

结合三部图综合扩散的 Slope One 推荐算法

王 冉¹, 徐 怡^{1,2}, 何明慧¹, 胡善忠¹

(1 安徽大学 计算机科学与技术学院, 安徽 合肥 230601;

2 安徽大学 计算智能与信号处理教育部重点实验室, 安徽 合肥 230039)

摘 要: Slope One 算法在评分预测时没有考虑项目之间的推荐关系, 导致推荐的准确性和多样性不高, 故提出了一种结合三部图综合扩散的 Slope One 算法. 首先在三部图中加入了项目类别节点, 然后利用三部图综合扩散计算项目之间的推荐度, 最后利用得到的推荐度结合 Slope One 进行评分预测, 由于三部图综合扩散算法同时经过用户节点和项目类别节点进行扩散, 并且计算得到的项目之间的推荐度是非对称的, 更能体现用户兴趣. 本文在 MovieLens 数据集上利用 4 种评价指标进行 5-折交叉验证. 实验结果表明: 算法有效的提高了预测的准确度和多样性.

关键词: 推荐系统; 三部图; slope one; 综合扩散

中图分类号: TP391

文献标识码: A

文章编号: 1000-7180(2018)04-0006-06

Slope One Recommendation Algorithm Through Combining Integrated Diffusion on Tripartite Graph

WANG Ran¹, XU Yi^{1,2}, HE Ming-hui¹, HU Shan-zhong¹

(1 Department of Computer Science and Technology, Anhui University, Hefei 230601, China;

2 Key Lab of IC&SP, Ministry of Education, Anhui University, Hefei 230039, China)

Abstract: The Slope One algorithm does not consider the recommended level between items when predict ratings, so the accuracy and diversity are not high. Therefore, a Slope One algorithm through combining integrated diffusion on tripartite graph is proposed. The idea is to add the genre nodes into the tripartite graph, and calculate the Slope One prediction ratings with the recommended level that calculated by the tripartite graph integrated diffusion algorithm. Since the diffusion through user nodes and item nodes, and the recommended level between the items is asymmetric, so it is better to reflect the user interest. The proposed method was tested by 5-fold cross-validation with four metrics, and the experiments on the MovieLens show that our approach achieves great improvement of prediction accuracy and diversity.

Key words: recommender system; tripartite graph; slope one; integrated diffusion

1 引言

随着海量信息不断地快速增长, 如何从过载的信息中选择用户感兴趣的内容是一个非常大的挑战, 而推荐系统提供了一个非常好的解决手段来应对这些问题. 不同于搜索引擎, 推荐系统不需要用户输入关键字信息, 而是主动推荐用户感兴趣的内

容^[1]. 目前推荐系统应用在各个领域, 比如微博的好友推荐、豆瓣的电影推荐以及 Amazon 等电商网站的商品推荐等, 在满足了用户的需求的同时, 增加了网站的点击量提高了企业的利润^[2-3]. 推荐算法是推荐系统的核心, 目前主流的推荐算法有: 基于协同过滤的推荐算法、基于内容的推荐算法、基于图的推荐算法以及混合推荐算法^[4], 而 Slope One 算法简洁

收稿日期: 2017-07-13; 修回日期: 2017-08-17

基金项目: 国家自然科学基金(61402005); 安徽省自然科学基金项目(1308085QF114); 安徽省高等学校省级自然科学基金项目(KJ2013A015, KJ2011Z020)

直观,可用于实时推荐,算法可以看成线性回归模型,利用所有用户的评分差来计算待预测用户未评分的项目,由于该算法不考虑用户或项目之间的相似关系,所以推荐效果有待提高. 针对以上问题,学者们提出了各自的改进方法^[5-6].

上述方法虽然一定程度上改善了 Slope One 算法的推荐效果,但是忽略了项目之间的非对称推荐关系. 针对这个问题,本文提出一种结合三部图综合扩散的 Slope One 算法.

