



计算机集成制造系统  
*Computer Integrated Manufacturing Systems*  
ISSN 1006-5911, CN 11-5946/TP

## 《计算机集成制造系统》网络首发论文

题目： 基于场景识别的云制造服务推荐  
作者： 郝予实，范玉顺  
收稿日期： 2018-10-15  
网络首发日期： 2019-03-18  
引用格式： 郝予实，范玉顺. 基于场景识别的云制造服务推荐[J/OL]. 计算机集成制造系统. <http://kns.cnki.net/kcms/detail/11.5946.TP.20190315.0936.024.html>



**网络首发：**在编辑部工作流程中，稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定，且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式（包括网络呈现版式）排版后的稿件，可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定；学术研究成果具有创新性、科学性和先进性，符合编辑部对刊文的录用要求，不存在学术不端行为及其他侵权行为；稿件内容应基本符合国家有关书刊编辑、出版的技术标准，正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性，录用定稿一经发布，不得修改论文题目、作者、机构名称和学术内容，只可基于编辑规范进行少量文字的修改。

**出版确认：**纸质期刊编辑部通过与《中国学术期刊（光盘版）》电子杂志社有限公司签约，在《中国学术期刊（网络版）》出版传播平台上创办与纸质期刊内容一致的网络版，以单篇或整期出版形式，在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊（网络版）》是国家新闻出版广电总局批准的网络连续型出版物（ISSN 2096-4188，CN 11-6037/Z），所以签约期刊的网络版上网络首发论文视为正式出版。

## 基于场景识别的云制造服务推荐

郝予实, 范玉顺<sup>+</sup>

(清华大学 自动化系, 北京 100084)

**摘要:** 为了更好地实现对云制造服务系统中服务组合场景信息的挖掘和组织, 并据此建立高效的服务推荐算法以辅助用户创建服务组合, 提出了基于场景识别的云制造服务推荐模型。模型首先对原始服务组合描述进行功能信息重构; 而后基于得到的场景综合描述对服务组合进行应用场景聚类, 并为各场景建立加权服务库; 最后通过识别用户需求的场景类别, 借助各场景加权服务库进行服务推荐。实际数据集上的实验结果证明该方法在推荐效果上有很大提升。

**关键词:** 云制造; 服务推荐; 服务组合; 场景聚类; 主题模型

**中图分类号:** TP391

**文献标识码:** A

## Cloud manufacturing service recommendation based on scenario recognition

HAO Yushi, FAN Yushun<sup>+</sup>

(Department of Automation, Tsinghua University, Beijing 100084, China)

**Abstract:** In order to better mine and organize the service composition scenario information in the cloud manufacturing service system, and establish an efficient service recommendation algorithm to assist users to create service compositions, a cloud manufacturing service recommendation model based on scenario recognition is proposed. The model first reconstructs the initial service composition description by supplementing function information. Then, the model clusters the service compositions by application scenario based on the obtained comprehensive scenario descriptions, and establishes a weighted service library for each scenario. Finally, the service recommendation is completed by identifying the scenario categories of user requirements and utilizing the weighted service library of each scenario. Experiments on the real-world data set show that this method brings a better performance in recommendation effect.

**Keywords:** Cloud manufacturing; Service recommendation; Service composition; Scenario clustering; Topic model

## 0 引言

近年来, 随着互联网技术、云计算以及面向服务的体系架构 (Service-Oriented Architecture, SOA) 的迅猛发展, 制造企业在经营模式和协作模式上正经历着深刻的变革, 越来越多的制造企业由产品提供者的角色转化为服务提供者的角色<sup>[1]</sup>。在这种背景下, 云制造这一新型制造模式应运而生, 并

取得了长足的发展<sup>[2]</sup>。

在云制造模式下，越来越多的制造业企业将其制造资源（如制造设备、软件、知识、数据等）与制造能力（如生产能力、检测能力、设计能力等）以制造服务的形式发布到互联网上<sup>[3]</sup>。第三方开发者借助云制造平台可以便捷地查找、使用和集成这些制造服务，以满足自身个性化的制造需求。由于单个制造服务往往仅能提供一种功能，而用户的制造需求往往具有较高的复杂性，因此在实际操作中，开发人员通常将多个制造服务组合使用，以满足用户复杂的个性化需求<sup>[4]</sup>。通过服务组合的创建，制造服务的功能得以扩展和协作，从而提升了制造能力。大量的制造服务与服务组合、云制造体系下的各方参与者、服务与服务组合包含的大量信息以及它们之间复杂的关联关系共同构成了云制造服务系统<sup>[5]</sup>。

随着制造服务数量的不断增长，云制造服务系统出现了严重的信息过载问题。用户在从海量的制造服务中筛选合适的服务进而创建服务组合时遇到了较大的困难<sup>[6]</sup>。在这种背景下，制造服务推荐算法获得了广泛的关注和研究，制造服务推荐算法旨在通过准确识别用户需求，自动化地为用户推荐可能满足其需求的服务列表，进而帮助用户快速创建服务组合<sup>[7]</sup>。

现有的针对云制造服务系统和制造服务推荐算法的研究主要集中在以下方面。针对云制造服务系统，研究者主要关注于云制造服务系统概念和架构、制造服务建模和分类、制造服务网络、制造服务评估和制造服务推荐等领域<sup>[8]</sup>。云制造服务系统概念和架构的研究者旨在为云制造服务系统确立统一的概念和定义，并通过提出标准化的系统架构实现云制造体系的搭建，为后续的研究建立体系基础<sup>[9]</sup>。对于制造服务建模和分类的研究主要聚焦于系统中的制造服务，研究者为制造服务建立统一的模型以期对它们进行规范化的描述，进而基于服务的功能属性等进行服务分类，实现对系统中制造服务的管理<sup>[7, 10]</sup>。制造服务网络的研究者将云制造服务系统中的服务关联关系抽象为网络化模型，进而利用网络分析的相关技术和手段对制造服务进行研究<sup>[11]</sup>。制造服务评估的研究者旨在构建服务的信誉评价体系，其主要关注于服务各项服务质量（Quality of Service, QoS）指标的识别和评价<sup>[12, 13]</sup>。制造服务推荐算法的研究是近年来的热门领域，也是本文的研究重点。早期的服务推荐算法主要利用语义匹配技术，通过匹配用户需求和服务描述文本的相似性进行推荐<sup>[14]</sup>。随着主题模型和协同过滤等算法的发展，研究者尝试利用各类主题模型对服务描述文本进行向量化，并且基于协同过滤的思想，利用服务历史组合记录的信息进行推荐<sup>[7, 15, 16]</sup>。近期，各类复杂的推荐模型相继被提出，研究者从服务流行度分析、服务网络特性分析、服务演化特性分析等角度入手，构建了一系列复杂的制造服务推荐模型<sup>[17, 18]</sup>。

尽管针对云制造服务系统和制造服务推荐算法的研究已经取得了一定的进展，然而，当前国内外的研究者仍忽视了以下两方面的问题，限制了云制造服务系统的发展和制造服务推荐算法效果的提升。

(1) 对已有服务组合应用场景信息缺乏挖掘和组织。云制造服务系统的现有研究多聚焦于服务层面，然而对于系统中服务组合蕴含的信息关注较少。事实上，每一个服务组合都对应于实际制造业务中的一个应用场景，该组合能够满足这一场景下的制造需求。通过对系统中已有服务组合的应用场景信息进行挖掘和组织，云制造服务系统的运营者可以从场景的角度对系统内的服务与服务组合进行管理。进一步地，通过为各类应用场景建立特定的加权服务库，可以辅助服务推荐过程的进行。

(2) 对用户制造需求的应用场景信息缺乏识别。当前的服务推荐算法均局限于从功能匹配的角度进行推荐，试图满足用户的各项功能需求，这些算法在推荐效果的提升上遇到了瓶颈。事实上，用户的制造需求往往基于特定的应用场景，通过对需求的应用场景信息进行挖掘和识别，利用场景特性和场景加权服务库进行服务推荐可以大大提升制造服务推荐的效果。

