

学校代号 10532

学 号 S141000880

分 类 号 TP301

密 级 普通



湖南大学
HUNAN UNIVERSITY

硕士学位论文

视频推荐系统的智能算法分析与设计

学位申请人姓名 李婵娟

培 养 单 位 信息科学与工程学院

导师姓名及职称 李仁发教授 曾庆光教授

学 科 专 业 计算机科学与技术

研 究 方 向 人工智能

论文提交日期 2018 年 5 月 15 日

学校代号：10532

学 号：S141000880

密 级：普通

湖南大学硕士学位论文

视频推荐系统的智能算法分析与设计

学位申请人姓名_____李婵娟_____

导师姓名及职称_____李仁发教授 曾庆光教授_____

培 养 单 位_____信息科学与工程学院_____

专 业 名 称_____计算机科学与技术_____

论文提交日期_____2018 年 5 月 15 日_____

论文答辩日期_____2018 年 5 月 26 日_____

答辩委员会主席_____罗娟 教授_____

Intelligent Algorithm Analysis and Design of Video Recommendation System

by

Li Chanjuan

B.E.(Hunan Normal University)2014

A thesis submitted in partial satisfaction of the

Requirements for the degree of

Master of Engineering

in

Computer Science and Technology

in the

Graduate School

of

Hunan University

Supervisor

Professor Li Renfa

Professor Zeng Qingguang

May, 2018

湖南大学

学位论文原创性声明

本人郑重声明：所呈交的论文是本人在导师的指导下独立进行研究所取得的研究成果。除了文中特别加以标注引用的内容外，本论文不包含任何其他个人或集体已经发表或撰写的成果作品。对本文的研究做出重要贡献的个人和集体，均已在文中以明确方式标明。本人完全意识到本声明的法律后果由本人承担。

作者签名：

日期： 年 月 日

学位论文版权使用授权书

本学位论文作者完全了解学校有关保留、使用学位论文的规定，同意学校保留并向国家有关部门或机构送交论文的复印件和电子版，允许论文被查阅和借阅。本人授权湖南大学可以将本学位论文的全部或部分内容编入有关数据库进行检索，可以采用影印、缩印或扫描等复制手段保存和汇编本学位论文。

本学位论文属于

1、保密□，在_____年解密后适用本授权书。

2、不保密☐。

(请在以上相应方框内打“√”)

作者签名：

日期： 年 月 日

导师签名：

日期： 年 月 日

摘 要

随着互联网信息技术在全世界范围内的迅速发展，人类已经逐渐步入信息过载的时代，导致了互联网信息很难及时被感兴趣的用戶发现，信息的消费者也很难从众多的数据中找到自己真正感兴趣的内容。因此，针对用户兴趣进行网络信息推荐成为目前研究的热门课题之一。随着网络视频技术的发展、视频信息的不断丰富，如何从浩瀚的视频中，为用户推荐感兴趣的视频内容，为本文的研究重点。

本文通过用户信息、视频信息、用户对视频的评分信息等数据为用户推荐感兴趣的视频，重点分析基于 BP 神经网络的视频推荐智能算法的优缺点，提出基于蜂群智能算法优化后的 BP 神经网络和基于强化学习的 BP 神经网络的智能视频推荐算法，将这些智能算法加入到视频推荐系统中，以实现提升视频推荐系统推荐效果的目标。本文主要工作包括：

针对目前视频推荐系统中数据庞大、样本空间复杂的问题，通过分析样本中数据属性之间的相关性，应用主成分分析法(PCA)对视频推荐系统中样本空间进行降维，采用主成分数据来表示原始数据，达到减少 BP 神经网络输入层神经元个数的目标，降低了视频推荐算法的复杂度。

针对基于 BP 神经网络视频推荐算法容易陷入局部极小值，收敛速度慢的问题，提出蜂群智能算法优化后的 BP 神经网络视频推荐算法，利用蜂群智能优化算法对神经网络的权值进行优化，避免 BP 神经网络在网络权值上随意性选取导致推荐系统陷入局部最优、收敛速度慢的问题，实现全局最优的视频推荐系统。

针对基于 BP 神经网络视频推荐算法中网络隐层节点结构难以确定的问题，提出基于强化学习智能算法的 BP 神经网络视频推荐算法，通过强化学习智能算法来调整神经网络隐层的结构，增删隐层节点的数目，达到最优化的网络隐层结构的目标，实现提升视频推荐算法精度的目标。

为验证基于智能算法优化后的 BP 神经网络视频推荐效果，本文采用 Movielens 数据集对算法进行验证，并利用准确率、均方误差、混淆矩阵、交叉熵损失函数等评估参数对实验结果进行综合评估，实现提升视频推荐效果的目标。

关键词：视频推荐；蜂群智能算法；强化学习；BP 神经网络；智能算法

Abstract

With the rapid development of Internet information technology throughout the world, humanity has gradually entered the era of information overload, resulting in the Internet information is difficult to find by interested users in a timely manner, and consumers of information are also difficult to access from numerous data. Find what you really like. Therefore, the recommendation of network information for user interest has become one of the hot topics in the current research. With the development of network video technology and the continuous enrichment of video information, how to recommend interesting video content for users from the vast video is the focus of this article.

This article recommends interesting videos for users based on user information, video information, and user rating information for videos. It focuses on the analysis of the advantages and disadvantages of video recommendation intelligent algorithms based on BP neural networks, and proposes BP neural networks optimized based on bee colony intelligence algorithms. The network and the intelligent video recommendation algorithm based on reinforcement learning BP neural network add these intelligent algorithms to the video recommendation system to achieve the goal of improving the recommendation effect of the video recommendation system. The main work of this article includes:

Aiming at the problem of large data and complex sample space in the current video recommendation system, principal component analysis (PCA) is used to reduce the dimension of the sample space in the video recommendation system by analyzing the correlation between data attributes in the sample. To represent the original data, to achieve the goal of reducing the number of neurons in the input layer of the BP neural network, and to reduce the complexity of the video recommendation algorithm.

Aiming at the problem that the video recommendation algorithm based on BP neural network is easy to fall into local minimum value and the convergence speed is slow, the BP neural network video recommendation algorithm optimized by bee colony intelligence algorithm is proposed, and the weight and threshold of neural network based on bee colony intelligence optimization algorithm are used. Optimizing to avoid the random selection of BP neural network on the network weights and thresholds leads to the problem that the recommendation system falls into a local

optimum and the convergence speed is slow, and a globally optimal video recommendation system is realized.

Aiming at the problem that the structure of network hidden layer nodes in BP neural network video recommendation algorithm is difficult to determine, a BP neural network video recommendation algorithm based on reinforcement learning intelligence algorithm is proposed. By strengthening the learning intelligence algorithm to adjust the structure of neural network hidden layer, add and delete hidden layers. The number of nodes achieves the goal of an optimized network hidden layer structure and achieves the goal of improving the accuracy of the video recommendation algorithm.

In order to verify the effectiveness of BP neural network video recommendation based on intelligent algorithm optimization, this paper uses Movielens data set to verify the algorithm, and uses the accuracy, mean square error, confusion matrix, cross-entropy loss function and other parameters to evaluate the experimental results. , to achieve the goal of improving video recommendations.

Key Words : video recommendation; bee colony algorithm; intelligent agent; BP neural network; intelligent algorithm

目 录

湖南大学学位论文原创性声明与学位论文版权使用授权书	I
摘 要	II
Abstract	III
插图索引	VII
附表索引	VIII
第 1 章 绪论	1
1.1 研究背景和意义	1
1.2 国内外研究现状	2
1.2.1 国内研究现状	2
1.2.2 国外研究现状	4
1.3 本文的主要工作及章节安排	6
第 2 章 推荐系统相关理论技术基础	8
2.1 推荐系统理论基础	8
2.2 常见推荐系统方法	8
2.2.1 基于关联规则的推荐	8
2.2.2 基于内容的推荐	8
2.2.3 基于协同过滤的推荐	9
2.2.4 混合的推荐机制	10
2.3 常见智能推荐算法	11
2.3.1 线性分类算法	11
2.3.2 支持向量机算法	11
2.4 神经网络理论基础	12
2.4.1 神经元	13
2.4.2 树突	13
2.4.3 BP 神经网络算法	13
2.4.3 BP 神经网络算法优缺点	15
2.5 本章小结	17
第 3 章 基于蜂群优化后的 BP 神经网络推荐算法	18
3.1 引言	18
3.2 数据处理和特征选择	18
3.2.1 数据采集	18
3.2.3 特征选择	20

3.3 基于蜂群优化后的 BP 神经网络视频推荐算法.....	22
3.3.1 蜂群智能算法的主要思想.....	22
3.3.2 基于蜂群优化后 BP 神经网络算法详细设计.....	25
3.4 实验和分析.....	28
3.4.1 实验数据及特征提取.....	28
3.4.2 视频推荐算法实验评价指标.....	29
3.4.3 实验结果对比和分析.....	30
3.5 本章小结.....	33
第 4 章 基于强化学习的 BP 神经网络视频推荐算法.....	34
4.1 基于强化学习的 BP 神经网络算法的主要思想.....	34
4.2 基于强化学习的 BP 神经网络算法的理论基础.....	34
4.2.1 隐层节点合并与拆分.....	35
4.2.2 Q-learning 算法基本原理.....	37
4.3 基于强化学习的 BP 神经网络算法的详细设计.....	37
4.4 实验结果和分析.....	41
4.5 本章小结.....	44
结 论.....	45
参考文献.....	47
附录 A 攻读硕士学位期间获得的学术论文.....	52
附录 B 攻读硕士学位期间所参与的项目.....	53
致 谢.....	54

插图索引

图 2.1 BP 神经网络算法结构图.....	14
图 2.2 BP 神经网络算法流程图.....	15
图 3.1 数据特征提取示意图.....	19
图 3.2 蜂群智能算法流程示意图.....	25
图 3.3 基于蜂群优化的 BP 神经网络算法流程图.....	26
图 3.4 BP/GA-BP/PSO-BP/EFBP 算法准确率比较.....	31
图 3.5 BP/GA-BP/PSO-BP/EFBP 算法均方误差比较.....	32
图 3.6 BP/GA-BP/PSO-BP/EFBP 算法 FPR 值比较.....	33
图 4.1 节点合并规则示意图.....	36
图 4.2 基于强化学习的 BP 神经网络算法的实现过程示意图.....	41
图 4.3 BP/FEBP/QLBP 算法准确率比较.....	42
图 4.4 BP/FEBP/QLBP 算法均方误差比较.....	43
图 4.5 BP/FEBP/QLBP 算法的 FPR 值比较.....	43

附表索引

表 3.1 数据采集和数据类型.....	19
表 3.2 新数据特征集和数据标签.....	20
表 3.3 特征数据集各主成分情况.....	28
表 3.4 BP/GA-BP/PSO-BP/FEBP 算法交叉熵损失函数.....	32
表 4.1 BP/FEBP/QLBP 算法交叉熵损失函数.....	43

第 1 章 绪论

1.1 研究背景和意义

随着二十一世纪科技和互联网的迅猛发展，人们已经逐步进入了数据大爆炸和人工智能化时代。数据所蕴含的价值正在逐步释放，智能算法的研究和应用得当空前的提升。如何从庞大的数据中找到自身需要的有效信息，成为当今智能算法推荐系统研究的重点之一。

据相关统计研究表明，到 2020 年，全球数据使用量将达到 44ZB 左右，涵盖了经济、社会、工作、生活的方方面面，人们将处于庞大的数据时代。2015 年，中国通过了《关于促进大数据发展行动纲领》，纲领中指出要利用大数据技术为社会经济发展提供源源不断的动力，其重点是要加强信息基础建设，并构建完整的、以数据为中心的大数据产业链。这一纲领的通过也表明中国已经进入了大数据共享开放的时代^[1]。

任何事物都具有两面性，大数据时代也是一样，在提供极其丰富的信息的同时，也导致了信息的过载，这一负面影响使得用户不得不消耗大量的时间从众多信息中过滤出自己真正需要的部分。一般而言，传统的搜索引擎都是按照用户提供的关键字来进行搜索，不同的用户用同样的关键字来进行搜索时，得到的结果也都是相同的，不能满足不同用户的个性化需求。针对这个问题，研究学者们也做了相关的研究，1995 年美国的学者就提出了个性化推荐系统，该系统可以利用用户的历史记录来分析用户的喜好和需求，更好的为用户提供需要的结果^[2]。

随着个性化推荐技术的不断成熟，人工智能算法的不断发展，越来越多的推荐系统开始使用人工智能算法构建推荐算法。比如国内的淘宝、今日头条、新浪微博、网易云音乐等等，都运用了智能算法推荐技术。随着智能算法推荐技术在实际应用上不断取得成功，推荐技术也得到了飞速发展，现在的推荐技术主要可以分为三大类，一是基于内容，二是基于协同过滤，三是混合推荐。在这三种当中，第二种协同过滤智能推荐算法是目前应用最为广泛的技术，但也还是存在一些技术难点，比如数据稀疏性、冷启动、信息过期等问题^[3]。随着二十一世纪的到来，计算机软硬件技术不断发展，人工智能、机器学习等算法的实现成为可能，基于智能算法的推荐系统逐步成为当今研究者热点研究问题之一。

此外，传统的个性化推荐方法主要侧重于如何把用户的喜好同内容相关联，从而实现内容的推荐，但是其忽略了用户其他潜在属性，比如性别、年龄等特点。如果将这些特征信息成功的运用到推荐技术中，可以有效地提高推荐内容的质量，使得推荐内容更加符合用户的个性化需求。例如根据用户性别的不同，给用户推

荐不同类型的视频内容，根据年龄的不同推荐适合不同年代的视频内容等等。同时，推荐系统也是在不断变化的，用户的新增与离开，内容的更新，就算是同一用户也会随着年龄、社会阅历、家庭等因素的改变而改变自己的兴趣喜好，由此可见，潜在信息对于提高推荐内容的质量具有重要影响^[4]。

因此，本文推荐系统结合了传统推荐系统的优点，考虑了用户喜好和一些潜在属性的关联，顺从当今智能算法发展的趋势，利用了蜂群智能算法、强化学习智能算法、BP 神经网络智能算法等，设计并实现了基于视频的智能算法推荐系统，对于个性化推荐系统而言具有非常重要的作用。

1.2 国内外研究现状

推荐系统即个性化推荐系统，主要是根据用户的历史行为记录来分析其喜好，并向用户推荐与其喜好相关联的内容。目前，许多电商企业逐步重视推荐系统的应用，因为公司可以利用推荐系统实现个性化营销，从而提高整个公司的营业额，创造更多的利润收入。在学术界，也有很多国内外学者参与到推荐系统的研究中，其主要集中在以下几个方面：

（1）采集用户信息和数学建模。最初的推荐系统采集的用户信息很少，只需要简单的基础信息。现在常用的推荐系统已经不仅仅是信息的采集，而是成为了一个用户交互系统，在与用户交互的过程中充分了解用户的兴趣分布与兴趣变化，同时运用数据挖掘技术，深度发掘用户的潜在需求^[5]。

（2）推荐算法研究。一个好的个性化推荐算法必须具备推荐内容准确和效率高的特点。基于内容推荐和协同过滤推荐是最经典的两种算法，但也分别存在优缺点，因此可以综合多种推荐算法，结合各算法优点实现推荐准确率和覆盖率的提升^[6]。

（3）推荐系统评价。要提高用户对推荐系统的接受度，就需要针对系统的各个方面作出综合的评价。其中，推荐内容的准确率和可靠性是最为核心的两个评价指标，如何确定评价指标的评判标准，以及如何收集用户对推荐内容的满意程度也是需要进一步研究的问题。

（4）推荐系统实际应用。要将推荐系统与实际公司系统相结合，重点研究推荐系统与其他应用系统的集成框架^[7]。

1.2.1 国内研究现状

推荐系统第一被正式提出是在 1995 年，在推荐系统发展的过程中吸取了很多其他领域的研究成果，例如认知科学、信息检索、市场建模等都被运用于推荐系统当中，使得系统性能取得了较大提升。现在是互联网高速发展的时代，一大批新兴产业陆续出现，其中电子商务的发展尤为迅猛，随着推荐系统在电子商务中