2 Slope One 算法

Slope One 算法(Slope One algorithm,SO) 使用简单的线性函数 $y = x + b$ 来预测目标用户未评分的项目,利用同时对项目 x 和项目 y 评分的所有用户的分值差对 b 进行线性拟合,最后预测目标用户对 y 的评分时直接带入目标用户已有的评分 x 即可^[7]. 例如计算表 1 中 User a 对 Item z 的预测评分,由表 1 可知 Item x 和 Item z 有两个用户有共同评分,分别是 User b 和 User c ,其中 User b 对 Item z 的评分比 Item x 高了 2 分($3 - 1 = 2$),而 User c 对 Item z 的评分比 Item x 低了 3 分($2 - 5 = -3$),因此 Item z 和 Item x 的平均评分差是 $(2 + (-3))/2 = -0.5$,由于 User a 对 Item x 的评分是 2,所以 User a 对 Item z 的评分是 $2 + (-0.5) = 1.5$;同理需要计算 Item y 和 Item z 的平均评分差,因为只有 User b 对 Item y 和 Item z 有共同评分,故 Item z 和 Item y 的平均评分差为 $3 - 2 = 1$,由于 User a 对 Item y 的评分为 4,所以 User a 对 Item z 的预测评分为 $4 + 1 = 5$,最后对两次预测评分求平均值得到 User a 对 Item z 最终的预测评分 $(1.5 + 5)/2 = 3.25$.

表 1 用户 - 项目评分矩阵

	Item x	Item y	Item z
User a	2	4	?
User b	1	2	3
User c	5	—	2

2.1 算法模型

Slope One 算法使用简单的线性函数 $y = x + b$ 对项目进行预测评分,其中 y 是待预测项目的评分, x 是已有评分,而 b 表示项目之间的评分差. 对于给定的项目 i 以及项目 j ,其评分差 dev_{ji} 计算公式如 (1) 所示:

$$\text{dev}_{ji} = \frac{\sum_{u \in C_{ji}} (r_{uj} - r_{ui})}{|C_{ji}|} \tag{1}$$

式中, r_{ui} 和 r_{uj} 分别表示用户 u 对项目 i 以及用户 u 对项目 j 的评分, C_{ji} 表示对项目 i 和项目 j 有共同评分的用户集合.

基于得到的项目评分差 dev_{ji} 可以计算目标用户 u 对目标项目 j 的预测评分 $\text{pred}(u, j)$,公式如 (2) 所示:

$$\text{pred}(u, j) = \frac{1}{|S(u, j)|} \sum_{i \in S(u, j)} (\text{dev}_{ji} + r_{ui}) \tag{2}$$

式中, r_{ui} 表示用户 u 对项目 i 的评分, dev_{ji} 表示 j 和 i 项目的评分差. $S(u, j)$ 表示用户 u 已评分的项目中与项目 j 的共同评分用户不小于 1 的项目集合,公式如 (3) 所示:

$$S(u, j) = \{i \mid i \in R(u), i \neq j, |C_{ij}| > 0\} \tag{3}$$

式中, $R(u)$ 表示用户 u 已评分的项目集合.

3 结合三部图综合扩散的 Slope One 推荐算法

Slope One 算法在预测评分时对所有用户同等的利用评分差,没有考虑项目之间内在的推荐度不同,导致推荐的准确率和多样性不高,故本文提出一种结合三部图综合扩散的 Slope One 推荐算法,对于三部图综合扩散的部分,与传统的基于用户-项目-标签的三部图综合扩散算法不同,提出了一种基于用户-项目-类别的三部图综合扩散算法,一方面对用户到项目节点的边增加了权值,另一方面引入了项目的类别节点,从而使物质扩散的过程更加精确. 最后利用用户-项目-类别三部图综合扩散得到的推荐度对 Slope One 的评分预测过程进行加权处理.

3.1 结合三部图综合扩散的 Slope One 推荐算法

用户-项目-类别的三部图可以表示为 $G(U, I, G, E_1, E_2)$,其中 $U = \{u_1, u_2, u_3, \cdots, u_m\}$ 是用户节点, $I = \{i_1, i_2, i_3, \cdots, i_n\}$ 是项目节点, $G = \{g_1, g_2, g_3, \cdots, g_r\}$ 是项目类别节点, $\text{deg}(i)$ 表示用户节点到项目节点的边集合, E_2 表示项目节点到项目类别节点的边集合. 计算用户 - 项目 - 类别三部图的综合扩散得到的项目之间的推荐度,则需要分别计算用户 - 项目二部图物质扩散得到的项目之间的推荐度以及项目 - 类别二部图物质扩散得到的项目之间的推荐度,最后利用 λ 将两次计算得到的推荐度进行加权得到最终的项目之间的推荐度. 用户 - 项目 - 类别三部图综合扩散过程如图 1 所示.