针对以上问题，本文创新性的提出了一种基于场景识别的云制造服务推荐模型（Cloud Manufacturing Service Recommendation Based on Scenario Recognition, SRSR）。SRSR 模型首先对系统内原始服务组合描述进行重构，通过补充功能信息描述为每个服务组合建立场景综合描述文本。而后，利用主题模型和聚类分析等手段对服务组合的应用场景进行聚类，并为各类应用场景建立特定的加权服务库，从而实现了服务组合场景信息的挖掘和组织。最后，通过对用户制造需求进行场景识别，利用各场景加权服务库为用户进行服务推荐。本文在实际数据集上对所提出模型的推荐效果进行了验证，实验表明，SRSR 模型用 MAP（Mean Average Precision）指标评估的综合推荐效果较当前最优模型提升了 6.1%。

## 1 问题定义

本章将为云制造服务系统和制造服务推荐问题给出详细描述和数学定义，以利于后续讨论。

### 1.1 云制造服务系统

云制造服务系统内主要包含四类实体，分别是制造服务提供者、制造服务、开发者以及服务组合。制造服务提供者将其拥有的制造资源与能力以制造服务的形式发布到云制造服务系统中。每个制造服务通常包含以下信息：服务名称、服务标签、服务创建时间、服务描述等。其中服务描述是在服务发布时，由服务提供者为其撰写的描述文本，通常包含对服务功能特性的介绍。开发者在系

统内特指通过筛选制造服务创建服务组合，以满足复杂的制造需求的人群。在实际系统中，开发者可以是服务系统的管理和运营者，可以是第三方的用户或客户，也可以同时是制造服务提供者，在本文的讨论范围内，我们不对此做出区分，均称为开发者或用户。服务组合是指由开发者创建的，集合多个制造服务以共同满足某一个个性化制造需求的整体。每个服务组合通常包含以下信息：服务组合名称、服务组合标签、服务组合创建时间、服务组合包含服务列表、服务组合描述等。其中服务组合描述是在服务组合创建时，由开发者为其撰写的描述文本，通常包含对服务组合应用背景与设计目标的介绍。

本文中，我们将云制造服务系统定义为  $SS = (S, SD, M, MD, R)$ 。其中， $S = \{s_1, s_2, \dots, s_{SN}\}$  表示制造服务的集合， $SN = |S|$  表示云制造服务系统中制造服务的数量。 $SD_i = \{w_{i1}, w_{i2}, \dots, w_{in_i}\}$  是一个单词集合，表示服务提供者或服务  $i$  撰写的描述，其中  $w_{ik}$  表示服务  $i$  的描述中的第  $k$  个单词。 $M = \{m_1, m_2, \dots, m_{MN}\}$  表示服务组合的集合， $MN = |M|$  表示云制造服务系统中已有服务组合的数量。 $MD_j = \{w_{j1}, w_{j2}, \dots, w_{jn_j}\}$  是一个单词集合，表示开发者或服务组合  $j$  撰写的描述，其中  $w_{jk}$  表示服务组合  $j$  的描述中的第  $k$  个单词。 $R = (r_{ij})_{i=1, j=1}^{MN \times SN}$  是一个矩阵，其记录了制造服务与服务组合之间的历史使用关系， $r_{ij} = 1$  表示服务组合  $i$  使用了服务  $j$ ， $r_{ij} = 0$  表示服务组合  $i$  没有使用服务  $j$ 。

## 1.2 制造服务推荐

制造服务推荐问题是指通过识别和分析用户的个性化制造需求，利用服务推荐算法在云制造服务系统中筛选可能满足需求的制造服务，以推荐服务列表的形式展现给用户，供其进行服务组合创建。因此，制造服务推荐算法的输入为用户的个性化制造需求，通常以一段文本描述的形式给出，算法的输出为一列带有顺序的服务列表，服务在列表中的排序越靠前，代表算法认为该服务越有可能满足用户的制造需求。

在云制造服务系统  $SS$  中，我们用集合  $Q$  来表示不同用户的制造需求。对于每一个制造需求  $q \in Q$ ，一个含有  $n_q$  个单词的单词集合  $QD_q = \{w_{q1}, w_{q2}, \dots, w_{qn_q}\}$  用来表示其需求描述，也即用户输入的个性化制造需求。制造服务推荐算法针对需求  $q \in Q$  输出的带有顺序的服务列表用  $RL_q$  表示。

## 2 模型架构与场景定义

为了更好地对服务组合应用场景信息进行挖掘和组织，进而提升制造服务推荐的效果，本文提出了一种基于场景识别的云制造服务推荐模型（SRSR 模型）。本章将从模型整体架构的层面入手，

对 SRSR 模型的实现过程进行介绍。进而，基于对模型的初步理解，明确场景的具体定义、表示和特征。

## 2.1 模型架构

SRSR 模型的整体架构图如图 1 所示。SRSR 模型共分为三个步骤，模型第一步利用云制造服务系统中的各描述信息与结构信息，进行服务组合场景综合描述重构，进而得出各服务组合场景主题向量；模型第二步基于各服务组合场景主题向量进行场景聚类，将服务组合所代表的应用场景进行聚类组织，并为每类场景计算场景描述向量和建立加权服务库；模型第三步首先对用户制造需求进行向量化，进而识别用户需求的应用场景信息，最后利用各类场景加权服务库进行服务推荐，为用户推荐一系列排序的服务列表。图 1 中不同颜色的流程箭头表示模型不同的步骤，接下来我们对各步骤进行详细说明。

步骤一的主要作用在于为系统内各服务组合建立场景主题向量，以供场景聚类使用。在云制造服务系统中，每一个服务组合都对应于一个实际的制造场景，通过对各服务组合对应的场景进行识别和聚类，可以有效地对系统内的各类应用场景信息进行组织和利用。为了实现这一目的，模型首先需要对各服务组合的场景信息进行提取整合，具体而言，就是为各服务组合创建场景综合描述。事实上，各服务组合在创立的同时，开发者已经为其撰写了一份描述文档，然而该原始描述通常着重于描述该服务组合的应用背景、设计目标和实现效果，但是对于服务组合具体包含的功能模块介绍并不全面。为了构建场景综合描述，模型需要为原始服务组合描述补充功能信息描述。我们知道，各制造服务在发布时，服务提供者会为其撰写一份功能描述文档。因此，通过将服务组合所使用的各制造服务的描述引入原始服务组合描述之中，即可为原始服务组合描述补充功能信息。通过这样的方式，步骤一对各服务组合原始描述进行重构，获得各服务组合的场景综合描述。而后，模型利用 LDA (Latent Dirichlet Allocation) 主题模型<sup>[19]</sup>，将各服务组合的场景综合描述向量化，得到各服务组合的场景主题向量。