的成功应用，各家公司和学术界也都加大了对推荐系统研究的力度。每年在 ACM 组织的会议中，对电子商务推荐系统的论文也占到了很大的比例。随着近年来 WEB2.0 技术的不断成熟，也间接的推动了个性化推荐技术的发展，用户从传统的被动接受网页内容，转变成为了网页内容的参与者^[8]。

到目前为止，国内很多网站或软件都采用了个性化推荐技术，其中较为成功的今日头条、360doc 小助手、网易云音乐等等。今日头条主要综合了用户特征、环境特征和文章自身的特征三大方面，运用机器学习技术来实现个性化推荐，有效地提高了推荐内容的准确率。360doc 小助手是利用人工智能自动建立相关文章间的关联关系，当有新文章发布时，系统通过分析新文章与用户收藏文章的相似度，以确定是否进行推荐^[9]。

自然科学基金项目：“电子商务个性化推荐系统及应用研究”项目组进行了一系列推荐系统相关的研究工作。该项目从采集用户信息和数学建模、推荐算法研究、推荐系统评价、推荐系统实际应用四个方面系统介绍推荐系统理论、方法、应用中的关键技术以及未来研究热点^[10]。

在学术研究领域，国内研究者也作出了诸多突出贡献，主要研究成果如下：

Chen H T^[11]等人通过分析非线性特征变换和广义线性算法可以应用到大规模回归和稀疏输入分类场景中，采用广义线性特征变换和深度学习相结合的深度神经网络算法，对稀疏高阶的数据集进行个性化推荐研究，并在 Google Play 上进行了验证，推荐效果很好。

Zhang H R^[12]等人通过分析传统的推荐系统主要分为推荐和不推荐的缺陷，提出概率推荐策略，采用随机森林算法对推荐系统错误分类、训练成本等进行综合考虑，通过概率的方式确定推荐行为，并在 MovieLens 数据集上进行验证，得出通过概率推荐产生推荐具有很好的推荐效果。

Zhang Y^[13]等人通过分析目前推荐系统已经逐渐成为网络、实体、社会三者之间相互联系的桥梁，提出以网络、实体、社会为核心的基于组推荐的智能推荐算法，通过对社会实体进行分组并进行评级得出基于组推荐算法具有较好的准确度和客观性。

Zhang S^[14]等人通过分析目前网络信息量的不断增长，复杂性和动态性的不断提高，以及深度学习在信息检索和推荐系统中的有效作用的现状，提出将深度学习方法应用到推荐系统中。与传统的推荐模式相比，深度学习方法具有高性能和高效率的特点，能够更好理解用户需求和数据特征。经实验证明，基于深度学习的推荐系统比传统的推荐系统具有更好的推荐效果。

Wang W^[15]等人通过介绍目前基于位置的物品推荐系统发展现状，分析基于位置的物品推荐存在用户位置采样率比较低、轨迹分类精度差、标准不统一等问题，提出连续化位置推荐算法，通过融合用户潜在特征，比如个人爱好、习惯等

因素，解决基于位置推荐系统数据稀疏性问题，并设计一种非对称的局部敏感技术，加速推荐系统进行 top-k 推荐过程，经实验表明连续化位置推荐算法具有更好的推荐效率和精度。

Zhao H^[16]等人通过分析目前协同过滤推荐算法存在数据稀疏以及冷启动的问题，提出利用矩阵分解和分解机方法对用户初始数据进行特征提取，并采用基于异构信息网络的推荐方法，对该数据集进行实验。实验表明基于异构信息网络的推荐算法具有更好的推荐效果。

目前，国内推荐系统研究正处理飞速发展的时期，越来越多研究者开始投身于个性化推荐系统的研究，包括企业研发工程师、研究机构、高校工作者甚至普通学生，个性化推荐技术是当今市场发展趋势，个性化推荐技术的研究具有非常广阔的研究空间和研究价值。

1.2.2 国外研究现状

个性化推荐最早起源与美国，经过多年的发展，已经被成功应用于企业生产经营中。在一个成熟的商业级推荐系统中，可能会存在百万级别的内容需要被推荐，而对于类似 Amazon, eBay, Youtube 这种拥有庞大用户数的应用来说，实现准确推荐的难度也会相应增加。一个高质量的个性化推荐系统可以深度发掘用户的潜力，为公司带来给多利润和价值。现在很多公司已经意识到推荐系统的重要性，并且投入了大量的资金用于研究该项技术，在美国，Netflix 公司就曾经为了提高网站内容的推荐准确率，开出了高达 100 万美元的奖励。当然，除了推荐内容的准确率之外，我们还可以从很多其他的维度来评价推荐算法的优劣，因此对算法的优化也有很多不同的角度，但是只有对整个推荐系统有一个系统的认识，才能更好地实现优化的目的。

一般而言，推荐系统包含三个重要模块，其分别是用户建模模块、推荐对象建模模块和推荐算法模块。用户建模模块主要是按照每个用户分别记录其行为，比如消费评分、购买记录、下载历史等等，其中有些信息比较容易收集到，但是对于一些关系用户隐私的信息，一般用户不太愿意提供，因此只能通过寻找其他的方式做出分析。推荐对象建模模块是通过数学建模的方式对采集到的用户行为信息进行分析，通过分析的结果可以发掘用户的潜在产品偏好和感兴趣的程度。推荐算法模块也是整个推荐系统的核心，按照编写好的推荐算法从产品集合中实时过滤出用户偏好的产品。在国外也有诸多学者开始推荐系统和应用，主要研究成果如下：

S Aciard^[17]等人通过提取用户对产品的评论、意见以及分享行为，来推测用户对产品的偏爱程度，提出基于用户评论的新型推荐系统。系统采用优先级机制对用户评论重要性进行排序，区分用户评论的重要等级，并将该方法在数码相机

数据集上验证，具有很好的推荐效果。

Le H S^[18]等人针对推荐系统中冷启动问题进行研究，通过对 MIPFGWC-CS 算法、NHSM 算法、FARAMS 算法等算法，在用户新注册时如何进行推荐的问题进行比较得出 NHSM 在一些常见的数据集上具有更好的推荐效果。

Musto C^[19]等人通过分析基于内容推荐系统现状，提出基于文本嵌入技术对文本信息进行特征提取的方法，并开发了基于内容推荐的 CBRS 框架，经实验证明基于文本内容推荐的框架具有与协同过滤和矩阵分解相似的推荐效果，尤其是在高维稀疏数据推荐场景中。

Katzman J^[20]等人通过分析目前医生和患者之间提供个性化治疗方案的场景，提出基于风险评估的深度学习推荐算法，相比传统的基于随机森林和神经网络个性化治疗方案推荐算法，基于风险评估的深度学习推荐算法能够较好的模拟患者特征和不同治疗方案之间有效性关系，同时还能有效评估该治疗方案的失败风险。

Revathy V R^[21]等人通过分析目前推荐系统中在视频、歌曲、移动应用等场景中的广泛应用，提出基于内容的协同过滤推荐系统，通过分析用户喜欢/评价行为来创建用户配置文件，并采用协同过滤方法分析用户曾经有类似喜欢/评级行为用户的行为来为用户提供个性化推荐功能，该方法已经广泛应用到诸如 Facebook 等流行网站中。

Beutel A^[22]等人通过分析目前推荐系统中往往容易忽略推荐物品所处的位置、时间、上下文信息等背景因素，因此提出嵌入上下文信息的深度神经网络推荐算法。该算法通过融入推荐物品的上下文特征信息，并将其加入到神经网络中隐藏层中，来完善目前的推荐系统的缺陷，实验证明该方法具有更高的推荐效果。

推荐技术不仅仅在学术界受到了许多学者的关注，在实际应用中，推荐系统得到了广泛的认可，并且产生了许多具有价值的应用实例，常见的应用推荐技术的推荐系统应用实例如下：

(1) TYPESTRY: 该推荐系统是施乐帕克研究中心在协同过滤技术的基础上实现的，采用自有 TQL 语言，能够完成 E-mail 的过滤和针对用户定制的个性化新闻推送，但是该系统只能适用于小客户群体，用户在查询时需要事先主动指定与自己喜好相近的用户，当客户群体变大后，该系统推荐效果不理想^[23]。

(2) ACF: ACF 系统是由美国卡耐基梅隆大学提出的主动协同过滤推荐系统，其实现原理是运用指针来标识用户之间的相关性，来达到主动的协同过滤推荐服务^[24]。

(3) GroupLens: GroupLens 系统常用来完成新闻的推荐，其原理是通过用户评分信息找到与该用户评分结果最为接近的用户，并根据权值最高的信息进行新闻内容推荐^[25]。

(4) MovieLens: 该系统是明尼苏达大学在 GroupLens 系统的基础上开发出

来的，它的评分信息采集与推荐内容的展示都是基于浏览器实现，并且跟 GroupLens 相比，MovieLens 专注于视频的推荐^[26]。

(5) Ringo: Ringo 是麻省理工学院媒体实验室为实现音乐推荐而开发的基于研究的协同过滤推荐系统。它可以自动判断某用户对某一歌曲的喜恶，并分类其评分结果，从而实现具体音乐的推荐^[27]。

(6) Video Recommender: 贝尔实验室开发了一个用于视频的协同过滤推荐系统。与 MovieLens 运用浏览器的方式不同，该系统采用 E-mail 的方式进行用户信息的采集与推荐结果的发送。

(7) FAB: FAB 是第一个混合推荐系统，由斯坦福大学开发实现，将内容推荐和协同过滤的优势进行了整合，提高了推荐到准确率。

国外推荐系统的研究比国内要早，技术也相对成熟，研究成果比国内也多；随着国外推荐系统技术的不断成熟，推荐技术的应用范围也逐渐增多，越来越多的企业、政府开始应用推荐技术进行系统开发。

1.3 本文的主要工作及章节安排

本文提出了一种基于优化后的 BP 神经网络的视频推荐智能算法，通过采用主成分分析法对数据集进行降维，采用蜂群智能算法以及强化学习等方法对 BP 神经网络进行优化并应用到视频推荐系统中，达到提高视频推荐效果的目的。基于优化后的 BP 神经网络视频推荐算法的主要工作如下：

1. 应用主成分分析法，对视频数据集进行降维，提高神经网络算法时间效率。主成分分析法是采用相关系数方法，对数据集特征向量进行相关性分析，在不丢失数据特征的前提下，提取出主要的特征向量，并以这些特征向量代表原始数据集特征参与神经网络计算，因此降低了神经网络复杂度。

2. 提出基于蜂群优化后的 BP 神经网络视频推荐算法，提高视频推荐效率。传统的 BP 神经网络算法拥有两个不足，第一个是易陷入局部极小值，第二个是算法收敛的速度较慢，采用蜂群优化算法可以解决 BP 神经网络上述问题，提升视频推荐效果。

3. 提出基于强化学习的 BP 神经网络视频推荐算法，提升视频推荐响应速度。BP 神经网络隐藏层的确定是一个很难控制的问题，通过强化学习动态调整 BP 神经网络中的隐藏层节点数，可以使得 BP 神经网络更快的收敛，达到提高视频推荐响应速度的目标。

本文主要分为四个章节，其内容安排如下：

第一章主要对论文的研究背景和意义进行介绍，详细分析了国内外推荐系统的研究现状，最后对本文的主要工作内容以及章节安排进行了陈述。

第二章主要介绍推荐系统相关技术基础以及常见的推荐系算法，分析当前推

荐系统算法存在的问题及缺陷，为本文核心研究内容奠定基础。

第三章主要介绍本文实验数据收集环境、数据特点和内容，并对数据特征进行处理，提出了基于蜂群优化后的BP神经网络视频推荐方法，对蜂群智能算法原理、BP神经网络算法原理以及算法优化过程进行了详细描述，并采用常见算法评价参数对BP神经网络、基于遗传算法的BP神经网络、基于粒子群算法的BP神经网络以及基于蜂群优化后的BP神经网络算法进行对比实验，得出基于蜂群算法优化的BP神经网络具有更好的视频推荐效果。

第四章主要介绍基于强化学习的BP神经网络视频推荐方法，利用强化学习方法对BP神经网络隐藏层进行优化，动态调整隐藏层的节点数，设计并给出了算法实现的核心流程以及对算法优缺点进行了分析，并采用算法评价参数对BP神经网络以及基于强化学习优化后的BP神经网络算法进行对比实验，得出基于强化学习优化的BP神经网络具有更好的视频推荐效果。

结论 对整篇论文内容进行了总结，并对未来论文研究方向做了展望。

第2章 推荐系统相关理论技术基础

2.1 推荐系统理论基础

在这个数据爆炸的时代，各种信息充斥着我们的生活，无论是对信息提供者还是信息需求者来说，都是机会与挑战并存。对于信息需求者，可以轻易地从互联网上获取大量的信息，但是如何从中获取自己真正需要的信息却不是一件容易的事；对于信息提供者，自己提供的信息是公司或研究者所需要的，但让自己提供的信息从海量的信息中崭露头角，也是其所面临的一个难题。推荐系统的出现为这一矛盾提供了解决的可能。推荐系统通过采集信息，行为分析以及算法推荐等步骤，最大程度将有价值的信息及时的推荐给用户，实现了二者的共赢。与传统的搜索引擎相比，推荐系统可以自动的利用用户的历史行为数据进行兴趣建模，将符合其兴趣的结果推荐给用户，而不需要用户提供明确需求。

个性化推荐的成功应用需要两个条件。第一是存在信息过载，因为如果用户可以很容易地从所有物品中找到喜欢的物品，就不需要个性化推荐了。第二是用户大部分时候没有特别明确的需求，因为用户如果有明确的需求，可以直接通过搜索引擎找到感兴趣的物品^[28]。

2.2 常见推荐系统方法

2.2.1 基于关联规则的推荐

基于关联规则的推荐的核心是挖掘出数据间的关联规则，其中最为经典的运用场景就是“购物篮问题”，美国沃尔玛超市曾经就通过分析发现，在某些特定的上下文环境中，啤酒和尿布这两种看似毫不相干的物品间存在着关联规则。因此，当发现某些产品间的潜在关联规则时，可以利用这些规则为用户提供推荐服务。

2.2.2 基于内容的推荐

为用户进行推荐服务，一般人的思维就是按照内容的相似程度进行推荐，这也是推荐系统最初的设计原理。其核心是基于推荐内容的中介数据，找出内容的关联关系，同时结合用户的历史兴趣数据，将类似的内容推荐给用户。

基于内容推荐的算法其优势在于，它能够较好的对用户的兴趣进行建模，从而实现更加准确的推荐。然而，这种推荐方式也会存在不足之处，首先，它必须对内容做出分析并且建立数学算法，而且推荐内容的好坏与算法的完整性和全面性息息相关。目前一般的应用都将关键字和标签作为最简单却也是最有效的方式

描述内容的中介数据。在对内容间的相似性进行分析时，该算法认为仅仅考虑了内容本身的属性，忽略了人的态度。这是因为算法是以用户的历史行为作为推荐的基础，而对于新用户来说缺少历史行为，即“冷启动”^[29]。

基于内容的推荐的核心在于对内容特征进行提取以及用户资料算法匹配，目前最经典的内容特征提取方法是词频-倒排文档频率的方法，用户资料算法常用的方法是机器学习以及神经网络的方法，比如：贝叶斯分类算法、决策树算法、随机森林算法以及 BP 神经网络等方法，基于内容的推荐算法可表示为如下：

$$u(c,s) = \text{score}(\text{ContentBased Profile}(c), \text{Content}(s)) \quad (2.1)$$

虽然这个方法有很多不足和问题，但它还是成功的应用在一些视频，音乐，图书的社交站点。

2.2.3 基于协同过滤的推荐

随着 WEB2.0 技术的不断成熟，各家网站也更加注重用户与网站之间的互动，在这样的背景条件下，也促使了基于协同过滤的推荐机制的提出。目前，基于协同过滤的推荐算法是推荐系统中应用最为广泛的推荐算法之一，其实现原理就是按照用户对信息的喜好，发掘出内容与内容间的关联关系，或者找出与其兴趣类似的其他用户，以此为依据进行推荐服务。协同过滤算法的基本思想是：找到与当前用户有相似的其他用户，对这些用户为参考来计算某物品或内容的效益值，让后对这些用户的效益值进行排序，把效益值较高的物品或内容推荐给该用户。基于协同过滤的推荐按照基础的不同可以分为三大类：

