

图书分类号_____

密级_____

UDC _____

浙江海洋学院

专业学位硕士研究生学位论文



基于 BP 人工神经网络的区域森林火灾预测研究

作者姓名: 胡超

指导教师: 顾沈明

专业种类: 农业推广

专业领域: 农业信息化

学习方式: 全日制

所在学院: 数理与信息学院

提交日期: 2015 年 4 月

浙江海洋学院专业学位硕士学位论文

基于 BP 人工神经网络的区域森林火灾研究

作者姓名： 胡超

指导教师： 顾沈明

专业种类： 农业推广

专业领域： 农业信息化

学习方式： 全日制

学位授予单位： 浙江海洋学院

论文答辩日期： 2014 年 5 月 27 日

论文答辩委员会签字：

姓名 教授（主席）

答辩日期： 年 月 日

**A Dissertation for Master's Degree Submitted to
Zhejiang Ocean University**



The regional forest fire research based on BP neural network

Candidate: **Hu Chao**

Supervisor: **Professor Gu**

Speciality: **Agricultural Informatization**

Date Of Submission: **April 2015**

浙江海洋学院

论文原创性声明

本人声明，所呈交的学位论文系在导师指导下本人独立完成的研究成果。文中依法引用他人的成果，均已做出明确标注或得到许可。论文内容未包含法律意义上已属于他人的任何形式的研究成果，也不包含本人已用于其他学位申请的论文或成果。

本人如违反上述声明，愿意承担以下责任和后果：

1. 交回学校授予的学位证书；
2. 学校可在相关媒体上对作者本人的行为进行通报；
3. 本人按照学校规定的方式，对因不当取得学位给学校造成的名誉损害，进行公开道歉；
4. 本人负责因论文成果不实产生的法律纠纷。

论文作者签名：

日期： 年 月 日

浙江海洋学院

论文知识产权权属声明

本人在导师指导下所完成的论文及相关的职务作品，知识产权归属浙江海洋学院。学校享有以任何方式发表、复制、公开阅览、借阅以及申请专利等权利。本人离校后发表或使用学位论文或与该论文直接相关的学术论文或成果时，署名单位仍然为浙江海洋学院。

学位论文作者签名：

指导教师签名：

日期： 年 月 日 日期： 年 月 日

《中国博士学位论文全文数据库》《中国优秀硕士学位论文全文数据库》
和《万方数据电子出版社》投稿声明

研究生处：

本人同意《中国博士学位论文全文数据库》和《中国优秀硕士学位论文全文数据库》出版章程的内容，愿意将本人的学位论文委托研究生处向中国学术期刊（光盘版）电子杂志社的《中国博士学位论文全文数据库》和《中国优秀硕士学位论文全文数据库》投稿，希望《中国博士学位论文全文数据库》和《中国优秀硕士学位论文全文数据库》给予出版，并同意在《中国优秀博硕士学位论文全文数据库》和《中国优秀硕士学位论文全文数据库》以及 CNKI 系列数据库中使用，同意按章程规定享受相关权益。

论文级别： 硕士 博士

学位论文作者签名：

指导教师签名：

日期： 年 月 日 日期： 年 月 日

作者联系地址（邮编）：浙江省舟山市临城新区长峙岛海大南路 1 号
浙江海洋学院数理与信息学院（316022）

作者联系电话：18368097306

摘要

2013 年国家统计局相关部门第八次全国森林资源清查显示, 我国森林面积 2.08 亿公顷, 森林覆盖率 21.63%。活立木总蓄积 164.33 亿立方米, 森林蓄积 151.37 亿立方米。天然林面积 1.22 亿公顷, 蓄积 122.96 亿立方米; 人工林面积 0.69 亿公顷, 蓄积 24.83 亿立方米。用我国森林资源与世界森林资源相比, 森林资源相对匮乏。被称之为地球之肺的森林, 是我们生存空间氧气的重要制造场所, 同时对空气中的粉尘过具有过滤作用, 它还是沙尘暴的重要防御者, 无论是国民经济的发展还是环境保持, 森林都是必不可少的宝贵自然资源。而森林火灾使这些资源造成极大的危害, 森林火灾预防和预测, 并采取有效措施是当务之急。预测和防治森林火灾对经济环境和社会环境的可持续发展具有重要意义。

通过对影响森林火灾的气候因子作为模拟神经的输入, 火灾发生情况作为输出, 可以有效分析各影响因素对火灾发生的权重和联系。人工神经网络通过对大量统计数据的训练仿真, 并模拟运算, 优化自身网络结构, 得出所需要的函数运算结构。在大量数据处理分析上, 这种方法相对于逻辑推理演算更具有优势。

本文首先对世界及我国森林火灾近况作了概述, 然后阐述了人工神经网络和 BP 神经网络结构、特点以及算法, 同时对影响森林火灾发生的相关气候因素的相关性进行简要分析。然后收集广西省桂林市和广东省广州市历史气候变化和森林火灾发生数据的历史气候数据和森林火灾发生数据建立预测模型。本研究通过对广西省桂林市和广东省广州市历史气候变化和森林火灾发生的数据作为研究基础, 运用 matlab 中的 BP 神经网络对以上两个地区的森林火灾建立预测模型, 并采用了一种改进粒子群算法对 BP 神经网络的性能进行优化, 仿真实验结果表明, 与传统的 BP 算法和粒子群算法优化后相比, 经改进后的粒子群优化 BP 神经网络的方法不仅能够快速收敛到神经网络的学习目标, 并且提高了模型的预测精度。

关键词: 森林火灾; 神经网络; 气象因素; 模型; 预测

ABSTRACT

In 2013, the 8th national forest inventory conducted by national statistics departments shows that there are 208 million hectares of forest area with 21.63% of forest coverage rate. Total stumpages are 16.433 billion cubic meters with forest reserves 15.137 billion cubic meters. The natural forest covers an area of 122 million hectares with accumulation of 12.296 billion cubic meters; 69 million hectares plantation area, volume 2.483 billion cubic meters. Compared with the international forest resources, forest resources in our country are relatively scarce. Forests, which are called the lungs of the earth, are the oxygen manufacturing sites which are important to our survival space, while at the same time have a filter effect for the dust in the air and play an important role in defending sandstorm. Forests are necessary precious natural resources both for the development of the national economy and environment protection. However, the forest fires make these resources cause great harm. Therefore, prevention of forest fires and put forward effective measures are urgent affairs. Prediction and prevention of forest fires have great significance for the sustainable development of the economic environment and the social environment.

Artificial neural network is an effective method for the prediction and prevention of forest fires. Through putting the climatic factors which might cause forest fire as the input of neural simulation and output of fire situation, weight of factors affecting fires and connection between these factors can be effectively analyzed. Artificial neural networks can optimize their network structure and work out the desired function computing architecture through a large number of statistics simulation practice and simulation operations. This approach has more advantages over logical reasoning calculus on massive data processing and analysis.

This thesis first provides an overview of the current situation of forest fires ,then describes the artificial neural network and BP neural network architecture, features and algorithms and gives a brief analysis of the relevant climatic factors affecting forest fires correlation. In this study, the historical data climate change and forest fires of Guilin in Guangxi Province and Guangzhou City in Guangdong Province is collected as the research

basis, and an improved particle swarm optimization algorithm was introduced to optimize the performance of the BP neural network. Compared with the traditional BP algorithm and particle swarm optimization, the improved particle swarm optimization algorithm can not only quickly converge to the neural network learning objectives, but also improve the accuracy of the prediction model.

KEYWORDS: forest fires; neural network; meteorological factors; model; forecast

摘 要	I
ABSTRACT	II
第一章 绪 论	- 1 -
1.1 研究背景	- 1 -
1.2 研究意义	- 2 -
1.3 国内外研究现状	- 2 -
1.3.1 国外研究现状	- 2 -
1.3.2 国内研究现状	- 3 -
1.4 研究的理论与方法	- 4 -
1.5 本文主要的研究内容	- 5 -
第二章 气候因素对森林火灾的影响	- 6 -
2.1 气候因子对世界森林火灾的影响	- 6 -
2.2 气候因子对我国森林火灾的影响	- 6 -
2.2.1 气象因素是影响森林火灾发生的自然因素	- 7 -
2.2.2 气候变化影响森林火灾发生规律变动	- 7 -
2.2.3 气候变暖变干将加重林火危害	- 7 -
2.3 本章小结	- 7 -
第三章 人工神经网络原理	- 8 -
3.1 人工神经网络简介	- 8 -
3.1.1 人工神经网络的发展简述	- 8 -
3.1.2 神经网络的生物结构	- 9 -
3.2 神经网络模型分类	- 11 -
3.2.1 依据拓扑结构划分网络	- 11 -
3.2.2 按网络学习模式划分的神经网络	- 12 -
3.3 人工神经网络的特点	- 13 -
3.4 人工神经网络的基本结构	- 13 -
第四章 BP 神经网络的结构和算法	- 16 -
4.1BP 人工神经网络简介	- 16 -
4.2 BP 神经网络的结构	- 16 -
4.3BP 神经网络的算法	- 17 -
4.4 BP 神经网络训练方法	- 19 -
4.5 BP 网络在 matlab 中实现的常用函数	- 20 -
第五章 基于 BP 神经网络的森林火灾预测	- 21 -

5.1 BP 神经网络预测结构和模型	- 21 -
5.1.1 森林火灾预测的 BP 网络结构确定	- 21 -
5.1.2 基于 BP 网络模型森林火灾预测模型	- 22 -
5.2 基于 BP 网络的桂林林火日发生预测	- 24 -
5.2.1 数据准备	- 24 -
5.2.2 对气候数据进行归一化处理	- 26 -
5.2.3 桂林市数据在 MATLAB 中训练及预测过程.....	- 26 -
5.2.4 桂林市预测数据和实际数据误差对比	- 29 -
5.2.5 桂林市样本拟合值与实际值相对误差分析	- 31 -
5.3 基于 BP 网络的广州林火日发生预测	- 32 -
5.3.1 数据准备	- 32 -
5.3.2 广州市数据在 MATLAB 中训练及预测过程.....	- 34 -
5.3.3 广州市预测数据和实际数据误差对比	- 36 -
5.3.4 广州市样本拟合值与实际值相对误差分析	- 38 -
5.4 PSO 优化 BP 网络的森林火灾预测	- 39 -
5.4.1 PSO 优化算法原理.....	- 39 -
5.4.2 改进粒子群优化算法	- 40 -
5.4.3 基于 IPSO 优化 BP 的过程.....	- 40 -
5.4.4 实验结果分析	- 41 -
5.5 本章小结	- 43 -
第六章 结 论	- 44 -
6.1 气象因素对森林火灾发生影响相关性分析	- 44 -
6.2 运用 BP 网络构建预测模型可行性分析	- 44 -
6.3 总结	- 45 -
参考文献	- 46 -
在读期间发表的学术论文及研究成果	- 49 -
致 谢	- 50 -

第一章 绪论

1.1 研究背景

森林资源对于经济可持续发展、生态维护是不可缺少的重要基础资源，对森林资源的保护是提高国家综合发展前景具有不可替代的重要意义。与 2013 年国家统计局相关部门我国森林资源清查数据相比较，我国森林面积 2.08 亿公顷，森林覆盖率 21.63%。活立木总蓄积 164.33 亿立方米，森林蓄积 151.37 亿立方米。天然林面积 1.22 亿公顷，蓄积 122.96 亿立方米；人工林面积 0.69 亿公顷，蓄积 24.83 亿立方米^[1]。人工林面积仍然居于世界首位。但是我国仍然是一个林地面积相对较小、生态系统脆弱的国家，世界森林覆盖率 31% 远远大于我国同期的森林覆盖率，人均森林所有面积也仅为寰球总体人均水平的 25%，人均占有森林蓄积只有世界人均水平的 14.3% 左右，我国森林资源森林资源质量不高的状况以及产量相对较低，资源分布不均匀，使得中国林业发展面临严峻的挑战^[2-3]。

危害森林资源的因素有很多，本文所研究的森林火灾是危害森林资源的是一种极具破坏力的森林灾害，首先，其不光会减少森林的覆盖率、降低林蓄积，更加应当注重的是它还会破坏地表土壤的组织机构，在危害地表的动物、植物、微生物的背景下，直接导致森林再生率的降低，是林业可持续发展的重要危害因素。其次，由于森林火灾引起的大火产生的空气污染气体和颗粒，会直接破坏生态环境，造成大气污染。

森林火灾是指由各种诱发森林起火的因素导致森林起火，失去超出人为控制范围，经过自由蔓延的方式扩展，导致大范围森林起火，促使森林资源、生物生态、经济、损失的一种灾害。导致森林火灾发生的人为因素和火源条件相对稳定，在某种程度上，这时气象因素在这个特定时间段的森林地区是森林火灾发生主要诱导因素^[4]。

森林火灾伴随着森林在地球上的出现而出现。据相关统计资料可知，世界范围内发生的森林火灾平均每年达到了二十多万次，超过 1 / 1000 全球森林总面积的森林植被在林火中烧毁。而平均每年有一万余次的森林火灾在我国发生，占世界百分之五，全国森林总面积的千分之七左右被烧毁^[5]。如此严峻的森林火灾灾害现状对我国的环境和自然来说都是极大的灾难。因此对森林火灾进行有效的预测和防治对遏制自然资源流失，保护生态环境，维护生态平衡来说具有重要意义。

纵观世界范围，每年受到森林火灾影响的森林面积多达几百万平方公里，尤其是近些年来，世界经济的高速发展，人类活动增多，致使全球气候变化，气温升高，森林火灾有明显的上升趋势。如 2009 年，在西班牙拉帕尔马岛发生森林火灾，林火过火面积多达两千公顷，4000 当地居民被疏散。重大森林灾害同年在希腊首都雅典北部山区，火灾造成过火面积已超过 48600 公顷^[6]。然而在第二年，在俄罗斯又发生森林大火，俄罗斯相关统计部门统计表明，俄罗斯此次森林大火失火处多达五百个以及二十多个泥炭着火点，其直接受灾总面积超过十九万公顷，经济损失高达 65 亿卢布，

造成约 50 人死亡，多达 500 多人受伤，被毁坏房屋超过 2000 间^[7]。根据世界历年来历史森林火灾的发生的数据和全球气候变化以及环境影响，未来林火发生情况有明显的增加趋势。

1.2 研究意义

森林火灾具有全球性和突发性等特性，且其危害性非常大。由历史数据可知，火灾年份中有四分之一到三分之一为林火重灾年，而由其造成的损失却能达百分之九十以上。如此惨重的损失，让我们不得不重新审视对森林火灾的预测和防治。当前，我国对森林火灾进行预测的部门主要是林业局和气象局，且预测只能停留在短期预测层面，并且对森林火灾传统的预测模式都是利用繁杂的数据和规则进行，这些只是死模型，很难得到优化，很显然这并不足以有效应对森林火灾发生的全球性和突发性等特性^[8]。因此，如何通过有效的新型的智能化的技术手段预测森林火灾，值得引起重视，并进行研究，其前景十分可观。如果森林火灾能得到有效预测，并得到控制，为国家减少经济损失具有直接意义，从而创造巨大的经济价值，对森林资源的保护，维护生态平衡都将有重要贡献。

预测森林火灾发生的研究是近年来森林火灾研究的重要趋向领域，在一定程度上讲气候因素又是森林火灾自然发生的主要因素。森林火灾与气候变化每年大幅波动，同时，不同季节，不同地区的气候类型，森林火灾发生频率和范围和周期都不一样^[9]。根据不同地区、不同季节的背景条件，分析相关地区历史气候资料，作为研究气候和气象因素与森林火灾之间的联系，运用神经网络的相关知识统计分析林火发生与气象因素的数据，使预测森林火灾的发生具有重要的现实意义。

1.3 国内外研究现状

1.3.1 国外研究现状

森林火灾对森林资源的严重威胁使得越来越多的国家和相关机构引起重视。尤其是世界各地的森林火灾的发生，导致当地遭受了巨大的经济损失和人员伤亡之后，西欧和北美地区的国家率先投入大量经费用于森林火灾的相关研究，各种现代科学技术也不断被运用到森林火灾研究领域，参阅最近几十年相关文献和报道，研究方向主要有温室气体对森林火灾的关系研究、不同时期降雨量与森林火灾的研究、多种气候因子对森林火灾的作用等，有关基于神经网络的气象因子对森林火灾预测研究也成为了热点。下面介绍国外学者进行的相关研究：