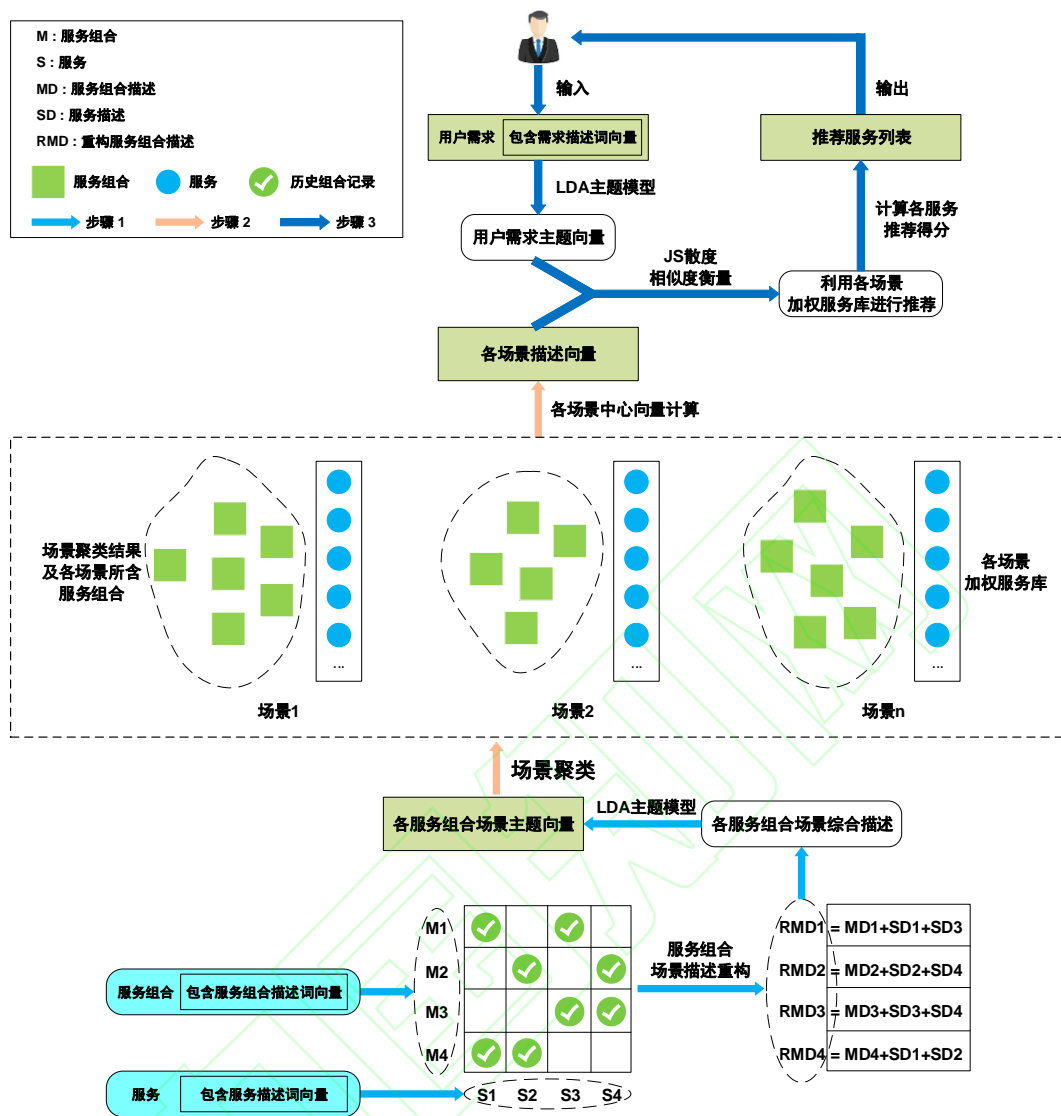


图 1 SRSR 模型整体架构

步骤一为系统内各服务组合所对应的应用场景进行了主题向量构建。由于系统内的服务组合之间可能存在相似的应用场景，也即某一些服务组合的应用场景是类似的，其满足的制造需求也是类似的，因此在步骤二中，我们对各服务组合场景主题向量进行聚类处理。通过进行场景聚类，相似的应用场景得以整合，不同的应用场景得以区分，模型实现了对云制造服务系统中各类应用场景的识别和组织。模型使用的聚类算法为改进的 K-means 聚类算法<sup>[20]</sup>，通过调整迭代终止条件和类数设置，可以使聚类效果达到最佳。聚类后获得的每一类场景均包含一系列代表性的服务组合，通过计算这些服务组合场景主题向量的中心，可以得到该类场景的场景描述向量。此外，对场景中各服务组合所使用的制造服务进行统计，可以为各应用场景建立特定的加权服务库，服务的权重即为该场景下某一服务出现的总次数与该场景下所有服务出现的总次数的比值。综上所述，步骤二实现了对

系统内各类应用场景的识别和组织，并为各场景建立了场景描述向量和加权服务库。

步骤三通过对用户制造需求进行场景识别，利用步骤二获得的各场景聚类结果和相应的加权服务库，最终实现服务推荐过程。首先，模型对用户输入的制造需求进行向量化，利用 LDA 主题模型提取用户需求主题向量。而后，模型分别计算用户需求主题向量与各场景描述向量之间的 JS 散度 (Jensen-Shannon divergence) [21]，用以衡量用户需求场景与系统内各场景的相似度，从而实现对用户需求场景的识别。最后，利用用户需求场景与系统内各场景的相似度信息，结合各场景加权服务库，计算各制造服务的推荐得分，最终为用户推荐一系列带有顺序的制造服务列表，以期满足用户的制造需求。

## 2.2 场景定义

本文提出“场景”这一抽象概念用以定义和描述服务组合的应用背景与环境属性。在服务系统中，每一个服务组合对应于实际制造业务中的一个应用背景，服务组合在这一背景与环境下，开展自身特定的功能，这一性质是服务组合的核心特性，我们使用场景的概念来表征服务组合的应用背景与环境属性。对于每一个服务组合个体而言，场景是其固有特性，但这一固有特性并不能从服务组合的显性信息中直接获取，需要算法的合理建模和挖掘。对于不同的服务组合个体之间，它们的应用场景既具有相关性又具有差异性，因此可以通过场景聚类分析的手段对服务系统中的场景信息进行组织，进而从更高的维度理解服务系统中的场景信息。

在数学上，对于服务组合个体而言，我们使用场景主题向量  $\theta_i$  表示其场景， $\theta_i$  是一个多维向量，不同服务组合个体之间场景主题向量的相似性即代表他们之间应用场景的相似性。场景主题向量  $\theta_i$  由服务组合的场景综合描述  $RMD_i$  进行 LDA 主题建模得到。由于不同服务组合之间的场景可能具有相似性，因此算法基于各服务组合的场景主题向量  $\theta_i$  对场景进行聚类，如图 1 所示，不同的服务组合可能可以聚类为一个应用场景，通过计算每一类应用场景内的服务组合场景主题向量  $\theta_i$  的中心，可以得出描述这一类场景的场景描述向量  $Center_k$ 。此外，对于每一类场景，我们为其构建了加权服务库  $Lib_k$ ，用以辅助服务推荐过程的进行。

## 3 基于场景识别的云制造服务推荐

本章中，我们将对 SRSR 模型的实现过程进行分步骤详细介绍，并给出数学计算过程。

### 3.1 服务组合场景主题向量构建

为了对各服务组合所对应的应用场景进行识别，我们利用云制造服务系统中的服务与服务组合原始描述信息与历史组合记录信息对原始服务组合描述进行重构，从而为各服务组合建立场景综合



描述。原始服务组合描述主要描述该服务组合的应用背景、设计目标和实现效果，而服务描述对于服务实现的功能给出了详细的介绍。因此，通过引入服务描述信息，可以补充原始服务组合描述中缺失的功能模块信息，进而实现服务组合场景综合描述的构建。

对于每一个服务组合  $m_i \in M$ ，根据前文定义，其历史组合记录可以由向量  $(r_{i1}, r_{i2}, \dots, r_{iSN})$  表示，其中  $r_{ij} = 1$  表示服务组合  $m_i$  使用了服务  $s_j$ 。为了建立服务组合  $m_i$  的场景综合描述，我们使用以下公式对其进行描述重构：

$$RMD_i = \sum_{j=1}^{SN} r_{ij} MD_i + \sum_{j=1}^{SN} r_{ij} SD_j \quad (1)$$

$m_i \in M$

$MD_i$  与  $SD_j$  为标准化的词向量，分别为服务组合  $m_i$  的原始描述与服务  $s_j$  的描述。式中， $\sum_{j=1}^{SN} r_{ij} SD_j$  为引入功能信息描述的过程，只有被服务组合使用的服务才会被引入进来。为了避免由于引入的服务描述过多而稀释了原始服务组合描述所包含的信息，我们为原始服务组合描述乘以一个权重因子  $\sum_{j=1}^{SN} r_{ij}$ ，也即服务组合  $m_i$  使用的服务个数。 $RMD_i$  为重构得到的词向量，也即为服务组合  $m_i$  构建的场景综合描述。 $RMD_i$  由一系列单词构成，可以表示为  $RMD_i = \{w_{i1}, w_{i2}, \dots, w_{im}\}$ 。