以用户为基础的推荐（User-based Recommendation），以项目为基础的推荐（Item-based Recommendation）和以算法为基础的推荐（Model-based Recommendation）。下面我们一个一个详细的介绍着三种协同过滤的推荐机制。

1. 以用户为基础的推荐是将用户作为基础单元，综合全体用户的信息喜好，将与某一用户喜好相近的“邻居”归为一组。现有的用户推荐通常采用“K-邻居”算法，即为当前用户找到 K 个喜好相近的“邻居”，并以这些“邻居”用户的历史喜好为基础进行推荐^[30]。

以用户为基础的协同过滤推荐机制和以统计学为基础的推荐机制在原理上大致相同，都是通过用户间的相似性和“邻居”用户组实现推荐。但是也会存在一定的差异，比如两种机制在对用户间相似性的计算方法上不同，以统计学为基础的推荐机制只运用了单个用户自身的属性，而以用户为基础的协同过滤推荐机制是建立在存在相同兴趣的两个用户在其他方面也会有相似的喜好这一假设之上，因此在计算相似性上会用到用户的历史喜好信息。

2. 以项目为基础的推荐也是利用相似性来进行推荐，但是是根据内容间的相似性，而不是用户。该方法通过分析全体用户对内容的喜好，挖掘内容之间的相

似性，再综合单个用户的历史喜好数据完成推荐。与以用户和统计学为基础的推荐机制类似，以项目为基础和以内容为基础的推荐机制也只是在计算内容相似性的算法上不相同，基于项目的机制是根据用户的历史喜好信息进行推荐，而基于内容的机制使用的是内容自身特征。

那么以用户为基础的推荐和以项目为基础的推荐哪个更好呢？这个问题在不同的应用场景中有不同的答案。对大部分网站而言，内容的数量相对于用户数要小很多，同时内容数量和内容间的相似性都较为稳定，因此这种场景下后者更加适应。而对于类似今日头条这种新闻推荐软件，则前者的效果更好，因为新闻的内容在不断的更新和变化，导致内容间的相似性不稳定。所以，场景是决定具体推荐机制的关键因素之一。

3.以算法为基础的推荐机制首先需要建立一个推荐算法，然后利用收集到的样本用户的兴趣数据对算法进行训练，最后利用算法对用户的兴趣数据做出实时推荐，其中算法是可以选择的，常见的算法有概率算法、贝叶斯算法、线性回归算法、机器学习算法等，基于概率算法的协同过滤推荐可表示为如下：

$$r(c, s) = E(r(c, s)) = \sum_{i=0}^n i \times \Pr(r(c, s) = i) | r(c, s'), s' \in S(c) \quad (2.2)$$

其中 $r(c, s)$ 表示推荐算法函数， $\Pr(c, s)$ 表示推荐概率。

基于协同过滤的推荐机制在现有的应用中最为普遍，主要得益于其具备的以下几大优势：首先这种方法可以不用对内容或者用户进行严格的建模，其次，对内容的描述不需要为机器可理解的。除了优势，这种方法也存在一些不足，第一，对新增内容和新增用户的“冷启动”；第二，用户历史喜好信息的数量和准确率对推荐结果有很大影响，因为通常采用稀疏矩阵来保存历史喜好数据，但是稀疏矩阵本身在计算上就存在一些缺陷，例如少数的错误信息会导致巨大的推荐误差等；第三，不适用于特殊兴趣的用户；第四，如果用户兴趣发生了改变，很难根据历史兴趣数据对推荐结果做出修正和演变^[31]。

2.2.4 混合的推荐机制

目前各大网站采用的推荐策略一般都不局限于某一种单一的策略，而是混合了若干种不同的方法，以实现最优结果。现在普遍采用的混合方法主要有以下几种：

加权的混合（Weighted Hybridization）：所谓加权的混合方式，即分别给予若干种推荐策略以不同的权重，并按照这些权重进行线性组合已得到一个最优的推荐结果，而这些权重的确定需要利用测试数据不断试验得到。

切换的混合（Switching Hybridization）：当面对数据量、系统运行状况、用户和物品的数目等不相同的时候，其运用的推荐策略往往也存在很大差异，因此

切换的混合方式就能够实现在对于不同的场景，可以自主地选择更合适的推荐机制。

分区的混合（Mixed Hybridization）：使用多种推荐机制，并将不同的推荐结果分不同的区显示给用户。其实，Amazon，当当网等很多电子商务网站都是采用这样的方式，用户可以得到很全面的推荐，也更容易找到他们想要的东西。

分层的混合（Meta-Level Hybridization）：综合多种推荐机制，将上一个推荐的结果作为输入，传给下一个推荐机制，实现多种推荐机制的优劣势集成，进而提高推荐的准确率^[32]。

2.3 常见智能推荐算法

2.3.1 线性分类算法

对于二分类的线性分类算法，首先通过已有样本去确定线性分类函数 $g(x) = w^T x + w_0$ 的系数，然后通过该线性算法去判断未知样本归类到具有最大判别函数的类别中；对于多分类问题的线性分类算法： $g_i(x) = w_i^T x + w_{i0}, i = 1, 2, \dots, c$ ，其中 c 表示类别数，首先通过已有样本去估算 w_i 和 w_{i0} ，然后再已该函数去判别未知样本的类别。线性判别函数的一般表达式为：

$$g_i(x) = w_i^T x + w_{i0} \quad (2.3)$$

其中 $x = \{x_1, x_2, \dots, x_d\}^T$ 是 d 维特征向量， $w = \{w_1, w_2, \dots, w_d\}^T$ 是权重向量， w_0 表示常值向量，又称阈值权^[33]。

线性分类算法实现原理比较简单，其样本训练时间不长，并且计算量也不大，但是对于推荐系统而言，系统的推荐效果会随着推荐内容不断复杂而变低。

2.3.2 支持向量机算法

支持向量机算法是建立在统计学理论基础之上的，通过将低维难于划分的数据映射到高维空间中，在高维空间中训练分类函数对样本进行分类。支持向量机有效解决了小样本、非线性以及高维数据等问题^[34]。

对于线性可分的训练集，可以在原始空间 R^n 找到超平面 $f(x) = \langle w, x \rangle + b; w \in R^n, b \in R$ 使得 $|y_i - f(x_i)| \leq \varepsilon$ ，其中 $\varepsilon > 0$ 。然后调整超平面的斜率 w 使得分类超平面与训练集 S 中任意点 (x_i, y_i) 距离尽可能大，即最大化分类平面，具体计算方法如下：

$$\begin{cases} \min \frac{1}{2} \|w\|^2 \\ st. |\langle w, x_i \rangle + b - y_i| \leq \varepsilon, i = 1, 2, \dots, n \end{cases} \quad (2.4)$$

对于非线性的支持向量机分类问题，通过引入非线性的核函数 $k(x_i, y_i) = \langle \phi(x_i), \phi(y_i) \rangle$ ，将低维空间的非线性可分的数据映射到一个高维空间中，在高维空间中做线性分类问题^[35]。支持向量机非线性分类问题表示如下：

$$\begin{cases} \min \left\{ -\frac{1}{2} \sum_{j=1}^l (a_i - a_i^*) \langle \phi(x_j), \phi(y_j) \rangle + \sum_{i=1}^l (a_i - a_i^*) y_i - (a_i - a_i^*) \varepsilon \right\} \\ \text{st. } \left| \sum_{i=1}^l (a_i - a_i^*) \right| = 0, 0 \leq a_i, a_i^* \leq c, i = 1, 2, \dots, l \end{cases} \quad (2.5)$$

支持向量机的非线性分类问题步骤如下：

(1) 首先引入非线性映射核函数 $k(x_i, y_i) = \langle \phi(x_i), \phi(y_i) \rangle$

(2) 寻找式中的最优解 a_i, a_i^* ：

$$\begin{cases} \min \left\{ -\frac{1}{2} \sum_{j=1}^l (a_i - a_i^*) \langle \phi(x_j), \phi(y_j) \rangle + \sum_{i=1}^l (a_i - a_i^*) y_i - (a_i - a_i^*) \varepsilon \right\} \\ \text{st. } \left| \sum_{i=1}^l (a_i - a_i^*) \right| = 0, 0 \leq a_i, a_i^* \leq c, i = 1, 2, \dots, l \end{cases} \quad (2.6)$$

(3) 计算

$$b = \begin{cases} y_i + \varepsilon - \sum_{i,j=1}^l (a_i - a_i^*) k(x_j, x_i), a_i \in (0, c) \\ y_i - \varepsilon - \sum_{i,j=1}^l (a_i - a_i^*) k(x_j, x_i), a_i^* \in (0, c) \end{cases} \quad (2.7)$$

(4) 计算样本 x 所检测的输出结果：

$$f(x) = \sum_{i=1}^l (a_i - a_i^*) k(x, x_i) + b \quad (2.8)$$

支持向量机算法的优点通过核函数将低维线性不可分映射到高维空间中进行线性可分，相比传统的线性分类算法，支持向量机解决了低维线性不可分的问题。但是在处理数据量比较大的数据集时，支持向量机算法训练的收敛速度比较慢，并且核函数的选择比较难以确定^[36]。

2.4 神经网络理论基础

近年来，随着全球神经网络研究热潮不断兴起，越来越多的基于神经网络科学的研究成果不断涌现，这一方面是因为神经网络科学本身取得了重大进展，更重要的是现阶段人们迫切需要人工智能途径解决计算机不够智能化的问题。通过研究人脑结构以及工作原理，不断完善神经网络算法，其中按误差逆向传播算法训练的多层前馈网络，是目前应用最为广泛的神经网络算法之一^[37]。

2.4.1 神经元

人工神经网络(ANN)是通过连接大量的处理单元(神经元)而形成的复杂的网络结构,通过对人体大脑结构的某种抽象、简化和模拟,以实现类似大脑的某些功能。

与传统的电脑相比,ANN在组织结构和实现功能方面更加类似于人体大脑,它不会机械的按照提前写好的程序依次的执行相应的步骤,而是能够动态地做出相应的调整,以实现更准确地识别或控制。人体大脑中的神经元又被称为神经细胞,也是细胞的一种,因此也具备细胞膜、细胞质和细胞核三大基本结构。但与一般的细胞不同,为了更好地完成信息的传递,需要与其他神经元建立链接,也就形成了很多突起,这些突起按照形态结构和功能又可分为轴突和树突,树突主要用来接受刺激并将冲动传入细胞体,而轴突是将神经冲动由细胞体传至其他神经元^[38]。

2.4.2 树突

树突在信息传递过程中具有重要作用。通过与轴突相连,并接收由相邻神经元传过来的化学递质,从而产生电位差,使信息通过电流的方式进行传递。对一个单独的神经元而言,可以同时具有多个树突。树突又可以分为两种,一种是兴奋型,另一种是抑制型。相互连接的神经元间的强度和极性不完全相同,并且可以动态的进行调整。基于人体大脑结构而构建的ANN网络也是利用了这一特征实现的^[39]。

2.4.3 BP 神经网络算法

BP神经网络算法是由Rumelhart等科学家在1986年提出的,它是一种按误差逆传播算法训练的多层反馈网络,主要由信息的正向传播和误差的反向传播两个过程组成。通过信息的正向传播来计算训练过程中算法的误差,通过误差的反向传播来反向修改算法中各层节点的权值和阈值,最终使得算法的误差不断降低,达到提升算法分类性能的目的。

BP神经网络常见的三层结构算法,它主要由输入层(S)、隐层(A)、输出层(R)构成,其中输入层、隐层、输出层都由若干同类神经元组成,各个层之间的神经元通过权连接,层与层之间的神经元采用互联的连接方式,层内神经元之间没有连接,其中输入层用于特征向量的输入,隐层用于网络中隐含的神经层,而输出层用于网络算法的输出^[39]。

BP神经网络算法结构如图2.1所示。




图 2.1 BP 神经网络算法结构图

如有 \$N\$ 个训练样本，对于每个神经元来说，每个训练样本在该神经元的训练误差可表示为：

$$Er = \frac{1}{2} \sum_{c=1}^L \sum_{j=1}^{n_c} (y_{cj} - \overline{y_{cj}})^2 \quad (2.9)$$

其中，\$n_c\$ 表示神经网络中各层的神经元个数，\$L\$ 表示对应的层数，\$\overline{y_{cj}}\$ 为实际输出值。因此，对于所有训练样本来说，神经网络算法的总误差可表示为：

$$E = \frac{1}{2} \sum_{r=1}^N Er \quad (2.10)$$

BP 神经网络，通过该训练误差，不断调修正神经网络算法中各层神经元（输入层-隐层，隐层-输出层）之间的连接权值，直到算法总误差降到可接受的程度，修正连接权值的公式如下：

$$w_{ij} = w_{ij} - \mu \frac{\partial E_r}{\partial w_{ij}} \quad (2.11)$$

其中，\$\mu\$ 为学习速率，\$w_{ij}\$ 表示神经元 \$i\$ 到 \$j\$ 之间的连接权值。

使用神经网络算法进行分类的主要步骤如下：对数据进行归一化、神经网络的创建、神经网络的训练和神经网络的分类。神经网络算法能够有效解决非线性、多变性的样本分类问题。BP 神经网络算法流程图如图 2.2 所示。




图 2.2 BP 神经网络算法流程图

2.4.3 BP 神经网络算法优缺点

目前 BP 神经网络算法是应用最广泛的神经网络算法，它的优势在于自学能力，不需要经验公式就能从已有数据中找出内在规律，具有逼近任意函数和非线性映射的能力，但是 BP 神经网络具有易陷入局部最小值、收敛速度慢、隐层节点难以确定等缺点，因此导致 BP 神经网络算法分类误差比较高^[40]。

BP 神经网络的主要优点如下：

1.非线性映射能力：BP 神经网络实质上实现了一个从输入到输出的映射功能，有人曾仅通过数学理论证明，任意精度的三层的神经网络可以按照任意精度逼近任何非线性连续函数。基于这一特点，使得 BP 神经网络能够有效地解决内部机制复杂的问题^[41]。

2.自学习和自适应能力：BP 神经网络在训练过程中能够发现输入数据与输出结果间的合理规则，并将这些规则转化成权值运用于网络中。

3.泛化能力：泛化能力简单的说就是将训练过程中学习到的规则成功应用于新数据的能力。因此，在对模式分类器进行设计时，不仅仅要考虑保证神经网络能够对需要分类的数据做出正确的分类，而且还要考虑之后对新模式或存在噪声的模式分类的正确率^[42]。

4.容错能力：容错能力是指在网络的某些处理单元遭受到损坏后，仍然能得到正确结果的能力，即在系统内部出现部分问题时，依然能够保证系统的正常运行。

目前，学术界有很多人都参与到了对 BP 神经网络的研究工作中，并在实践过程中，利用该网络解决了很多难题。但是也显示出了一些问题，主要包括以下几点：

1.局部极小化问题：这是 BP 神经网络经常遇到的一个问题，因为按照网络的基本原理，在训练过程中，权值的大小是随着局部改善方向而渐渐改变的，这个过程中就会使得权值收敛到局部极小点，造成训练的失败。因为初始权值对该网络非常重要，不同的初始权值也会导致最终权值收敛到不同的局部极小点^[43]。

2.算法的收敛速度慢：该算法的实质即为梯度下降算法，所以也会存在“锯齿形现象”，这就导致了算法效率低的问题。这种现象是因为优化目标函数的复杂性，使得在处理单元的输出结果在近似 0 或者 1 的时候，得到部分平坦区，而平坦区内权值的变化小，导致训练几乎停滞；除此之外，为了使网络实现 BP 算法，需要提前将每次迭代步长的更新规则告知网络，这也间接导致了算法的低效率，进而拖慢了收敛速度^[44]。

3.神经网络结构选择不：人们只能按照个人经验选择网络结构，但结构选择不当会影响网络的性能。结构过大，会导致训练时间过长，并可能产生过拟合，而结构过小，又可能会使得网络无法收敛，因此结构的选择也就显得尤为重要。

5.神经网络分类能力和训练能力的矛盾问题：分类能力即泛化能力，训练能力即自学习能力。这两者之间存在着紧密的联系，分类能力与训练能力在一定范围能呈正相关关系。但当训练能力增强到一个极限值后，训练能力越强，分类能力反而越差，即过拟合。如何避免过拟合现象的出现，也是研究 BP 神经网络的一大难点问题^[45]。