Youssef Safi^[10]等利用神经网络结合气象气候因子，构建了森林火灾因子分析模型，利用神经网络高容错能力和适应森林火灾随机性和复杂性的非线性特点，建立了森林火灾预测模型。

Wright^[11]等学者利用相对湿度对森林火灾预测进行研究，通过研究发现，当空气

湿度在百分之五十以上时极有可能发生森林火灾。

Gisbome^[12]等利用空气湿度、温度、风速等作为森林火灾预测因子，对森林火灾进行预报。

Viegas^[13]等学者研究了森林火灾发生时，降雨量与森林火灾成灾面积的相关研究，每年2到4月发生的森林火灾与降雨量之间关系不明显，这主要是因为这一时段可诱发森林火灾的气象因素较弱；而6到9月份之间，降水量越高森林火灾的发生概率越小。通过对实验的分析发现，降雨量越大，森林环境的保水量越高越不容易引发森林火灾。

Gillett^[14]等学者运用统计学的相关办法，运用历史气候数据建立了预测森林火灾过火面积的统计模型，有很高的精准度。

Williams^[15]等学者通过对澳洲地区温室气体对气候的影响导致的森林火灾变化发现，影响当地森林火灾的最主要气候因子是空气的相对湿度，一般情况下，相对湿度越小，越容易引发森林火灾。该研究成果对基于气象因子的森林火灾预测提供了理论依据。

Fried^[16]等学者研究了二氧化碳浓度与风速对森林火灾的影响，研究表明，当二氧化碳浓度比一般情况多出一倍，温度和风速偏大时，会加剧森林火灾的燃烧程度，并且促使火灾的发生间隙缩短。

Flannigan^[17]等学者通过加拿大的森林火灾天气指标预测系统对森林火灾进行预测火情状况，这一系统是利用气象因子等数据计算森林环境中可燃物的水份保有量估算可能发生的森林火灾严重程度。预测结果表明其精准度很高。

1.3.2 国内研究现状

我国森林火灾预测以及预报研究工作相对欧美发达国家起步较晚，建国之后，首先借鉴欧美等地区的预测方法和研究理论，建立了一系列符合我国实情的预报方法，例如风速综合指标法等，改革开放之后我国逐步建立森林火灾险情预报系统，近年来，随着科技进步，我国学者对森林火灾相关研究不断增多，如利用蚁群聚类算法在森林火灾预测中的研究、运用人工神经网络的对森林火灾成灾面积的研究、基于传感器数据融合的森林火灾监测、基于无线传感网络的森林火灾检测、基于图像处理的森林火灾检测技术、森林火险等级预测预报系统、以及森林火灾分布时空规律的研究等等。下面介绍我国学者进行的相关研究：

李德^[18]等收集整理四川省的历史气候气象数据和林火发生情况数据，以温度、湿度、降水量、气压、风速等气候因子作为研究指标，将气象因子对森林火灾发生的影响作了研究。

徐海龙^[19]等收集整理大兴安岭地区近20年的历史森林火情数据并利用主成分分析、线性回归分析、模糊聚类等方法对大兴安岭火灾过火面积进行预测。

黄家荣^[20]等收集河南各地区森林火灾成灾面积的统计数据作为研究资料,利用人工神经网络建立了森林火灾成灾面积的预测模型,并在 matlab 中计算实现,具有很高的准确度,预测相对误差在 1.2% 以下。

周来法^[21]等对台州地区森林火灾和相关气象因素研究发现,晴、阴、雨及云量这些天气要素对森林火灾的发生影响不明显,而风速、风向、日均温度和相对湿度等气象因子对当地森林火灾的发生影响显著。

黄光华^[22]等对利用无线传感器网络设计建立了森林火灾监测系统并对无线传感器网络节点的硬件软件的具体设计方法进行了研究。这种检测系统相较传统森林火灾检测系统降低了成本。

马奔^[23]等以全国森林火灾成灾面积作为研究数据,应用 BP 神经网络模型对成灾面积进行了预测,对预测方法进行了检验。然后又利用修正的 BP 神经网络模型,对预测方法进行了改进。

陈东宾^[24]等利用修正的 BP 神经网络算法对森林火灾识别进行了,且识别成功率高、识别迅速,验证了采用神经网络在森林火灾识别应用的正确性和有效性。

1.4 研究的理论与方法

人工神经网络是一种应用类似于大脑神经突触联接的结构进行信息处理的数学模型。在工程与学术界也常直接简称为神经网络或类神经网络。神经网络是一种运算模型,由大量的节点(或称神经元)之间相互联接构成。每个节点代表一种特定的输出函数,称为激励函数(activation function)^[25]。每两个节点间的连接都代表一个对于通过该连接信号的加权值,称之为权重,这相当于人工神经网络的记忆。网络的输出则依网络的连接方式,权重值和激励函数的不同而不同。而网络自身通常都是对自然界某种算法或者函数的逼近,也同样是对一种逻辑策略的表达^[26]。

人工神经网络是利用数学网络计算来完成这种模拟的,所以人工神经网络总的来说是一种数学模型。人工神经网络的功能主要是与人工神经元有关,神经网络因为其功能作用不同可以有很多种类型,通常神经网络的功能主要由两个因素所决定:其一是人工神经网络中的人工神经元相互连接的方式,也就是网络结构,网络结构可以分为层次型结构和互连型结构等;二是神经网络中人工神经元的函数关系。网络结构不同和函数关系不同的人工神经网络所具功能也不近相同。它通过计算机应用构建仿照人脑神经网络的运算活动特征,对发生事件的输入信息进行分布式并行信处理而达到预期输出效果或计算结果的一种数学模型。将数据通过这种模型内部的大量运算和训练,调整内部的输入因素的互相连接关系,直到他运行合理,达到处理复杂问题和数据。

森林火灾受地形、气候、可燃物、火源等多种因子的影响,因而森林火灾是一种非常复杂的现象,由于人工神经网络具有很强的容错能力以及高度非线性动力学系统适应随机性和复杂性的森林火灾的非线性发生,使得其可以模拟逼近任意非线性函数

和非线性动力学中的森林火灾发生情况^[27]。本文在分析森林火灾的历史数据的基础上,选取影响森林火灾的气象因子,通过人工神经网络模型分析森林火灾的发生情况,并对其预测。通过对森林火灾模型进行神经网络的自学习和训练得到模拟仿真结果,希望能将神经网络技术与森林火灾的预测统一起来,为建立有效智能的森林火灾预警系统提供理论和技术层面的支持。

1.5 本文主要的研究内容

本文主要分别对桂林地区 2005 年和 2010 年以及广州市 2000 年和 2005 年的历史气候数据和森林火灾发生数据作为研究基础。运用 BP 神经网络运算方法,建立数学模型,以当地的历史气候数据作为输入数据,林火历史发生次数作为输出数据。通过大量历史的气候数据和林火发生数据进行训练,使神经网络进行自适应学习获得人工神经网络对林火发生的预测方法。其中历史气候数据的输出指标包括日平均气温、日平均相对湿度、日降水量、日均风速。通过日均气候数据和历史森林火灾的发生情况实现每日发生火灾情况的预测模型,展示对火灾发生的预测情况,并与实际林火发生数据进行对比。最后利用 IPSO (粒子群优化算法)对 BP 网络优化,并对其实验结果进行了比较分析,提高预测精度。通过应用 BP 网络对影响森林火灾的气象因素进行分析预测确定出森林火灾与气候因素的相关性,对森林火灾发生进行宏观预测。

第二章 气候因素对森林火灾的影响

2.1 气候因子对世界森林火灾的影响

当前,全球气候温度处于上升态势。十九世纪中到二十世纪末期的一百年间,全球地面的平均温度上升了约 0.6 摄氏度,预计到 21 世纪末,全球的地面平均温度还将上升 1.4 ~5.8 摄氏度^[28]。林火的发生与干旱的严重程度和持续时间长短有密切关系,森林可燃物干燥,极易燃烧,而近年来太平洋的厄尔尼诺现象和全球升温态势,全球气候越趋多变,导致森林火灾的燃烧性加大。由于发生过森林火灾的森林所处生长环境的改变,其对环境湿度状况更加敏感,会进一步加剧森林火灾发生频率。

森林火灾的发生与自然和人为因素有很大相关性,从自然因素来看,二十世纪八十年代之后,随着全球气候变暖,森林火灾呈现上升趋势。从社会因素来看,由于世界范围内人口膨胀,对着工业化进程加快,砍伐森林,大量排放二氧化碳等人类活动对森林的影响加剧,进一步提高森林火灾发生的危险性。当前各国都开始关注森林资源的持续稳定发展,因此各国加强对森林火灾的防御和控制。世界各国不断增加森林防火预算经费,尽管如此,森林火灾的过火范围并未得到有效降低。特别是 90 年代中后期,被林火毁坏的热带数以百万计,对全球生态平衡严重破坏^[29]。

气候异常导致世界范围森林火灾区域分布扩大。无论是低纬度还是高纬度地区都没能逃此厄运。从高纬度地区来看,气候干燥的夏季,由于日照时间长,发生森林火灾的可能性很高。如从华盛顿开始经过加利福尼亚、美国的洛基山脉、加拿大、日本北海道、朝鲜、苏联欧洲部分北欧的斯堪的纳维亚半岛到冰岛等区域在干旱季森林火灾频发,形成“森林火灾带”。而如印度尼西亚这样的低纬度地区,在干旱年份(如受到 1977 年厄尔尼诺现象影响)森林火灾持续时间达半年之久,损失惨重^[30]。

2.2 气候因子对我国森林火灾的影响

随着全球气候变暖,中国的气候也出现异常状况,二十世纪八十年代以来我国气温以每十年 0.22 的速率递增,冬春季尤为明显,且极端气候频发,干旱加重,导致森林火灾发生频率增加,分布区域扩大。例如:1987 年 5 月 6 日发生在黑龙江大兴安岭地区的森林火灾是我国建国以来最严重的一次,过火面积 101 万公顷,61.4 万平方米的房舍、650 万斤的粮食被烧毁,死亡 193 人,受伤 226 人^[31]。2009 年 2 月 12 日贵州省发生多起森林火灾,武警、公安干部群众与火灾战斗 11 个小时才把火扑灭。2010 年发生在大理市的“3·12”特大森林火灾过火面积达 836.35 公顷,造成经济损失达 446 万余元。

2.2.1 气象因素是影响森林火灾发生的自然因素

气象气候带不同,各地区林火发生状况不同。由于日照纬度等因素的不同,全球分为多种气候带和气候类型,各个地区由于所处气候带不同,其林火发生规律也不同。林火发生的规律以及频率形成了地方特点,与其所处气候带相对应。同时,每年的不同季节变化、每月每日不同时间段气象因素不同,导致林火发生频率也不同。森林火灾一般发生在当地气候比较干旱,温度相对较高、空气湿度较低的天气情况下。很显然的可以发现,森林火灾的发生在很大程度上受到气候因子的影响。例如在 1987 年的大兴安岭地区发生的重大森林火灾,在火灾发生前夕,当地空气湿度相比以往较低,接近两年雨量偏少,干旱的气候条件使得森林环境中可燃物起火的风险提高,在这种情况下促使了此次森林大火的发生^[32]。

2.2.2 气候变化影响森林火灾发生规律变动

随着人类活动的增加人为因素例如二氧化碳过量排放、地表植被破坏、重金属污染、南北极上空臭氧层空洞逐年变大,导致全球气候变暖,气候异常。气候的不正常变化致使陆地下垫面与森林环境相关的水平衡遭到破坏、地表灌木植被环境恶化、空气湿度异常、土壤水分流失^[33]。而受气候影响变化最大的就是中纬、高纬度地区,相对我国来说,受影响最大的就是西北、华北以及东北地区,干旱年份日益增多,尤其是春冬两季。在这样的气候背景下,森林所处生态环境遭到严峻挑战,森林火灾发生的概率趋于上升,对森林资源产生严重威胁。

2.2.3 气候变暖变干将加重林火危害

纵观世界范围来看,我国是受全球气候变化影响较严重的国家。根据历史气象资料统计分析发现,其中,我国的平均气温总体升高了大约 0.6 摄氏度左右,北方地区平均年降水量大约是每十年降低 30 毫米,而南方地区每十年平均增加 40 毫米左右。以百年时间段为观察时段,我国冬季明显变暖。近 30 年间我国已经有大约 20 个冬季偏暖^[34]。更加令人担心的是,华北地区气候暖干缺湿情况日益严重,加剧了森林火灾的发生危害概率。从林火统计数据天气情况分析发现,森林环境温度偏高,湿度不足时森林火灾诱发的高危因素。

2.3 本章小结

气候因子是影响森林火灾的重要因素之一,同时气候条件的变化也促使森林火灾发生规律变动,由于近些年来全球气温升高,气候变暖变干也同样会加重林火的危害。从气象因素为实验因子,并基于 BP 神经网络建立预测模型是本文研究的基础。

第三章 人工神经网络原理

人工神经网络自从上世纪八十年代在世界范围内的复苏经过近三十年的发展，ANN 已经在很多研究领域得到应用，如模式识别、人工智能自动化控制、分析信号、决策系统等众多研究领域取得了重要应用^[35-36]。通过研究应用逐步发现，人工神经网络的自我学习、联想记忆特点对人工智能和数据仿真模拟起到重要作用。基于神经网络的预测研究也得到广泛的应用和开发。例如：基于人工神经网络的粮食产量预测研究，基于神经网络货运物流应用研究，基于神经网络的港口物流需求的研究等等。

3.1 人工神经网络简介

人工神经网络（ANN）可以从计算机软件很容易地实现模拟仿真，模拟人类大脑实现高性能的并行信息处理能力的数学模型。第一，是通过实际数据或事件发生的实例的学习能力。第二，从学习待预测的事件的实例数据和同类型数据进行分析模拟，从而获得预测结果以及结论。在实际运用中，运用人工神经网络（ANN）替代传统的数学模型，在短时间内高效率产生对事件的模拟。人工神经网络在原则上适用于有大量的科学统计数据但是缺少相关的解决方法，这样可以利用神经网络分析某一事件的大量实例，构建数学模型，通过神经网络的自我学习能力，达到预期目标。尤其在医学，电信，经济，工程，环境等中遇到很多问题，都是拥有大量的实例数据，而缺少一种科学方法对这些发生的实例进行学习归纳，并对可能发生的情况进行预测。而且这些问题是一般定性的数据处理方法无法处理的^[37]。

3.1.1 人工神经网络的发展简述

科学届对人工神经网络的发展按时间顺序可以概括为四个阶段，分别是：早期阶段、过渡阶段、高潮阶段和平稳阶段。早期阶段主要为各国的研究学者对人工神经网络进行的初步研究，包括 MP 模型、Hebb 学习规则、感知器(perceptron)和自适应线性网络 Adaline。过渡阶段是在 1970 年以后，那时神经网络研究还处于低潮时期，对于这一时期的人工神经网络的研究，许多科学家提出了如自适应共振理论，神经网络理论和 BP 学习理论。高潮阶段的主要研究成果有 HNN 模型、Boltzman 机模型并使多层网络的 BP 算法得到发展，并且迄今为止 BP 算法也是应用最广泛的网络。近年来，人工神经网络的发展进入到平稳阶段，神经网络理论的应用的各个领域多元化发展。并且神经网络理论在各个领域都取得了令人欣慰的进展，如测绘领域，很多学者都在研究如何采用人工神经网络方法进行变形预测，并且取得了一定的成果，得到一些有意义的结论^[38-39]。

3.1.2 神经网络的生物结构

人脑包含有胶质细胞，这些胶质细胞负责供应大脑工作所需营养，但除此之外还包含作为脑组织组成的基本单元的神经细胞，这样的神经细胞大约有一千四百亿个，它们还是神经系统的结构和功能单元，因此，它们也被称作神经元（Neuron）。并且每个神经元有大约一百个其他神经元与之相连接，这些神经元负责信息的接收或产生，传递和处理。这样就形成一个极其庞大且复杂的生物神经网络^[40]。

3.1.2.1 生物神经元的结构

生物神经元由细胞体、树突和轴突、突触等构成。神经元通过突触进行连接。下面就细胞体、树突、轴突和突触进行简单介绍。其结构图参见图 3-1

细胞体（Cell body）由细胞核、细胞质和细胞膜构成。细胞体外部的细胞膜是一种选择、通透性的膜，它通过保持膜内外细胞液的成分差异，从而形成膜内外电位差，因此也被称作膜电位。在细胞体上，输入信号的强度会对其外部细胞膜的大小产生影响，其值范围约为 20~100mV。细胞体能够为神经元的活动供给能量，并且可以进行呼吸、新陈代谢等不同的生化过程。