LDA 主题模型<sup>[19]</sup>认为一段文本的词汇生成过程是由这段文本的潜在主题所指导的，而文本的主题信息及各主题的权重可以从抽象的层面代表文本更为本质的特征。因此，本文使用 LDA 主题模型对描述文本进行建模，以期提取各描述的潜在主题特征，从而实现对描述文本的向量化，以利于后续分析使用。对于服务组合集合  $M = \{m_1, m_2, \dots, m_{MN}\}$ ，将各服务组合的场景综合描述  $RMD_i = \{w_{i1}, w_{i2}, \dots, w_{im}\}$  的生成过程建模如下：

- (1) 对于每个主题  $k = 1, 2, \dots, T$ ，
  - (a) 取单词概率分布  $\phi_k \sim \text{Dirichlet}(\beta)$
- (2) 对于每个服务组合  $m_i \in M$ ，
  - (a) 取主题概率分布  $\theta_i \sim \text{Dirichlet}(\alpha)$
  - (b) 对于每个单词  $w \in RMD_i$ ，
    - (i) 取一主题  $z \sim \text{Multinomial}(\theta_i)$
    - (ii) 取一单词  $w \sim \text{Multinomial}(\phi_z)$

式中， $T$  为主题数量， $\phi_k$  为主题  $k$  下的单词多项式分布， $\theta_i$  为服务组合  $m_i$  下的主题多项式分布， $\alpha$  和  $\beta$  分别是  $\theta_i$  和  $\phi_k$  服从的狄利克雷分布的超参数。

而后，我们应用吉布斯采样 (Gibbs sampling)<sup>[22]</sup>来推断参数  $\theta_i$  和  $\phi_k$  的取值。所得到的  $\theta_i$  是一个  $1 \times T$  的向量，记为  $(\theta_i^1, \theta_i^2, \dots, \theta_i^T)$ ，其表示服务组合  $m_i$  的场景综合描述  $RMD_i$  的主题分布。主题分布向

量  $\theta_i$  满足以下约束:

$$\sum_{i=1}^T \theta_i = 1 \quad \theta_i \in [0,1] \quad (2)$$

至此,我们实现了对各服务组合场景综合描述的向量化和主题特征提取,从而为各服务组合  $m_i$  建立了场景主题向量  $\theta_i$ 。

### 3.2 云制造服务系统场景聚类

无论是系统中已经创建的服务组合,还是用户新提出的制造需求,其均对应于某一特定的应用场景。通过对云制造服务系统中各类应用场景进行聚类组织,发现各类应用场景的特征,可以帮助系统运营者和开发者从场景的角度更好的理解制造需求。通过为每一场景建立场景描述向量和加权服务库,可以更好的刻画各场景的信息,从而提升制造服务推荐的效果。

接下来,我们采用改进的 K-means 聚类算法<sup>[20]</sup>,对各服务组合  $m_i$  的场景主题向量  $\theta_i$  进行聚类,从而实现了对服务系统的场景聚类。传统的 K-means 算法在进行聚类中心初始化时采用随机设置聚类中心的方式,然而随机设置的聚类中心往往质量较差,导致聚类结果较差或陷入局部最优解。本文认为场景主题向量之间越相似,越不可能同时成为聚类中心<sup>[23]</sup>,基于此,本文聚类中心初始化过程如下:

- (1) 随机选取一个样本点作为初始聚类中心  $Center_1$ ;
- (2) 计算每个样本点与最近的已有聚类中心的距离,该距离表示为  $D(\theta_i)$ ;
- (3) 计算每个样本点被选为下一个聚类中心的概率  $P(\theta_i)$ ,并依据该概率选择出下一个聚类中心;
- (4) 重复(2)、(3)直到选择出  $K$  个聚类中心。

其中,过程(2)采用欧氏距离计算两个样本点之间的距离,两样本点欧氏距离计算公式如下:

$$dist(\theta_i, \theta_j) = \sqrt{\sum_{i=1}^T (\theta_i - \theta_j)^2} \quad (3)$$

过程(3)中概率  $P(\theta_i)$  计算公式如下:

$$P(\theta_i) = \frac{D(\theta_i)^2}{\sum_{j=1}^{MN} D(\theta_j)^2} \quad (4)$$

过程(4)中,  $K$  为初始化设置的聚类中心个数,初始化完成后,得到的聚类中心集合记为  $Center = \{Center_1, Center_2, \dots, Center_k\}$ 。

完成聚类中心初始化后,算法通过反复迭代完成聚类过程,每次迭代过程如下:

- (1) 根据公式(3),计算每一个样本点与各个聚类中心的距离  $dist(\theta_i, Center_k)$ ;
- (2) 将每一个样本点  $\theta_i$  划分至距离其最近的聚类中心所对应的类中;
- (3) 根据划分结果,更新各类聚类中心;
- (4) 判断是否构成迭代终止条件,判断是否继续迭代。

其中，过程（3）更新各类聚类中心所采用的公式如下：

$$Center_k = \frac{1}{|C_k|} \sum_{\theta_i \in C_k} \theta_i \quad (5)$$

式中， $C_k$  表示第  $k$  类， $\theta_i \in C_k$  代表第  $k$  类中的所有样本， $|C_k|$  表示第  $k$  类中的样本个数。过程（4）中迭代终止条件有两种，一种是达到预先设置的迭代次数上限  $N_m$  时，一种是两次迭代的误差平方和准则函数  $J$  的差值  $\Delta J$  小于预先设置的阈值  $\delta$  时，即  $\Delta J < \delta$  时。如果达到两种终止条件的一种，则聚类算法停止，最后得到的各聚类中心及各样本聚类结果即为最终结果，如果没有达到终止条件，则算法继续迭代，直至达到某一迭代终止条件为止。误差平方和准则函数模型如下：

$$J = \sum_{k=1}^K \sum_{\theta_i \in C_k} dist(\theta_i, Center_k) \quad (6)$$

完成场景聚类后，我们为每个场景建立加权服务库。对于任一场景  $k$ ，服务系统中每个服务在该场景下的权重计算如下：

$$s_j\_weight_k = \frac{\sum_{m_i \in C_k} r_{ij}}{\sum_{l=1}^{SN} \sum_{m_i \in C_k} r_{il}} \quad (7)$$

式中， $m_i \in C_k$  代表聚类至场景  $k$  中的所有服务组合， $s_j\_weight_k$  表示服务  $s_j$  在场景  $k$  下的权重，若  $s_j\_weight_k > 0$ ，则将服务  $s_j$  加入场景  $k$  的服务库中， $s_j$  在场景  $k$  的服务库中的权重即为  $s_j\_weight_k$ 。通过完成对所有场景和服务的计算，即可为每一场景建立加权服务库。

至此，我们完成了服务系统场景聚类的过程和加权服务库构建的过程。通过聚类，共获得  $K$  类应用场景， $C_k$  表示第  $k$  类场景， $Center_k$  表示第  $k$  类场景的中心，也即第  $k$  类场景的场景描述向量， $Center_k$  是根据最终的聚类结果，利用公式（5）计算而得的。对于每一个应用场景  $k$ ，建立了加权服务库，记为  $Lib_k = \{s_1(s_1\_weight_k), s_2(s_2\_weight_k), \dots, s_{SN\_k}(s_{SN\_k}\_weight_k)\}$ ，其中， $Lib_k$  表示场景  $k$  的加权服务库， $s_i$  表示服务库中的各服务， $s_i\_weight_k$  为服务  $s_i$  在场景  $k$  下所对应的权重， $SN\_k$  为场景  $k$  的加权服务库中的服务数量。

### 3.3 制造服务推荐

基于前期挖掘得到的服务系统场景聚类信息、各场景描述向量和各场景加权服务库，本步骤通过对用户制造需求的场景识别，进行服务推荐。

首先，用户以自然语言的形式输入一段制造需求  $q$ ，希望系统推荐一系列服务供其进行服务组合的创建，从而满足其个性化的制造需求。需求的描述文本可以表示为一个单词集合，即