6.神经网络样本依赖性问题：BP 神经网络的逼近能力与推广能力会受到学习样本的典型性的影响，但是按照所需场景，从样本中选出典型实例构成训练数据，这也是一个难题^[46]。

综上所述，BP 神经网络本身存在诸多不足，因此本文提出基于蜂群优化后的 BP 神经网络算法，解决了 BP 神经网络容易陷入局部最优的问题，达到全局最优的目标，同时提出基于强化学习的 BP 神经网络算法，通过 Q-learning 算法来更改网络节点的影响因子，并提出网络节点的合并和分裂原则，从而解决了 BP 神经网络隐层节点结构问题，并将这些方法应用到视频推荐系统中，从而提高了视频推荐效果^[47]。

2.5 本章小结

本章主要介绍常见的推荐系统以及 BP 神经网络算法，详细阐述推荐系统相关的理论基础，并分析了常见的推荐系统的原理；同时重点阐述了 BP 神经网络算法相关理论基础和实现原理，详细分析了 BP 神经网络的优缺点，为下文提出基于优化后的 BP 神经网络算法视频推荐方法提供相关理论技术基础。

第 3 章 基于蜂群优化后的 BP 神经网络推荐算法

3.1 引言

为了提升视频推荐系统的效果，开展了基于蜂群智能算法、神经网络等算法的视频推荐系统的研究，经实验证明具有较好的效果。BP 神经网络算法是目前神经网络研究中应用最为广泛的网络算法之一，采用负梯度下降算法，有效克服了单层感知器不能解决 XOR 等问题。但是基于负梯度下降算法导致了 BP 神经网络容易陷入局部极小值，无法及时从极小值区域跳出，从而导致 BP 神经网络收敛速度变慢，甚至在某些极端情况下，无法收敛的情况。另外，在现实环境中，如何确定 BP 神经网络算法的拓扑结构，以及隐藏层的层数和神经元个数，也是当前研究的热点问题。针对 BP 神经网络陷入局部极小值导致视频推荐效果不佳的问题，本章采用了蜂群智能算法的思想，利用蜂群寻蜜源的方法，找出初始化最优的 BP 神经网络权值和阈值，以该权值和阈值对 BP 神经网络进行初始化，有效地避免 BP 神经网络初始权值和阈值随机选取导致陷入局部极小值的问题，基于蜂群优化后的 BP 神经网络算法加快了网络的收敛速度，提升了视频推荐系统推荐效果^[48]。

3.2 数据处理和特征选择

3.2.1 数据采集

本实验数据主要来自 MovieLens 1M 数据集，数据采集了 6040 个用户对 3900 部视频的评分数据，这些数据主要包含视频风格、视频的年代，用户的年龄、性别、职业、邮编以及用户对视频的评分。MovieLens 1M 数据集包含三个文件：用户评分表(rating.dat)、用户信息表(users.dat)和视频信息表(movies.dat)；其中用户评分表主要包含四列数据：用户 ID、视频 ID、用户对视频的评分以及时间戳；用户信息表主要包含五列数据：用户 ID、用户性别、用户年龄、用户职业以及用户邮编；视频信息表主要包含三列数据：视频 ID、视频名称以及视频类型。数据采集表如表 3.1 所示。

在本文实验中，主要采用用户 ID、用户性别、用户年龄、视频 ID、视频类型、视频评分这些数据。通过 python 工具包 Pandas 对原始数据进行合并提取，去掉无用或缺失的数据，同时把数据集中的文本数据转换成数字类型，比如：用户性别可以用 1 代表男性，0 代表女性等。

表 3.1 数据采集和数据类型

数据表	数据类型
用户评分表(rating.dat)	用户 ID、视频 ID、用户对视频的评分以及时间戳
用户信息表(users.dat)	用户 ID、用户性别、用户年龄、用户职业以及用户邮编
视频信息表(movies.dat)	视频 ID、视频名称以及视频类型

数据特征提取过程如图 3.1 所示：




图 3.1 数据特征提取示意图

由图 3.1 可知，新的数据集主要包含：用户 ID 特征、性别特征、年龄特征、视频 ID 特征、视频类型等具体一共 63 个特征以及用户对视频的平均评分；其中用户 ID 特征、性别特征、年龄特征、视频 ID 特征、视频类型等特征作为样本集输入，用户对视频的平均评分为数据标签；通过对推荐系统视频分类的评分和真实评分标签的检验，来判断推荐系统是否能够推荐符合用户喜好的视频，从而判断推荐系统的推荐效果。新数据特征集和数据标签如表 3.2 所示。

表 3.2 新数据特征集和数据标签

特征	视频 ID	观看该视频的男生数	观看该视频的女生数	观看该视频各年龄段 (18,25,35,45,50, 56)人数	视频主次类型等 63 个
标签	用户对该视频的平均评分				

3.2.3 特征选择

特征选择是进行数据处理非常重要的步骤之一，好的特征选择方法可以有效提高算法的实现效果，如何进行特征选择，剔除无效特征集，减少特征数量，同时保留样本特征信息是本节的研究重点。本节主要采用主成分分析法，通过对特征空间的相关系数矩阵进行计算，分析各个成分的相关性，有策略地选择可以代表其他特征的主要特征集，并用这些特征集作为神经网络算法的输入来进行神经网络算法的建立和分类，有效降低了神经网络算法建模的维数，提高了算法分类的时间效率。主成分分析法的步骤如下^{[49][50]}：

数据集合 $X = \{x_{ij}, i=1, \dots, n, j=1, \dots, m\}$ ，其中 n 表示数据集中的样本数， m 表示每个样本拥有的特征数，因此构成了一个 $n \times m$ 的矩阵。

$$X = [x_{ij}]_{n \times m} = \begin{bmatrix} x_{11}, x_{12}, \dots, x_{1m} \\ x_{21}, x_{22}, \dots, x_{2m} \\ \dots, \dots, \dots, \dots \\ x_{n1}, x_{n2}, \dots, x_{nm} \end{bmatrix} \quad (3.1)$$

1. 求相关系数矩阵

设 $\tilde{x}(i=1, 2, \dots, n, j=1, 2, \dots, m)$ 是中心标准化的观测数据，其中 $\bar{x}_j$ 是变量 x_j 的样本均值， SD_j 是变量 x_j 的样本标准差。则：

$$\tilde{x}_{ij} = \frac{x_{ij} - \bar{x}_j}{SD_j} \quad (3.2)$$

$$\bar{x}_j = \frac{1}{n} \sum_{i=1}^n x_{ij} \quad (3.3)$$

$$SD_j = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_{ij} - \bar{x}_j)^2} \quad (3.4)$$

经过上述中心标准化以后得到新的中心化标准矩阵为：

$$\tilde{X} = [\tilde{x}_{ij}]_{n \times m} = \begin{bmatrix} \tilde{x}_{11}, \tilde{x}_{12}, \dots, \tilde{x}_{1m} \\ \tilde{x}_{21}, \tilde{x}_{22}, \dots, \tilde{x}_{2m} \\ \dots, \dots, \dots, \dots \\ \tilde{x}_{n1}, \tilde{x}_{n2}, \dots, \tilde{x}_{nm} \end{bmatrix} \quad (3.5)$$

通过样本相关矩阵计算公式，得到中心化标准矩阵的相关系数矩阵：

$$R = \frac{1}{n-1} \tilde{X}^T \tilde{X} = \begin{bmatrix} r_{11}, r_{12}, \dots, r_{1m} \\ r_{21}, r_{22}, \dots, r_{2m} \\ \dots, \dots, \dots, \dots \\ r_{m1}, r_{m2}, \dots, r_{mm} \end{bmatrix} \quad (3.6)$$

$$\text{其中相关系数矩阵 } r_{ij} = \frac{\sum_{k=1}^n (x_{ki} - \bar{x}_i)(x_{kj} - \bar{x}_j)}{\sqrt{\sum_{k=1}^n (x_{ki} - \bar{x}_i)^2 \sum_{k=1}^n (x_{kj} - \bar{x}_j)^2}}。$$

2. 计算特征向量与特征值

由特征向量和特征值计算方法可知，特征方程如下：

$$|\lambda I - R| = 0 \quad (3.7)$$

解该方程得到特征值 $\lambda_i, i=1, 2, \dots, m$ 以及与特征值相对应的特征向量 $e_i, i=1, 2, \dots, m$ ，其中 $\|e_i\|=1$ 。

3. 主成分分析

对相关系数矩阵 R 进行特征分解，得到 $R = U \Lambda U^T$ ，其中 Λ 是由 R 的特征值 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m \geq 0$ 组成的对角阵， U 是由 R 的标准正交化的特征向量按列并排组成的正交阵，它是由主成分 $Z_1, Z_2, \dots, Z_m$ 表示原变量 $\tilde{X}_1, \tilde{X}_2, \dots, \tilde{X}_m$ 时的系数矩阵：

$$\begin{cases} \tilde{X}_1 = u_{11}Z_1 + \dots + u_{1m}Z_m \\ \dots \\ \tilde{X}_m = u_{m1}Z_1 + \dots + u_{mm}Z_m \end{cases}, \text{ 即 } \begin{bmatrix} \tilde{X}_1 \\ \dots \\ \tilde{X}_m \end{bmatrix} = U \begin{bmatrix} Z_1 \\ \dots \\ Z_m \end{bmatrix} \quad (3.8)$$

解该方程可得主成分 $Z = U^T \tilde{X}$ ：

$$\begin{cases} Z_1 = u_{11}\tilde{X}_1 + \dots + u_{1m}\tilde{X}_m \\ \dots \\ Z_m = u_{m1}\tilde{X}_1 + \dots + u_{mm}\tilde{X}_m \end{cases} \quad (3.9)$$

4. 计算主成分贡献率和累计贡献率

特征值 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m$ 的大小反映了主成分 $Z_1, Z_2, \dots, Z_m$ 对原变量贡献的大小，其中 λ_j 为第 j 个主成分 Z_j 的贡献率， λ_j 为前 j 个主成分的累计贡献率。当累计贡献率达到 85%~95% 的特征值 $\lambda_1, \lambda_2, \dots, \lambda_m$ 所对应的第 1、第 2、... 第 m 个成分作为主成分。

5. 计算主成分贡献矩阵 A 、主成分 Z_p 的累计贡献率 b_p 以及累计贡献率达到 85% 的主成分矩阵 $Z_{\geq 0.85}$ 。

$$A = \frac{1}{\sum_{i=1}^m \lambda_i} \begin{bmatrix} \lambda_1 & & \\ & \dots & \\ & & \lambda_m \end{bmatrix} \quad (3.10)$$

$$b_p = \frac{\sum_{i=1}^p \lambda_i}{\sum_{i=1}^m \lambda_i} \quad (3.11)$$

$$Z_{\geq 0.85} = (U^T \tilde{X})_{\geq 0.85} \quad (3.12)$$

由以上步骤可知，主成分分析法通过比较各特征向量的贡献率来对特征集进行排序，把贡献率在某个阈值的特征向量从特征集中抽取出来，组合成新的特征空间，来作为神经网络的输入数据。主成分分析法用较少的数据指标来表示原来的高维的信息，降低了数据维度，减少了神经网络输入向量的维数，减少神经网络输入数据的复杂性，简化网络结构，提高网络计算速度。

3.3 基于蜂群优化后的 BP 神经网络视频推荐算法

3.3.1 蜂群智能算法的主要思想

蜂群智能算法(Artificial Bee Colony Algorithm, ABC 算法), 是由 Karaboga 小组提出为了解决多变量函数优化问题而提出的。蜂群智能算法是模仿蜜蜂寻找蜂蜜的行为出发, 通过人工蜂不断对蜜源进行优劣比较, 引入正负反馈机制对局部最优解进行调整, 最终得出全局最优解的过程。算法具有较快的收敛速度以及鲁棒性, 并且能够和其他算法进行结合使用。基本的蜂群智能算法主要包含三个部分: 雇佣蜂、非雇佣蜂以及蜜源, 非雇佣蜂又包含两个部分: 侦查蜂和观察蜂; 其中雇佣蜂主要用于搜索采集蜜源, 然后把存储在雇佣蜂身上的蜜源信息分享给其他蜜蜂, 雇佣蜂、观察蜂、蜜源是两两对应的关系, 当当前蜜源在预先设定的次数之内处于停滞状态, 且不是当前全局最优时, 则放弃该蜜源, 雇佣蜂转变成侦查蜂重新搜索蜜源。非雇佣蜂主要负责寻找蜜源和蜜源决策, 其中侦查蜂负责随机搜索初始蜜源, 观察蜂负责通过雇佣蜂分享的所有信息对蜜源优劣进行决策, 当搜索到的蜜源为优质蜜源时, 会形成正反馈; 当搜索到的蜜源为劣质蜜源时, 会形成负反馈。越优质的蜜源吸引观察蜂的概率越大, 因此, 越是优质的蜜源, 越容易被观察蜂选择; 观察蜂选择蜜源后并在其邻域寻找新的蜜源, 若找到更优的便会反馈给雇佣蜂修改信息; 直到循环迭代结束, 输出全局最优蜜源^[51]。

蜂群智能算法在进行过程中将蜂蜜分为三种: 雇佣蜂、侦查蜂以及观察蜂。其中雇佣蜂是明确与蜜源有关系的蜜蜂, 它能够将蜜源信息与其他蜜蜂进行分享;

观察蜂是根据雇佣蜂的分享信息作出选择的蜜蜂，主要是判断蜜源优劣问题；侦查蜂是对蜜源进行随机搜索。

首先，算法随机初始 S 个蜜源，则雇佣蜂/侦查蜂数量=观察蜂数量= S ，侦查蜂随机搜索产生一组蜜源后便转变成雇佣蜂，雇佣蜂通过邻域搜索寻找更优的蜜源，采集并将蜜源信息存储起来；当雇佣蜂采集蜂蜜返巢时，会将蜜源信息通过一定方式分享给观察蜂；观察蜂则通过对雇佣蜂分享的这些蜜源作出决策，如果该蜜源为优质蜜源则派出蜜蜂进行采集，否则不去采集；

其次，当雇佣蜂不断分享蜜源信息，观察蜂对蜜源的优劣做出决策，越来越多的蜜源信息会被观察蜂加入到“蜜源信息表”中，当某个蜜源经过有限次迭代后不再更新信息，则会抛弃该蜜源（极小值），雇佣蜂转而变成侦查蜂去寻找其他蜜源；

然后，随着算法迭代循环，观察蜂获取的蜜源信息会不断增多，优质的蜜源会派出更多的蜜蜂进行采集，形成正反馈，劣质的蜜源会不断被抛弃，形成负反馈，直到蜂群算法达到指定的迭代次数，取出蜜蜂汇聚最多的蜜源，即“全局最优解”[52]。

通过对蜂群智能算法基本思想进行分析可知，雇佣蜂的数量可以代表解的数量，蜜源的位置可代表问题一个可能的解，蜜源对应采集的蜂蜜数量代表该解是否最优。因此蜂群智能算法其实就是不断迭代寻优的求解过程，其主要步骤如下：

(1) 初始化阶段

向量空间 $X = \{x_m, m=1,2,\dots,S; n=1,2,\dots,N\}$ 表示整个问题空间，蜜源位置 $x_m (m=1,2,\dots,S)$ 表示优化问题中的解， $x_{mi} (i=1,2,\dots,N)$ 表示目标函数 $f(x)$ 最小化的参数组合数。有上述定义可知，侦查蜂随机初始产生蜜源的过程可表示为：

$$x_{mi} = l_i + rand(0,1) * (u_i - l_i) \quad (3.13)$$

其中 u_i 和 l_i 分别表示 $x_{mi} (i=1,2,\dots,N)$ 的上界和下界。

(2) 雇佣蜂操作

雇佣蜂会根据初始化位置对当前位置 x_{mi} 上周边蜜源 $v_{mi} (i=1,2,\dots,N)$ 进行搜索，然后对搜寻到的新蜜源进行评价并计算新蜜源的适应度，同时雇佣蜂通过贪婪选择算法选择更优的解，雇佣蜂搜索新蜜源的方式以及搜索到新蜜源 $v_{mi} (i=1,2,\dots,N)$ 的适应度计算公式可表示为：

$$v_{mi} \leftarrow x_{mi} + \gamma \Phi_{mi} (x_{mi} - x_{ki}) \quad (3.14)$$

$$fit_m(x_m) = \begin{cases} \frac{1}{1 + f_m(x_m)}, & f_m(x_m) \geq 0 \\ 1 + abs(f_m(x_m)), & f_m(x_m) < 0 \end{cases} \quad (3.15)$$