树突（Dendrite）是细胞体由内向外延伸出的数量很多并相对短（长约 1mm 左右）的像树枝状突起的体神经纤维，周围其它神经元需通过树突传入信息。

轴突（Axon）是神经元突起的最长管状纤维，其长度一般在几厘米到一米之间。在距细胞体的轴突远端，轴突管状纤维会有大量分支，这些分支被称为轴突末梢即神经末梢。神经元传递的神经信号通过轴突传递到其他神经元，轴突是信息传递的主要通道。

突触（Synapse）在相联系的神经元之间通过约 15~50nm 的微小的间隙相联系。两个神经元之间的细胞质需要通过突触进行连接，它们并不能直接连接。一个神经元的冲动通过突触能够传到下一神经元或者能够传到下一细胞。突触前膜、突触间隙和突触后膜构成突触。神经元的轴突末梢分支膨大而构成的突触小体膜就是突触前膜。突触前膜与突触后膜两者的距离空间就是突触间隙。而神经元的突触后膜则可以是细胞体、树突或者轴突^[41-43]。

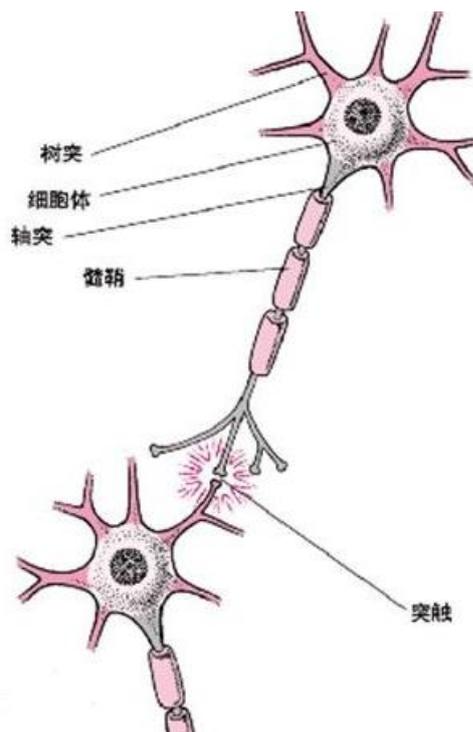


图 3-1 生物神经元结构

Fig 3.1 Biological neuron structure

zkq 20150910

3.1.2.2 生物神经元如何进行信息处理

在生物神经元当中，信息为宽度与幅度相同的脉冲串；突触是输入输出的接口；树突和细胞体作为输入端，接收来自突触点的输入信号；细胞体就相当于一个微型处理器，它对各个树突和各个细胞体的各部位收到的来自其它神经元信号进行组合，并且在一定条件下触发，产生了输出信号；输出信号会沿轴突传到末梢，而轴突末梢作为一个输出端会通过突触将这个输出信号向其他神经元的树突和细胞体进行传递。因为细胞膜本身对不同的离子具有不同通透性，就会使膜内外的细胞液离子产生浓度差。而神经元在没有神经信号输入的时候，它的细胞膜内外会因为离子的浓度差而造成约 70mV（内负外正）的电位差，被称为静息电位，因此神经元的状态是静息状态。当感应到外界刺激的时候，突触便会致使神经细胞的膜电位产生变化，若膜电位从静息电位向正偏移，那么此时的神经元状态处于兴奋状态；反之如果向负偏移，那么神经元的状态就处于抑制状态。在某个给定的时刻，神经元会处于静息、兴奋、抑制三种状态之一。并且，电位变化是可以进行累加的，这个神经细胞膜的电位是其所有突触产生的电位之和，当其值超过-55mV 左右时，便会产生一个脉冲，这个脉冲又被称作神经冲动，并且这个脉冲能够通过轴突向其它神经细胞传递，因此膜电位的总和直接影响该神经细胞兴奋状态下放出的脉冲数。但是突触传递信息有一定时间的延迟，对于温血动物来说延迟时间是 0.3ms~1.0ms。一般情况下每一个神经细胞的轴突连接

着约 100~1000 个其它神经细胞，而神经细胞的信息便是这样从一个神经细胞传递到另一个神经细胞的，而且这种传播是正向的，逆向传播是不被允许的^[44-45]。

3.1.2.3 生物神经网络

生物神经网络是由多个生物神经元以确定的方式及拓扑结构互相连接而形成的，它是一种更加复杂、灵巧的生物信息处理系统。据研究表明，每个生物神经网络系统均为一个有层次、多单元的动态信息处理系统，它们都有独自独特的运行方式和控制机制，用来接收来自生物内外的输入信息，并且对其进行综合分析处理，而后调节控制机体能对环境做出适应的反应。然而生物神经网络的功能并不只是单个神经元信息处理功能简单叠加后的功能。生物神经网络的每个神经元都会有许多的突触与其它神经元进行连接，无论哪个单独的突触连接都不能够对一项信息进行安全表现；只有在它们集成总体的状态下，才能够感应刺激，并能够明确答复刺激的特殊性质。由于在神经元之间突触的连接强度和连接方式都不同而且有可塑性，因此神经网络在宏观上就能够呈现出复杂的千变万化的信息处理能力^[46-47]。

3.2 神经网络模型分类

神经网络经过多年发展，现已延伸出多种类型，不同方法的神经网络，例如被广泛应用的 BP 神经网络、RBF 神经网络、线性神经网络等，处理不同问题应选择相应的神经网络模型作为实验方式。

3.2.1 依据拓扑结构划分网络

按网络拓扑结构可将神经网络划分为前馈神经网络和反馈神经网络。下面就其做简单介绍。

2.3.1.1 前馈神经网络

前馈神经网络是人工神经网络的一种，一般简称为前馈网络。作为最早被提出的一种人工神经网络，前馈神经网络是最简单的一种人工神经网络类型。前馈神经网络因其层数不同，可划分为单层前馈神经网络和多层前馈神经网络。即只有一个输出层的神经网络为单层前馈神经网络，它没有计算功能，包含一个或更多的隐含层的神经网络为多层前馈神经网络。在多层前馈神经网络中，其信息的输入和输出是一个单向传递的过程，即第一层的输出信号作为第二层的输入信号，第二层的输出信号又作为第三层的输入信号，但不会形成反馈，依次类推形成一个有向无环图。感知器（Perceptrons）、RBF（Radial Basis Function）网络、BP（Back Propagation）网络等都是常见的前馈神经网络。下面就这三种最常见的前馈神经网络做一个简单的介绍^[48-49]。

（1）感知器（Perceptrons）。感知器神经网络可被认为是最简单的一种前馈神经网络，感知机神经网络主要在模式分类以及基于模式分类的控制学习及多模态控制

中得到运用。与前馈神经网络相似，感知器网络也可分为单层感知机网络和多层的感知机网络。

(2) RBF (Radial Basis Function) 神经网络。在了解 RBF 神经网络之前需要先了解 RBF 神经元，神经元的变换函数为 RBF (Radial Basis Function) 的神经元即为 RBF 神经元。隐含层由 RBF 神经元构成的前馈神经网络即为 RBF 神经网络。RBF 网络由三层构成，输入层、隐含层和输出层。其中隐含层由 RBF 神经元组成，输出层由线性神经元组成。

(3) BP (Back Propagation) 神经网络。BP 神经网络是目前应用范围较广的神经网络模型。BP 神经网络的算法是按误差逆传播算法。大量的输入、输出关系都贮存在 BP 神经网络中。

2.3.1.2 反馈网络

在反馈神经网络中的每个神经元将自己的输出信号作为其它神经元的输入信号，形成至少一个反馈回路。反馈神经网络经过一段时间的工作才可以达到稳定状态，其中 Hopfield 神经网络是著名的反馈神经网络，得到广泛应用^[50]。

3.2.2 按网络学习模式划分的神经网络

神经网络是一个不断进行学习的网络，即它通过不断地数据训练逐步对各层神经元之间的权值进行修改纠正，使得权值的达到预期期望要求，在这个过程中，神经网络把预先修正的权值更新存储到神经网络中。通俗的讲，神经网络的学习过程就是神经网络修正连接各层神经元权值的过程，在随着训练不断向前，神经网络的性能也不断优化，依据神经网络的学习方法，神经网络大致分为三类：

1.有监督学习。有监督学习也被称为有教师学习，神经网络的学习过程可以说是一个实际输出结果和目标输出结果进行比较不断接近目标结果的过程。在这个学习过程中，外界会存在一个“教师”，而这个目标结果便是外界存在的“教师”根据输入提供的目标结果。神经网络根据实际结果与目标结果进行比较得到的误差，按照一定的规则，对网络权值进行调节。

2.无监督学习。无监督学习是一种依靠自己的力量学习，并不需要外界的“教师”提供目标结果和反馈。网络感应到输入信号，按自己的原则对权值进行调整，使其具有一定的顺序。

3.再励学习。再励学习中，外部力量不会提供目标输出，而是会对网络的输出结果给予奖惩的评价，网络的学习体系会根据奖惩评价选取到好评的操作，从而完善自己。

还有一些网络可以预先设好权值，它们在对问题进行分析的过程中，不会因时间的变化而变化，它们不需要外界的“教师”进行指导，也不需要依靠自己的力量进行学习调整。其中包括 Hopfield 网络和双向联想记(BidirectionalMemory)网络等都是不

需要学习的网络^[51]。

3.3 神经网络的特点

第一，ANN 具有对大规模数据并行协同处理的能力。单一结构的神经网络处理数据的功能很简单，但对于由大量神经元组成的神经网络对大数据处理功能很强。

第二，ANN 在对数据处理时，高容错和高联想是其主要特点。一个单一的神经元或连接对网络的整体功能的影响都比较小。在 ANN 中，储存数据和处理数据是同时进行的。信息存储的分布提供了容错功能，其数据分布在几乎整个网络。所以当相对于整体少数神经元信息丢失毁坏时，任然可以访问其中数据。

第三，人工神经网络具有较强的自主学习能力。神经网络的学习可分为监督式学习或无监督式学习。由于其操作运行方式的不精确性，有除去不相关因素，支持少部分数据实现数据处理的功能，使处于这种处理不精确性的情况下，以自动分类比较自然的方式进行，体现了它具有很强的泛化能力。

第四，ANN 是大规模自组织、自适应的非线性动力系统。人工神经网络具有一般非线性动力系统的共性，即不可预测性、耗散性、高维性、不可逆性、广泛连接性和自适应性等等^[52]。

3.4 神经网络的基本结构

从技术角度上来说，运用神经网络解决实际问题包括以下三个主要步骤：

第一步是架构的人工神经网络，选择合适的网络结构，即神经元或处理元件的数目（PE）的使用，并以适当的方式连接它们，以形成整体网络。

第二个步骤是选择一个合适的算法用于训练网络，即寻求确定对每个突触重量建模两个神经元之间的物理连接的最佳值的方法。

第三步是取样数据集，从数据库中提取需要的数据作为神经网络的学习或训练的输入数据。例如，设定输入集合 V ，在学习过程中通过迭代地调整，使神经网络的指定任务网络设定一个良好的突触权重，通过训练完成一个定义良好的神经网络数学模型^[53]。

神经网络工作模型由图 3-2 给出

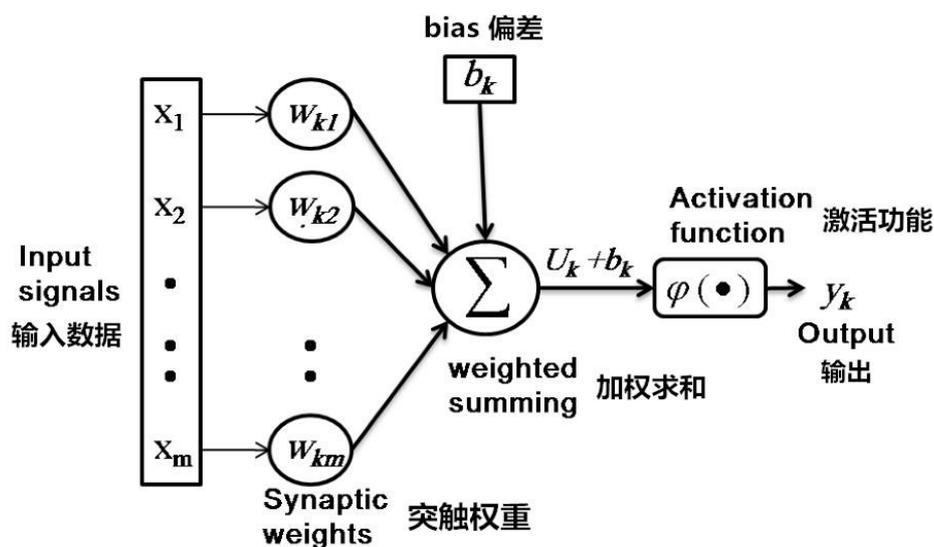


图 3-2 神经网络工作结构模型

Fig3.2 Artificial neural network model of work structure

从数学上来说，该图显示一组输入信号 $\{X_1, X_2, \dots, X_m\}$ 通过每个的神经元被自动接收，在整个连接结构中，加权相当于树突。这些连接的突触加权值是 $\{W_{k1}, W_{k2}, \dots, W_{km}\}$ 。然后，神经元计算的总和，如公式（a）

$$u_k = \sum_{j=1}^m W_{kj} x_j \quad (a)$$

如果这个总和大于一定的偏差 b_k ，神经元尝试通过激活其他神经元进行以其整个轴突的形式数据输出，计算公式如（b）

$$y_k = \Phi(u_k + b_k) \quad (b)$$

其中 ϕ 是神经元的激活函数的输出信号^[54]。多层次和大量的神经元组合构成一个神经网络。这是神经元以第一种形式层通过并将它们分组，然后各个层的每个神经元将被连接到相邻层中的每一个神经元，如图 3-2。

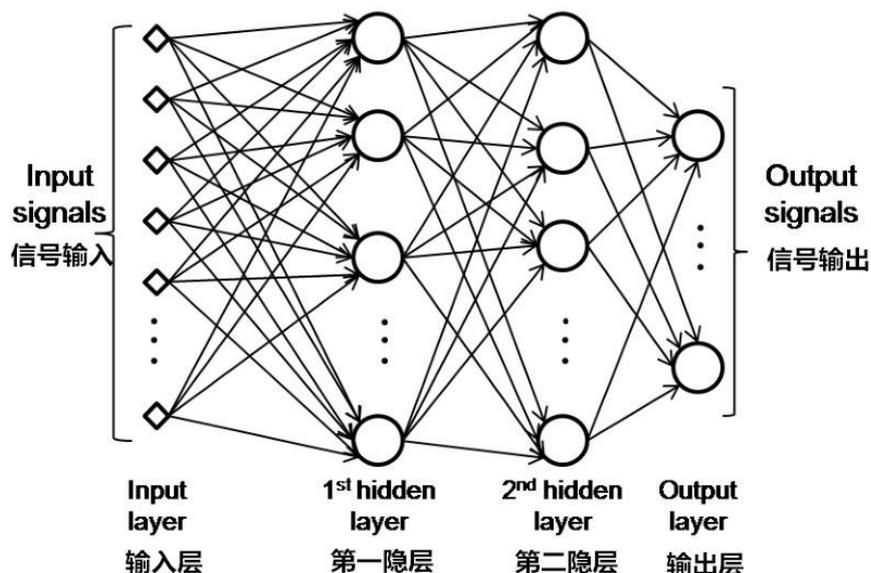


图 3-2 神经网络多层感知器 (MLP)

Fig 3.2 Multilayer perceptron artificial neural networks (MLP)

根据此架构设计的人工神经网络被称为多层感知器 (MLP)，即将学习训练的数据集合映射到单一的输出的数据集上[55]。具有以下特征：

- (1) 相同层的神经元对其他层神经元连接传递，但是与同层神经元不连接传递。
- (2) 输入信号只从输入层沿一个方向流动至所述的输出层，因此构建的这一类神经网络也被称为前馈神经网络。
- (3) 输入层的神经元的数目与输入数据的数据空间的尺寸相对等，即数据集以输入层为 m 维对象矢量输入，则隐层的神经元也是 m 维。
- (4) 输出层的神经元数目与输入数据集假定本对象的分类数量相同。