$QD_q = \{w_{q1}, w_{q2}, \dots, w_{qm_q}\}$ ，与 3.1 节类似，再次应用 LDA 主题模型和借助其中间结果  $\phi_k$  可以实现对需求描述  $QD_q$  的向量化和主题特征提取，我们称得到的主题向量  $\theta_q = (\theta_q^1, \theta_q^2, \dots, \theta_q^T)$  为用户需求主题向量，其也满足式 (2) 的约束。接下来，为进行对用户需求的场景识别，我们采用 JS 散度<sup>[21]</sup>工具对用户需求主题向量和各场景描述向量进行相似度衡量。记用户需求主题向量  $\theta_q$  与场景描述向量  $Center_k$  的 JS 散度为  $JSD(Center_k \parallel \theta_q)$ ，计算公式如下：

$$\begin{aligned} KLD(Center_k \parallel \theta_q) &= \sum_{t=1}^T Center_k^t \log(Center_k^t / \theta_q^t) \\ \theta_m &= (Center_k + \theta_q) / 2 \\ JSD(Center_k \parallel \theta_q) &= (KLD(Center_k \parallel \theta_m) + KLD(\theta_q \parallel \theta_m)) / 2 \end{aligned} \quad (8)$$

其中， $JSD(Center_k \parallel \theta_q)$  的值越小，表示用户需求主题向量  $\theta_q$  与场景描述向量  $Center_k$  的相似度越高，也即用户需求场景更可能接近于场景  $k$ 。

经过以上步骤，我们实现了对用户需求的场景识别。接下来，利用用户需求场景与各场景的相似度和各场景的加权服务库，计算服务系统中各服务  $s_i \in S$  的推荐得分  $score_i$ ，计算公式如下：

$$score_i = \sum_{k=1}^K \frac{I_{Lib_k}(s_i)}{JSD(Center_k \parallel \theta_q)} \times s_i\_weight_k \quad (9)$$

$s_i \in S$

式中， $I_{Lib_k}(s_i)$  为示性函数，当  $s_i \in Lib_k$  时， $I_{Lib_k}(s_i) = 1$ ；当  $s_i \notin Lib_k$  时， $I_{Lib_k}(s_i) = 0$ 。由于  $JSD(Center_k \parallel \theta_q)$  的值越小代表相似度越高，因此在式中取倒数。 $score_i$  表示服务  $s_i$  的推荐得分，其值越高，表示服务  $s_i$  越可能满足用户的需求。

经过对系统中所有服务  $s_i \in S$  进行推荐得分计算，最后，我们按照推荐得分  $score_i$  由高到低对所有服务进行排序，从而生成了一个推荐服务列表  $RL_q$ ，并输出给用户。至此，我们基于对服务系统和用户需求的场景识别，完成了对用户个性化制造需求  $q$  的制造服务推荐过程。

## 4 实验设计与结果分析

### 4.1 实验数据集

ProgrammableWeb.com<sup>1</sup> 是迄今为止最大的服务和组合在线资源库。虽然 ProgrammableWeb.com 并非专门的制造服务数据集，但其包含的信息、服务组合关系和拓扑结构均

<sup>1</sup> <http://www.programmableweb.com>

与制造服务数据集一致。与制造服务数据集一样，ProgrammableWeb.com 中的服务包含名称、提供者、类别、发布日期、标签和服务描述等信息；其中的服务组合包含名称、创建日期、开发者、调用服务列表和服务组合描述等信息。因此，我们采用 ProgrammableWeb.com 数据集验证制造服务推荐算法的效果。

我们爬取了 ProgrammableWeb.com 资源库上自 2005 年 9 月至 2016 年 6 月的全部服务和组合数据，共计包含服务 13269 个，服务组合 5840 个，各类描述文本总词汇量为 21891。其中，服务与服务组合的描述文本在进行实验前进行了必要的预处理和数据清洗工作<sup>[24]</sup>，如分词、停止词去除、词干提取等，处理后的描述文本被存储为词向量的形式作为算法的输入，我们称该词向量为原始描述。

## 4.2 评估指标

本文采用在推荐算法领域被广泛接受的评估指标 MAP@N (Mean Average Precision @ top N) 来评估制造服务推荐算法的推荐效果，该指标定义如下：

$$MAP@N = \frac{1}{|Q|} \sum_{q \in Q} \frac{1}{N_q} \sum_{s \in S_q} \left( \frac{n(q,s)}{r(q,s)} \cdot I(q,s) \right) \quad (10)$$

式中， $|Q|$  表示参与评估的制造需求的数量， $S_q$  为需求  $q \in Q$  实际使用的服务集合， $N_q = \min\{N, |S_q|\}$ ， $N$  代表取推荐列表的前  $N$  项进行评估。对于每个服务  $s \in S_q$ ， $r(q,s)$  表示服务  $s$  在推荐列表中的排位，将  $S_q$  中的服务按照其在推荐列表中出现的顺序排列， $n(q,s)$  为服务  $s$  在该列表中的排位。当  $r(q,s) \leq N$  时， $I(q,s)=1$ ；当  $r(q,s) > N$  时， $I(q,s)=0$ 。当  $N$  值取整个推荐列表的长度时，我们将此 MAP 值称为 MAP@J。

MAP@N 的取值范围为  $[0,1]$ ，其值越接近 1，表示推荐算法的推荐效果越好。

## 4.3 对比方法

本文选取 6 种对比方法用以和提出的推荐算法进行比较分析。

### 4.3.1 服务端主题匹配 (SDCM)

SDCM 是文献[25]中提出的推荐算法<sup>[25]</sup>，算法应用 LDA 概率模型对服务与用户需求进行建模，提取服务与用户需求的潜在主题特征，并基于主题特征的匹配展开推荐。通过对服务描述生成过程进行建模，算法推测出服务的主题概率分布  $p(t|s)$  与主题的单词概率分布  $p(w|t)$ ，并依此计算服务针

对用户需求  $q$  的推荐得分，计算公式如下：

$$SDCM(q, s_i) = \prod_{w \in QD_q} \sum_{t=1}^T p(w|t) p(t|s_i) \quad (11)$$

SDCM 仅依赖于服务端信息进行推荐，并未对服务组合的模式进行挖掘分析，本文利用该对比方法佐证挖掘服务组合模式的重要性与基于场景识别推荐的优势。

#### 4.3.2 服务组合端协同过滤 (MDCF)

MDCF 算法立足于传统的邻域协同过滤思想，其认为相似的服务组合往往倾向于使用相似的服务。MDCF 算法利用 LDA 主题模型对服务组合与用户需求进行建模，获取其主题特征向量，并依据服务组合与用户需求的主题向量相似度匹配，计算各服务的推荐得分，计算公式如下：

$$MDCF(q, s_i) = \frac{\sum_{m_j \in U(N, q)} \text{sim}(q, m_j) r_{ji}}{\sum_{m_j \in U(N, q)} \text{sim}(q, m_j)} \quad (12)$$

式中， $U(N, q)$  为与需求  $q$  相似度最高的  $N$  个服务组合的集合， $\text{sim}(q, m_j)$  计算用户需求  $q$  与服务组合  $m_j$  之间主题特征向量的余弦相似度。

#### 4.3.3 LDA+矩阵分解 (MF)

MF 算法首先利用 LDA 主题模型计算服务组合与用户需求的主题特征向量。而后，通过求解以下优化问题对矩阵  $R$  进行分解：

$$\min_{v_i} \left( \sum_j \left( \sum_i (r_{ji} - \eta_j^T v_i)^2 + \lambda \|v_i\|^2 \right) \right) \quad (13)$$

各服务推荐得分计算如下：

$$MF(q, s_i) = \zeta^T v_i \quad (14)$$

其中， $\eta_j$  和  $\zeta$  是由 LDA 模型得出的主题特征向量。

MDCF 和 MF 算法分别是传统协同过滤和矩阵分解算法的扩展方法，它们在实践中均被证明有较好的推荐效果并被广泛应用。

#### 4.3.4 基于服务领域聚类的服务推荐 (DTM)

基于服务领域聚类的服务推荐 (DTM) 是文献[26]中提出的推荐算法<sup>[26]</sup>，其意识到服务可以划分至不同的功能领域，从服务领域聚类的角度出发进行服务推荐。算法首先依据服务描述信息对服务进行功能领域聚类，将服务系统中的服务划分至不同的功能域。接下来，算法应用极限学习机 (Extreme Learning Machine, ELM) 工具分别训练需求—功能领域、功能领域—服务两个识别器，从