图1 用户-项目-类别三部图物质扩散过程

由于传统的基于用户-项目-标签的三部图的边没有权值,分配资源时采用平均分配策略,没有利用评分信息^[8].本文在用户-项目-类别三部图中对用户-项目二部图中的边加入了评分作为边权,资源按与节点相连的边权大小占与该节点相连的所有边权之和的比例进行扩散.对于给定的项目节点 i 和 j ,在加权情况下计算项目节点 i 通过物质扩散传递给节点 j 的资源 σ_{ji} 的计算公式如(4)所示:

$$\sigma_{ji} = \sum_{u \in U} \frac{e_{ui} e_{uj}}{\deg(i) \deg(u)} \quad (4)$$

式中, U 是用户集合, $\deg(i)$ 表示连接项目节点 i 的所有边的权值之和, $\deg(u)$ 表示连接用户 u 的所有边的权值之和. e_{ui} 和 e_{uj} 的取值如公式(5)所示:

$$e_{ui} = \begin{cases} E_{ui}, & (u, i) \in E_1 \\ 0, & (u, i) \notin E_1 \end{cases} \quad (5)$$

式中,其中 E_{ui} 表示用户 u 节点与项目 i 节点边的权值.

对于项目-类别二部图,加入项目的类别节点主要因为项目类别相对于标签而言更容易获取并且能更准确的体现项目内在的联系,比如一部电影,当它上映时就对应其所属的类别,而且这些类别对项目的描述也十分准确.如表2所示,对于Item1,其对应的类别是喜剧和战争,则在项目-类别二部图中增加项目节点Item1到喜剧和战争节点的边.

表2 项目的类别信息

	Action	Comedy		Thriller	War
Item 1	0	1		0	1
Item 2	1	0		1	0
Item 3	0	0		0	1

由于项目对类别没有评分等信息,所以项目节点到类别节点的边没有权值,资源从节点平均扩散,计算项目节点 i 通过物质扩散传递给节点 j 的资源

ρ_{ji} 的公式如(6)所示:

$$\rho_{ji} = \frac{1}{\deg(i)} \sum_{g \in G} \frac{e_{ig} e_{jg}}{\deg(g)} \quad (6)$$

式中, G 是项目类别集合, $\deg(i)$ 表示项目 i 的度, $\deg(g)$ 表示类别 g 的度. e_{ig} 和 e_{jg} 的取值如公式(7)所示:

$$e_{ig} = \begin{cases} 1, & ig \in E_2 \\ 0, & ig \notin E_2 \end{cases} \quad (7)$$

式中,当类别 g 节点存在连接项目 i 节点的边时, e_{ig} 为1;反之, e_{ig} 为0.

对于基于用户-项目-类别三部图综合扩散算法,计算项目 i 通过物质扩散传递给 j 项目的资源 res_{ji} 计算公式如(8)所示:

$$\text{res}_{ji} = \lambda \cdot \sigma_{ji} + (1 - \lambda) \cdot \rho_{ji} \quad (8)$$

式中,当 $\lambda \in [0, 1]$, σ_{ji} 表示用户-项目二部图中项目 i 通过物质扩散传递给 j 项目的资源; ρ_{ji} 表示项目-类别二部图中项目 i 通过物质扩散传递给 j 项目的资源.

基于公式(8)计算基于用户-项目-类别三部图综合扩散得到的项目之间的推荐度,并结合推荐度和Slope One的评分预测过程进行加权处理.改进后的Slope One评分预测公式如(9)所示:

$$\text{respred}(u, j) = \frac{\sum_{i \in S(u, j)} (\text{dev}_{ji} + u_i) \cdot \text{res}_{ji}}{\left| \sum_{i \in S(u, j)} \text{res}_{ji} \right|} \quad (9)$$

式中, $S(u, j)$ 表示用户 u 已评分的项目中与项目 j 共同评分次数不小于1次的项目集合, dev_{ji} 表示 j 和 i 项目的评分差, res_{ji} 是通过用户-项目-类别三部图综合扩散得到的项目 i 对项目 j 的推荐度,注意,这里不能写成 res_{ij} ,因为需要预测的是 j 项目的评分,所以计算的是已有评分的项目 i 对待预测项目 j 的推荐程度,而 res_{ij} 表示的是项目 j 对项目 i 的

推荐程度.

结合三部图综合扩散的 Slope One 推荐算法描述如下.

