



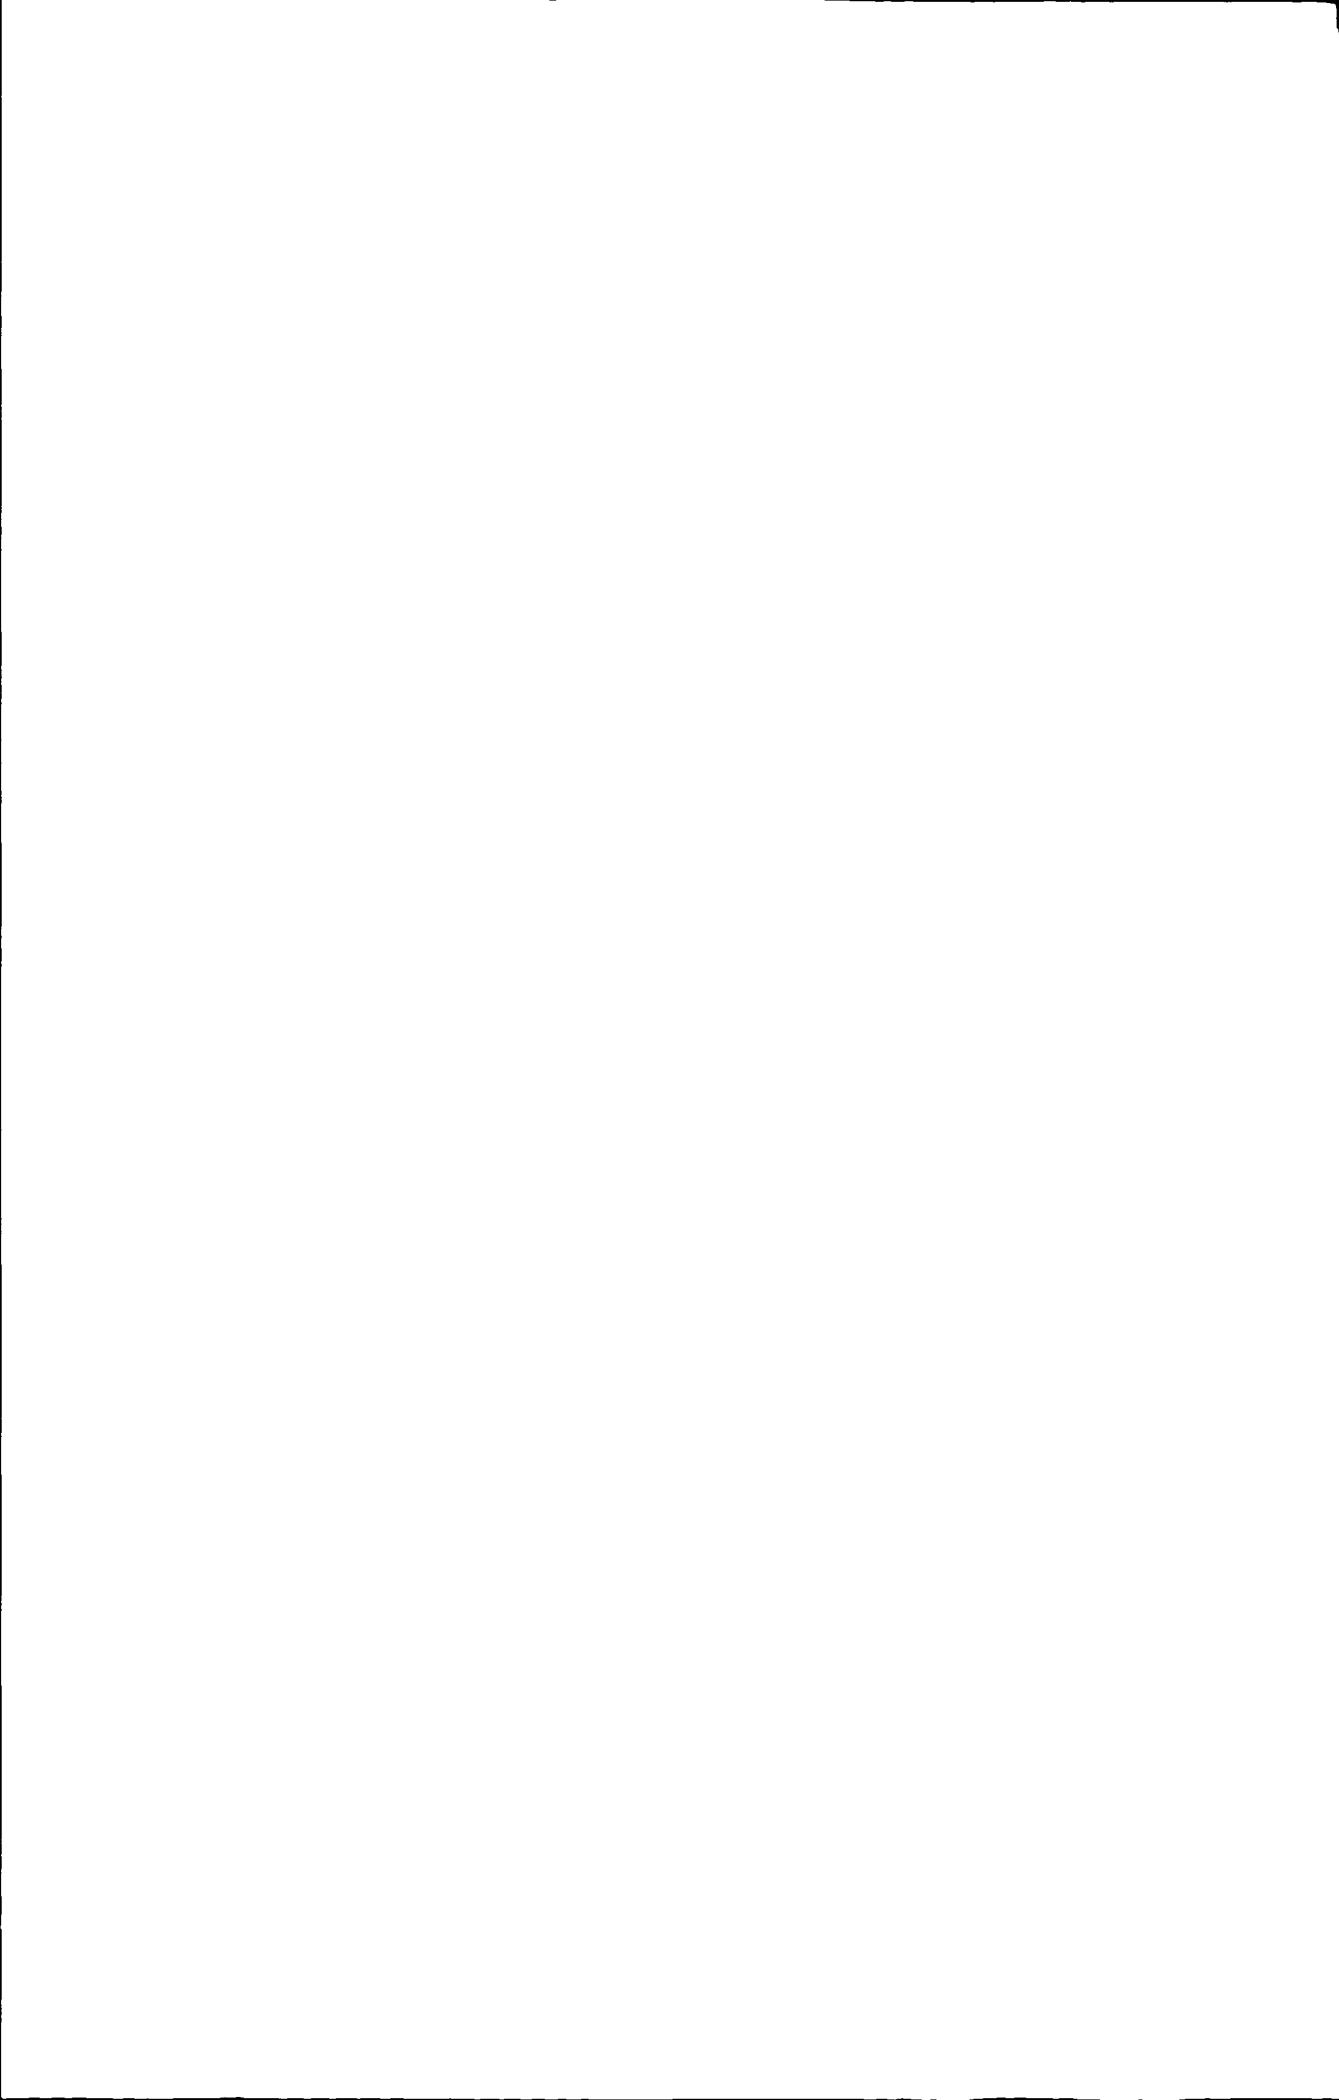
Classified Index: TP399

U.D.C: _____

Dissertation for the Master Degree in Engineering

**A STUDY ON DECISION-MAKING
METHOD OF STOCK BASED ON
GENETIC NEURAL NETWORK**

| | |
|-------------------------------------|----------------------------------|
| Candidate: | Lu Xiuze |
| Supervisor: | Prof. Ye Deqian |
| Academic Degree Applied for: | Master of Engineering |
| Specialty: | Computer Software and Theory |
| Date of Oral Examination: | June 2010 |
| University: | Qingdao Technological University |



硕士学位论文

一种基于遗传神经网络的股票决策 的方法研究

学位论文答辩日期:

指导教师签字:

答辩委员会成员签字:



目 录

| | |
|------------------------|-----|
| 摘 要..... | I |
| Abstract..... | III |
| 第 1 章 绪 论..... | 1 |
| 1.1 研究背景、目的及意义..... | 1 |