而实现了用户需求到所需服务的映射。DTM 模型的详细介绍、计算过程和参数设置等可参阅文献 [26]。

DTM 模型在实际应用中取得了很好的推荐效果，被广泛视为当前最先进的推荐算法之一。通过与 DTM 模型的对比，我们试图评估我们提出的 SRSR 模型与当前最优模型在推荐效果上的提升幅度，并试图分析场景识别与聚类的模式相较服务功能领域聚类的模式是否具有更强的实际意义和更好的推荐效果。

#### 4.3.5 基于服务组合描述重构的服务推荐 (SRSR\_变体 1)

该对比方法 (SRSR\_变体 1) 是本文提出的 SRSR 模型的变体。该方法省略了服务组合应用场景聚类过程，仅利用服务组合描述的功能信息重构结果进行推荐。算法前期服务组合描述重构过程、LDA 主题特征提取过程均与 SRSR 模型一致，在获得服务组合主题向量  $\theta_j$  和用户需求主题向量  $\theta_q$  后，直接应用 JS 散度衡量二者相似度，并利用该相似度信息计算各服务的推荐得分，计算公式如下：

$$score_i = \sum_{j=1}^{MN} \frac{1}{JSD(\theta_j \parallel \theta_q)} \times r_{ji} \quad (15)$$

$$s_i \in S$$

该方法作为 SRSR 模型的简化版本，其不具备场景识别与聚类的模块，但其他部分与 SRSR 模型处理相同。我们使用该方法作为对比方法，用以证明所提出的场景识别思想的有效性，并证明通过对服务系统的应用场景进行识别和组织以及对用户需求场景进行识别和匹配可以大大提升推荐算法的效果。

#### 4.3.6 基于服务组合聚类服务推荐 (SRSR\_变体 2)

该对比方法 (SRSR\_变体 2) 也是本文提出的 SRSR 模型的变体。该方法省略了服务组合描述功能信息重构的过程，以服务组合的原始描述信息作为其场景描述进行处理。算法后期应用场景识别与聚类、用户需求场景识别与匹配等过程均与 SRSR 模型一致，不同之处在于该算法直接以服务组合的原始描述信息作为其场景描述，直接进行 LDA 主题提取，并将基于原始描述提取的主题向量作为后续聚类模块的输入。

该方法作为 SRSR 模型的另一种简化版本，其不具备服务组合描述功能信息重构模块，但其他部分与 SRSR 模型处理相同。我们使用该方法作为对比方法，用以证明对服务组合的原始描述信息进行重构，也即通过补充功能信息描述为每个服务组合建立场景综合描述文本，可以提升服务组合描述的质量和信含量，进而证明建立服务组合的场景综合描述可以提升算法的推荐效果。

## 4.4 实验结果分析

### 4.4.1 实验设置

数据集中的每一个服务组合均含有其创建时间，实验中，将测试时间窗口设置为一个月，并令其逐月向前移动，当时间窗口移动到某一个月时，将当月新创建的服务组合作为测试集，该月之前创建的服务组合作为训练集。训练集中的服务组合数据参与模型训练，测试集中的服务组合数据用以测试推荐效果，其中，测试集服务组合描述文本被视为用户输入的制造需求，这些服务组合实际所使用的服务列表作为推荐算法的理论真实值。在实验中，将测试时间窗口从 2013 年 7 月逐月移动至 2016 年 6 月，共计获得 36 个 MAP@N 评估结果，而后，将这 36 个 MAP@N 结果依据各自测试集服务组合数量进行加权平均，最终将加权平均值作为各推荐算法的 MAP@N 评估结果。通过对近三年的数据逐月进行测试，实验充分评估了各推荐算法的效果，最终获得的加权平均 MAP@N 结果可用于比较各算法的推荐效果。

实验参数设置如下。在 SRSR 模型中，根据经验，设置狄利克雷分布超参数  $\alpha = 50/T$ ， $\beta = 0.01$ ，聚类算法迭代次数上限  $N_m = 500$ ，聚类算法迭代终止阈值  $\delta = 0.00001$ ；经过参数寻优，设置 LDA 模型主题数  $T = 50$ ，吉布斯采样迭代次数  $N_{iter} = 1000$ ，聚类算法聚类中心个数  $K = 35$ 。各对比方法的实验参数均设置为其最优参数。

### 4.4.2 实验示例

在本节中，我们选取一个实例来进一步说明数据集的特征和 SRSR 模型的具体训练和预测步骤。我们选取 ProgrammableWeb.com 上的服务组合“*MultCloud*”、“*Cloud Elements*”和“*Rainbow Data Sync*”为例，来直观的展示模型的执行过程，这三个服务组合都属于“企业云端文档管理”应用场景。我们以“*MultCloud*”和“*Cloud Elements*”作为训练集，以“*Rainbow Data Sync*”作为测试集。我们所利用的从 ProgrammableWeb.com 上爬虫获取的服务的数据主要有服务名称、发布日期和服务描述；服务组合的数据主要有服务组合名称、创建日期、调用服务列表和服务组合描述，以上描述均为文本形式。

首先，“*MultCloud*”和“*Cloud Elements*”的原始数据包括一段文本形式的描述，经过数据集的预处理和数据清洗工作后，可以获得两个 21891 维的描述词向量，向量的每一项代表一个单词，每一项的值代表描述文本中对应单词的出现次数。随后，算法开始服务组合描述重构过程，将“*MultCloud*”和“*Cloud Elements*”所使用的服务的描述词向量重构进入它们的原始描述词向量，特别的，“*MultCloud*”和“*Cloud Elements*”均使用了服务“*Box*”，因此“*Box*”的描述词向量会被同



时引入“*MultiCloud*”和“*Cloud Elements*”的词向量之中。经过重构后，每个服务组合获得了一个重构后的描述词向量，即场景综合描述。随后，算法利用 LDA 模型对这些词向量进行主题特征提取，进而为各服务组合建立场景主题向量，根据参数设定，服务组合的场景主题向量为 50 维向量。接下来，算法开始对所有服务组合的场景主题向量进行场景聚类，根据参数设定，所有服务组合被聚类为 35 类。由于“*MultiCloud*”与“*Cloud Elements*”的场景具有高度相似性，其中“*MultiCloud*”帮助企业实现云端移动、编辑、组合和存储文档，“*Cloud Elements*”帮助企业实现云存储、消息传递和文档共享等，因此，“*MultiCloud*”与“*Cloud Elements*”被聚类至一个场景之下。接下来，算法为每个场景计算场景描述向量和加权服务库。可以发现，“*MultiCloud*”与“*Cloud Elements*”所在的场景类别中的服务组合多是“企业云端文档管理”领域下的服务组合，因此我们可以将该场景命名为“文档管理”场景，而该场景下的服务组合很多都使用了服务“*Box*”，“*Box*”是一个企业云端文档和内容管理平台。因此，在“文档管理”场景下，“*Box*”服务在其加权服务库中拥有很高的权重，被认为很适合该场景。至此，模型完成了训练阶段的任务。

在预测阶段，“*Rainbow Data Sync*”的描述文本被作为用户需求输入到模型。同样经过预处理和 LDA 主题特征提取后，可以获得“*Rainbow Data Sync*”的 50 维主题向量。接下来，算法将“*Rainbow Data Sync*”的主题向量与 35 类场景的场景描述向量进行相似性匹配。由于“*Rainbow Data Sync*”实现的是企业在云端的数据与文档共享、同步和传输，因此经过计算后，“*Rainbow Data Sync*”与“文档管理”场景的相似性最高。而在“文档管理”场景加权服务库中，“*Box*”服务又具有最高的权重，因此在计算各服务的推荐得分后，“*Box*”服务获得了最高的分数，也就在最终的推荐服务列表中排在了第一的位置。而事实上，服务组合“*Rainbow Data Sync*”的确使用了“*Box*”服务，这证明我们的推荐结果是有意义的，也证明了所提出模型的有效性。