输入 用户集合 U , 项目集合 I , 项目类别集合 G , 边集合 E_1 和 E_2 .

输出 目标用户 u 对目标项目 j 的预测评分 $\text{respred}(u, j)$.

Step 1. 通过用户对项目的评分得到项目之间的共同评分用户集合 C_{ij} , 利用公式(1) 和 C_{ij} 计算目标用户已评分项目和待预测项目的评分差 dev_{ji} .

Step 2. 构建用户 - 项目 - 类别三部图 $G(U, I, G, E_1, E_2)$.

Step 3. 在用户 - 项目 - 类别三部图中, 对于用户 - 项目加权二部图, 利用公式(4) 计算项目 i 分配给项目 j 的资源 σ_{ji} , 也就是项目 i 对项目 j 的推荐度.

Step 4. 在用户 - 项目 - 类别三部图中, 对于项目 - 类别二部图, 利用公式(6) 计算项目 i 分配给项目 j 的资源 ρ_{ji} , 也就是项目 i 对项目 j 的推荐度.

Step 5. 将 Step 3 和 Step 4 计算得到的 σ_{ji} 和 ρ_{ji} 利用公式(8) 进行加权, 得到用户 - 项目 - 类别三部图中项目 i 分配给项目 j 的资源 res_{ji} , 也就是最终的项目 i 对项目 j 的推荐度.

Step 6. 将 Step 1 计算得到的 dev_{ji} 和 Step 5 计算得到的 res_{ji} 带入公式(8) 得到最终的预测评分 $\text{respred}(u, j)$.

Step 7. 结束.

4 实验结果与分析

本节通过实验比较结合三部图综合扩散的 Slope One 推荐算法 (TGSO) 和 Slope One 算法 (SO)、加权的 Slope One 算法 (WSO) 以及基于用户-项目节点的加权二部图 Slope One 推荐算法 (WNBISO) 的推荐准确度和推荐多样性.

4.1 数据集

实验采用目前推荐领域广泛使用的 MovieLens 100k 数据集, 该数据集由 GroupLens 研究组收集和整理, 包含 943 名用户对 1 682 部电影的 100 000 多个评分, 并且每个用户至少有 20 个评分, 评分数据稀疏度为 93.7%, 稀疏度较高, 评分范围在 1~5 之间, 分值越高表明用户对电影的喜爱程度越高. 本文使用 5-折交叉验证的方法对提出的改进算法进行验证.

4.2 评价标准

本文采用的 4 种评价标准对实验结果进行对比, 分别是平均分排名 (ARankS)、平均绝对偏差 (MAE)、均方根误差 (RMSE) 以及多样性 (Diversification) [9].

(1) 平均分排名 (ARankS): 分值排名 (RankS) 表示用户测试集中的项目在已排序的推荐列表中的相对位置. 比如用户 u 有 1 000 个未选择的项目, 根据预测评分从大到小进行排序, 当测试集中的项目 i 出现在推荐列表的第 5 个位置, 则分值排名 $\text{Rank}_{ui} = 5/1\,000 = 0.005$. 当项目 i 位置越靠前, 则分值排名的值越小, 推荐准确度越高; 反之, 推荐准确度越低. 用户 u 测试集中所有项目 Rank_{ui} 的平均分值排名如公式如(10)所示:

$$\text{ARankS} = \frac{\sum_{i \in T(u)} \text{Rank}_{ui}}{|T(u)|} \quad (10)$$

式中, $T(u)$ 表示 u 的测试集, Rank_{ui} 表示测试集中的项目 i 在排序后的推荐列表中的分值排名.

(2) 平均绝对偏差 MAE (Mean Absolute Error): 过计算预测评分与实际评分的差值的绝对值来衡量预测评分的准确性, MAE 值越大, 表明误差越大, 推荐精度越低; 反之, MAE 值越小, 表明误差越小, 推荐精度越高, 公式如(11)所示:

$$\text{MAE} = \frac{\sum_{i \in T(u)} |R_{ui} - P_{ui}|}{|T(u)|} \quad (11)$$

式中, R_{ui} 表示用户 u 对项目 i 的实际评分, P_{ui} 表示用户 u 对项目 i 的预测评分, $T(u)$ 表示测试集中用户 u 评分的项目集合.