| 1.1.1 研究背景..... | 1 |
| 1.1.2 研究目的及意义..... | 2 |
| 1.2 研究方法..... | 2 |
| 1.3 国内外研究状况..... | 5 |
| 1.3.1 国内研究现状..... | 5 |
| 1.3.2 国外研究现状..... | 5 |
| 1.4 本文主要研究内容..... | 6 |
| 本文组织结构..... | 7 |
| 第 2 章 股票知识..... | 9 |
| 2.1 股票..... | 9 |
| 2.2 股票投资分析..... | 10 |
| 2.3 技术分析..... | 11 |
| 2.4 技术指标..... | 13 |
| 本章小结..... | 16 |
| 第 3 章 神经网络理论..... | 17 |
| 3.1 人工神经网络概述..... | 17 |
| 3.1.1 什么是神经网络..... | 17 |
| 3.1.2 人工神经网络的发展过程..... | 18 |
| 3.2 基本神经元模型..... | 20 |
| 3.3 神经网络的特点..... | 21 |
| 3.4 神经网络的学习..... | 22 |
| 3.5 BP 算法及缺点..... | 23 |
| 本章小结..... | 24 |
| 第 4 章 拐点寻找与模型的建立..... | 25 |
| 4.1 引言..... | 25 |
| 4.2 可行性分析..... | 26 |
| 4.3 BP 学习算法的不足..... | 28 |
| 4.4 遗传算法..... | 28 |
| 4.5 改进..... | 29 |
| 4.6 拐点的定义..... | 30 |
| 4.7 泛化..... | 34 |