#### 4.4.3 结果分析

图 2 表示 SRSR 模型及对比方法 1-4 的 MAP@N 实验结果，横坐标表示  $N$  的不同取值，也即考察取不同长度推荐列表的推荐效果，纵坐标表示各算法的 MAP@N 结果。

SDCM 算法仅依赖于服务端的信息进行挖掘推荐，其通过挖掘服务描述的潜在主题特征，与用户需求进行匹配。然而，该算法并没有对服务的历史组合规律进行考虑和利用，但是服务的历史组合记录以及服务组合的描述文本中均含有大量有价值的信息，因此，SDCM 算法的效果显著差于其他对比方法。由此可见，挖掘和利用服务系统中服务组合端的信息是很有意义的，服务的历史组合记录中蕴含了丰富的价值信息。本文从服务组合端入手，构建服务系统的场景识别体系，也正依赖




图2 各推荐模型 MAP@N 结果\_1

于这些价值信息。

MDCF 与 MF 算法均利用服务组合端及服务的历史组合记录展开推荐，因此其推荐效果均优于 SDCM。然而，这两种算法将服务系统中的各服务组合均视为独立的个体，在构建推荐模型时并未对服务组合之间的潜在逻辑关系进行挖掘和利用。因此，这两种算法不能发现服务系统内部潜在的应用场景信息，其推荐模式仍停留在服务个体和服务组合个体的层面，不能从场景的角度看待用户需求 and 进行推荐，故这两种算法的推荐效果仍差于其他算法。

DTM 算法从服务系统中服务个体之间功能属性联系的角度出发，通过进行服务功能领域聚类对系统内的服务个体进行再组织，并通过对用户需求进行功能领域分解展开服务推荐。然而，DTM 算法对服务系统的组织仍停留在服务功能的层面，未能对服务系统中潜在的应用场景信息进行挖掘和管理，也不能对用户需求的应用场景信息进行很好的识别，故其推荐效果仍落后于 SRSR 模型。DTM 算法在实际应用中取得了很好的推荐效果<sup>[26]</sup>，并被广泛视为当前最先进的推荐算法之一，而本文提出的 SRSR 模型的推荐效果显著优于 DTM 算法，证明 SRSR 模型较当前最优模型在推荐效果上有显著提升，也证明了场景识别与聚类的模式相较服务功能领域聚类的模式具有更强的实际意义和更好的推荐效果。

图3表示 SRSR 模型及 SRSR 模型的两个变体模型的 MAP@N 实验结果，其横纵坐标含义与图2一致。

SRSR\_变体1模型去除了 SRSR 模型中场景识别与聚类的模块，其他部分与 SRSR 模型一致。因此该模型不能够对服务中的应用场景信息进行挖掘和组织，也不能识别用户需求的应用场景，故而从推荐效果上看，其 MAP@N 值显著低于 SRSR 模型。由此证明，本文所提出的场景识别思想具有有效性，通过对服务系统的应用场景进行识别和组织以及对用户需求场景进行识别和匹配可以




图3 各推荐模型 MAP@N 结果\_2

大大提升推荐算法的效果。此外，虽然 SRSR\_变体 1 模型与 MDCF 算法、MF 算法都是从服务组合个体层面出发展开推荐，但是因为 SRSR\_变体 1 模型增加了服务组合描述功能信息重构的过程，通过重构，为服务组合描述增添了功能信息，故其推荐效果优于 MDCF 与 MF 算法。

SRSR\_变体 2 模型去除了 SRSR 模型中服务组合描述功能信息重构的模块，其他部分与 SRSR 模型一致。因此该模型不能为原始服务组合描述补充功能信息，也即未能为服务组合建立场景综合描述，从推荐效果上看，其 MAP@N 值低于 SRSR 模型。由此证明，对服务组合的原始描述信息进行重构，也即通过补充功能信息描述为每个服务组合建立场景综合描述文本，可以提升服务组合描述的质量和信含量，进而证明建立服务组合的场景综合描述可以提升算法的推荐效果。

综合以上分析，SRSR 模型的推荐效果显著优于所有对比实验，这得益于 SRSR 模型能够从应用场景的层面理解和组织服务系统和用户需求。SRSR 模型首先对服务组合描述信息进行重构，通过补充功能描述为各服务组合建立场景综合描述文本，进而模型采用场景聚类的手段，挖掘和组织服务系统内应用场景信息，最终从场景的角度理解和识别用户需求，并利用各场景加权服务库开展服务推荐。以上过程克服了传统推荐算法不能识别服务系统及用户需求场景信息的不足，因此取得了最优的推荐效果。

表 1 中列出了 SRSR 模型及各对比方法的具体实验结果。比较 SRSR 模型与 DTM 模型结果可知，SRSR 模型推荐效果较当前最优方法提升了 6.1%，这得益于对服务系统场景信息的挖掘和利用。比较 SRSR 模型与 SRSR\_变体 2 模型结果可知，通过进行服务组合描述重构和构建服务组合场景综合描述，可以使推荐效果提升约 4.0%。比较 SRSR 模型与 SRSR\_变体 1 模型结果可知，通过对服务系统和用户需求场景信息进行识别，可以使推荐效果提升约 11.1%。

表 1 SRSR 模型及各对比方法 MAP@N 实验结果

推荐算法	MAP@5	MAP@20	MAP@J
<b>SRSR</b>	<b>54.30%</b>	<b>56.31%</b>	<b>57.12%</b>
<b>DTM</b>	48.12%	50.18%	51.02%
<b>MF</b>	40.38%	42.33%	43.17%
<b>MDCF</b>	38.49%	40.32%	41.10%
<b>SDCM</b>	9.55%	11.11%	12.36%
<b>SRSR_变体 2</b>	50.35%	52.36%	53.15%
<b>SRSR_变体 1</b>	43.40%	45.23%	46.01%

#### 4.4.4 参数讨论

$K$  为场景聚类模块执行时预先设置的聚类中心个数，该值由算法执行者设定。由于事先并不知道该服务系统当中应用场景的类别数，因此需要通过参数调整实验寻找其最优取值。如果  $K$  值设置过小，则可能将不同类的场景聚为一类；如果  $K$  值设置过大，则可能将同一个场景进行无谓的拆分，这些均会影响算法效果。图 4 表示了参数寻优的实验过程，横坐标表示  $K$  值的不同取值变化，纵坐标表示不同  $K$  值所对应的 MAP@J 指标结果，同时模型其他参数均设置为最优值。从图中可以看出，MAP@J 的变化趋势为随着  $K$  的增大而先增后减，当  $K$  值取 35 时，MAP@J 指标取得最大值，也即推荐算法效果最好。因此，我们认为该服务系统应用场景的类别数为 35，在后续实验中，均设置  $K = 35$ 。

## 5 结束语

近年来，随着云计算和 SOA 体系架构的迅猛发展，网络化制造与云制造的概念和技术均获得了




图 4  $K$  值参数寻优

广泛的关注和应用。越来越多的制造业企业开始把他们拥有的制造资源、制造能力以制造服务的形式进行封装，并发布到互联网上，构成了复杂的云制造服务系统。制造用户与开发者可以在云制造服务系统中便捷地查询、筛选和组合这些制造服务，并构建个性化的制造服务组合以满足其复杂的制造需求。通过制造服务组合的构建，系统中的服务实现了功能协作与扩展，可以快速满足更加个性化和复杂的制造需求，增强了云制造服务系统的生命力。然而，随着信息过载问题的日益严重，对精准的制造服务推荐算法的需求也日益增加。但是，现有的制造服务推荐算法研究主要聚焦于服务个体功能的层面，不能对服务系统应用场景信息进行挖掘和组织，也不能从场景识别的角度解构制造需求，这限制了服务系统与制造服务推荐算法的发展。