需要运用神经网络多层感知器运算的不同类的数据集，需要构建不同层数的隐层数目和相对应的维数。

第四章 BP 神经网络的结构和算法

4.1 BP 神经网络简介

BP 神经网络 (Back Propagation Neural Networks) 是在 1986 年由 Rumelhart 和 McClelland 等科学家所提出的一种按误差逆传播算法进行数据训练的多层前馈式的人工神经网络。目前 BP 神经网络学科领域越来越广泛, 如在医学方面的生理、心理学方面以及建立理论模型和网络模型与算法研究等方面。BP 神经网络可以不通过事先确定的函数关系式, 只通过数据训练, 学习和存贮大量的数据输入前和输出后的函数关系。BP 神经网络通过反向传播修正网络的权值和阈值, 以减小输出值与期望值的误差值。BP 神经网络拓扑结构包括输入层 (input)、隐含层(hidden layer)和输出层(output layer)^[56]。

4.2 BP 神经网络的结构

(1) BP 人工神经网络 (Back Propagation Artificial Neural Networks) 是一种含有三层神经元或者是多层神经元的人工神经网络。

(2) BP 神经网络通过各个神经元突触链接前后层神经元, 它是神经网络中多层感知器的一种, 隶属于人工神经网络。其主要特点是误差反馈向前传递, 对误差值不断修正, 直到误差小于预期误差。

(3) BP 网络拓扑结构。BP 神经网络与一般神经网络同样具备输入层、隐含层、输出层。隐含层的数量是一到多层, 每层的神经元和神经元之间互相相连接, 每层的神经元之间都有一个连接权值, 是一个向前推进的网络拓扑结构。如图 4-1 所示, BP 网络的每层神经元互相不连接, 而相邻层之间的神经元互联, 神经元传输信息经过每层的可不断修正调节的权值运算, 并传输到下一层。

(4) 学习数据逆向传播修正。准备进行学习的数据通过输入层输入, 通过隐含层向中间层进行传播, 在输出层得到初始值, 然后再从输出层途径各个中间层回到输入层, 从一层到下一层逐步修正输出值与期望值之间的差值。以此方式修正被称为 BP 算法。

通过计算输出值和期望误差并逆向的传播, 误差向前反馈, 权值不断修正, 网络对输入模式映射关系的误差度不断减小^[57]。

网络拓扑结构

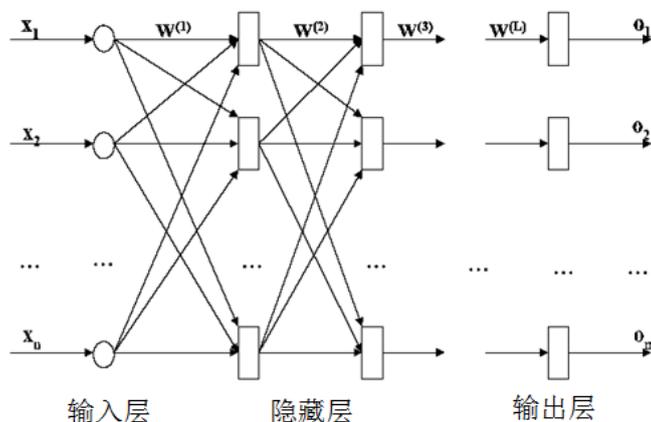


图 4-1 BP 网络拓扑结构

Fig 4.1 BP network topology structure

4.3BP 神经网络的算法

BP 神经网络算法是一种监督式学习算法，即输出层实际输出值与期望输出值不符立即进行误差反向传播。其算法依据最小二乘法,即 LMS 算法,采用逐层向前的方式,使得输出值与期望值之间的误差平方和在阈值范围内^[58]。

(1) BP 网络的结构定义

设定输入层神经元个数为 n ，隐含层神经元个数为 p ，输出层神经元个数为 q 个。

(2) BP 网络的数据变量定义

设定 N 个输入层输入数据为 $x = (x_1, x_2, x_3 \dots x_n)$ ，其对应的隐含层输入数据设为 $h_i = (h_{i1}, h_{i2}, h_{i3} \dots h_{ip})$ ，隐含层输出数据为 $h_o = (h_{o1}, h_{o2}, h_{o3} \dots h_{op})$ ，输出层输入数据为 $y_i = (y_{i1}, y_{i2}, y_{i3} \dots y_{in})$ ，输出层输出数据 $y_o = (y_{o1}, y_{o2}, y_{o3} \dots y_{oq})$ ，期望数据为 $d_o = (d_1, d_2, d_3 \dots d_q)$

(3) BP 网络初始化设定

设定各层的连接权值范围，一般为 $(-1, 1)$ 。误差函数为 e ，误差精度值为 ε ，最大学习次数为 m 。

(4) 选取样本输入数据

设定输入数据个数为 k 个样本，样本输入为 $x(k) = (x_1(k), x_2(k), x_3(k), \dots, x_n(k))$ ，期望输出为 $d(k) = (d_1(k), d_2(k), d_3(k), \dots, d_q(k))$

(5) BP 网络计算隐含层和输出层的输入值和输出值

设定 w_{ih} 为输入层与隐含层的链接权值, w_{ho} 隐含层与输出层的连接权值。隐含层

阈值为 b_h 。输出层阈值为 b_o 。误差函数 $e = \frac{1}{2} \sum_{o=1}^q (d_o(k) - y_{o_o}(k))^2$

样本数据为 $k = 1, 2, \dots, m$ 。设定激活函数为 $f(x)$, 则有

隐含层输入值计算 $hi_h(k) = \sum_{i=1}^n w_{ih} x_i(k) - b_h$, 其中 $h = 1, 2, \dots, p$

隐含层输出值计算 $ho_h(k) = f(hi_h(k))$, 其中 $h = 1, 2, \dots, p$

输出层输入值计算 $yi_o(k) = \sum_{h=1}^p w_{ho} ho_h(k) - b_o$, 其中 $o = 1, 2, \dots, q$

输出层输出值计算 $yo_o(k) = f(yi_o(k))$, 其中 $o = 1, 2, \dots, q$

(6) 计算样本数据 (设样本数据为 k 个) 误差函数 e 对输出层的各神经元偏导数
设此偏导数为 $\delta_o(k)$ 。

已知 $yi_o(k)$, 偏导公式转换为 $\frac{\partial e}{\partial w_{ho}} = \frac{\partial e}{\partial yi_o} \frac{\partial yi_o}{\partial w_{ho}}$, 式中

$$\frac{\partial yi_o(k)}{\partial w_{ho}} = \frac{\partial (\sum_h^p w_{ho} ho_h(k) - b_o)}{\partial w_{ho}} = ho_h(k),$$

$$\frac{\partial e}{\partial yi_o} = \frac{\partial (\frac{1}{2} \sum_{o=1}^q (d_o(k) - y_{o_o}(k))^2)}{\partial yi_o} = -(d_o(k) - y_{o_o}(k)) y_{o_o}'(k)$$

$$= -(d_o(k) - y_{o_o}(k)) f'(yi_o(k)) \triangleq -\delta_o(k)$$

(7) 通过以上的运算结果, 推导计算误差函数 e 对隐含层各层神经元偏导数。
设此偏导数为 $\delta_h(k)$ 。

误差函数 e 对输入层与隐含层连接权值偏导数为 $\frac{\partial e}{\partial w_{ih}} = \frac{\partial e}{\partial yi_o} \frac{\partial yi_o}{\partial w_{ih}} = -\delta_o(k) ho_h(k)$

误差函数 e 对隐含层与输出层连接权值偏导数为

$$\frac{\partial e}{\partial w_{ih}} = \frac{\partial e}{\partial hi_h(k)} \frac{\partial hi_h(k)}{\partial w_{ih}}$$

$$\text{其中 } \frac{\partial hi_h(k)}{\partial w_{ih}} = \frac{\partial(\sum_{i=1}^n w_{ih}x_i(k) - b_h)}{\partial w_{ih}} = x_i(k)$$

$$\frac{\partial e}{\partial hi_h(k)} = -(\sum_{o=1}^q \delta_o(k)w_{ho})f'(hi_h(k)) \triangleq -\delta_h(k)$$

(8) 通过误差函数 e 对输出层中的各神经元偏导数 $\delta_o(k)$ 和隐含层的输出值

$ho_h(k)$ 修正权值 $w_{ho}(k)$ 。计算公式如下：

$$\text{变量值 } \Delta w_{ho}(k) = -\mu \frac{\partial e}{\partial w_{ho}} = \mu \delta_o(k) ho_h(k),$$

神经元修正值为 $w_{ho}^{N+1} = w_{ho}^N + \eta \delta_o(k) ho_h(k)$ ，其中 N 代表第 N 个神经元。

(9) 通过误差函数 e 对隐含层的各神经元偏导数 $\delta_h(k)$ 和输入层神经元输入，修

正连接权值 $w_{ih}(k)$ 。

$$\text{变量值 } \Delta w_{ih}(k) = -\mu \frac{\partial e}{\partial w_{ih}} = -\mu \frac{\partial e}{\partial hi_h(k)} \frac{\partial hi_h(k)}{\partial w_{ih}} = \delta_h(k) x_i(k)$$

神经元修正值为 $w_{ih}^{N+1} = w_{ih}^N + \eta \delta_h(k) x_i(k)$

(10) 对权值修正后，计算全局误差是否达到预期误差范围之内，设全局误差为

$$E, \text{ 则 } E \text{ 为: } E = \frac{1}{2m} \sum_{k=1}^m \sum_{o=1}^q (d_o(k) - y_o(k))^2$$

(11) 通过全局误差 E 半段是否达到预期要求，误差达到预期则结束运算，否则选取下一样本及对应输出，返回计算隐含层各神经元的输入和输出^[59]。

4.4 BP神经网络训练方法

(1) 构建网络的输入层和输出层。输入和输出层的神经元根据需要仿真的实际数据和仿真结果确定。

(2) 输出层的维数可根据构建网络选取的训练数据的要求确定。例如：运用构建的 BP 网络对数据进行分类，分为 x 类，则网络输出层的神经元个数为 x 或 $\log_2 x$ 。

(3) 隐含层的设计。对于任意一个闭区间内的连续函数 BP 神经网络可以用只含有一层隐含层的网络进行拟合，因此通过一个具备三层的 BP 网络就可以实现从 x 维到多维的映射。

4.5 BP 网络在 matlab 中实现的常用函数

在 matlab 中实现 BP 网络算法，需要运用 matlab 工具箱调用工具函数^[60]，下边介绍实现 BP 算法的几个常用函数^[61]：

(1) 常用神经元间的传递函数：

tansing 函数：tansing 函数是一个双曲正切 S 型传递函数，用于将神经元输入值在 $(-\infty, +\infty)$ 区间内的数值映射到 $(-1, +1)$ 区间上。它是 BP 网络隐含层常用的传递函数；

purelin 函数：purelin 函数是一个线性传递函数，它是 BP 网络输出层常用的传递函数；

(2) BP 网络建立函数为 newff 函数，通过 newff 函数建立一个 BP 神经网络。

(3) BP 网络训练函数为 train 函数，其用于训练 BP 神经网络。

(4) 数据仿真函数是 sim 函数，其用于训练前后的 BP 神经网络仿真。

第五章 基于BP神经网络的森林火灾预测

5.1 BP神经网络预测结构和模型

5.1.1 森林火灾预测的BP网络结构确定

建立森林火灾预测BP神经网络的结构，需要确立神经网络输入层的矩阵维数、隐含层的神经元个数（即节点数）、BP网络层数、输入和隐含层的传输函数、隐含层和输出层的传输函数等等。

1) 输入层数据准备

输入层输入影响火灾发生的气象数据矩阵，包括每天的日平均气温（Daily mean temperature）、日平均相对湿度（Daily mean relative humidity）、日平均风速（Daily mean wind Speed）日降水量（Daily rainfall）。以日期和林火影响因素构建输入矩阵。

2) BP网络传递函数的选择

Logsig函数（Log-sigmoid型函数）tansig函数（tan-sigmoid型函数）purelin函数等。

Logsig函数是输入和隐含层的传输函数，tansig函数和purelin函数是隐含层和输出的传输函数。

Logsig传输函数的数学公式为：

$$\text{logsig}(x) = \frac{1}{1 + e^{-x}}$$

Log-sigmoid函数的基本性质是定义域为 $(-\infty, +\infty)$ ，它的值域为 $(0,1)$ 。应用到神经网络中即输入数据可取任意值，限定输出范围在0到1之间。

tansig函数的数学公式为：

$$\text{tansig}(x) = \frac{2}{1 + e^{-2x}} - 1$$

tansig函数的基本性质是定义域为 $(-\infty, +\infty)$ ，它的值域范围为 $(-1,1)$ 。即输入数据可取任意值，限定输出范围在-1到1之间。

purelin函数是一个线性函数，其公式为：

$$\text{purelin}(x) = a^x + b \quad (\text{其中 } a \text{ 和 } b \text{ 为常数})$$

purelin 函数的基本性质是定义域为 $(-\infty, +\infty)$ ，它的值域范围为 $(-\infty, +\infty)$ 。即输入数据和输出数据都在负无穷到正无穷之间。

在桂林市与广州市气象数据作为样本训练集每日林火发生预测时，采取了各种函数运用进行训练，根据需要拟合数据的数据特点，采用 logsig 函数作为输入层和隐含层的传递函数， tansig 函数作为隐含层和输出层的传递函数的效果最好。

3) 神经元个数的确定：

此次运算我采用的是 3 层 BP 神经网络。确定神经元的个数和网络层数在目前来说没有成型的理论支持，一般先构建网络，设定不同的网络神经元个数和网络层数，每次设定都进行实验，对比实验结果的误差精度。但实验选取神经元个数和层数时，应当设定一个范围，一般情况下，在能够接受的误差范围内，尽量减少隐含层的神经元个数。本文针对所选取的实验数据，从小到大依次增加所建立的神经网络隐含层神经元个数，先设置少量，进行实验，然后逐渐增加，直到实验误差在允许的阈值范围内。一个具备 3 层的 BP 神经网络，若隐含层的神经元个数足够大，就可以逼近任意一个非无界区域上的任何连续函数，因此，神经元个数越多对预期要达到的目标越好。但伴随存在的问题是神经元数量过多时，可能会导致训练时间增加，神经网络的结构不够简易^[61]。

5.1.2 基于 BP 网络模型森林火灾预测模型

森林火灾的起火过程、扩散传导、熄灭过程与本地区的气象条件有很大的联系性。影响森林火灾的发生的主要气象因素包括气温、湿度、风速和降水量。大气环流是影响各个气象条件变化的基本动力，同时森林火险的等级与气温、相对湿度、风速、日均降水量等要素有决定性关系。

其中气温以及湿度是森林火灾发生的重要因素，风向等是森林火灾传递蔓延的主要因素。所以说做好关于森林火灾发生的森林火情严重性预知，预报森林火灾发生概率具有非常重要的意义^[62]。

基于神经网络森林火灾预测模型结构框图如图 5-1:

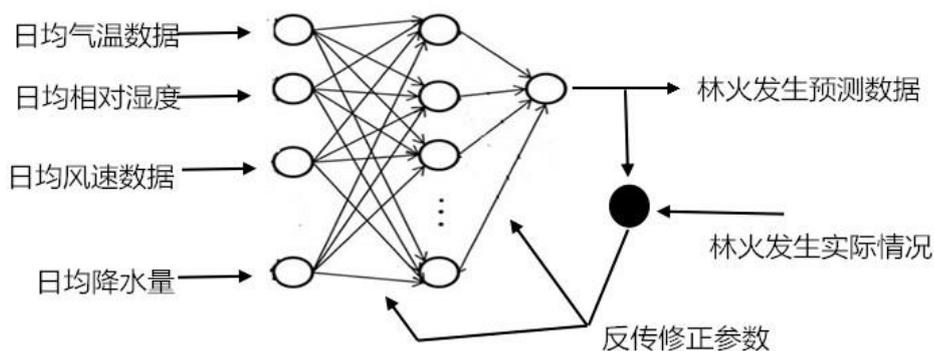


图 5-1 基于神经网络森林火灾预测模型结构

Fig5.1 Forest fire prediction model based on Neural Network

根据 BP 算法的运算步骤，首先是将数据进行正向传播，计算出每个连接权的值，计算网络和输入样本数据级的误差，如果误差大于设定的值 ϵ ，那么就需要反传修正权值，重新进行正向传播，进行对比，如果不小于设定的容许误差 ϵ ，继续反传修正权值，重新进行正向传播，直至误差达到容许的范围之内。这个过程的 BP 神经网络模型学习算法流程图，如图 5-2:

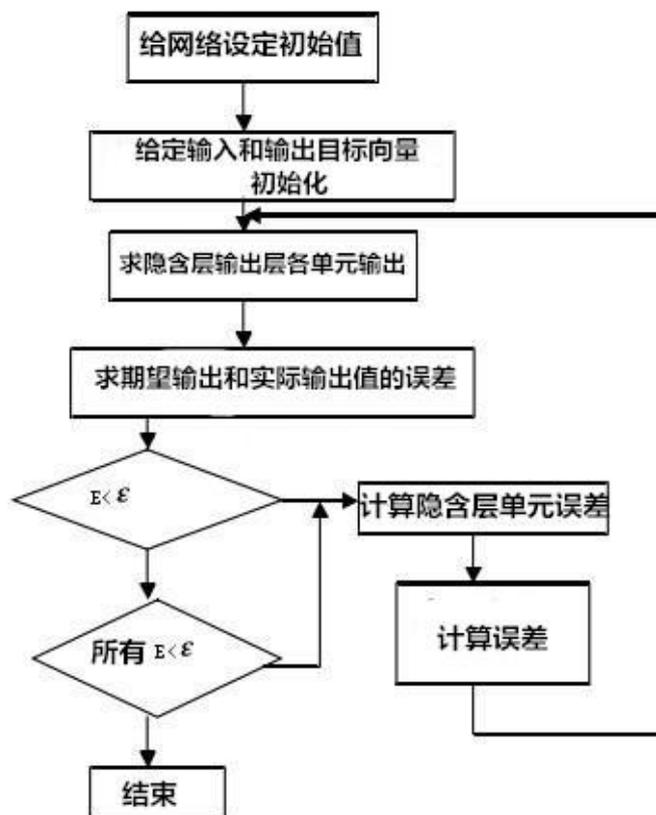


图 5-2 BP 算法流程图

Fig5.2 BP neural network algorithm flow chart

5.2 基于 BP 网络的桂林林火日发生预测

5.2.1 数据准备

现在准备广西壮族自治区桂林市 2005 年每月每天的日平均气温 (Daily mean temperature)、日平均相对湿度 (Daily mean relative humidity)、日平均风速 (Daily mean wind Speed) 和日均降水量 (Daily rainfall) 作为输入, 森林火灾是否发生赋予数值含义, 即森林火灾发生的输出数值为 1, 森林火灾不发生的输出数值为 0。以桂林市 2005 年全年数据作为对森林火灾发生预测作为训练样本, 通过对桂林市 2010 年的历史气候数据做出预测, 经过对桂林市的火灾发生预测情况和森林火灾发生的实际情况进行对比统计, 从而评价预测结果的优良性。

表 5-1 给出的是桂林市 2005 年 6 月份的历史气候数据和火灾发生状况数据, 如下:

表 5-1 桂林市 2005 年 6 月份的林火训练值
Tab 5.1 Forest fire training sample values of Guilin in June. , 2005

年份	月份	日期	平均气温 (/°C)	日平均相对湿度 (%)	日平均风速 (m/s)	日平均降水量 (mm)	森林火灾发生实际情况
2005	6	1	14.4	88	1.6	2.2	0
2005	6	2	18.6	71	1.8	0.1	0
2005	6	3	20.5	63	0.9	0	1
2005	6	4	19.5	63	0.8	0	1
2005	6	5	19.4	80	1.5	1	0
2005	6	6	19.9	87	1.6	3	0
2005	6	7	22.8	77	1.4	0	0
2005	6	8	24.8	74	1.7	0	0
2005	6	9	24.5	69	3.5	0	1
2005	6	10	13.4	74	4.9	0	0
2005	6	11	11.6	82	3.5	0.1	0
2005	6	12	13.6	69	4.2	0.2	0
2005	6	13	19.1	45	3	0	1
2005	6	14	18.9	53	0.9	0	1
2005	6	15	18.4	69	0.9	0	0

2005	6	16	17	94	1.4	27.3	0
2005	6	17	18.1	92	1.1	10.4	0
2005	6	18	18.4	98	0.7	2.3	0
2005	6	19	20.2	92	0.9	14.5	0
2005	6	20	22.4	69	1.2	0	1
2005	6	21	22.3	69	1.3	0	1
2005	6	22	25	78	1.2	0	0
2005	6	23	21.6	82	2.9	6.1	0
2005	6	24	23	78	1.3	0	0
2005	6	25	20.9	86	0.6	14.1	0
2005	6	26	22.1	80	0.9	0	0
2005	6	27	24	79	1	0.3	0
2005	6	28	25.2	82	1.2	0.1	0
2005	6	29	27.1	71	2.6	0.1	0
2005	6	30	28.2	73	1.8	0.2	0

表 5-2 给出的是桂林市 2010 年待预测样本数据，如下：

表 5-2 桂林市 2010 年待预测样本数据
Tab5.2 Forest fire predict sample values of Guilin in 2010

样本	平均气温 (/°C)	日平均相对湿度 (%)	日平均风速 (m/s)	日平均降水量 (mm)	森林火灾发生实际情况
样本 1	14.5	44	3.3	0	1
样本 2	16.9	34	1.3	0	1
样本 3	21.6	88	2	4.8	0
样本 4	22.5	93	1.3	0	0
样本 5	17.8	96	1.5	58.7	0
样本 6	15.3	66	1.3	0	1
样本 7	19.8	54	1.5	0	1
样本 8	17.8	96	1.5	58.7	0
样本 9	18	83	1.3	0	0
样本 10	21.6	85	1	0	0
样本 11	23.3	87	1.3	0	0

样本 12	24.8	86	2	0	0
样本 13	22.1	90	1	7.3	0

5.2.2 对气候数据进行归一化处理

简单的来说归一化的目的就是通过归一化的方法将复杂数据转换成便于实验计算的数据的一种方法。

数据通过 matlab 神经网络模型预测实验前，一般情况下要对样本参数进行数据归一化处理，这样可以有效地减小不同数据之间数据大小比例的差异以及单位的不同所造成的误差，在运行神经网络之前要对进行仿真预测的数据进行归一化处理，即将数据全部转化在 0 到 1 的区间之内。

对训练样本进行归一化,对森林火灾数据归一化的公式为：

$$y = \frac{x - \min}{\max - \min}$$

公式中的 x 为归一化前的数据,y 为归一化后的数据;min 代表本列数据的最大值, max 代表本列数据的最小值。

5.2.3 桂林市数据在 MATLAB 中训练及预测过程

将森林火灾训练数据和预测数据利用 xlsread 导入 matlab 设定 p 为输入层数据矩阵，即气象数据，将 2005 年桂林市历史气候数据和森林火灾发生状况导入 excel 表格中，将文件夹命名为 train_data_day，从 train_data_day excel 文件读取数据，从 sheet1 中的 D2 单元格开始读取到 Gn 结束（n 为数据矩阵完结处）其中单元格 D 列到 G 列共 4 列数据，依次为日平均气温、日平均相对湿度、日平均风速和日降水量，即：

```
p=xlsread('train_data_day','sheet1','D2:Gn');
%对数据矩阵 p 进行归一化处理
p_max=max(p);
p_min=min(p);
[~,m]=size(p);
for i=1:m
    p(:,i)=(p(:,i)-p_min(i))/(p_max(i)-p_min(i));
end
```

设定 t 为输出层数据，即桂林市 2005 年的森林火灾实际发生情况，同样，从

train_data_day excel 文件读取数据，从 sheet1 中的 H2 单元格开始读取到 H31 单元格结束，即

```
t=xlsread('train_data_day','sheet1','H2:Hn');
对 t 数据进行归一化处理
pp_max=max(pp);
pp_min=min(pp);
[~,m]=size(pp);
for i=1:m
    pp(:,i)=(pp(:,i)-pp_min(i))/(pp_max(i)-pp_min(i));
end
```

利用 newff 函数建立 BP 神经网络 net1，传递函数为 logsig 函数和 tansig 函数
net1=newff(p,t,[88],{'logsig','tansig'});

其中 p 为神经网络的输入矩阵，同时限定神经网络的神经元个数与 p 矩阵相符，t 是输出林火发生与否的典型值，即训练目标，即 1 或 0，[88]是设定隐含层神经元个数为 88 个。

```
net1.trainParam.max_fail = 20;
```

允许训练迭代不下降次数为 20 次

利用 train 函数对神经网络进行训练 Net1 为 BP 神经网络，p 代表神经网络输入，t 代表神经网络目标，即：

```
net1=train(net1,p,t);
```

输入需要进行预测的数据，将 2010 桂林历史气候数据导入 excel 表格中，将文件夹命名为 data_day，从 data_day excel 文件读取数据。

```
pp=xlsread('data_day','sheet1','D2:Gn');
```

运用 sim 函数执行代码，使数据通过 BP 神经网络进行预测，其中 R1 为输出层预测数据

```
R1=(sim(net1,pp'))
```

图 5-3 给出的是多样本 BP 网络训练拟合曲线：

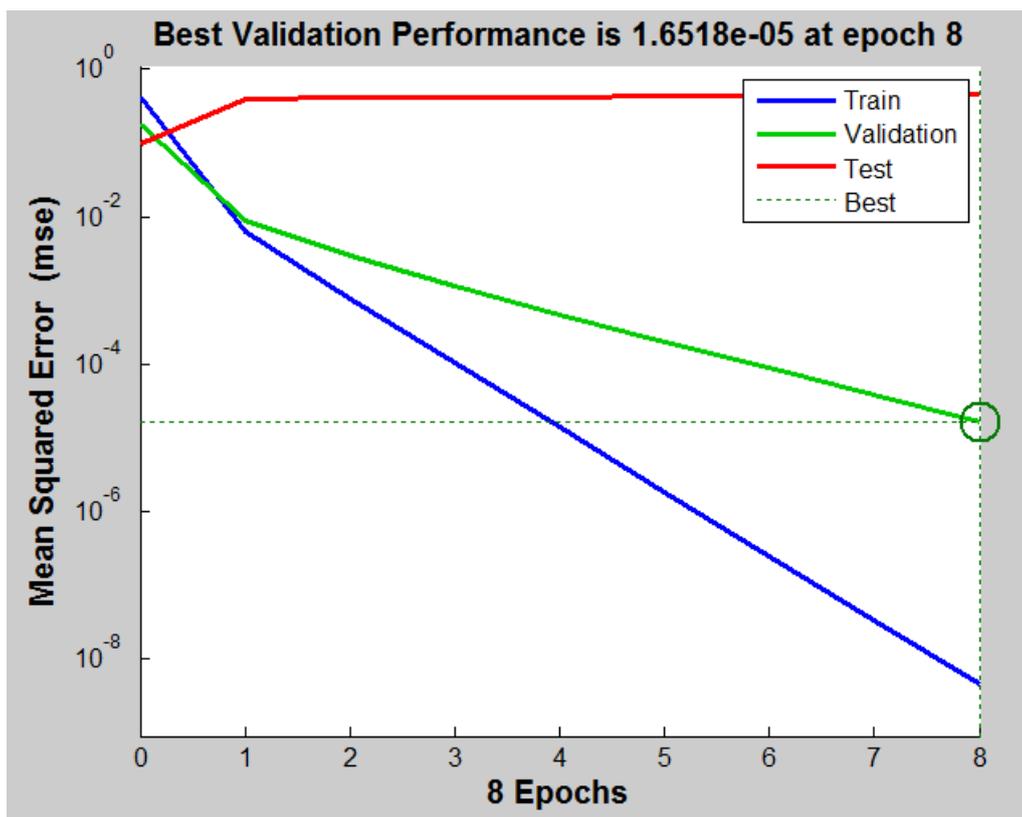


图 5-3 BP 网络训练拟合曲线

Fig5.3 The training of BP network curve fitting

图 5-3 展示了，桂林市气象数据和森林火灾发生数据运用 newff 函数进行的训练过程。matlab 运用其中 60% 的数据用于对网络训练，20% 用于数据检验，剩下 20% 用于数据验证。这是为了防止过度拟合的发生，采取了对训练提前终止的策略。

样本数据的仿真结果如下：

e =0.0165 0.1202 -0.0025 -0.0031 -0.0580 0.2771 0.1608 -0.0580 -0.1196 -0.0160
-0.0055 -0.0015 -0.0085

表 5-3 2010 年桂林市样本预测拟合值

Tab5.3 Day forecast of forest fire of Guilin in 2010

样本	林火发生与否	林火发生预测拟合值
样本 1	1	0.9835
样本 2	1	0.8798
样本 3	0	0.0025
样本 4	0	0.0031
样本 5	0	0.0580

样本 6	1	0.7229
样本 7	1	0.8392
样本 8	0	0.0580
样本 9	0	0.1196
样本 10	0	0.0160
样本 11	0	0.0055
样本 12	0	0.0015
样本 13	0	0.0085

表 5-3 给出的是广州市 2005 年样本数据的预测拟合值与森林火灾发生实际情况的数据。

5.2.4 桂林市预测数据和实际数据误差对比

为了直观的对比 BP 神经网络预测值和实际情况,运用 matlab 对样本林火实际发生值和 BP 神经网络预测值进行对比,建立方式如下:

```

y1=[1,1,0,0,0,1,1,0,0,0,0,0,0];
y2=[0.9835 0.8798 0.0025 0.0031 0.0580 0.7229 0.8392 0.0580 0.1196 0.0160 0.0055
0.0015 0.0085];
%建立实测值与预测值图
plot(1:13,y1,'b',1:13,y2,'r');
h = legend('实测值','BP 神经网络预测值');
axis([1,13,-1,1.5]);
hold on
%建立图表标题
title('实测值与预测值');
xlabel('样本');
ylabel('林火发生值');
%建立预测误差图
e=y1-y2
figure(4);
plot(1:13,e,'b');
axis([1,13,-1,1]);
title('预测误差 e');
xlabel('样本');

```

ylabel('误差值');

其中, y_1 为林火实际发生值, y_2 为 BP 网络预测值, e 为预测误差。如图 5-4 为 BP 神经网络预测桂林森林火灾拟合效果图。

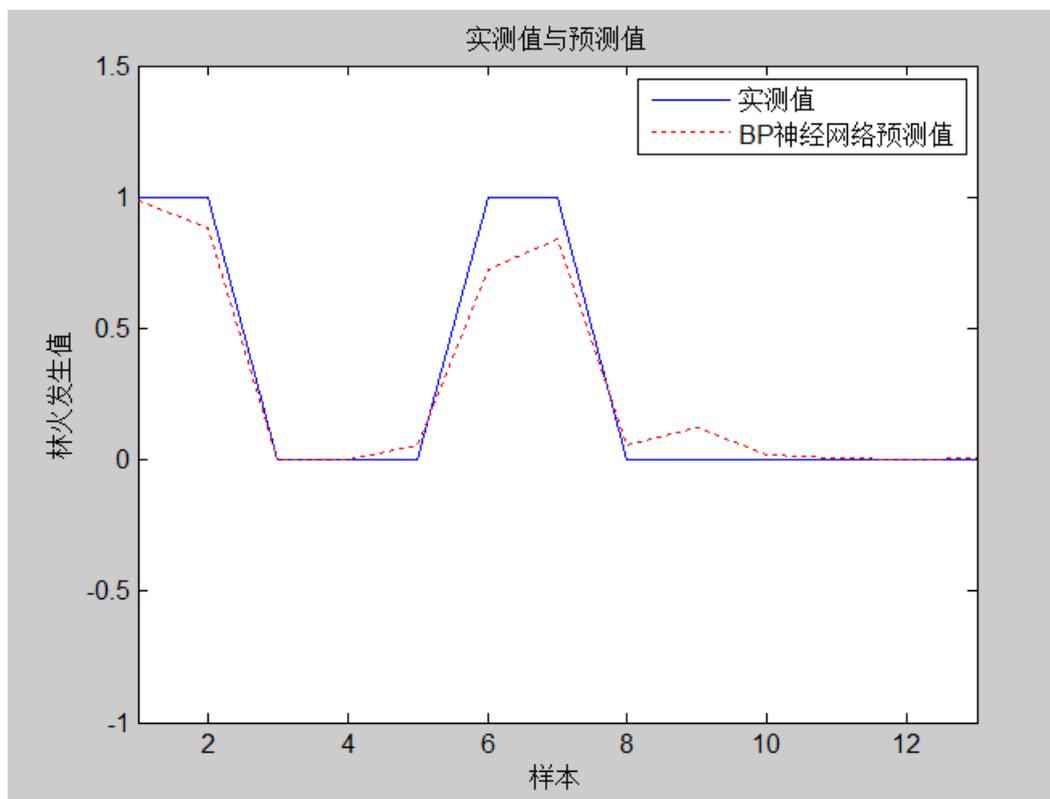


图 5-4 BP 神经网络预测桂林森林火灾拟合效果图

Fig5.4 The fitting effect chart of prediction for Guilin forest fire of BP neural network