其中 Φ_{mi} 是一个在 $[-1,1]$ 之间的随机数, x_{ki} 为随机选择的蜜源, 自适应因子 γ 表达式如下:

$$\gamma = \gamma_{\min} + (fitv(i) - fit_{\min}) \times (\gamma_{\max} - \gamma_{\min}) / (fitv_{vag} - fit_{\min}) \quad (3.16)$$

其中: $fitv(i), fitv_{vag}, fit_{\min}$ 分别为雇佣蜂当前的适应度、平均适应度以及群体最小适应度值; $\gamma_{\max}, \gamma_{\min}$ 分别表示最大与最小自适应因子值。在蜂群迭代过程中, 初始阶段搜索需要较大的搜索步长, 即要较大的自适应因子; 当雇佣蜂接近最优蜜源时, 则要进行精细化搜索即减少自适应因子, 因此引入自适应因子 γ 提高蜂群算法动态搜索的性能。

(3) 观察蜂操作

观察蜂会根据雇佣蜂分享的蜜源信息以概率 P_m 的形式进行决策, 概率越大则蜜源被选中的概率越大, 观察蜂进行蜜源决策时, 概率计算方法如下:

$$P_m = \frac{fit_m(x_m)}{\sum_{m=1}^S fit_m(x_m)} \quad (3.17)$$

其中, P_m 表示蜜源被观察蜂选中的概率; 若蜜源被观察蜂概率选中, 则会派出更多的蜜蜂对该蜜源进行采集; 并且通过邻域搜索寻找更优蜜源, 若找到则通知原先的雇佣蜂修改信息; 若蜜源在事先约定次数下一直都未被观察蜂选中或者蜜源陷入停滞状态, 则放弃该蜜源, 雇佣蜂转变成侦查蜂重新初始化蜜源。随着蜂群搜索不断进行, 优质蜜源会被越来越多蜜蜂进行采集, 劣质蜜源会不断被抛弃。

(4) 侦查蜂操作

初始化时, 侦查蜂会对蜜源进行随机搜索, 若侦查蜂搜索到蜜源, 则转变为雇佣蜂进行蜜源采集; 其次, 当雇佣蜂分享完当前搜索到的蜜源信息, 若该蜜源在有限次内没有更新, 雇佣蜂会放弃该蜜源, 进而转变成侦查蜂, 用随机搜索到的新蜜源替代当前蜜源^[53]。

蜂群智能算法的流程图如图 3.2 所示。蜂群智能算法采用“蜜蜂寻蜜”的思想, 不断搜索蜜源(解)并进行适应度计算, 多次迭代后寻找到全局最优解; 本章采用蜂群智能算法的思想对 BP 神经网络的初始权值和阈值进行优化, 降低神经网络陷入局部极小值的可能, 提高 BP 神经网络收敛速度。




图 3.2 蜂群智能算法流程示意图

3.3.2 基于蜂群优化后 BP 神经网络算法详细设计

基于蜂群优化后的 BP 神经网络算法（FEBP 算法）是采用蜂群智能算法的思想，通过雇佣蜂、观察蜂以及侦查蜂对蜜源进行搜索过程的原理进行深入研究，将蜂群寻蜜源的思想融入到 BP 神经网络中。

通过蜂群智能算法的迭代思想，以最优的权值和阈值初始化 BP 神经网络中各层节点（输入层-隐层，隐层-输出层）的权值和阈值，减少了 BP 神经网络迭代寻优的时间，降低了 BP 神经网络陷入局部最优的风险。不断地更新 BP 神经网络权值和阈值使得 BP 神经网络的误差会达到设定的阈值，算法既可以终止。

基于蜂群优化后的 BP 神经网络具有精度高、误差小、收敛速度快等优点，能够有效解决 BP 神经网络陷入局部最优解的历史问题。通过应用基于蜂群优化后的 BP 神经网络算法在视频推荐系统中，可以具有更好的视频推荐效果，提升用户感知^[54]。本小节主要介绍基于蜂群优化后 BP 神经网络算法(以下简称为：FEBP 算法)的详细设计过程，FEBP 算法的流程图如图 3.3 所示：




图 3.3 基于蜂群优化的 BP 神经网络算法流程图

基于蜂群优化后的 BP 神经网络算法主要包含两个过程：主成分分析法对样本特征集进行降维，利用主要成分来代替原来的数据集；其次是利用蜂群智能算法对权值和阈值进行优化，获取最优的权值和阈值，防止 BP 神经网络随机选择权值和阈值带来的问题；根据上述算法流程图，基于蜂群优化后的 BP 神经网络算法伪代码如下：

算法：蜂群优化后的 BP 神经网络算法（FEBP）

Input: $X_{mi}, m=1,2,\dots,S; i=1,2,\dots,N$ 为初始蜜源；

S 表示解的个数， N 表示优化参数的数目；

l_i, u_i 为参数的上下边界；

Min 表示雇佣蜂转变成侦查蜂前的迭代次数；

Max 表示算法迭代的最大次数；

Threshold 为神经网络的误差阈值；

Output: 蜂群优化后的 BP 神经网络 *FEBP*

Steps:

对样本进行主成分分析，将主成分作为神经网络的输入；

计算相关系数矩阵： $R = \text{corrcoef}(X)$ ；

计算累计方差贡献率： $\text{sum}(\text{sum}(\text{lambda}R(1:i,1:i),2),1) / X_{\text{sum}}$ ；

侦查蜂随机初始产生蜜源： $x_{mi} = l_i + \text{rand}(0,1) * (u_i - l_i)$ ；

for ($j=1$ to Max)

雇佣蜂进行蜜源邻域搜寻： $v_{mi} \leftarrow x_{mi} + \gamma \Phi_{mi}(x_{ki} - x_{mi})$ ；

并进行适应度评价选择更优蜜源： $\text{fit}_m(x_m) = \begin{cases} \frac{1}{1 + f_m(x_m)}, & f_m(x_m) \geq 0 \\ 1 + \text{abs}(f_m(x_m)), & f_m(x_m) < 0 \end{cases}$ ；

观察蜂进行蜜源选择并进行邻域搜索： $P_m = \frac{\text{fit}_m(x_m)}{\sum_{m=1}^S \text{fit}_m(x_m)}$ ；

若蜜源经过 Min 次迭代陷入停滞状态，抛弃该蜜源，雇佣蜂转变成侦查蜂重新搜索蜜源替代先前蜜源；

当算法达到迭代次数 Max ，跳出循环；

end

根据蜂群智能算法计算出的最好蜜源位置，即神经网络算法的权值和阈值；

用该权值和阈值初始化神经网络参数以及网络结构；

while (误差 > Threshold)

for(每个权值 w_{mi})

计算权值增益 Δw_{ij} ；

更新权值： $w_{ij} = w_{ij} + \Delta w_{ij}$ ；

end

计算神经网络的误差；

end

常见的 BP 神经网络优化算法有：遗传算法、粒子群算法等，其中遗传算法适合求解离散型问题，但是存在汉明悬崖问题；粒子群算法适合求解实数问题，算法简单，但是存在局部最优问题；而利用蜂群算法优化 BP 神经网络，寻找最优的网络权值和阈值，可兼有神经网络的泛化映射能力和蜂群算法的全局迭代及局部搜索的特点，相比其他算法具有更好的优化效果^{[55][56]}。

3.4 实验和分析

本文实验主要采用 Python 工具语言进行原始数据处理、算法实现以及进行实验，利用 MATLAB 工具对实验结果进行对比分析；Python 语言是一种面向对象的解释型计算机语言，具有强大的库，比如：机器学习库 `sklearn-learn`，方便广大开发者完成各类程序；MATLAB 是一款用于数据分析、数据可视化、算法开发以及数值计算的高级计算机语言和交互式环境，具有强大的可视化功能，适用于本实验结果对比分析。

3.4.1 实验数据及特征提取

本节主要介绍基于蜂群优化后的 BP 神经网络视频推荐算法，实验采用 MovieLens 1M 数据集，可以得到 6040 个用户对 3900 个视频评价的数据集，其包含：用户数据集、视频数据集以及用户对视频评分的数据集；将这三个数据集通过 Python 工具进行合并得到一个包含用户 ID、视频 ID、用户年龄、用户性别、视频类型、用户对视频评分的数据集。然后对该数据集进行特征提取，特征提取的方式如下：特征集以视频 ID 为列向量，把观看过该视频的用户的评分的平均值作为该视频 ID 的标签，即真实值；然后提取观看过该视频的用户的年龄、性别、类型等数据的特征，主要包含的特征有：平均年龄、最大年龄、最小年龄、总人数、男性数、女性数、男女数的差距、各年龄段数目以及他们的方差、标准差、中位数等数据，作为该视频的特征数据集，当特征提取完毕后将无效的视频数据特征样本从特征数据集中进行删除，得到最后有效的特征数据集为 1966*63 个，再采用主成分分析法对特征数据集进一步处理，利用相关系数矩阵，求出特征值和特征向量，再求出各特征的贡献率，当特征集中某些特征的累计贡献率达到 85% 时，即选取这些特征作为主成分矩阵中的数据，具体主成分矩阵的计算过程已在 3.2.3 节中给出，最终通过计算得到用户对视频的评分的主成分特征集如表 3.3 所示：

表 3.3 特征数据集各主成分情况

主成分	贡献率(%)	累计贡献率(%)
视频 ID	15.6	15.6
视频主类型	18.5	34.1
视频次类型	16.1	46.2
用户各年龄段数目(6 列)	22.3	69.5
用户男性数	8.2	77.7
用户女性数	8.1	85.8

通过上表可以看出视频 ID、视频类型以及用户性别和年龄等特征的累计贡献率达到了 85.8%（超过 85%），因此可以用这 11 个参数作为神经网络的输入，将

非主成分从特征空间集中删除。由此可得，主成分特征集的数据集大小为 1966×11 ；然后对主成分特征数据集进行随机化处理，前一部分数据集 1000×11 作为训练集，后一部分 966×11 作为测试集；利用新的特征空间进行算法训练，可以在一定程度上减少算法训练的时间，提高算法精确度和时间效率。当新的特征空间集生成之后，就可以用新的特征空间集检验基于蜂群优化后的 BP 神经网络视频推荐算法。基于蜂群优化后的 BP 神经网络针对 BP 神经网络容易陷入局部最优的问题，通过优化 BP 神经网络初始化权值和阈值的方式，避免 BP 神经网络陷入局部最优的问题；目前，常用的 BP 神经网络局部优化算法有基于遗传算法优化的 BP 神经网络(GA-BP)以及基于粒子群优化的 BP 神经网络(PSO-BP)，本文将对以上算法进行对比分析。

3.4.2 视频推荐算法实验评价指标

为了有效验证基于蜂群优化后的 BP 神经网络视频推荐算法实验结果的有效性，比较不同算法的推荐性能，需要对算法的推荐输出值和真实值进行评估，常见的算法分类性能评估方式主要有：准确率（Accuracy）、均方误差 MSE（Mean Squared Error）、混淆矩阵、交叉熵损失函数、精确率（Precision）和召回率（Recall）等，本文主要采用准确率、均方误差、交叉熵损失函数、精确率、召回率以及 F1_score 这些评估参数对各个算法进行评估，假设 y_i 是第 i 分类样本的真实类别， y'_i 是第 i 个样本的分类类别，样本集为 n_{sample} ，则以上评估参数相关介绍和具体计算公式如下：

准确率（Accuracy）：准确率是用来衡量样本分类正确所占的比例，则在 n_{sample} 样本集上准确率为：

$$accuracy = \frac{1}{n_{sample}} \sum_{i=1}^{n_{sample}} L(y_i' = y_i) \quad (3.18)$$

其中 $L(x)$ 是指示函数，用来表示分类值和真实值是否相等，若分类结果和真实结果为完全相同时，则准确率为 1，当分类结果和真实结果越不相符时，准确率就越低。

均方误差 MSE（Mean Squared Error）：均方误差是衡量算法分类值和真实值之间的“平均误差”，主要用来评价数据变化程度的一种方法，均方误差越小表示数据变化的程度越小，即分类的数据与真实值越接近。均方误差又称 l_2 范数损失（ $l_2-norm loss$ ），均方误差的计算公式如下：

$$MSE(y, y') = \frac{1}{n_{sample}} \sum_{i=1}^{n_{sample}} (y_i - y'_i)^2 \quad (3.19)$$

交叉熵损失函数：交叉熵损失函数(cross-entropy cost function)是神经网络里面常用来衡量分类值和真实值之间接近度的重要标志之一，可以用来评估当前训

练得到的概率分布与真实分布的差异情况。交叉熵损失函数计算方法如下：

$$C(y_i, y'_i) = -\frac{1}{n_{sample}} \sum_{i=1}^{n_{sample}} (y_i \ln(y'_i) + (1 - y_i) \ln(1 - y'_i)) \quad (3.20)$$

其中 y_i 表示真实分布， y'_i 表示算法计算后的分类分布。由该式可知，交叉熵具有非负性，并且该值越小表示算法分类值与真实值越接近，相比方差损失函数，交叉熵损失函数具有权重更新、训练速度更快的特点。

精确率和召回率：精确率（Precision）和召回率（Recall）其中精确率主要用于反映推荐到用户喜欢的项目数量和所有推荐项目数量的比值；召回率主要反映在推荐系统中被推荐的项目中有多少使用感兴趣的项目，它的计算公式是通过推荐项目中用户感兴趣的项目个数除以用户所有感兴趣的项目的总个数。假设模型真正的样本集合为 A ，模型输出的正样本集合为 B ，则有：

$$\begin{cases} Precision(A, B) = \frac{|A \cap B|}{|B|} \\ Recall(A, B) = \frac{|A \cap B|}{|A|} \end{cases} \quad (3.21)$$

另外，我们有时候需要对精确率和召回率进行权衡，因此需要计算 F_β 分数。 F_β 分数计算公式如下：

$$F_\beta = (1 + \beta^2) \frac{precision * recall}{\beta^2 * precision + recall} \quad (3.22)$$

当 $\beta=1$ 时，称为 F_1 分数，常用于分类和信息检索中。

基于蜂群优化后的 BP 神经网络视频推荐算法，因采集数据复杂，实验结果分类较多，因此简单的用准确率和均方误差来检验实验结果可信度不高，所以本文还通过交叉熵损失函数、F1_score、Precision、Recall 对各算法推荐效果进行综合对比，验证算法的精确性和鲁棒性；其中可以交叉熵损失函数反映算法对视频评分的分类能力，然后将各类算法应用到个性化推荐中，系统利用用户年龄、性别等特征，以及优化后的 BP 神经网络模型来判断该用户对电影的评分，通过评分进行排序，可以得到该用户评分高的视频，然后为用户推荐高分(≥4 分)的视频，然后利用 F1_score、Precision、Recall 这些参数来检验应用各种算法的个性化推荐系统的推荐效果，得出应用基于优化后的 BP 神经网络具有其他推荐系统更好的视频推荐效果。

3.4.3 实验结果对比和分析

基于优化后的 BP 神经网络视频推荐算法，主要采用了 MovieLens 1M 数据集，利用数据集中的视频的 ID、用户的 ID、视频的类型、用户性别、用户年龄以及用户对视频的评分等数据进行一系列实验。在进行实验之前，首先把实验数据进

行了处理，提取了数据特征，比如：评价某视频的男性数目、女性数目、各个年龄段的人数、平均年龄等等，通过提取视频特征、用户特征以及视频类型这些特征，利用主成分分析法对特征集进行降维，再对这些数据用用户对该视频的评分进行标记，再将数据集分成训练集和测试集，并用 BP 神经网络、基于遗传算法的 BP 神经网络、基于粒子群优化的 BP 神经网络以及基于蜂群优化后的 BP 神经网络分别进行训练和测试。最后再通过准确率、均分误差、交叉熵损失函数等参数对各个算法的分类结果进行综合比较和评估，利用 MATLAB 工具对实验结果进行比较分析和可视化展示，得出基于蜂群优化后的 BP 神经网络算法(FEBP 算法)对相比传统的 BP 神经网络算法具有更好的视频分类效果，从而应用基于蜂群优化后的 BP 神经网络的推荐系统，将可以更加精确地根据用户特征对用户喜爱的视频进行评分分类；若视频分类的评分越高，表示用户对该视频的就越喜好，因此，可以将评分高的视频推荐给该用户，达到提高视频推荐系统的精度目标。