(3) 均方根误差 RMSE (Root Mean Squared Error): 同 MAE 相似, 利用预测评分与实际评分的误差来衡量预测评分的准确性, 并且会加大预测不准确评分的影响. 同 MAE 相同, RMSE 值越小越好, 公式如(12)所示:

$$\text{RMSE} = \sqrt{\frac{\sum_{i \in T(u)} (R_{ui} - P_{ui})^2}{|T(u)|}} \quad (12)$$

式中, R_{ui} 表示用户 u 对项目 i 的实际评分, P_{ui} 表示用户 u 对项目 i 的预测评分, $T(u)$ 表示测试集中用户 u 评分的项目集合.

(4) 多样性 (Diversification): 用来衡量用户推荐个性化推荐的程度, 推荐列表的差异性越大, 则多样性值越高. 公式如(13)所示:

$$\text{Diversification} = \frac{2 \sum_{i \neq j} (1 - \frac{|L_i \cap L_j|}{|L_i|})}{n(n-1)} \quad (13)$$

式中, L_i 表示用户 U_i 的推荐列表集合, L_j 表示用户 U_j 的推荐列表集合, 多样性的值越大, 则推荐的个性化程度越高; 反之, 值越小, 推荐的个性化程度越低.

4.3 实验结果对比

为了验证本文提出算法的有效性, 实验采用 5-折交叉验证, 将 MovieLens 数据集随机划分 5 组 20% 的数据, 每次轮流选取 1 组数据作为测试集, 剩下的 4 组数据合并作为训练集, 一共进行 5 次实验, 相当于 5 组数据集, 分别用 $u_1 u_2 u_3 u_4 u_5$ 表示. 实验利用了 ARankS、MAE、RMSE、以及 Diversification 4 种指标对比了经典的 Slope One 算法 (SO)、加权的 Slope One 算法 (WSO)、基于用户-项目节点的二部图物质扩散的 Slope One 算法 (WNBISO) 以及本文提出的结合三部图综合扩散的 Slope One 算法 (TGSO).

由于本文提出的 TGSO 算法需要训练参数加权参数 λ , 故本文设置参数 λ 从 0 到 1 以 0.1 为间隔, 分别对比 5 组数据集 (u_1-u_5), 不同 λ 参数对应的 MAE 值, 如图 2 所示:




图 2 不同参数 λ 对应的 MAE 值

由图 2 可以看出, 在 5 组不同的数据集下, 当 λ 取值为 0.3 时, MAE 的值较低, 推荐准确率高, 故在后面的对比实验中取加权参数 λ 的值为 0.3.

图 3 表示的是平均分排名 (ARankS) 在 u_1-u_5 不同数据集下的对比实验, 横坐标代表的是数据集的编号, 纵坐标是 ARankS 的值.

由于 ARankS 的值越小推荐的准确率越高, 由图 3 可以看出在 u_1-u_5 不同数据集下, 本文提出的 TGSO 算法的推荐效果均好于 SO 算法, WSO 算法以及 WNBISO 算法.

图 4 表示不同数据集下的 MAE 值, 横坐标代表的是 u_1-u_5 不同数据集, 纵坐标是 MAE 的值.

由于 MAE 的值越小预测评分的误差越小, 推荐结果越精确, 所以由图 4 可以看出在 u_1-u_5 不同数据集下, 本文提出的 TGSO 算法的推荐效果均好




图 3 不同数据集下的平均分排名




图 4 不同数据集下的 MAE 值

于 SO 算法, WSO 算法以及 WNBISO 算法.

图 5 表示不同数据集下的 RMSE 值, 横坐标代表的是 u_1-u_5 不同数据集, 纵坐标是 RMSE 的值.




图 5 不同数据集下的 RMSE 值

RMSE 和 MAE 相同, 值越小推荐的准确率越高, 由图 5 可以看出在 u_1-u_5 不同数据集下, 本文提出的 TGSO 算法的推荐效果均好于 SO 算法、WSO 算法以及 WNBISO 算法.

图 6 分别是不同推荐步长 s 的情况下, u_1-u_5 不同数据集的平均多样性的实验对比, 横坐标均为推荐的步长 s , 取值在 10 到 100 之间, 以 10 为间隔, 纵坐标分别是 u_1-u_5 数据集下的平均多样性的值.