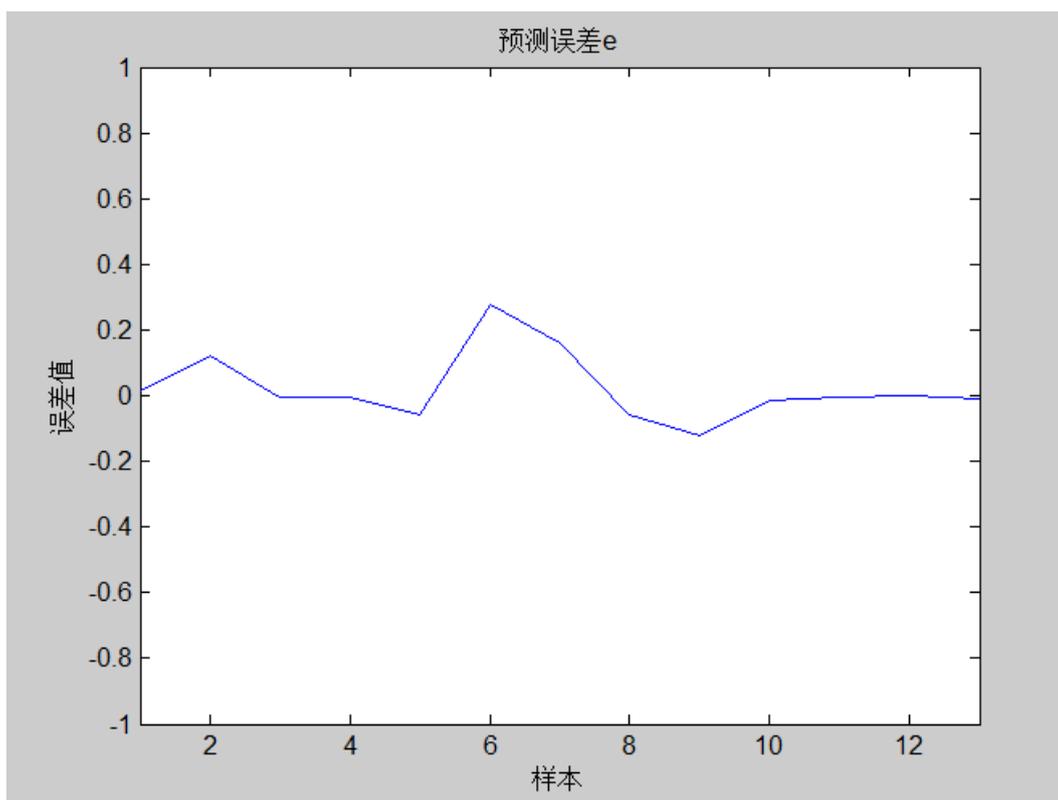


图 5-5 BP 神经网络预测桂林森林火灾的误差

Fig 5.5 The error of prediction for Guilin forest fire of BP neural network

图 5-5 展示了 BP 神经网络的森林火灾预测拟合值与实际值的误差。

5.2.5 桂林市样本拟合值与实际值相对误差分析

如表 5-4 给出的是桂林市 2010 年森林火灾发生样本数据的拟合值与实际值的相对误差，收集的实际统计数据 and 构建的神经网络计算的拟合值进行比较得出相对误差。通过相对误差可以直观发现相对误差在 0.1 左右，有极个别数据误差达到 0.2，从定性的分析角度可以对森林火灾的发生进行预测。

表 5-4 桂林市森林火灾样本预测相对误差
Tab5.4 The error of prediction for Guilin forest fire

样本	样本相对误差
样本 1	0.0165
样本 2	0.1202
样本 3	-0.0025
样本 4	-0.0031
样本 5	-0.0580
样本 6	0.2771

样本 7	0.1608
样本 8	-0.0580
样本 9	-0.1196
样本 10	-0.0160
样本 11	-0.0055
样本 12	-0.0015
样本 13	-0.0085

5.3 基于 BP 网络的广州林火日发生预测

为了测试设计的神经网络对相似气候条件和环境条件差异不大地区的林火预测的有效性，对广州市运用设计的 BP 神经网络模型进行测试。

5.3.1 数据准备

现在准备广东省广州市 2000 年每月每天的日平均气温(Daily mean temperature)、日平均相对湿度(Daily mean relative humidity)、日平均风速(Daily mean wind Speed)和 20 时到次日 20 时的日降水量(Daily rainfall)作为输入，森林火灾是否发生赋予数值含义，即森林火灾发生的输出数值为 1，森林火灾不发生的输出数值为 0。以广州市 2000 年 3 月份数据作为对森林火灾发生预测作为训练样本，通过对广州市 2005 年的历史气候数据做出预测，经过对桂林市的火灾发生预测情况和森林火灾发生的实际情况进行对比统计，对其结果进行分析。

表 5-5 给出的是用做为训练样本的广州市 2000 年 3 月份林火发生和气候数据。

表 5-5 广州市 2000 年 3 月份的林火训练值

Tab 5.5 Forest fire training sample values of Guangzhou in March , 2000

年份	月份	日期	平均 气温 (/°C)	日平 均相对湿 度 (%)	日平 均风速 (m/s)	日平 均降水量 (mm)	森 林 火 灾 发 生 实 际 情 况
2000	3	1	22	74	2	0	1
2000	3	2	21.7	73	1.3	0	0
2000	3	3	21.8	76	1.8	0	0
2000	3	4	21.6	70	1.5	0	1
2000	3	5	17.4	73	1.8	0	0
2000	3	6	14.4	44	3.3	0	1
2000	3	7	16.8	33	1.3	0	1

2000	3	8	18.8	44	1	0	0
2000	3	9	19.7	53	1.5	0	1
2000	3	10	21.5	65	1.3	5.1	0
2000	3	11	21.3	76	1.3	0	0
2000	3	12	22.2	71	1.5	0.2	0
2000	3	13	21.6	82	1.8	2.4	0
2000	3	14	21.5	88	2	4.8	0
2000	3	15	22.4	93	1.3	0	0
2000	3	16	20.8	86	1	2.7	0
2000	3	17	18.2	87	2	0.8	0
2000	3	18	16.8	85	1.5	0	0
2000	3	19	20.4	74	0.3	0	0
2000	3	20	27	75	1.5	0	1
2000	3	21	22.4	76	1.3	0	0
2000	3	22	22.2	86	1.2	0	0
2000	3	23	17.8	79	2.5	6.7	0
2000	3	24	17.7	96	1.5	58.7	0
2000	3	25	18	82	1.3	0	0
2000	3	26	21.6	85	1	0	0
2000	3	27	23.3	86	1.3	0	0
2000	3	28	24.8	85	2	0	0
2000	3	29	22.1	91	1	7.3	0
2000	3	30	22.2	76	0.8	0	0
2000	3	31	22	81	0.8	0	0

表 5-6 给出的是广州市 2005 年待预测样本数据。

表 5-6 广州市 2005 年待预测样本数据
Tab 5.6 Forest fire predict sample values of Guangzhou in 2005

样本	平均气温 (/°C)	日平均相对湿度 (%)	日平均风速 (m/s)	日平均降水量 (mm)	森林火灾发生实际情况
样本 1	10.7	87	1	3.7	1

样本 2	10.4	93	1.2	5.8	1
样本 3	12.1	67	2.3	2.1	1
样本 4	21	81	1.3	0	0
样本 5	21.5	89	0.9	0.6	0
样本 6	7.7	61	2.1	0.4	0
样本 7	10.7	55	1.3	0	1
样本 8	12.5	76	0.9	0	1
样本 9	21	85	1.4	1.7	0
样本 10	20.5	78	1.2	0	0
样本 11	22.4	81	1.4	14	0
样本 12	21.1	84	1.2	0	0
样本 13	23.1	88	1	0	0
样本 14	23.9	84	1.4	0.5	0
样本 15	19.5	87	1.8	9.2	0

5.3.2 广州市数据在 MATLAB 中训练及预测过程

第一，训练数据输入层导入。

将森林火灾训练数据和预测数据利用 xlsread 导入 matlab。同样设定 p 即气象数据为输入层数据矩阵，将 2000 年广州市历史气候数据和森林火灾发生状况导入 excel 表格中，将数据文件 train_data_day，从 train_data_day .excel 文件读取数据，从 sheet1 中的 D2 单元格开始读取到 Gn 结束（n 为数据矩阵完结处）其中单元格 D 列到 G 列共 4 列数据，依次为日平均气温、日平均相对湿度、日平均风速和日降水量，即：

```
p=xlsread('train_data_day','sheet1','D2:Gn');
%对数据矩阵 p 进行归一化处理
p_max=max(p);
p_min=min(p);
[~,m]=size(p);
for i=1:m
    p(:,i)=(p(:,i)-p_min(i))/(p_max(i)-p_min(i));
end
```

第二，训练数据输出层导入。设定 t 为输出层数据，即广州市 2000 年的森林火灾实际发生情况，同样，从 train_data_day excel 文件读取数据，从 sheet1 中的 H2 单元格开始读取到 H31 单元格结束，即

```
t=xlsread('train_data_day','sheet1','H2:Hn');
对 t 数据进行归一化处理
pp_max=max(pp);
pp_min=min(pp);
[~,m]=size(pp);
for i=1:m
    pp(:,i)=(pp(:,i)-pp_min(i))/(pp_max(i)-pp_min(i));
end
```

利用 newff 函数建立 BP 神经网络 net1，传递函数为 logsig 函数和 tansig 函数
`net1=newff(p,t',[88],{'logsig','tansig'})`;

其中 p 为神经网络的输入矩阵，同时限定神经网络的神经元个数与 p 矩阵相符，t 是输出林火发生与否的典型值，即训练目标，即 1 或 0，[88]是设定隐含层神经元个数为 88 个。

```
net1.trainParam.max_fail = 20;
```

允许训练迭代不下降次数为 20 次

第三，数据训练。利用 train 函数对神经网络进行训练 net1 为 BP 神经网络，p 代表神经网络输入，t 代表神经网络目标，即：

```
net1=train(net1,p,t');
```

输入需要进行预测的数据，将 2005 广州市历史气候数据导入 excel 表格中，将文件夹命名为 data_day，从 data_day excel 文件读取数据。

```
pp=xlsread('data_day','sheet1','D2:Gn');
```

运用 sim 函数，使数据通过 BP 神经网络进行预测，其中 R1 为输出层预测数据

```
R1=(sim(net1,pp'))
```

表 5-7 给出的是广州市 2005 年样本数据的预测拟合值与森林火灾发生实际情况的数据。

表 5-7 2005 年广州市样本预测拟合值
 Tab5.7 Day forecast of forest fire of Guangzhou in 2005

样本	森林火灾发生实际情况	林火发生预测拟合值
样本 1	1	0.9485
样本 2	1	0.9512
样本 3	1	0.9112
样本 4	0	0.1454
样本 5	0	0.0395

样本 6	1	0.9842
样本 7	1	0.9684
样本 8	1	0.9323
样本 9	0	0.0644
样本 10	0	0.2803
样本 11	0	0.0501
样本 12	0	0.0875
样本 13	0	0.0162
样本 14	0	0.0107
样本 15	0	0.0613

5.3.3 广州市预测数据和实际数据误差对比

同样运用 matlab 对样本林火实际发生值和 BP 神经网络预测值进行对比，建立方式如下：

```

y1=[1,1,1,0,0,1,1,1,0,0,0,0,0,0,0];
y2=[0.9485 0.9512 0.9112 0.1454 0.0395 0.9842 0.9684 0.9323 0.0644 0.2803 0.0501
0.0875 0.0162 0.0107 0.0613 ];
%建立实测值与预测值图
plot(1:15,y1,'b',1:15,y2,'r');
h = legend('实测值','BP 神经网络预测值');
axis([1,15,-1,1.5]);
hold on
%建立图表标题
title('实测值与预测值');
xlabel('样本');
ylabel('林火发生值');
%建立预测误差图
e=y1-y2
figure(4);
plot(1:15,e,'b');
axis([1,15,-1,1]);
title('预测误差 e');
xlabel('样本');

```

ylabel('误差值');

其中, y_1 为林火实际发生值, y_2 为BP网络预测值, e 为预测误差。如图5-6展示了BP神经网络预测广州森林火灾拟合效果。

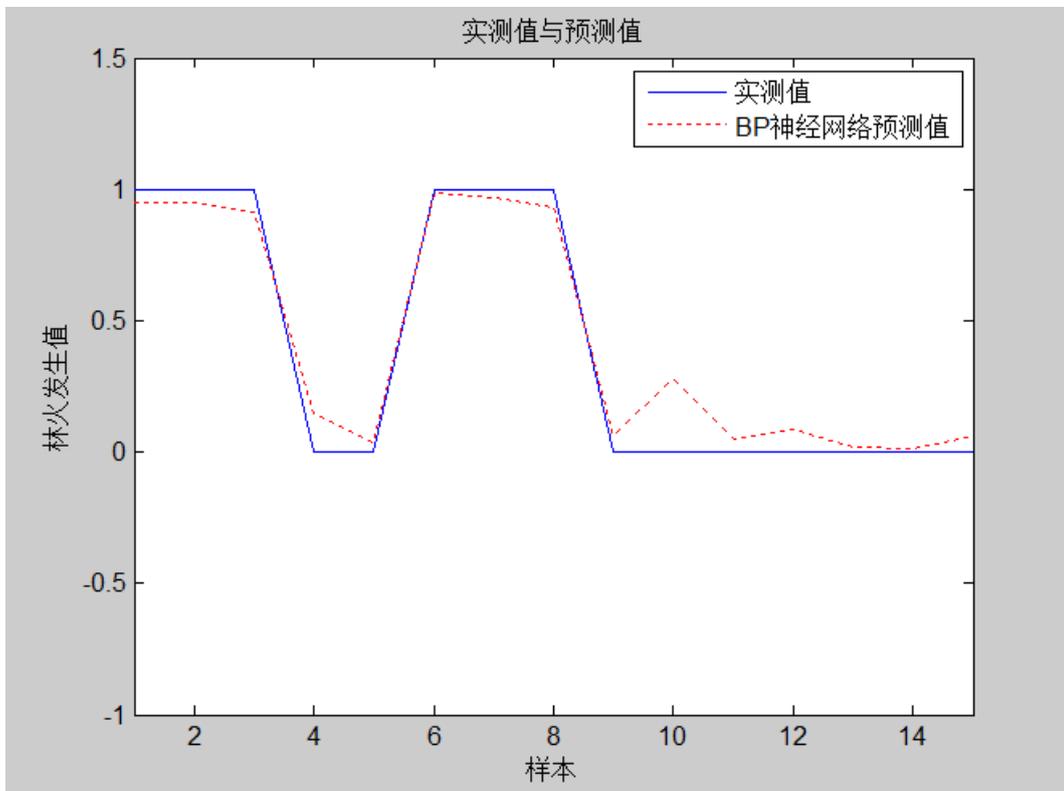


图 5-6 BP 神经网络预测广州森林火灾拟合效果图

Fig5.6 The fitting effect chart of prediction for Guangzhou forest fire of BP neural network