图 3.4 BP/GA-BP/PSO-BP/FEBP 算法准确率比较

准确率主要反映算法对样本分类的准确度，当分类的结果与真实的结果越靠近，准确率的值就越大，算法的准确率就越好。BP 神经网络算法、GA-BP 算法、PSO-BP 算法以及 FEBP 算法准确率实验结果如图 3.4 所示，由图可知，FEBP 算法对用户评分的分类的准确率要高于传统的 BP 算法、GA-BP 算法以及 PSO-BP 算法，其中基于蜂群优化后的 BP 神经网络算法(FEBP)相比传统的 BP 神经网络算法的视频推荐准确率提高了 11.2%，在测试样本集比较小的情况下，基于蜂群优化后的 BP 神经网络算法比 GA-BP 以及 PSO-BP 算法具有较低的准确率，但是随着样本测试的不断增多，基于蜂群优化后的 BP 神经网络算法对视频评分的分类准确率相比 BP、GA-BP 以及 PSO-BP 算法的准确率分别提高了 12.14%、8.97%、5.13%。

图 3.5 比较了 BP 神经网络算法、GA-BP 算法、PSO-BP 算法以及 FEBP 算法的 MSE（均方误差）。均方误差可以定性判断算法对样本集分类的“平均误差”，均方误差越小，代表样本分类误差越低。由图 3.5 可知，FEBP 算法对视频评分分类的均方误差 MSE 的值，相比传统 BP 神经网络算法、GA-BP 算法、PSO-BP 算法的均分误差分别降低了 11.41%、5.93%和 2.41%；由此可知，基于蜂群优化后的 BP 神经网络对视频评分的分类比其他算法具有更低的平均误差，但是仅仅从准确率和均方误差上判断 FEBP 算法对视频评分的分类还不够具有说服力，准确率和均方误差表现更好的算法，只能说明算法的整体分类精度高，在现实网络中，用户对视频的评分是主观个性化的事件，因此需要更精细的指标对用户评分分类算法进行检验，目前使用较多的精细指标有：F1_Score、Precision、Recall 以及交叉熵损失函数等，本文采用交叉熵损失函数这些指标对用户评分分类结果进行评价，采用 F1_Score、Precision、Recall 对推荐系统的推荐效果进行评价。




图 3.5 BP/GA-BP/PSO-BP/FEBP 算法均方误差比较

结合神经网络算法的相关知识，采用交叉熵损失函数用来衡量算法的鲁棒性。基于用户评分及视频类型的推荐系统的各算法的交叉熵损失函数实验结果如表 3.5，由表可知，基于蜂群优化后的 BP 神经网络算法对用户评分分类的鲁棒性相比传统的 BP 神经网络算法、GA-BP 算法、PSO-BP 算法分别提高了 9.53%、5.07%和 3.85%，

表 3.4 BP/GA-BP/PSO-BP/FEBP 算法交叉熵损失函数

算法	BP 算法	GA-BP 算法	PSO-BP 算法	FEBP 算法
交叉熵	0.2958	0.2819	0.2783	0.2676

通过这些评价参数能在一定程度上反映了各种算法的精度，误差和各类样本

分类等情况，衡量的推荐系统中视频评分的检测效果，为了验证算法对推荐系统的作用，本文采用了 F1_Score、Precision、Recall 对推荐系统的推荐效果进行评价。基于蜂群优化后的 BP 神经网络算法的 F1_Score、Precision、Recall 如图所示：




图 3.6 BP/QA-BP/PSO-BP/FEBP 算法 FPR 值比较

由图可以看出，基于蜂群优化的 BP 神经网络算法对用户的推荐用户感兴趣的视频（评分 ≥ 4 分的视频为用户感兴趣视频）精确率、召回率以及 F1_score 都比传统的 BP 神经网络、QA-BP 算法以及 PSO-BP 算法都要好；其中 FEBP 算法的 F1_score 相对传统的 BP 神经网络、QA-BP 算法以及 PSO-BP 算法分别提高了 32.08%、24.74%以及 3.35%。

3.5 本章小结

本章主要介绍基于基于蜂群优化后的 BP 神经网络的视频推荐算法的详细设计和实现，详细介绍了 MovieLen 数据集采集内容以及数据集特征选择过程，重点分析了主成分分析法、蜂群智能算法、BP 神经网络算法的算法流程，利用主成分分析法对用户视频评分的样本特征基进行降维，选取贡献率高的主要的样本特征集对算法进行训练和测试，提高了模型的时间效率；详细设计了基于蜂群优化后的 BP 神经网络的视频推荐算法，采用蜂群算法的思想对 BP 神经网络算法的初始权值和阈值参数进行优化，防止 BP 神经网络陷入局部最优的问题，提高了算法对视频评分分类检测的能力；最后本章采用实验对 FEBP 算法分类及推荐效果进行验证，采用了与其他常见的 BP 神经网络局部最优问题的优化算法进行实验对比，得出 FEBP 算法具有更高的视频推荐效果。

第4章 基于强化学习的BP神经网络视频推荐算法

BP神经网络隐层节点结构的确定一直是BP神经网络算法的难题之一，在以前的实验研究中，人们主要靠经验方法手工对神经网络隐层节点进行分配，通过不断尝试得到最优的隐层数。由神经网络算法原理可知，随着神经网络层数的增加，分类精度也会逐渐增加，但是实际上随着神经网络层数不断增多，网络结构会变得很复杂，反而会导致网络的分类效果降低。目前已有研究证明，三层的神经网络结构能够逼近任意精度的非线性连续函数，因此通过改变神经网络层数达到提高分类精度的目的已经变得不再重要，反而通过调整隐层节点数以及节点的影响因子来提高神经网络分类精度，逐渐成为神经网络优化的热点问题。目前，越来越多的研究者开始利用各种算法对神经网络隐层节点数以及节点影响因子进行优化，本文采用基于强化学习的方法对BP神经网络隐层节点结构进行优化，提升BP神经网络分类精度，从而达到提升视频推荐效果的目的^[57]。

4.1 基于强化学习的BP神经网络算法的主要思想

基于强化学习的BP神经网络算法的主要思想是采用分层优化思想，对输入层与隐层，隐层与输出层进行分层优化，根据神经网络中隐层节点相关性以及样本集平均误差和，通过事先约定的规则，计算隐层节点之间的相似度，根据相似度的不同，对隐层节点进行合并或删减，不断调整隐层节点的数据，并在增删隐层节点数目的同时，根据相应的规则更新隐层节点的权值，得到隐层节点数和权值优化后的神经网络结构；采用Q-learning强化学习算法的思想，利用Q-learning强化学习中的Q值思想，对节点影响因子进一步进行分析，把节点过去经验通过累计的方法，累计到Q值中，并用该值作为“奖励值”对节点影响因子进行调整，使得神经网络能够具备以往优化的“经验知识”，加快了神经网络收敛速度，最终获取最优化BP神经网络算法。

相比传统的BP神经网络，基于强化学习的BP神经网络算法不仅收敛速度快，时间开销比较少，而且更容易找到全局最优解，分类精度也更高。

4.2 基于强化学习的BP神经网络算法的理论基础

基于强化学习的BP神经网络算法是借助相关性概念对神经网络隐层节点进行有策略的合并和删减，利用Q-learning强化学习算法思想对隐层节点影响因子进行调整优化以及BP神经网络算法基本思想进行构建。算法采用了分层优化思想（隐层-输出层、输入层-隐层），对各层节点之间连接的权值进行调整，把算

法整体的平均误差和降到最低，提升了 BP 神经网络算法分类效果。本节主要介绍基于强化学习的 BP 神经网络算法相关的理论知识，为接下来的算法详细设计奠定理论基础。

4.2.1 隐层节点合并与拆分

1. 节点的相关系数计算

假设 y_{pi} ， y_{pj} 分别为隐层节点 i 和节点 j 的实际输出值， y_{pi} ， y_{pj} 的平均值分别用 u_{pi} ， u_{pj} 表示，标准差分别用 SD_{pi} ， SD_{pj} 表示，则节点 i 和节点 j 之间的相关系数可表示为：

$$c_{ij} = \frac{\text{cov}(y_{pi}, y_{pj})}{\sqrt{\text{var}(y_{pi}) \text{var}(y_{pj})}} = \frac{\sum_{p=1}^P (y_{pi} - u_{pi})(y_{pj} - u_{pj})}{SD_{pi} SD_{pj}} \quad (4.1)$$

2. 节点的合并规则

通过相关系数计算之后，会得到各节点之间的相关性，当 i, j 的相关系数大于某个阈值时，就可以将这节点 i 和节点 j 合并成隐层中新的节点 $\hat{ij}$ ，并更新新隐层节点 $\hat{ij}$ 与输入层节点 m 之间的连接权值，更新方法如下：

$$w'_{m\hat{ij}} = (\eta_i w_{mi} + \eta_j w_{mj}) / 2 \quad (4.2)$$

其中 w_{mi} 和 w_{mj} 分别代表输入节点 m 与节点 i 和节点 j 之间的原始连接权值， η_i 和 η_j 分别表示节点 i 和节点 j 的影响因子，同时还要更新新隐层节点 $\hat{ij}$ 与输出层节点 n 之间的连接权值，权值更新方法如下：

$$w'_{\hat{ij}n} = \eta_i w_{in} + \eta_j w_{jn} \quad (4.3)$$

其中 w_{in} 和 w_{jn} 分别表示节点 i 和节点 j 与输出节点 n 之间的原始连接权值， η_i 和 η_j 表示同上，至此节点合并规则以及权值更新完成。节点合并规则示意图如图所示：




图 4.1 节点合并规则示意图

3. 节点拆分规则

与节点合并规则不同，节点拆分是在神经网络算法经过一段时间的训练之后，当算法训练误差变化低于某个阈值时，才开始进行节点拆分，即：

$$E(t) - E(t + \tau) \leq \xi \quad (4.4)$$

其中 $E(t)$ 表示某个时刻下的误差， τ 表示训练周期， ξ 为阈值。

对已经通过一定训练的神经网络算法隐层节点进行拆分可以更快的找到目标函数，提高神经网络分类效果。假设有隐层节点 i ，拆分为新的隐层节点 i_1 ， i_2 ，输入层与输出层连接权值更新规则如下：

$$w'_{mi_1} = (1 + \varphi)\eta_i w_{mi} \quad (4.5)$$

$$w'_{mi_2} = (-\varphi)\eta_i w_{mi} \quad (4.6)$$

$$w'_{i_1n} = (1 + \varphi)\eta_i w_{in} \quad (4.7)$$

$$w'_{i_2n} = (-\varphi)\eta_i w_{in} \quad (4.8)$$

式中 $\varphi \in (-1, 0)$ ，其他各变量表示内容同上。

4.2.2 Q-learning 算法基本原理

Q-learning 强化学习算法主要思想是对状态 State 和采取的行为 Action 进行综合评价，通过对每个状态下采取的行为后的 Q 值和奖励 Reward 值进行计算，并更新 Q 值表和 Reward 值，得出当前状态下收益最大的行为组合。

Q 值函数的更新公式为：

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha(r_{t+1} + \lambda \max_{a'} Q(s_{t+1}, a') - Q(s_t, a_t)) \quad (4.9)$$

其中 α 是学习速率(learning rate)， λ 是折扣因子(discount factor)，由公式可以看出，学习速率 α 越大，保留之前的训练效果就越少。折扣因子 λ 越大， $\max_{a'} Q(s_{t+1}, a')$ 的作用就越大，即算法在训练“记忆”中具有较好的效果的行为。由此可知，Q-learning 算法不仅对当前状态有一定的保留，还具有一定程度上“预感”某个行为对当前状态具有更好的可能^[58]。

Q-learning 算法流程如下：

初始化折扣因子 λ 和奖励 Reward 矩阵 R ，令 Q 值等于 0。

a. 对于每一次探索动作 episode：

b. 随机选择一个初始状态 s

c. 若未达到目标状态，则执行以下几步：

在当前状态 s 的所有可能行为中选取一个行为 a ；

并利用选定的行为 a 得到下一个状态 $\tilde{s}$ ；

按照 Q-learning 算法计算 $Q(s, a)$ 值

令 $s = \tilde{s}$ ，继续循环操作；

Q 值矩阵计算完成之后，则可以很容易从任意状态 s_0 出发找到目标状态的行为路径。其主要步骤如下：

a. 令当前状态 $s = s_0$ ；

b. 确定行为 a 使得 $Q(s, a) = \max_{\tilde{a}} \{Q(s, \tilde{a})\}$ ；

c. 令当前状态 $s = \tilde{s}$ ；

循环 b、c 两步，使得 s 达到目标状态。

4.3 基于强化学习的 BP 神经网络算法的详细设计

基于强化学习的 BP 神经网络算法(QLBP 算法)主要由两部分组成：一部分是神经网络结构优化，另一部分是影响因子的强化学习。这两部分优化分别通过神经网络 agent 和强化学习 agent 来完成的，其中神经网络 agent 优化是采用分层优化算法根据输入层与隐层、隐层与输出层之间权值进行训练和调整，降低神经网络平均误差和；影响因子的优化是采用 Q-learning 强化学习的方法思想，通过 Q

值的不断调整来完成影响因子的优化。

假设有一个三层前向神经网络，训练样本的个数 P ；输入层、隐层和输出层节点数分别为 M, H 和 N ；理想输入向量和期望输出层向量分别是 $X_p (p=1, 2, \dots, P)$ 和 $T_p = (t_{p1}, t_{p2}, \dots, t_{pN})$ ，其中 $p=1, 2, \dots, P$ ；网络的实际输出层向量 $O_p = (o_{p1}, \dots, o_{pN})$ ，其中 $p=1, 2, \dots, P$ ；隐层节点 i 和输出层节点 j 之间的连接权值为 w_{ij} ；输入层节点 k 和隐层节点 i 之间的连接权值为 w_{ki} ；节点 m 影响因子为 η_m ；神经网络的传递函数为函数： $f(x) = 1/(1+e^{-x})$ ； $x_{pk}, p=1, 2, \dots, P; k=1, 2, \dots, K$ 表示样本 p 在节点 k 的输入向量； $y_{pi}, p=1, 2, \dots, P; i=1, 2, \dots, H$ 表示样本 p 在节点 i 的输出向量；样本集的平方和误差为： $E = \frac{1}{2P} \sum_{p=1}^P \sum_{n=1}^N (t_{pn} - o_{pn})^2$ 。基于强化学习的 BP 神经网络算法主要步骤如下：

1. 隐层与输出层之间权值 w_{ij} 调整优化

由上述定义可知，输出节点 j 的理想输出为 t_{pj} ，估计输出值为 o'_{pj} ；则权值优化的目的即是估计输出值 o'_{pj} 比实际输出值 o_{pj} 更接近目标值 t_{pj} ，权值优化可表示为：

$$o'_{pj} = o_{pj} + (t_{pj} - o_{pj}) \times \kappa \quad (4.10)$$

其中 $\kappa \in (0, 1)$ ，当 κ 值越接近于 1，表示估计值与目标值越接近，当 κ 值越接近于 0 表示估计值与目标值越远，因此隐层与输出层之间的权值优化目标通过不断调整隐层 H 的节点数目，使得 κ 值越接近于 1。设更新后的权值为 w'_{ij} 则节点 j 估计值可表示为：

$$o'_{pj} = f\left(\sum_{i=1}^H w'_{ij} y_{pi}\right) = f\left(\sum_{i=1}^H (w_{ij} + \Delta w_{ij}) y_{pi}\right) \quad (4.11)$$

因 $f(x) = 1/(1+e^{-x})$ ，将该式代入上面方程求解可得：

$$\sum_{i=1}^H \Delta w_{ij} y_{pi} = f^{-1}(o'_{pj}) - f^{-1}(o_{pj}) = \ln \frac{\kappa \times t_{pj} + (1-\kappa) \times o_{pj}}{1 - [\kappa \times t_{pj} + (1-\kappa) \times o_{pj}]} - \ln \frac{o_{pj}}{1 - o_{pj}} \quad (4.12)$$