本文从服务系统场景信息挖掘与组织、用户需求场景信息识别与匹配的角度出发，提出了一种基于场景识别的云制造服务推荐模型（SRSR 模型）。模型首先对系统内原始服务组合描述进行功能信息重构，为每个服务组合建立场景综合描述文本。进而，SRSR 模型利用主题建模与场景聚类的方式对服务系统的应用场景信息进行挖掘和聚类，实现了从场景的角度组织和管理服务系统的信息。在识别出服务系统场景类别后，模型为各类应用场景建立了特定的加权服务库，并通过对用户制造需求进行场景识别开展服务推荐。在实际数据集上的综合实验表明，SRSR 模型用 MAP@N 指标评估的综合推荐效果较当前最优模型提升了 6.1%。

在未来的研究中，我们计划解决冷启动服务的推荐问题。随着新的制造服务的不断增加，如何对没有历史使用记录的冷启动服务进行推荐是亟待解决的问题。我们拟挖掘服务之间的协作属性关系，对冷启动服务的组合模式进行预测，进而实现对没有历史使用记录的冷启动服务的合理推荐。

## 参考文献：

- [1] LI Bohu, ZHANG Lin, WANG Shilong, et al. Cloud manufacturing: a new service-oriented networked manufacturing model [J]. *Computer Integrated Manufacturing Systems*, 2010, 16(1): 1-16 (in Chinese). [李伯虎, 张霖, 王时龙, 等. 云制造——面向服务的网络化制造新模式[J]. *计算机集成制造系统*, 2010, 16(1): 1-16.]
- [2] YI Shuping, LIU Mi, WEN Peihan. Overview of cloud manufacturing service based on lifecycle theory [J]. *Computer Integrated Manufacturing Systems*, 2016, 22(4): 871-883 (in Chinese). [易树平, 刘觅, 温沛涵. 基于全生命周期的云制造服务研究综述[J]. *计算机集成制造系统*, 2016, 22(4): 871-883.]
- [3] LIU N, LI X, SHEN W. Multi-granularity resource virtualization and sharing strategies in cloud manufacturing [M]. New York, USA: Academic Press Ltd., 2014.
- [4] ZHOU J, YAO X. A hybrid approach combining modified artificial bee colony and cuckoo search algorithms for multi-objective cloud manufacturing service composition [J]. *International Journal of Production Research*, 2017, 55(16): 1-20.

- [5] MA Wenlong, WANG Zheng, ZHAO Yanwei. Optimizing services composition in cloud manufacturing based on improved ant colony algorithm [J]. *Computer Integrated Manufacturing Systems*, 2016, 22(1): 113-121 (in Chinese). [马文龙, 王铮, 赵燕伟. 基于改进蚁群算法的制造云服务组合优化[J]. *计算机集成制造系统*, 2016, 22(1): 113-121.]
- [6] TAO F, ZHANG L, LIU Y, et al. Manufacturing service management in cloud manufacturing: overview and future research directions [J]. *Journal of Manufacturing Science & Engineering*, 2015, 137(4).
- [7] FAN Y, HUANG K, TAN W, et al. Domain-aware reputable service recommendation in heterogeneous manufacturing service ecosystem [J]. *International Journal of Computer Integrated Manufacturing*, 2015, 28(11): 1178-1195.
- [8] LI Bohu, ZHANG Lin, REN Lei, et al. Typical characteristics, technologies and applications of cloud manufacturing [J]. *Computer Integrated Manufacturing Systems*, 2012, 18(7): 1345-1356 (in Chinese). [李伯虎, 张霖, 任磊, 等. 云制造典型特征、关键技术与应用[J]. *计算机集成制造系统*, 2012, 18(7): 1345-1356.]
- [9] BUTALA P, SLUGA A. Decentralised network architecture for cloud manufacturing [J]. *International Journal of Computer Integrated Manufacturing*, 2017, 30(4-5): 395-408.
- [10] YUAN M, DENG K, CHAOVALITWONGSE W A. Manufacturing resource modeling for cloud manufacturing [J]. *International Journal of Intelligent Systems*, 2017, 32(4).
- [11] LI F, ZHANG L, LIU Y, et al. A clustering network-based approach to service composition in cloud manufacturing [J]. *International Journal of Computer Integrated Manufacturing*, 2017, 30(3): 1-12.
- [12] LI C, WANG S, KANG L, et al. Trust evaluation model of cloud manufacturing service platform [J]. *International Journal of Advanced Manufacturing Technology*, 2014, 75(1-4): 489-501.
- [13] HUANG Yun. The research on evaluation model of cloud service based on QoS and application [D]. Hangzhou: Zhejiang Gongshang University, 2013: 78 (in Chinese). [黄云. 基于 QoS 的云服务评价模型及应用的研究[D]. 杭州: 浙江工商大学, 2013: 78.]
- [14] TAO F, HU Y, ZHAO D, et al. Study on resource service match and search in manufacturing grid system [J]. *International Journal of Advanced Manufacturing Technology*, 2009, 43(3-4): 379-399.
- [15] ZHANG W Y, GUO S S, ZHANG S. Combining hyperlink-induced topic search and Bayesian approach for personalised manufacturing service recommendation [J]. *International Journal of Computer Integrated Manufacturing*, 2016, 30(11): 1-12.
- [16] ZHENG Z, MA H, LYU M R, et al. QoS-aware web service recommendation by collaborative filtering [J]. *IEEE Transactions on Services Computing*, 2011, 4(2): 140-152.
- [17] ZHANG S, ZHANG W Y, LIU J, et al. A time-aware Bayesian approach for optimal manufacturing service recommendation in distributed manufacturing environments [J]. *Journal of Manufacturing Systems*, 2013, 32(1): 189-196.
- [18] LIU Yi, FAN Yushun, HUANG Keman. Web service ecosystem model and service recommendation strategy from overall perspective [J]. *Computer Integrated Manufacturing Systems*, 2016, 22(1): 133-143 (in Chinese). [刘轶, 范玉顺, 黄科满. 全局视角下的 Web 服务系统模型及推荐策略[J]. *计算机集成制造系统*, 2016, 22(1): 133-143.]
- [19] BLEI D M, NG A Y, JORDAN M I. Latent dirichlet allocation [J]. *Journal of Machine Learning Research*, 2012, 3: 993-1022.
- [20] KANUNGO T, MOUNT D M, NETANYAHU N S, et al. An efficient K-means clustering algorithm:

- analysis and implementation [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2002, 24(7): 881-892.
- [21] LIN J. Divergence measures based on the Shannon entropy [M]. Piscataway, N. J., USA: IEEE Press, 1991.
- [22] PORTEOUS I, NEWMAN D, IHLER A, et al. Fast collapsed gibbs sampling for latent dirichlet allocation [C]// Proceedings of the 2008 ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Las Vegas, Nevada, USA: ACM, 2008: 569-577.
- [23] ARTHUR D, VASSILVITSKII S. K-means++: the advantages of careful seeding [C]// Proceedings of the 2007 Acm-Siam Symposium on Discrete Algorithms. New Orleans, Louisiana, USA: Society for Industrial and Applied Mathematics, 2007: 1027-1035.
- [24] HUANG K, YAO J, FAN Y, et al. Mirror, mirror, on the web, which is the most reputable service of them all? [C]// Proceedings of the 2013 International Conference on Service-Oriented Computing. Berlin, Heidelberg, Germany: Springer, 2013: 343-357.
- [25] LI C, ZHANG R, HUAI J, et al. A probabilistic approach for web service discovery [C]// Proceedings of the 2013 IEEE International Conference on Services Computing. Washington, D. C., USA: IEEE, 2013: 49-56.
- [26] XIA B, FAN Y, WU C, et al. Domain-aware service recommendation for service composition [C]// Proceedings of the 2014 IEEE International Conference on Web Services. Washington, D. C., USA: IEEE, 2014: 439-446.

## 作者简介:

郝予实 (1992—), 男, 吉林长春人, 博士研究生, 研究方向: 面向服务计算、云制造服务系统、服务推荐等, E-mail: haoys14@mails.tsinghua.edu.cn;

+范玉顺 (1962—), 男, 江苏扬州人, 教授, 博士, 博士生导师, 研究方向: 工作流理论与技术、面向服务计算、企业建模与企业集成等, 通信作者, E-mail: fanyus@tsinghua.edu.cn。