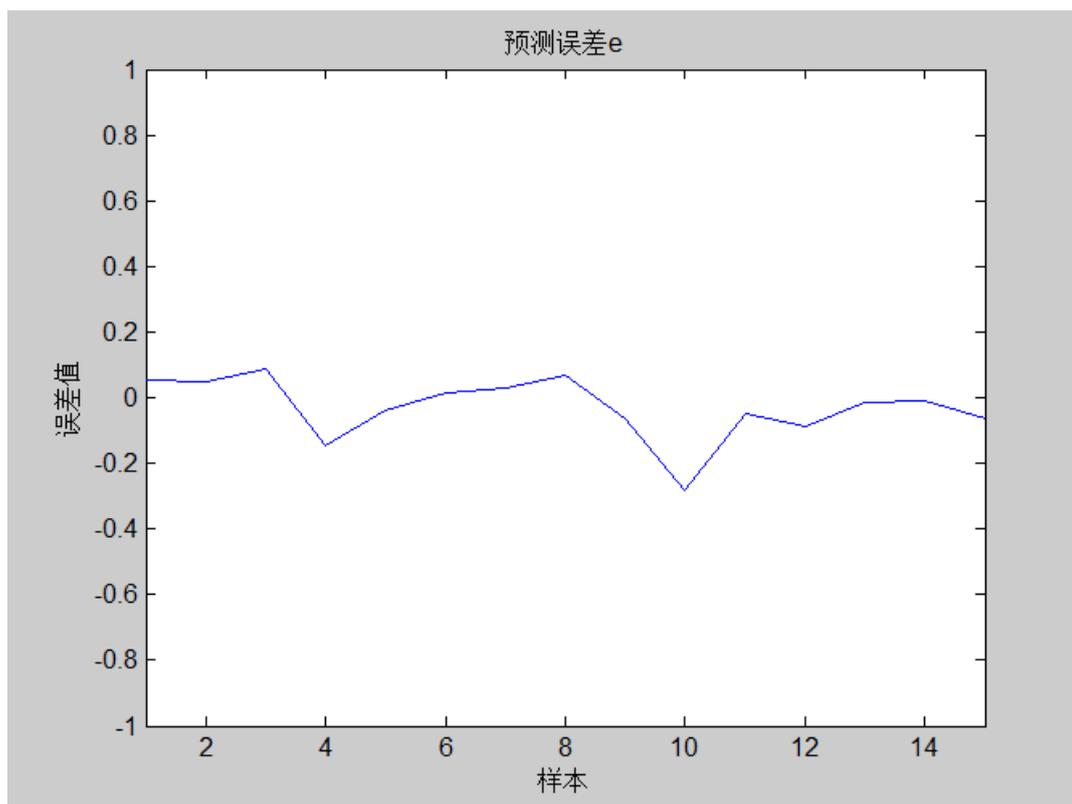


图 5-7 BP 神经网络预测广州森林火灾的误差

Fig 5.7 The error of prediction for Guangzhou forest fire of BP neural network

图 5-7 展示了 BP 神经网络的森林火灾预测拟合值与实际值的误差。

5.3.4 广州市样本拟合值与实际值相对误差分析

表 5-8 给出的是广州市 2005 年森林火灾发生样本数据的拟合值与实际值的相对误差，运用实际值和通过 BP 神经网络的拟合值进行计算得出相对误差。通过相对误差可以直观发现相对误差在 0.1 左右，从工程角度可以对森林火灾的发生进行预测。

表 5-8 广州森林火灾样本预测相对误差

Tab5.8 The error of prediction for Guangzhou forest fire

样本	样本相对误差
样本 1	0.0515
样本 2	0.0488
样本 3	0.0888
样本 4	-0.1454
样本 5	-0.0395
样本 6	0.0158
样本 7	0.0316

样本 8	0.0677
样本 9	-0.0644
样本 10	-0.2803
样本 11	-0.0501
样本 12	-0.0875
样本 13	-0.0612
样本 14	-0.0107
样本 15	-0.0613

5.4 PSO 优化 BP 网络的森林火灾预测

5.4.1 PSO 优化算法原理

粒子群优化算法是对鸟群觅食过程中的迁徙和聚集的模拟,由简单个体组成的群落以及个体之间的互动行为模拟搜索全局最优解。在 PSO 算法中,每个优化问题的解都是搜索空间中一只鸟,称之为“粒子”。所有的粒子都有一个由被优化的函数决定的适应值,每个粒子还有一个速度决定它们飞翔的方向和距离。然后粒子们就追随当前的最优粒子在解空间中搜索。PSO 初始化为一群随机粒子。然后通过迭代找到最优解。在每一次迭代中,粒子通过跟踪两个“极值”来更新自己。第一个就是粒子本身所找到的最优解。这个解叫做个体极值 $pbest$ 。另一个极值是整个种群目前找到的最优解。这个极值是全局极值 $gbest$ 。在找到这两个最优值时,粒子根据下面的公式来更新自己的速度和新的位置:

$$V(t+1) = V(t) + c1 * Rand() * (pbest(t) - x(t)) + c2 * Rand() * (gbest - x(t)) \quad (1)$$

$$X(t+1) = X(t) + V(t+1) \quad (2)$$

其中: V 是粒子的飞行速度; X 是当前粒子的位置; $pbest$ 和 $gbest$ 如前面的定义; $Rand()$ 是介于(0,1)之间的随机数; $c1,c2$ 是学习因子,通常 $c1=c2=2$ 。

上述公式构成了基本 PSO 算法,试验表明,基本 PSO 算法早期收敛速度非常快,但却暴露出局部搜索能力差的缺点,这使得算法后期收敛速度缓慢且求解精度降低。为改善 PSO 算法的局部搜索能力,Shi 等学者^[63]为式(1)的速度项引入了惯性权重 W ,变为

$$V(t+1) = W * V(t) + c1 * Rand() * (pbest(t) - x(t)) + c2 * Rand() * (gbest - x(t)) \quad (3)$$

基本 PSO 算法可看作是 $W=1$ 的情况,可以为 W 选取合适的值,从而使得算法在全

局和局部的搜索能力之间达到最佳平衡。

5.4.2 改进粒子群优化算法

在粒子群算法的可调节参数中,惯性权值是最重要的参数,较大的权值有利于提高算法的全局搜索能力,而较小的权值会增强算法的局部搜索能力。为了找到一种能在全局搜索和局部搜索之间取得最佳平衡的惯性权值选取方法,研究人员进行了大量的研究工作,先后提出了线形递减权值(LDIW)策略^[63]、模糊惯性权值(FIW)策略^[64]和随机惯性权值(RIW)策略^[65]。其中,FIW 策略需要专家知识建立模糊原则,实现难度较大;RIW 策略被用于求解动态系统;LDIW 策略相对简单且收敛速度快,因此被广泛使用。

LDIW 策略就是在迭代过程中线性地减小 W 的值,用公式表示为

$$W = (W_{start} - W_{end})(t_{max} - t) / t_{max} + W_{end} \quad (4)$$

其中: t_{max} 为最大允许迭代次数; t 为当前的迭代次数; W_{start} 和 W_{end} 分别是初始惯性权值和进化到最大允许迭代次数的取值。由式(2)、(式 3)和式(4)构成了 LDIW-PSO 算法。它简单、直观,且具有较好的寻优能力,因此被广泛利用。

受 LDIW 策略启发,为了在全局搜索和局部搜索之间取得更好的平衡,本文将 LDIW 策略改造为一个非线性递减权值策略,就是将 $(t_{max} - t) / t_{max}$ 项平方,目的是在算法早期通过加快惯性权值的递减速度,使得算法尽快进入局部搜索,即

$$W = (W_{start} - W_{end})(t_{max} - t)^2 / t_{max}^2 + W_{end} \quad (5)$$

在本文中,我们称改进权值递减策略的算法为 IPSO(Improved PSO)。通过以上方法使得 PSO 算法进入局部搜索才能获得更好的求解效率,改善了算法的后期收敛精度。

5.4.3 基于 IPSO 优化 BP 的过程

粒子群算法优化 BP 网络的基本思想是:利用粒子群 PSO 算法优化的权值和阈值作为 BP 神经网络的初始权值和阈值并进行训练和预测^[66]。

将 IPSO 用于训练 BP 网络的方法是:粒子群中每个粒子的位置表示 BP 网络中当前迭代中的权值集合,每个粒子的维数由网络中起连接作用的权值的数量和偏置个数决定。以给定训练样本集的神经网络输出误差作为神经网络训练问题的适应函数,适

应度值表示神经网络的误差,误差越小则表明粒子在搜索中具有更好的性能。粒子在权值空间内移动搜索使得网络输出层的误差最小,改变粒子的速度即更新网络的权值,以减少均方误差(MSE)。通过这种方式,IPSO 优化搜索训练神经网络的权值和偏置来获得更小的 MSE。每次迭代过程中产生 MSE 最小的粒子为目前全局最优的粒子,即算法公式 3 中的 gbest。

IPSO 算法如下:

步骤 1:初始化参数,包括神经网络拓扑结构、种群大小、加速系数、迭代次数上线、误差限 err-goal 等。

步骤 2:如果算法收敛准则满足或达到最大迭代次数,执行步骤 6,否则执行步骤 3。

步骤 3:对每个粒子 i 在网络中正向传播,计算其在输出层的输出,得到误差 E_i ,如果 $E_i < pb_i$,则 $pb_i = E_i$, $p_i = x_i$,如果 $E_i < gb$,则 $gb = E_i$, $p_g = x_i$ 。

步骤 4:按公式(2)、(3)和(5)分别计算并更新每个粒子的速度和位置。

步骤 5:迭代次数加 1,并转步骤 2。

步骤 6:结束。

其中: pb_i 表示单个粒子在以前搜索中的最优状态(即最小 MSE), gb 表示粒子群在以前搜索中的最优状态,其对应于在以前搜索中的单个粒子的最优位置 p_i 和全局最优位置 p_g 。BP 网络中正向传播途径隐含层和输出层节点时,均采用 Sigmoid 型函数(简称 S 型函数)作为自适应函数(也称激励函数)。S 型函数的表达式为: $f(x) = 1/(1 + \exp(-x))$ 。

5.4.4 实验结果分析

改进的粒子群优化算法对 BP 网络优化对桂林市和广州市的气候数据即日均气温、日均湿度、日均风速、日降水量 4 项指标因素作为粒子群优化算法的 4 个输入层,以林火发生情况这一指标因素作为粒子群优化算法的输出层。以样本数据作为该网络的训练数据。

对桂林市和广州市两地的林火预测效果图如图 5-8 和 5-9 所示:

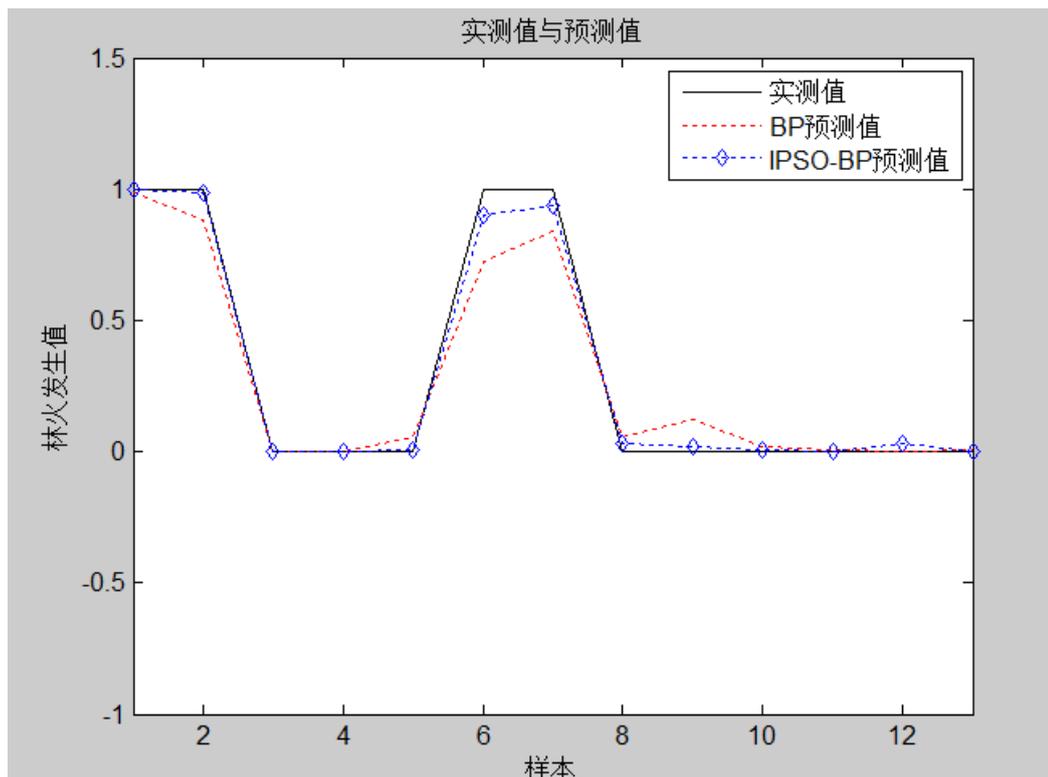


图 5-8 IPSO-BP 神经网络预测桂林森林火灾拟合效果图

Fig5.8 The fitting effect chart of prediction for Guilin forest fire of IPSO-BP neural network

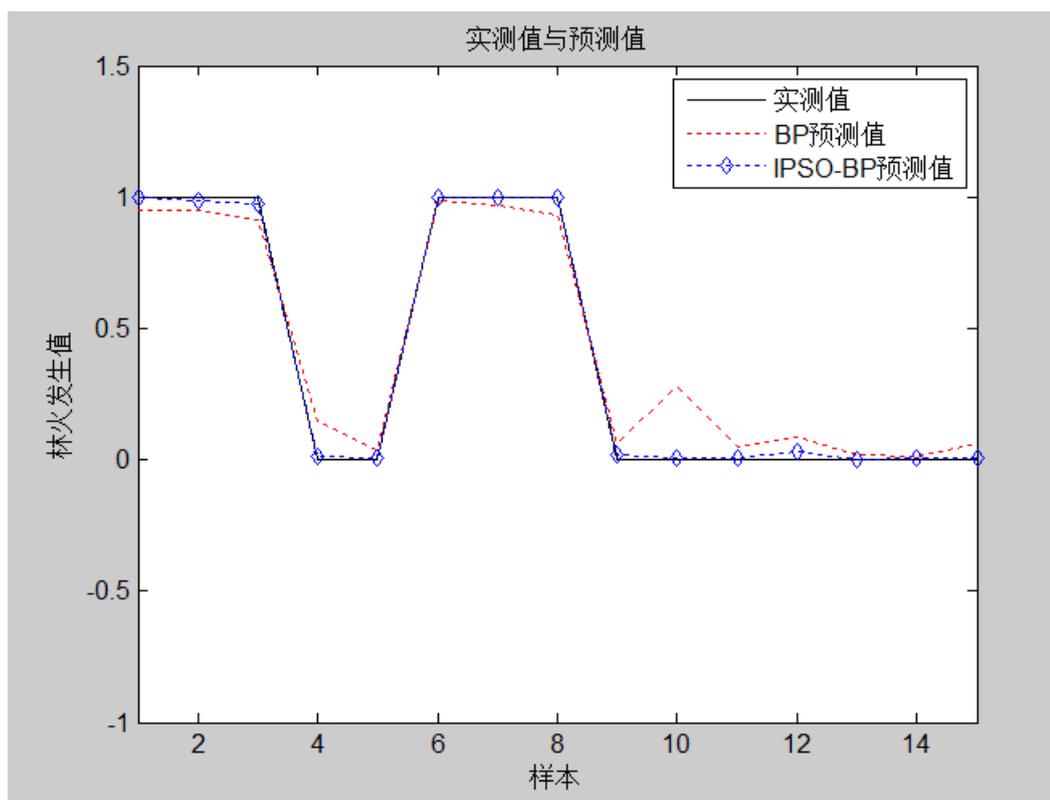


图 5-9 IPSO-BP 神经网络预测桂林森林火灾拟合效果图

Fig5.9 The fitting effect chart of prediction for Guangzhou forest fire of IPSO-BP neural network

通过桂林市和广州市两地的 IPSO-BP 神经网络预测森林火灾拟合效果图可知, 由于 BP 网络自身具有收敛速度慢和容易陷入局部极小点等缺陷, 利用 IPSO 对 BP 算法优化能够通过追随当前搜索到的最佳值来搜索全局最优, 其学习算法简单、预测精度高、收敛速度快。

5.5 本章小结

利用 BP 神经网络建立的森林火灾预测模型, 对桂林市和广州市两地可以比较精确的预测当日火灾发生状况。利用 BP 神经网络建立的森林火灾预测模型对同属亚热带气候区的两地区的预测效果较好。通过对粒子群优化算法进行了改进, 并将改进算法用于 BP 网络的训练, 并与原始 BP 网络进行了比较。结果表明, 用改进粒子群优化算法用于 BP 神经网络优化, 不仅更快地收敛于最优解, 而且很大程度地提高了结果的精度。