令 $f^{-1}(o'_{pj}) - f^{-1}(o_{pj}) = \phi_{pj}$ ，求解 ϕ_{pj} 可得， $\sum_{i=1}^H \Delta w_{ij} y_{pi} = \phi_{pj}$ ，即：

$$\begin{pmatrix} \Delta w_{1j} \\ \Delta w_{2j} \\ \dots \\ \Delta w_{Hj} \end{pmatrix} = \begin{pmatrix} y_{11} & \dots & y_{1i} \\ y_{21} & \dots & y_{2i} \\ \dots & \dots & \dots \\ y_{p1} & \dots & y_{pi} \end{pmatrix}^{-1} \begin{pmatrix} \phi_j \\ \phi_{2j} \\ \dots \\ \phi_{pj} \end{pmatrix} \quad (4.13)$$

根据样本集的平方和误差为： $E = \frac{1}{2} \sum_{p=1}^P \sum_{n=1}^N (t_{pn} - o_{pn})^2$ 最小化原则，可以得到 Δw_{ij} 的近似解：

$$\Delta w_{ij} = \sum_{p=1}^P \phi_{pj} \times y_{pi} / \sum_{p=1}^P (y_{pi})^2 \quad (4.14)$$

通过上述步骤，即可计算出隐层节点 i 与输出层节点 j 的权值变化与样本实际输出值和估计值的关系（与 κ 相关），因此可以根据输出集和估计集之间平方和误差来确定隐层节点数目，即只需要在区间 $[1, H]$ 选择最优的隐层节点数，使得样本集平方和误差 E 最小即可。

2. 输入层与隐层之间权值 w_{ki} 调整优化

当样本集平方和误差变化率 $\Delta E = 0$ 时，即神经网络算法陷入了局部最小值状态，如何让神经网络跳出局部最小值状态而找到全局最优，则需要对输入层与隐层之间的权值做进一步优化^[59]。输入层与隐层之间权值 w_{ki} 的求解如下：

$$\begin{cases} \eta_i f(\sum_{k=1}^M w_{ki} x_{pk}) = y_{pi} \\ \eta_i f(\sum_{k=1}^M (w_{ki} + \Delta w_{ki}) x_{pk}) = y_{pi} + \Delta y_{pi} \end{cases} \quad (4.15)$$

其中 $\eta_i \in [0, 1]$ 为隐层节点 i 的影响因子，其他变量同上，求解该方程可知：

$$\sum_{k=1}^M \Delta w_{ki} x_{pk} = f^{-1}\left(\frac{y_{pi} + \Delta y_{pi}}{\eta_i}\right) - f^{-1}\left(\frac{y_{pi}}{\eta_i}\right) \quad (4.16)$$

令 $f^{-1}\left(\frac{y_{pi} + \Delta y_{pi}}{\eta_i}\right) - f^{-1}\left(\frac{y_{pi}}{\eta_i}\right) = \sigma_{pi}$ ，将 $f(x) = 1 / (1 + e^{-x})$ 代入上式可得：

$$\Delta w_{ki} = \sum_{p=1}^P \sigma_{pi} \times x_{pk} / \sum_{p=1}^P (x_{pk})^2, k = 1, 2, \dots, N \quad (4.17)$$

3. 影响因子 η_i 的调整优化

隐层节点 i 的输出为： $y_i = \eta_i f(\sum_{k=1}^M w_{ki} x_{pk})$ ；输出层节点 j 的实际输出为：

$o_{pj} = f(\sum_i w_{ij} \eta_i f(\sum_k w_{ki} x_{pk}))$ ，将 $f(x) = 1 / (1 + e^{-x})$ 与上述两式合并求解，可以得到影响因子的变化如下：

$$\begin{aligned}
 \Delta \eta_i &= -\mu \frac{\partial E}{\partial \eta_i} = -\mu \frac{\partial E}{\partial o_{pj}} \frac{\partial o_{pj}}{\partial \eta_i} = -\mu \frac{\partial [\frac{1}{2} \sum_{p=1}^P \sum_{j=1}^N (t_{pj} - o_{pj})^2]}{\partial o_{pj}} \frac{\partial o_{pj}}{\partial \eta_i} \\
 &= \mu \sum_{p=1}^P \sum_{j=1}^N (t_{pj} - o_{pj}) o_{pj} (1 - o_{pj}) w_{ij} f(\sum_i w_{ki} x_{pk}) \\
 &= \mu \sum_{p=1}^P \sum_{j=1}^N (t_{pj} - o_{pj}) o_{pj} (1 - o_{pj}) y_{pi} w_{ij} / \eta_i
 \end{aligned} \tag{4.18}$$

由上述公式可知，影响因子 η_i 的增量与权值 w_{ij} 成正比，因此当权值达到最优的时候影响因子不一定是最优；影响因子最优时，权值不一定最优；所以本文采用 Q-learning 算法对影响因子进行优化，为了简化计算，强化学习更新公式采用以下方式进行：

$$Q_i(t+1) \leftarrow Q_i(t) + \alpha(r_i(t) - Q_i(t)) \tag{4.19}$$

其中 $r_i(t)$ 是实际累计奖励， $Q_i(t)$ 是 $r_i(t)$ 的参考奖励， $\alpha \in (0,1]$ 是学习率(或学习步长)；对于每一步 *episode*，考察实验中 t 时刻的实际累计奖励 $r_i(t)$ 和参考奖励 $Q_i(t)$ 的偏差值，并用该偏差值乘以学习率 α (或学习步长)；若实际累计奖励 $r_i(t)$ 和参考奖励 $Q_i(t)$ 偏差越大，则 $Q_i(t)$ 的下一步更新 $Q_i(t+1)$ 就越大；通过多次循环得到更新后的参考奖励表，通过该表既可以找到累计奖励值最大的 Q 值路径。设隐层节点的影响因子 η_i 符合高斯分布，则影响因子的更新公式如下：

$$\eta_i(t+1) = \eta_i(t) + (1 - e^{-(r_i(t) - Q_i(t))^2})(r_i(t+1) - Q_i(t+1)) \tag{4.20}$$

当 $r_i(t) > Q_i(t)$ 时，则更新影响因子。将 Q-learning 算法中更新的 Q 值作为神经网络算法的训练数据，利用前一时刻的 $Q_i(t)$ 值和当前时刻的 $Q_i(t+1)$ 值作为神经网络的训练数据去调整神经网络的影响因子；利用神经网络的输出计算实际累计奖励值 $r_i(t)$ ，然后利用式 4.19 去更新 $Q_i(t+1)$ 值；从而达到利用 Q-learning 算法调整神经网络权值和误差的目的。随着算法的迭代不断继续，会使得神经网络的权值不断逼近 Q-learning 算法的状态-行为值函数^[60]。

4. 算法优化终止条件

算法优化如果不限终止条件，将会导致训练算法过拟合等现象，这样反而会导致算法分类误差增大，因此还需要对神经网络算法优化设置终止条件，终止条件如下^[61]：

- 目标函数值出现预定次数的无优化现象；
- 达到预定的循环次数；
- 在连续两个周期内，误差不减反增，即： $E(t) < E(t+T)$

当算法训练过程中出现上述现象中的一个条件，就终止算法训练过程。

基于强化学习的 BP 神经网络算法首先通过随机化的方法创建 BP 神经网络，然后采用分层优化的思想对输入层-隐层，隐层-输出层之间的权值进行优化，使得神经网络样本集平方和误差不断降低；其中，分层优化的方法降低了神经网络陷入局部最小值的可能，提高了神经网络收敛的速度；然后为了实现对隐层结构进行自动化调整，引入了隐层节点的影响因子参数以及根据相关系数进行节点合并和删除规则，通过 Q-learning 强化学习的算法对隐层节点的影响因子进行优化，根据目标奖励值和实际奖励的关系，来调整隐层节点的影响因子，降低神经网络的样本集平方和误差，并设定一个隐层节点影响因子阈值；然后，根据隐层节点影响因子阈值，将低于影响因子阈值的对隐层节点进行自动化删除；最后，根据相关系数节点删除合并规则，对隐层节点进一步进行合并和拆分，并更新合并和拆分后的隐层节点的权值，输出一个识别精度高、误差小的 BP 神经网络。基于强化学习的 BP 神经网络算法实现示意图如下：




图 4.2 基于强化学习的 BP 神经网络算法的实现过程示意图

因此，基于强化学习的 BP 神经网络能够防止 BP 神经网络陷入局部最优解的问题，提高了 BP 神经网络算法的精度，为视频推荐提供更高的推荐效果；由于算法对神经网络结构的节点数进行了优化，所以算法结构冗余度低，因此空间复杂度相比之下会降低。此外，算法还对影响因子进行优化，使得算法具有“经验积累”的能力，因此收敛速度也会更快，时间复杂度更低。

4.4 实验结果和分析

基于强化学习优化后的 BP 神经网络视频推荐算法的实验数据和环境与第三章的相同，为了验证基于强化学习优化后的 BP 神经网络视频推荐算法效果，本

章准确率、均分误差、交叉熵损失函数等参数对强化学习优化后的 BP 神经网络算法和传统的 BP 神经网络算法进行对比实验，并对视频推荐结果进行综合比较和评估，得出基于强化学习的 BP 神经网络算法(QLBP 算法)对视频推荐系统相比传统的 BP 神经网络算法具有更好的推荐效果。

BP 神经网络算法和 QLBP 算法准确率实验结果如图 4.3 所示，由图可知，QLBP 算法对用户评分的的分类的准确率要高于传统的 BP 神经网络算法，其中基于强化学习优化后的 BP 神经网络算法(QLBP)相比传统的 BP 神经网络算法的视频推荐准确率提高了 12.8%；在测试样本集比较小的情况下，基于强化学习算法的波动幅度相对 BP 神经网络算法来说要小很多，并且随着样本测试集的不断增加，基于强化学习优化后的 BP 神经网络算法相比 BP 神经网络平稳性更高。




图 4.3 BP/FEBP/QLBP 算法准确率比较

图 4.4 比较了 BP 神经网络算法和 QLBP 算法的 MSE（均方误差）。由图可知，QLBP 算法对视频评分分类的均方误差 MSE 的值大约在 0.35 左右，相比传统 BP 神经网络算法 (≈ 0.4) 的均方误差分别降低了 12.5%；相比本文第三章提出的 FEBP 算法降低了 6.47%；由此可知，基于强化学习优化后的 BP 神经网络对视频评分的分类比 BP 神经网络算法具有更低的平均误差，与第三章一样，仅仅从准确率和均方误差上判断 QLBP 算法对视频评分的分类还不够具有说服力，因此需要更精细的指标：交叉熵损失函数指标对用户评分分类结果进行评价。

基于用户评分及视频类型的推荐系统的各算法的交叉熵损失函数实验结果如表 4.1，由表可知，基于强化学习优化后的 BP 神经网络算法对用户评分分类的鲁棒性相比传统的 BP 神经网络算法分别提高了 8.69%，相比本文第三章提出的 FEBP 算法提高了 4.67%。




图 4.4 BP/FEBP/QLBP 算法均方误差比较

表 4.1 BP/FEBP/QLBP 算法交叉熵损失函数

算法	BP 算法	FEBP 算法	QLBP 算法
交叉熵	0.2958	0.2676	0.2801

为了验证基于强化学习算法对推荐系统的作用，本文采用了推荐效果评价参数：F1_Score、Precision、Recall 对推荐系统的推荐效果进行评价。基于强化学习优化后的 BP 神经网络算法的 F1_Score、Precision、Recall 如图所示：




图 4.5 BP/FEBP/QLBP 算法的 FPR 值比较

由图 4.5 可以看出，基于蜂群优化的 BP 神经网络算法对用户的推荐用户感兴

趣的视频（评分 ≥ 4 分的视频为用户感兴趣视频）精确率、召回率以及 F1_score 都比传统的 BP 神经网络算法推荐效果都要好；其中 QLBP 算法的 F1_score 相对传统的 BP 神经网络提高了 35.29%，相比本文第三章提出的 FEBP 算法视频推荐效果提高了 8.23%。

4.5 本章小结

本章主要介绍基于强化学习的 BP 神经网络算法视频推荐算法的详细设计和实现，简单介绍了 BP 神经网络节点合并和拆分规则、Q-learning 算法的原理，设计基于 Q-learning 强化学习的 BP 神经网络视频推荐算法，有效地避免了 BP 神经网络容易陷入局部最优和算法结构难以确定的问题，通过实验验证了基于强化学习的 BP 神经网络算法相比传统的 BP 神经网络算法、FEBP 算法具有更高的分类精度和推荐效果，因此可以应用该算法提高了视频推荐效果。

结 论

随着互联网的快速发展，信息不断增多，冗余的网络信息越来越使得人们很难找到自己需要的信息，个性化推荐方法的出现，在一定程度上解决了这些问题。本文主要通过研究 MovieLens 1M 视频评分数据集，利用主成分分析法对数据集降维，采用 Python 语言实现优化后的 BP 神经网络算法，利用 Matalab 工具对改进后的 BP 神经网络算法进行实验仿真，得出基于优化后的 BP 神经网络对视频评分具有更好的分类效果；然后系统应用该算法到个性化推荐中，系统可以利用用户年龄、性别等特征，以及优化后的 BP 神经网络模型来判断该用户对电影的评分，通过评分进行排序，可以得到该用户评分高的视频，然后为用户推荐高分的视频，应用基于优化后的 BP 神经网络具有其他推荐系统更好的视频推荐效果。

本文主要工作如下：

1、采用 Matalab 工具对 MOVIELENS 1M 数据集中原始数据进行特征提取，主要提取的数据有用户 ID、视频 ID、用户性别、用户年龄、视频类型等数据，采用平均值、最大值、最小值、数目等方式对数据集中的数据进行特征提取，并对各个特征样本进行标记，主要标记类型为用户对该视频的平均评分，评分主要有 1,2,3,4,5 五种类型，最后对这些采集的数据进行去文本化和归一化，得到特征空间集合，以适应 BP 神经网络算法的要求。

2、采用主成分分析法对特征空间相关系数进行计算，得出该特征空间的特征值和特征向量，利用特征值表示该特征的贡献率，然后计算各特征的累计贡献率，把累计贡献率高于 85% 的特征空间作为该特征集的主成分，然后选取这些主成分作为新的特征集对接下来的算法验证，降低了特征空间的维度，减少了 BP 神经网络的输入规模，提高了算法计算的效率。

3、BP 神经网络算法是采用负梯度下降算法，有效克服了单层感知器不能解决 XOR 等问题，目前神经网络研究中应用最为广泛的网络算法之一。但是基于负梯度下降算法导致了 BP 神经网络容易陷入局部极小值，无法从极小值区域跳出，导致 BP 神经网络收敛速度变慢，甚至在某些极端情况下，无法收敛的情况。本文，针对 BP 神经网络陷入局部极小值导致视频推荐效果不佳的问题，通过蜂群智能算法思想对 BP 神经网络权值和阈值选择进行优化，通过选择比较合适的权值和阈值，避免 BP 神经网络陷入局部极小值，提升网络的收敛速度，达到提升视频推荐系统推荐效果的目的。

4、BP 神经网络隐层节点的确定一直是 BP 神经网络算法的难题之一。由神经网络算法原理可知，神经网络的层数越多，理论上分类精度就越高，但是实际上随着神经网络层数不断增多，网络结构会变得很复杂，网络的分类效果反而会

降低。目前三层的神经网络结构已经能够实现任意精度的非线性连续函数逼近，因此通过改变神经网络层数达到提高分类精度的目的已经变得不再重要，反而通过调整隐层节点数以及节点的影响因子来提高神经网络分类精度，逐渐成为神经网络优化的热点问题。文中采用基于强化学习的方法对 BP 神经网络隐层节点以及节点影响因子进行优化，提升 BP 神经网络分类精度，从而达到了提升视频推荐效果的目的。