由图 6 可以看出, 本文提出的 TGSO 算法在给定的所有步长 s 下的平均多样性均高于 SO 算法、WSO 算法和 WNBISO 算法. 随着步长 s 的增加, 多




图6 不同推荐步长 s 下的平均多样性

多样性的值总体呈现下降趋势,这是因为推荐列表长度的增加意味着不同用户之间推荐列表包含相同项目的概率的增加。

综上,结合图2~6可知,本文提出的 TGSO 算法,在提高推荐精度的同时,也提高了推荐的多样化程度,避免了给不同用户推荐相同商品的单一推荐模式,取而代之的是更加个性化的推荐。

5 结束语

为了解决 Slope One 算法推荐准确度和多样性不高的问题,本文提出了一种结合三部图综合扩散的 Slope One 算法(TGSO)。实验通过4种评价指标与其他3种算法利用5-折交叉验证进行对比,证明了算法的有效性。下一步的工作是考虑在此基础上加入时间因素从而进一步提高推荐的效果。

参考文献:

- [1] 孟祥武,刘树栋,张玉洁,等. 社会化推荐系统研究[J]. 软件学报,2015,25(6):1356-1372.
- [2] 黄兰,钱育蓉,于炯,等. 融合可信度和时效标签的商品推荐算法[J]. 微电子学与计算机,2017,34(6):78-83.

(上接第5页)

参考文献:

- [1] 穆立波,霍志勇. 频域抗干扰中的门限检测和处理[J]. 计算机与网络,2010,36(10):46-48.
- [2] 孟博,龚文飞,孙昕. 基于反加窗和重叠选择的窄带干扰抑制方法[J]. 导航学报,2014,2(2):93-96.
- [3] 周景龙. 基于高速FFT结构的频域抗干扰算法的FPGA实现[J]. 微电子学与计算机,2014,31(5):32-35.
- [4] 曹龙,方娟,马强. 基于FPGA的窄带干扰抑制算法在GPS中的应用[J]. 电子设计工程,2013,21(17):174-177.
- [5] 肖进杰,李金海,欧松林. 窄带抗干扰算对捕获跟踪的影响[J]. 微电子学与计算机,2016,33(9):101-105.

- [3] 卢露,魏登月. 一种基于隐语义模型的协同过滤算法[J]. 微电子学与计算机,2015,32(2):73-75.
- [4] 张怡文,王冉,程家兴. 基于用户兴趣度的改进二部图随机游走推荐方法[J]. 计算机应用与软件,2015,31(6):76-79.
- [5] 杜茂康,刘苗,李韶华,等. 基于邻近项目的 Slope One 协同过滤算法[J]. 重庆邮电大学学报(自然科学版),2014,26(3):421-426.
- [6] 李桃迎,李墨,李鹏辉. 基于加权 Slope one 的协同过滤个性化推荐算法[J]. 计算机应用研究,2017,34(8):2264-2268.
- [7] Zhao Zhengde, Li Jianjun. Based on slope-one hybrid recommendation[C]// Advanced Research and Technology in Industry Applications. Ottawa, Ontario, IEEE, 2014:203-205.
- [8] 廖志芳,李玲,刘丽敏,等. 三部图张量分解标签推荐算法[J]. 计算机学报,2012,35(12):2625-2632.
- [9] Shang M S, Zhang Z K, Zhou T, et al. Collaborative filtering with diffusion-based similarity on tripartite graphs[J]. Physica A Statistical Mechanics & Its Applications, 2009, 389(6):1259-1264.

作者简介:

王冉男,(1993-),硕士研究生. 研究方向为个性化推荐、深度学习。

徐怡(通讯作者)女,(1981-),博士,副教授. 研究方向为智能信息处理、粒计算、粗糙集理论、个性化推荐。

E-mail: xuyi1023@126.com.

何明慧男,(1991-),硕士研究生. 研究方向为神经网络、个性化推荐。

胡善忠男,(1990-),硕士研究生. 研究方向为粗糙集理论、个性化推荐。

- [6] Chuachin Wang, Jianming Huang, Hsianchang Cheng. A 2K/8K mode small-area FFT processor for OFDM demodulation of DVB-T receivers[J]. IEEE Transactions on Consumer Electronics, 2005, 51(1):28-32.

作者简介:

罗伟杰男,(1992-),硕士研究生. 研究方向为卫星导航抗干扰算法. E-mail: luoweijie@ime.ac.cn.

李金海男,(1978-),博士,副研究员,研究生导师. 研究方向为高端卫星导航定位与应用。

欧松林男,(1987-),硕士,助理研究员. 研究方向为 GNSS 卫星导航定位。