某一个或某几个特征如“banner_position”特征,此特征共有 7 个特征类别值,分别为 0、1、2、3、4、5、7,在广告点击率预估中代表一条广告所处不同广告 banner 位置。此特征单个类别值的广告点击率大小如图 3 所示。




图 3 单特征类别点击率

对特征进行 One-Hot Encoding 编码。虽然基于决策树的随机森林不需要进行 One-Hot Encoding,但是本文实验中采用相同的特征,以此保证对比实验的客观性。One-Hot Encoding 编码方式调用 sklearn 里面的接口 One-Hot Encoder。对于取值数目较多的分类特征如“device_ip”和“device_id”等进行特征降维,之后作 One-Hot Encoding 编码。对出现频率很少的特征值都归为同一类特征,避免产生巨大的矩阵向量维度,降低计算复杂度,提高资源利用率。

特征工程的工作均是通过以上步骤完成。本文对比实验中所用到的数据完全一致,只有特征工程相同,才能更好地比较模型自身的优势。

2.3 实验结果及分析

本文实验中分别使用逻辑回归 (Logistic regression, LR) 模型、NB 模型、随机森林 (Random forest, RF) 模型等浅层模型以及 RNN 作为 GRUs 及其本文算法改进模型对比实验。以上所有模型均采用相同输入特征,其中 3 种神经网络模型在层数以及每层的节点数保持一致,优化算法全都采用梯度下降算法,激励函数为 tanh。

在广告点击率预估实验中,不同模型有着不同的预估效果,取所有模型各自最好的 AUC 值作为实验对比,AUC 值大小如图 4 所示。




图 4 不同模型下的最高 AUC 值

从图 4 可以看出,在 3 种使用浅层模型预估广告点击率实验中,基于 RF 的广告点击率预估效果最好,AUC 值为 0.696,主要在于 RF 采用 bootstrap 方法有放回地随机抽取新的广告样本集作为训练样本,通过构建多棵分类回归树,达到较好的预估效果。同时,基于 RF 模型的 AUC 值明显要低于基于 RNN 模型的实验结果。这是因为浅层模型中没有充分挖掘广告特征间的非线性关系,随着样本量的增加,模型的泛化能力也相对减弱。而在基于循环神经模型的点击率预估实验中,基于门控循环单元的神经网络模型以及步长改进的模型效果最好,

AUC 值分别为 0.785 和 0.789。

3 种基于循环神经网络模型在不同迭代次数下的 AUC 变化如图 5 所示。




图 5 不同神经网络模型在迭代次数下的 AUC 变化

RNN 和 GRUs 用相同固定的步长 0.001, 隐藏层为 3 层, 节点个数为 256。从图 5 中可以看出, 在相同的激励函数 tanh 下, 随着迭代轮次的增加, RNN 的 AUC 值提升相比 GRUs 和本文模型都更加缓慢, 而且最佳的 AUC 值比本文模型降低了将近 0.05。这是因为 RNN 在随着样本量和迭代轮次增加, 使得当前的模型输出与前面很长的一段广告序列信息产生遗漏, 造成梯度消失或爆炸的原因。而 GRUs 和本文模型在迭代轮次的增加下, AUC 值上升趋势快, 这是因为相对于 RNN, GRUs 在隐藏层的计算方法上引入了门单元结构, 利用门单元特殊的门控机制来控制梯度传播, 在广告特征计算的历史信息中将重要特征保留, 从而避免了梯度消失或爆炸, 提高了模型预估效果。但是本文模型在迭代 140 次左右的时候达到了最大 AUC 值, 而 GRUs 要在 160 次左右到达最大的 AUC 值。本文模型要比 GRUs 在更少的迭代次数下达到最优, 最佳 AUC 值比 GRUs 下大 0.005 左右。这是因为本文模型在 GRUs 的基础之上改变了步长优化算法, 使得步长在每次迭代都更新幅度大小, 使得训练时间更少, 模型更加精确。本实验说明, 基于步长改进算法的本文模型在广告点击率预估中效果要更好, 证明了步长改进算法的可行性和有效性。

3 结 论

本文采用基于 GRUs 模型的方法预估广告点击率问题, 利用 GRUs 中特有的门控机制来加强广告特征在时间上的联系, 进而增强广告特征之间的非线性关系。基于 GRUs 模型, 在优化方法上提出一种步长改进算法, 使得梯度下降在训练优化模型时, 每轮迭代的步长发生更新。实验结果表明, 利用步长改进算法后的梯度下降法优化的模型对比其他