5、为了验证优化后的 BP 神经网络对视频评分的分类效果及其更好的推荐效果。本文采用准确率（Accuracy）、均方误差 MSE（Mean Squared Error）、交叉熵损失函数、F1_score/Precision/Recall 等常用的方法进行了比较，对于基于蜂群优化算法的 BP 神经网络采用了这些参数和 BP 神经网络、基于遗传算法的 BP 神经网络以及基于粒子群优化的 BP 神经网络进行了对比，对实验结果分析可知基于蜂群优化算法的 BP 神经网络比其他算法具有更高的分类精度、鲁棒性及推荐效果；然后为了验证基于强化学习的 BP 神经网络算法的视频分类及推荐效果，本文采用 BP 神经网络作为对比算法，从准确率、均方误差、交叉熵损失函数、Precision、Recall、F1_score 进行验证，得出基于强化学习的 BP 神经网络具有更高的分类精度、鲁棒性及推荐效果；然后本文利用 Matlab 工具对实验结果进行图形化展示；最后得出基于蜂群优化后的 BP 神经网络算法和基于强化学习的 BP 神经网络算法对视频分类效果会比其他算法更加优越，进而实现更好的视频推荐效果。

展望如下：

本文提出了基于蜂群优化后的 BP 神经网络视频算法和基于强化学习的 BP 神经网络视频算法，相比传统的基于 BP 神经网络的推荐算法，本文提出的算法具有更高的推荐效果，但是在应用于实际的网络环境前，本文算法还有需要做进一步的完善。需要在未来的工作中进一步完善的方面有：

(1)结合使用蜂群智能算法和强化学习的思想对 BP 神经网络进一步优化，提出具有更高精度的视频推荐算法，并进一步考虑算法的时间复杂度和空间复杂度，做到实时高效地视频推荐效果。

(2)对样本空间采用自适应权值的方式，不断调整各个样本的权值，达到突出重要特征，降低非重要特征的目的，提高整个数据集数据有效性，从而提升视频个性化推荐的效果。

(3)利用用户在网络中的沉淀信息，对未参与评分以及用户信息不完整的用户也能够具有很好的推荐效果，充分考虑各种与用户相关联的网络信息，达到提升推荐系统效果的目标。

参考文献

- [1] 凌铖. 大数据时代的计算机信息处理技术研究. 中国新通信, 2016, 18(7):76-76.
- [2] 李洺吉, 王晶. 个性化推荐系统安全防护研究. 信息通信技术, 2016(6):43-47.
- [3] 徐蕾, 杨成, 姜春晓,等. 协同过滤推荐系统中的用户博弈. 计算机学报, 2016, 39(6):1176-1189.
- [4] 孙克雷, 陈安东. 基于用户兴趣的个性化推荐算法研究. 安徽建筑大学学报, 2017, 25(1):65-69.
- [5] 李建荣. 基于数据挖掘的移动用户个性化推荐系统研究与设计. 现代电子技术, 2016, 39(22):59-63.
- [6] 文俊浩, 舒珊. 一种改进相似性度量的协同过滤推荐算法. 计算机科学, 2014, 41(5):68-71.
- [7] 雷鸣, 朱明. 情感分析在电影推荐系统中的应用. 计算机工程与应用, 2016, 52(10):59-63.
- [8] 王卫健. 基于数据挖掘的电子商务商品个性化推荐技术研究. 电子科技大学, 2014.18(10):23-28
- [9] 陆艺, 曹健. 面向隐式反馈的推荐系统研究现状与趋势. 计算机科学, 2016, 43(4):7-15.
- [10] 刘树栋, 孟祥武. 基于位置的社会化网络推荐系统. 计算机学报, 2015, 38(2):322-336.
- [11] Cheng H T, Koc L, Harmsen J, et al. Wide & Deep Learning for Recommender Systems// The Workshop on Deep Learning for Recommender Systems. ACM, 2016:7-10
- [12] Zhang H R, Min F. Three-way recommender systems based on random forests. Knowledge-Based Systems, 2016, 91(4):275-286
- [13] Zhang Y. GroRec: A Group-Centric Intelligent Recommender System Integrating Social, Mobile and Big Data Technologies. IEEE Transactions on Services Computing, 2016, 9(5):786-795
- [14] Zhang S, Yao L, Sun A. Deep Learning based Recommender System: A Survey and New Perspectives. 2017, 9(5):46-55
- [15] Wang W, Yin H, Sadiq S, et al. SPORE: A sequential personalized spatial item recommender system// IEEE, International Conference on Data Engineering. IEEE, 2016:54-65

- [16] Zhao H, Yao Q, Song Y, et al. Learning with Heterogeneous Side Information Fusion for Recommender Systems. 2018:14-17
- [17] Aciar S, Zhang D, Simoff S, et al. Recommender System Based on Consumer Product Reviews// Ieee/wic/acm International Conference on Web Intelligence. IEEE Computer Society, 2017:719-723
- [18] Le H S. Dealing with the new user cold-start problem in recommender systems: A comparative review. Information Systems, 2016, 58(5):87-104
- [19] Musto C, Semeraro G, Gemmis M D, et al. Learning Word Embeddings from Wikipedia for Content-Based Recommender Systems// Advances in Information Retrieval. Springer International Publishing, 2016:29-34
- [20] Katzman J, Shaham U, Bates J, et al. DeepSurv: personalized treatment recommender system using a Cox proportional hazards deep neural network. BMC Medical Research Methodology, 2016, 18(1):24
- [21] Revathy V R, Pillai A S. Classification and Applications of Social Recommender Systems// Proceedings of the Eighth International Conference on Soft Computing and Pattern Recognition (SoCPaR 2016). 2018:19-29
- [22] Beutel A, Covington P, Jain S, et al. Latent Cross: Making Use of Context in Recurrent Recommender Systems// the Eleventh ACM International Conference. ACM, 2018:46-54
- [23] Lin S Y, Lai C H, Wu C H, et al. A trustworthy QoS-based collaborative filtering approach for web service discovery. Journal of Systems & Software, 2014, 93(4):217-228.
- [24] B. Thorat P, M. Goudar R, Barve S. Survey on Collaborative Filtering, Content-based Filtering and Hybrid Recommendation System. International Journal of Computer Applications, 2015, 110(4):31-36.
- [25] Konstan J A, Miller B N, Maltz D, et al. GroupLens: applying collaborative filtering to Usenet news. CACM, 2016, 40(3):77-87.
- [26] D Addio R M, Manzato M G. A Collaborative Filtering Approach Based on User's Reviews// Intelligent Systems. IEEE, 2014:204-209.
- [27] Tao Z, Ming C, She J, et al. Item Recommendation Using Collaborative Filtering in Mobile Social Games: A Case Study// IEEE Fourth International Conference on Big Data and Cloud Computing. IEEE Computer Society, 2014:293-297.
- [28] 徐正巧, 赵德伟. 深度学习理论视角下的移动学习推荐系统的设计和研究. 智能计算机与应用, 2014(2):57-58.
- [29] 徐玲玲, 孙丙宇, 方薇. 基于内容过滤的农资电子商务推荐系统. 计算机系统

- 应用, 2014, 23(3):83-87.
- [30] Ekstrand M D, Riedl J T, Konstan J A. Collaborative Filtering Recommender Systems// The adaptive web. Springer-Verlag, 2015:291-324.
- [31] Herlocker J L, Konstan J A, Terveen L G, et al. Evaluating collaborative filtering recommender systems// The adaptive web. Springer-Verlag, 2015:291-324.
- [32] Al-Hassan M, Lu H, Lu J. A semantic enhanced hybrid recommendation approach: A case study of e-Government tourism service recommendation system. Decision Support Systems, 2015, 72:97-109.
- [33] 何海江. 基于线性分类算法的软件错误定位模型. 计算机工程与应用, 2017, 53(21):42-48
- [34] 王振武, 孙佳骏, 于忠义,等. 基于支持向量机的遥感图像分类研究综述. 计算机科学, 2016, 43(9):11-17
- [35] 丁雪芳, 王琪. 基于改进支持向量机的 Wi-Fi 室内定位算法. 计算机工程与应用, 2016, 52(6):90-93
- [36] Yao M, Zhu C. SVM and adaboost-based classifiers with fast PCA for face reocognition// IEEE International Conference on Consumer Electronics-China. IEEE, 2017:1-5
- [37] 杨航, 刘凌, 倪骏康,等. 双关节刚性机器人自适应 BP 神经网络算法. 西安交通大学学报, 2018(1):21-24
- [38] 吕恩辉, 王雪松, 程玉虎. 基于反卷积特征提取的深度卷积神经网络学习. 控制与决策, 2018(3):44-48
- [39] Ren T, Liu S, Yan G, et al. Temperature prediction of the molten salt collector tube using BP neural network. Renewable Power Generation Iet, 2016, 10(2):212-220.
- [40] Zhao Z, Xu Q, Jia M. Improved shuffled frog leaping algorithm-based BP neural network and its application in bearing early fault diagnosis. Neural Computing & Applications, 2016, 27(2):375-385.
- [41] Wang J, Shi P, Jiang P, et al. Application of BP Neural Network Algorithm in Traditional Hydrological Model for Flood Forecasting. Water, 2017, 9(1):48.
- [42] Sridhar B. Authentication by Hand Vein Patterns using Back Propagation Network. 2018(7):126-142
- [43] Zheng H L, Tuo X G, Peng S M, et al. Determination of Gamma point source efficiency based on a back-propagation neural network. 2018(1):29-32
- [44] Balaji L, Thyagarajan K K. An enhanced performance for H.265/SHVC based on combined AEGBM3D filter and back-propagation neural network. Signal Image &

Video Processing, 2018:1-9

- [45] Guan H, Dai Z, Zhao A, et al. A novel stock forecasting model based on High-order-fuzzy-fluctuation Trends and Back Propagation Neural Network. Plos One, 2018, 13(2):42-66
- [46] Tian Y Y. Using a Back Propagation Neural Network Based on Genetic Algorithm to Study Influence Factors of Carbon Dioxide Emissions in China. Science Technology & Industry, 2018, 17(5):73-77
- [47] Ghose D K, Samantaray S. Modelling sediment concentration using back propagation neural network and regression coupled with genetic algorithm. Procedia Computer Science, 2018, 125:85-92
- [48] Liu Y, Xu L, Li M. The Parallelization of Back Propagation Neural Network in MapReduce and Spark. Kluwer Academic Publishers, 2017,25(11):21-24
- [49] Hassanin M F, Shoeb A M, Hassanien A E. Grey wolf optimizer-based back-propagation neural network algorithm// Computer Engineering Conference. IEEE, 2017:213-218
- [50] Singh K R, Chaudhury S. Efficient technique for rice grain classification using back-propagation neural network and wavelet decomposition. Iet Computer Vision, 2017, 10(8):80-87
- [51] Seetharaman K, Chembian W T. Multi-spectral satellite color image retrieval based on GMRFM and Back-propagation algorithm with Artificial Neural Network// International Symposium on Electronics and Smart Devices. IEEE, 2017,15(4):40-47
- [52] Jabari F, Masoumi A, Mohammadi-Ivatloo B. Long-Term Solar Irradiance Forecasting Using Feed-Forward Back-Propagation Neural Network// International Conference of Iran Energy Association. 2017,17(6):32-38
- [53] Rathee N. Investigating back propagation neural network for lip reading// International Conference on Computing, Communication and Automation. IEEE, 2017:373-376
- [54] Pan L, Feng X, Sang F, et al. An improved back propagation neural network based on complexity decomposition technology and modified flower pollination optimization for short-term load forecasting. Neural Computing & Applications, 2017(13):1-19
- [55] 秦国华,谢文斌,王华敏.基于神经网络与遗传算法的刀具磨损检测与控制.光学精密工程,2015,23(05):14-21.
- [56] 刘贺,张弘强,刘斌.基于粒子群优化神经网络算法的深基坑变形分类方法.吉林

大学学报(地球科学版),2014,44(05):9-14.

- [57] Wang Y, An H, Liu Z, et al. Parallelizing Back Propagation Neural Network on Speculative Multicores// IEEE, International Conference on Parallel and Distributed Systems. IEEE, 2017:902-907
- [58] Guo K, Yang C, Liu T. Caching in Base Station with Recommendation via Q-Learning// Wireless Communications and NETWORKING Conference. IEEE, 2017:1-6
- [59] Zimmer M, Doncieux S. Bootstrapping Q-Learning for Robotics from Neuro-Evolution Results. IEEE Transactions on Cognitive & Developmental Systems, 2017,17(9):1-1
- [60] Klidbary S H, Shouraki S B, Kourabbaslou S S. Path planning of modular robots on various terrains using Q-learning versus optimization algorithms. Intelligent Service Robotics, 2017, 10(2):121-136
- [61] Guan H, Dai Z, Zhao A, et al. A novel stock forecasting model based on High-order-fuzzy-fluctuation Trends and Back Propagation Neural Network. Plos One, 2018, 13(2):66-75

附录 A 攻读硕士学位期间获得的学术论文

软件著作权:

- [1] 李婵娟, 李仁发, 刘四平, 屠晓涵, 曾庆光. 基于会话的推荐及可视化分析系统 V1.0: 中国. 2018SR274518. 2018-4-23.

附录 B 攻读硕士学位期间所参与的项目

- [1] 国家自然科学基金[61173036]: 以汽车为例的 CPS 若干问题研究.
- [2] 国家高技术研究发展计划(863)资助项目子项[2012AA01A301-01]: 行业应用市场分析和电磁计算软件研发.
- [3] 国家自然科学基金面上项目[61672217]: 新一代汽车嵌入式系统功能安全的建模与算法研究.

致 谢

时光荏苒，转眼间四年就匆匆而去。在这特别的4年里，我经历了人生最大的一次洗礼，从最初的懵懂少年到如今踌躇满志、成熟稳重的研究生，无论是思想上、学习上、技能上还是生活中各方面自己都得到了很大的提升。在这四年研究生学习生涯中，我得到了众多老师、朋友和家人们的鼓励和支持。借此毕业论文完成之际，我由衷地感谢那些一路上给予我理解、帮助、指导、伴我成长的人。

首先，我要感谢我的导师李仁发教授。当初休学一年回到学校，我迷茫至极。李老师送了我一个字——“Grit”，是李老师的理解与鼓励才有了现在的我。最开始选题我就陷入了困境，是李老师帮我指明方向，悉心教导我学习方法。每次有困惑向李老师咨询，李老师都会详细的帮我解答，是李老师的理解让我从容不迫，更加有勇气面对论文中乃至生活上的难题。“人生是一场马拉松，起跑的优劣都无关紧要，笑到最后的都是一直在跑的人，也就是一辈子都在学习的人。”李老师这句深情寄语我一直铭记于心，受益终身。李老师宽阔的胸襟，渊博的学识，严谨的科研态度感染着我前行，能成为李老师的学生，是我一生莫大的荣幸。

感谢李新星老师、李明媚老师、段伟老师。当我面临休学时是李新星老师的支持与理解宽慰着我；当我在获取专业实践学分遇到差错时，是李明媚老师耐心的帮助让我顺利拿到学分；当我因为是往届的原因在准备答辩材料遇到困难时，是段伟老师不厌其烦的帮我一一处理。感谢学院的老师们，是你们的认真负责和无私奉献让我顺利走上毕业之路。

感谢李蕊老师、赵欢老师，杨科华老师。谢谢李蕊老师在开题和中期检查中对我的指导，让我少走了很多弯路，明白了何为科研。

感谢我的室友陈炫玲、詹随、宁晓兰。那一年，是你们的陪伴让我更加体会到团结的快乐，我们一起爬岳麓山，游橘子洲，一起互相鼓励学习，谈天说地。现在你们依旧在鼓励着我关心着我，给了我无限的动力。

感谢我的实验室伙伴刘四平、屠晓涵、袁娜、邓湘军、宋金林、朱立民、秦凯强等。无论我遇到什么难题，你们都会不遗余力的帮助我，谢谢你们的鼓励与指导，让我在实验室找到归属感。

感谢我的家人。不仅研究生生涯，一直以来，家人都是我坚强的后盾，让我专心前行，无论发生什么，家人都支持并鼓励着我。感谢你们的无私奉献让我更加坚定自己的目标，我会用更好的自己来回报你们。

最后，谨向审阅本论文及答辩组的评委老师们致以深深的敬意和诚挚的感谢。由于本人研究水平有限，文中难免有不足之处，恳请各位老师批评、指正。

李婵娟 2018 年 5 月 4 日于湖南大学