第六章 结论

6.1 气象因素对森林火灾发生影响相关性分析

本文通过对桂林市和广州市两个地区的数据分析可发现，每年 9 月到下一年 4 月间多发，主要原因是这几个月间空气湿度较低，日均降水量较小。

(1) 日均气温影响分析。

通过数据发现桂林市森林火灾大部分发生在最高气温 10 摄氏度左右以上的天气，其中九成以上发生在 18 摄氏度以上的天气；广州市森林火灾一般发生在 11 摄氏度以上的天气，其中九成以上的森林火灾发生在高于 15 摄氏度的天气中。

森林火灾的发生与当地气温呈正相关关系。

(2) 相对湿度影响分析。

两市森林火灾发生日，绝大多数当日湿度在 65% 以下，湿度越高发生森林火灾的情况越少，相反当日空气湿度较小的天气，容易发生森林火灾。相对湿度与森林火灾的发生呈反相关关系。

(3) 日降水量对森林火灾影响的相关分析。通过对两市日降水量和森林火灾数据分析各得到，在森林火灾一般发生在日降水量小于 0.3mm 的天气情况下。日降水量和森林火灾发生呈反相关关系。

(4) 风对森林火灾的影响。通过数据发现，风对森林火灾的發生的影响因素不大，但风是林火的蔓延主要推手，尤其是在秋冬季节，空气气流使得空气和地面干燥，可能会造成重大的森林火灾。

(5) 总结。影响森林火灾发生的气候因素中，日均温度、日均湿度、日降水量对森林火灾的发生影响权重较大，日均风速对森林火灾的蔓延和扩大起到推波助澜的作用。近年来，由于气候的逐年变化，其中 20 世纪 90 年代增温尤为明显，降水量有所增加，日照时数呈下降趋势。由于以上原因，森林火灾发生情况每年的变化也会有所不同，每年森林火灾发生状况也会发生变化。所以，因气候变化带来的对森林火灾的误差需作进一步的研究。

6.2 运用 BP 网络构建预测模型可行性分析

本文采用了 logsig 函数作为输入层和隐含层的传递函数，tansig 函数作为隐含层和输出层的传递函数构建了 BP 网络训练模型。通过利用 BP 神经网络可以对各层之间的权值不断反馈修正的特点，使日均气温、日平均相对湿度、日均风速和日降水量的这四项影响森林火灾发生因素的权值系数尽可能的逼近实际对林火发生影响的相关度，使得训练最终达到预期目标。运用大量的森林火灾发生的实际数据和当日气候

数据作为样本进行训练,通过实际值与预测值的比较可以得出良好的预测结果。通过桂林市和广州市两地的预测误差数据看,训练预测值和林火实际发生值的误差大部分在 0.1 左右,有极个别数据有一定偏差,以大量预测的实际结果来看可以达到林火预测的目标。

由于气象因素只是影响林火发生因素的一种,而人为因素、可燃物、火源等也有关系,所以预测会存在一定误差。但是总体来看,应用 BP 网络对影响森林火灾的气象因素进行分析预测可以确定出与森林火灾发生的相关气候等因素,对森林火灾发生的宏观预测有很重要的指导意义。

6.3 总结

本文做了如下几方面的研究工作:

(1) 通过收集预测地区日均气温、日均相对湿度、日均风速和日降水量等气象因素和林火发生数据作为训练样本,构建的 BP 神经网络森林火灾预测模型,可以比较精确的预测当日火灾发生状况。

(2) 在利用 matlab 构建 BP 网络的过程中,对应设置网络参数,筛选了合适的传递函数,使得预期的预测效果较好,模拟仿真较为准确。

(3) 通过利用气象因子对森林火灾进行预测,基于 BP 神经网络的方法对实际发生情况有良好的模拟效果,使得利用人工智能神经网络对林火进行预测的可行性,提供了有力的理论以及技术支持。

(4) 本文做的以上工作人工神经网络建立简化的有效的森林火灾宏观预测预报系统展现了很好的应用前景。

(5) 将粒子群优化算法改进 BP 人工神经网络,采用了 IPSO-BP 算法对森林火灾进行预测,该方法不仅具有它们各自的优点,同时还弥补了它们在训练过程中易陷入局部极小值以及收敛速度慢等缺陷。实验效果较好,同时该算法适用于小样本的预测研究。

结合在实验中存在的问题,不足之处及有待研究的问题在于几下几个方面:

(1) 由于森林火灾的发生,除去气象因素外,还受多种不稳定性因素如人为、火源、可燃物等及一些无法统计数据等多方面的影响,以及本实验所选择的样本数据为特定地区的气候数据和森林火灾发生数据,因此对森林火灾预测仿真过程中存在一定的局限性,预测数据难免会存在一定的误差。

(2) 虽然本文运用 BP 算法的预测精度相对较高,但在训练中仍存在不稳定性,因此对其拟合性能还有待完善。

(3) 采用改进的粒子群优化算法在对森林火灾进行预测时,其预测精度相对较高、收敛速度相对较快,但是对预测实验的改善效果不是十分理想,其还有待完善及提高模型的预测精度。

参考文献

- [1]徐济德. 我国第八次森林资源清查结果及分析[J]. 林业经济,2014,(3):6-8.
- [2]叶兵. 国内外森林防火技术及其发展趋势[D].北京: 中国林业科学研究院,2000.
- [3]舒立福,田晓瑞,徐忠忱. 森林可燃物可持续管理技术理论与研究[J]. 火灾科学,1999,(4):20-26.
- [4]魏书精. 黑龙江省森林火灾碳排放定量评价方法研究[D].哈尔滨: 东北林业大学,2013.
- [5]舒立福,田晓瑞,李红. 世界森林火灾状况综述[J]. 世界林业研究,1998,(6):42-48.
- [6]宋亚军. 近期林火科学研究文献计量分析[D].北京: 北京林业大学,2013.
- [7]安娜·玛丽·索罗维奇,吴慧雯. 俄罗斯森林大火为中国森林防火敲响警钟[J]. 生命与灾害,2010,(09):28-31.
- [8]张惠莲. 当前气候变化下如何加强森林火灾预测预报[J]. 森林防火,2010,(4):33-36.
- [9]李丽琴,牛树奎. 中国气候变化与森林火灾发生的关系[J]. 安徽农业科学,2010,22:11993-11994.
- [10]Youssef Safi ,Abdelaziz Bouroumi.Prediction of Forest Fires using Artificial Neural Networks[J].Applied Mathematical Sciences, 2013, (6):271 - 286
- [11]Wright A,Bailey W.Fire ecology[J].New York:John Willey&Sons,1982:274-289
- [12]Groisman P Ya,Co-Authors.Contemporary Climate Changes in High Latitudes of the Northern Hemisphere:Daily Time Resolution[D].AMS Proc.of the 14th Symposium On Global Change and Climate Variations Long Beach,California,2003,2(4):9-13
- [13]Viegas D X,Pinol J.Estimating live fine fuels moisture content using meteorologically-Based indicts [J]International Journal of Wild land Fire,2001,1(10):223-240
- [14]Gillett N P.Weaver A J.Zwiers F W.et al.Detecting the Effect of Climate Change on Canadian Forest Fires[J].Geophysical Research letters.2004.31(18):1-4
- [15]Williams A A J, Karoly D J, Tapper N.The sensitivity of Australian fire danger to climate Change[J].climatic Change, 2001, 49: 171-191.
- [16]Fried J.S, Tom M.S. and Mills E.The Impact of Climate Change on Wildfire Severity :A Regional Forecast for Northern California[J].climatic Change, 2004,64(1-2): 169-191.
- [17]Flannigan M D, Campbell II, Wonton M, Carcaillet C, Richard P, Bergeron Y.Future fire in Canada's boreal forest: Paleoecology results and general circulation model-regional climate model simulations[J].Can.J.For.Res.2001, 31(1): 854-864.
- [18]李德. 四川省重点地区森林火灾与气象因子的关系研究[D].北京林业大学,2013.
- [19]徐海龙. 大兴安岭森林火灾过火面积预测的研究[D].东北林业大学,2009.
- [20]黄家荣,刘倩,高光芹,刘小丽,魏春生,段群迷,程作峰. 森林火灾成灾面积的人工神经网络 BP 模型预测[J]. 河南农业大学学报,2007,(03):273-275.

- [21]周来法,屈道金,张加正,吕先进,王宇荣. 气象因子对森林火灾影响的研究[J]. 浙江林业科技,1991,06:33-38.
- [22]黄光华. 基于无线传感器网络的森林火灾监测系统的设计与研究[D].南昌:江西理工大学,2012.
- [23]马奔,薛永基,顾艳红. 修正的 BP 神经网络森林火灾成灾面积预测研究[J]. 资源开发与市场,2014,(12):1441-1443.
- [24]陈东宾. 基于视频图像的森林火灾监测[D].沈阳:沈阳理工大学,2008.
- [25]郑艺丁. 遗传神经网络的综合进化研究[D].北京:北京化工大学,2001.
- [26]毛健,赵红东,姚婧婧. 人工神经网络的发展及应用[J]. 电子设计工程,2011,(24):62-65.
- [27]P. Cortez and A. Morais, A Data Mining Approach to Predict Forest Fires using Meteorological Data, in J. Neves, M. F. Santos and J. Machado Eds., New Trends in Artificial Intelligence, Proceedings of the 13th EPIA 2007, Portuguese Conference on Artificial Intelligence[C].(2007), December,Guimaraes, Portugal, 512 - 523.
- [28]J.G.Pausas.Changes in Fire and Climate in the Eastern Iberian Peninsula(Mediterranean Basin)[J].Climate Change,2004,6(3):337~350.
- [29]F.Mouillot,S.Rambal,and R.Joffre,Simulating Climate Change Impacts on Fire Frequency and Vegetation Dynamics in a Mediterranean-type Ecosystem[J].Global Change Biology,2002,8(5):423-437
- [30]Brown TJ,BI Hall,AL Westerling.The impact of twenty-first century climate change on wild land Fire danger in the western in the western United States:An applications Perspective[J].Climate Change,2007,62(1):365-388
- [31]赵玲,李树岭,宋庆利.干湿气候变化对森林火灾的影响[J].内蒙古气象,2004,1:33-35
- [32]孙海滨,王美莲,张红星,张志国,赵鹏武,周梅. 大兴安岭森林火灾与气象因子相关性研究[J]. 内蒙古农业大学学报(自然科学版),2012,Z1:87-90.
- [33]Clark J S.Effect of climate change on fire regimes in northwestern Minnesota[J].Nature,1988.334: 233-235.
- [34]任国玉. 气候变暖成因研究的历史、现状和不确定性[J]. 地球科学进展,2008,(10):1084-1091.
- [35]朱大奇. 人工神经网络研究现状及其展望[J]. 江南大学学报,2004,(1):103-110.
- [36]汤素丽,罗宇锋. 人工神经网络技术的发展与应用[J]. 电脑开发与应用,2009,(10):59-61.
- [37]覃光华. 人工神经网络技术及其应用[D].成都:四川大学,2003.
- [38]徐长安. 关于人工神经网络学科的思考[J]. 中国科教创新导刊,2009,(01):58.
- [39]孙吉辉,孟祥锋. 人工神经网络简介[J]. 中学课程资源,2008,(10):159.
- [40]陈惟昌. 生物神经网络与人工神经网络[J]. 科技导报,1991,(03):41-44+61.
- [41]王伟,唐延林. 生物神经元的一个统计模型初探[J]. 贵州农学院学报,1995,(04):66-69.
- [42]王立禾. 生物神经网络系统中的辨识问题研究[D].上海:上海交通大学,2012.
- [43]刘彩红. BP 神经网络学习算法的研究[D].重庆:重庆师范大学,2008.

- [44]曾庆茂. 基于神经网络和模糊推理的信息融合技术[D].西安: 西安科技大学,2005.
- [45]陈元琳. 基于人工神经网络的动态系统仿真模型和算法研究[D].大庆: 大庆石油学院,2006.
- [46]何新贵,许少华. 过程神经元网络及其在时变信息处理中的应用[J]. 智能系统学报,2006,(01):1-8.
- [47]谢铭培,杨震晖,王宗彩,金妮. 神经元网络信息处理模型及其在管理信息系统中的应用[J]. 复旦学报(自然科学版),1989,(04):453-460.
- [48]刘旭升. 基于人工神经网络的森林植被遥感分类研究[D].北京: 北京林业大学,2004.
- [49]李鑫. 基于神经网络分类器的汉字识别系统研究[D].阜新: 辽宁工程技术大学,2005.
- [50]杨扬. 基于人工神经网络的光学字符识别系统及硬件实现[D].贵阳: 贵州大学,2006.
- [51]曹慧媛. 神经网络在认知诊断中的应用研究[D].南昌: 江西师范大学,2009.
- [52]杜晓亮. 神经网络在空气质量预测中的应用研究[D].济南: 山东大学,2009.
- [53]李海波. 神经网络在混凝土冻融循环性能预测中的应用研究[D].西安: 西安建筑科技大学,2009.
- [54]刘冬英. 神经网络模型在长江中下游河道洪水预报中的应用研究[D].武汉: 武汉大学,2005.
- [55]黄斌. 神经网络在沅江中上游水环境质量评价中的应用研究[D].长沙: 湖南大学,2006.
- [56]黄丽. BP 神经网络算法改进及应用研究[D].重庆: 重庆师范大学,2008.
- [57]夏玫. BP 神经网络泛化能力改进研究[D].太原: 太原科技大学,2009.
- [58]刘天舒. BP 神经网络的改进研究及应用[D].哈尔滨: 东北农业大学,2011.
- [59]吴仕勇. 基于数值计算方法的 BP 神经网络及遗传算法的优化研究[D].昆明: 云南师范大学,2006.
- [60]童飞. 基于 BP 神经网络的水上交通事故预测及 MATLAB 实现[D].武汉: 武汉理工大学,2005.
- [61]冯蓉,杨建华.基于 BP 神经网络的函数逼近的 MATLAB 实现[J].榆林学院学报,2007,(02):20-22.
- [62]潘贤良,朱寿燕. 森林火灾与气象因素的关系初探[J]. 森林防火,2000,(04):22-23.
- [63]Shi Y, Eberhart R. Empirical study of particle swarm optimization[A].International Conference on Evolutionary Computation[C].Washington, USA: IEEE, 1999.1945-1950.
- [64]Shi Y, Eberhart R. Fuzzy adaptive particle swarm optimization[A].The IEEE Congress on Evolutionary Computation[C].San Francisco, USA: IEEE, 2001.101-106.
- [65]Eberhart R, Shi Y. Tracking and optimizing dynamic systems with particle swarms [A].The IEEE Congress on Evolutionary Computation [C]. San Francisco, USA: IEEE, 2001.94-100.
- [66]张苓. 粒子群算法在 BP 神经网络优化中的应用[R]. 电路与信号处理国际会议, 2010.

在读期间发表的学术论文及研究成果

在读期间发表的学术论文:

- [1] 顾沈明, 胡超, 吴伟志, 王霞. 多标记序信息系统的 uncertainty 研究[J]. 南京大学学报 (自然科学版), 2013, 51(2): 1-7.

在读期间获得的实用新型专利:

- [1] 新型笔记本扫描仪, ZL 2013 2 0780546. 4, 中国, 2014 年 5 月 7 日, 顾沈明, 胡超, 雷婧.
- [2] 一种多媒体教学用带扫描仪的白板擦, ZL 2013 2 0835844. 9, 中国, 2014 年 9 月 3 日, 顾沈明, 雷婧, 胡超.

致 谢

本文是在顾沈明教授的悉心指导下完成的。从论文的选题、设计到撰写等方面，顾老师都给予我极大的支持与帮助。他严于律己，宽以待人的高尚品德，深深影响着我的为人处事。他兢兢业业，一丝不苟的治学态度，激励着我在业务上不断刻苦专研。

在此，我向导师致以衷心的感谢和深深的敬意。

感谢数理与信息学院的各位领导和老师，他们的教导给我指明了前进的方向。

感谢同学和朋友们的陪伴与帮助，祝愿大家在今后的生活、工作中一帆风顺，心想事成！

在此，我要特别感谢我的父母及家人，是他们给予我无微不至的关心和呵护，让我顺利完成学业。

值此论文完成之际，衷心感谢在百忙中评阅论文和参加答辩的各位专家、教授！真诚地祝愿你们生活美满，工作顺利！