模型, 在广告点击率预估上使用的训练时间更短, 预估效果更好, 为媒体网站和广告主在投放广告的分类筛选、位置排版等提供参考价值, 提高广告收益。

本文实验只选取了梯度下降这一种优化算法, 在后续工作中, 可以在步长控制算法的基础之上寻找更有效的优化算法, 尝试对 GRUs 的隐藏层节点进行改变。

参考文献:

- [1] 刘鹏, 王超. 计算广告[M]. 北京: 人民邮电出版社, 2015:24-24.
- [2] 刘庆振. 计算广告学: 大数据时代的广告传播变革: 以“互联网+”技术经济范式的视角[J]. 现代经济探讨, 2016(2):87-91.
- [3] Dave K S, Varma V. Learning the click-through rate for rare/new ads from similar ads[C]// International ACM SIGIR Conference on Research and Development in Information Retrieval. ACM, 2010:897-898.
- [4] Oentaryo R J, Lim E P, Low J W, et al. Predicting response in mobile advertising with hierarchical importance-aware factorization machine [C]// ACM International Conference on Web Search and Data Mining. ACM, 2014:123-132.
- [5] Zhu W Y, Wang C H, Shih W Y, et al. SEM: A softmax-based ensemble model for CTR estimation in real-time bidding advertising[C]// IEEE International Conference on Big Data and Smart Computing. IEEE, 2017:5-12.
- [6] Chapelle O, Zhang Y. A dynamic bayesian network click model for web search ranking [C]// International Conference on World Wide Web. ACM, 2009:1-10.
- [7] Zhang Y, Dai H, Xu C, et al. Sequential click prediction for sponsored search with recurrent neural networks[C]// Twenty-Eighth AAAI Conference on Artificial Intelligence. AAAI Press, 2014:1369-1375.
- [8] Jozefowicz R, Zaremba W, Sutskever I. An empirical exploration of recurrent network architectures [C]// International Conference on International Conference on Machine Learning. JMLR. org, 2015:2342-2350.
- [9] Tjandra A, Sakti S, Manurung R, et al. Gated recurrent neural tensor network [C]// International Joint Conference on Neural Networks. IEEE, 2016:448-455.
- [10] Zhou G B, Wu J, Zhang C L, et al. Minimal gated unit for recurrent neural networks[J]. International Journal of Automation and Computing, 2016, 13(3):226-234.
- [11] Wu C, Wang J, Liu J, et al. Recurrent neural network based recommendation for time heterogeneous feedback

- [J]. Knowledge-Based Systems, 2016, 109(C): 90-103.
- [12] Huiwen Guo, Xinyu Wu, Wei Feng. Multi-stream deep networks for human action classification with sequential tensor decomposition[J]. Signal Processing, 2017, 140: 198-206.
- [13] Kusumoputro B, Sutarya D, Na L. Nuclear power plant fuel's quality classification using ensemble back propagation neural networks[J]. Advanced Materials Research, 2013, 685: 367-371.
- [14] Bowyer K, Kranenburg C, Dougherty S. Edge detector evaluation using empirical ROC curves[J]. Comput Vision & Image Understand, 2001, 84(1): 77-103.

Advertisement click-through rate predicting based on gated recurrent unit neural networks

CHEN Qiaohong, DONG Wen, SUN Qi, JIA Yubo

(School of Information Science and Technology, Zhejiang Sci-Tech University, Hangzhou 310018, China)

Abstract: In order to improve the putting effect of online advertising, to improve the user experience of advertising, and to increase the revenue of advertising, an advertisement click-through rate predicting method based on the gated recurrent unit neural networks is proposed in this paper. This method combines proper gate unit structure of gated recurrent unit network and time sequence characteristics of advertising data, and utilizes time-based back propagation algorithm to train the network model. This paper proposes step size improvement algorithm of gated recurrent unit neural networks so that the training time is less and the model is more accurate. The experiment shows that compared with logistic regression, random forest, naive bayes and recurrent neural network models, the method proposed in this paper has more accurate advertisement click-through rate prediction and contributes to three-side game of advertisers, media and target audience so as to achieve win-win.

Key words: online advertising; gated recurrent unit; click-through rate; time-based back propagation; three-side game

(责任编辑: 康 锋)