| | |
|------------------------------------|----|
| 4.8 股票的选择..... | 38 |
| 4.9 股票数据的预处理及分析..... | 39 |
| 4.9.1 输入变量的处理..... | 39 |
| 4.9.2 规范化处理..... | 39 |
| 4.10 BP 模型的建立..... | 40 |
| 4.11 基于遗传神经网络的双网络股票决策支持模型..... | 42 |
| 本章小结..... | 43 |
| 第 5 章 基于遗传神经网络的股票决策..... | 44 |
| 5.1 引言..... | 44 |
| 5.1.1 MATLAB 的发展概述..... | 44 |
| 5.1.2 MATLAB 的主要功能..... | 45 |
| 5.1.3 MATLAB 的技术特点..... | 46 |
| 5.1.4 MATLAB 神经网络工具箱..... | 47 |
| 5.2 用 MATLAB 实现遗传算法..... | 48 |
| 5.3 MATLAB 各参数的确定..... | 53 |
| 5.4 确定中间层个数..... | 54 |
| 本章小结..... | 55 |
| 第 6 章 基于遗传神经网络的股票决策支持模型仿真..... | 56 |
| 6.1 通过 MATLAB 建立以价格为输出的 BP 模型..... | 56 |
| 6.2 模型训练预测..... | 56 |
| 本章小结..... | 63 |
| 结 论..... | 64 |
| 参 考 文 献..... | 66 |
| 攻读硕士学位期间发表的学术论文..... | 70 |
| 致 谢..... | 71 |

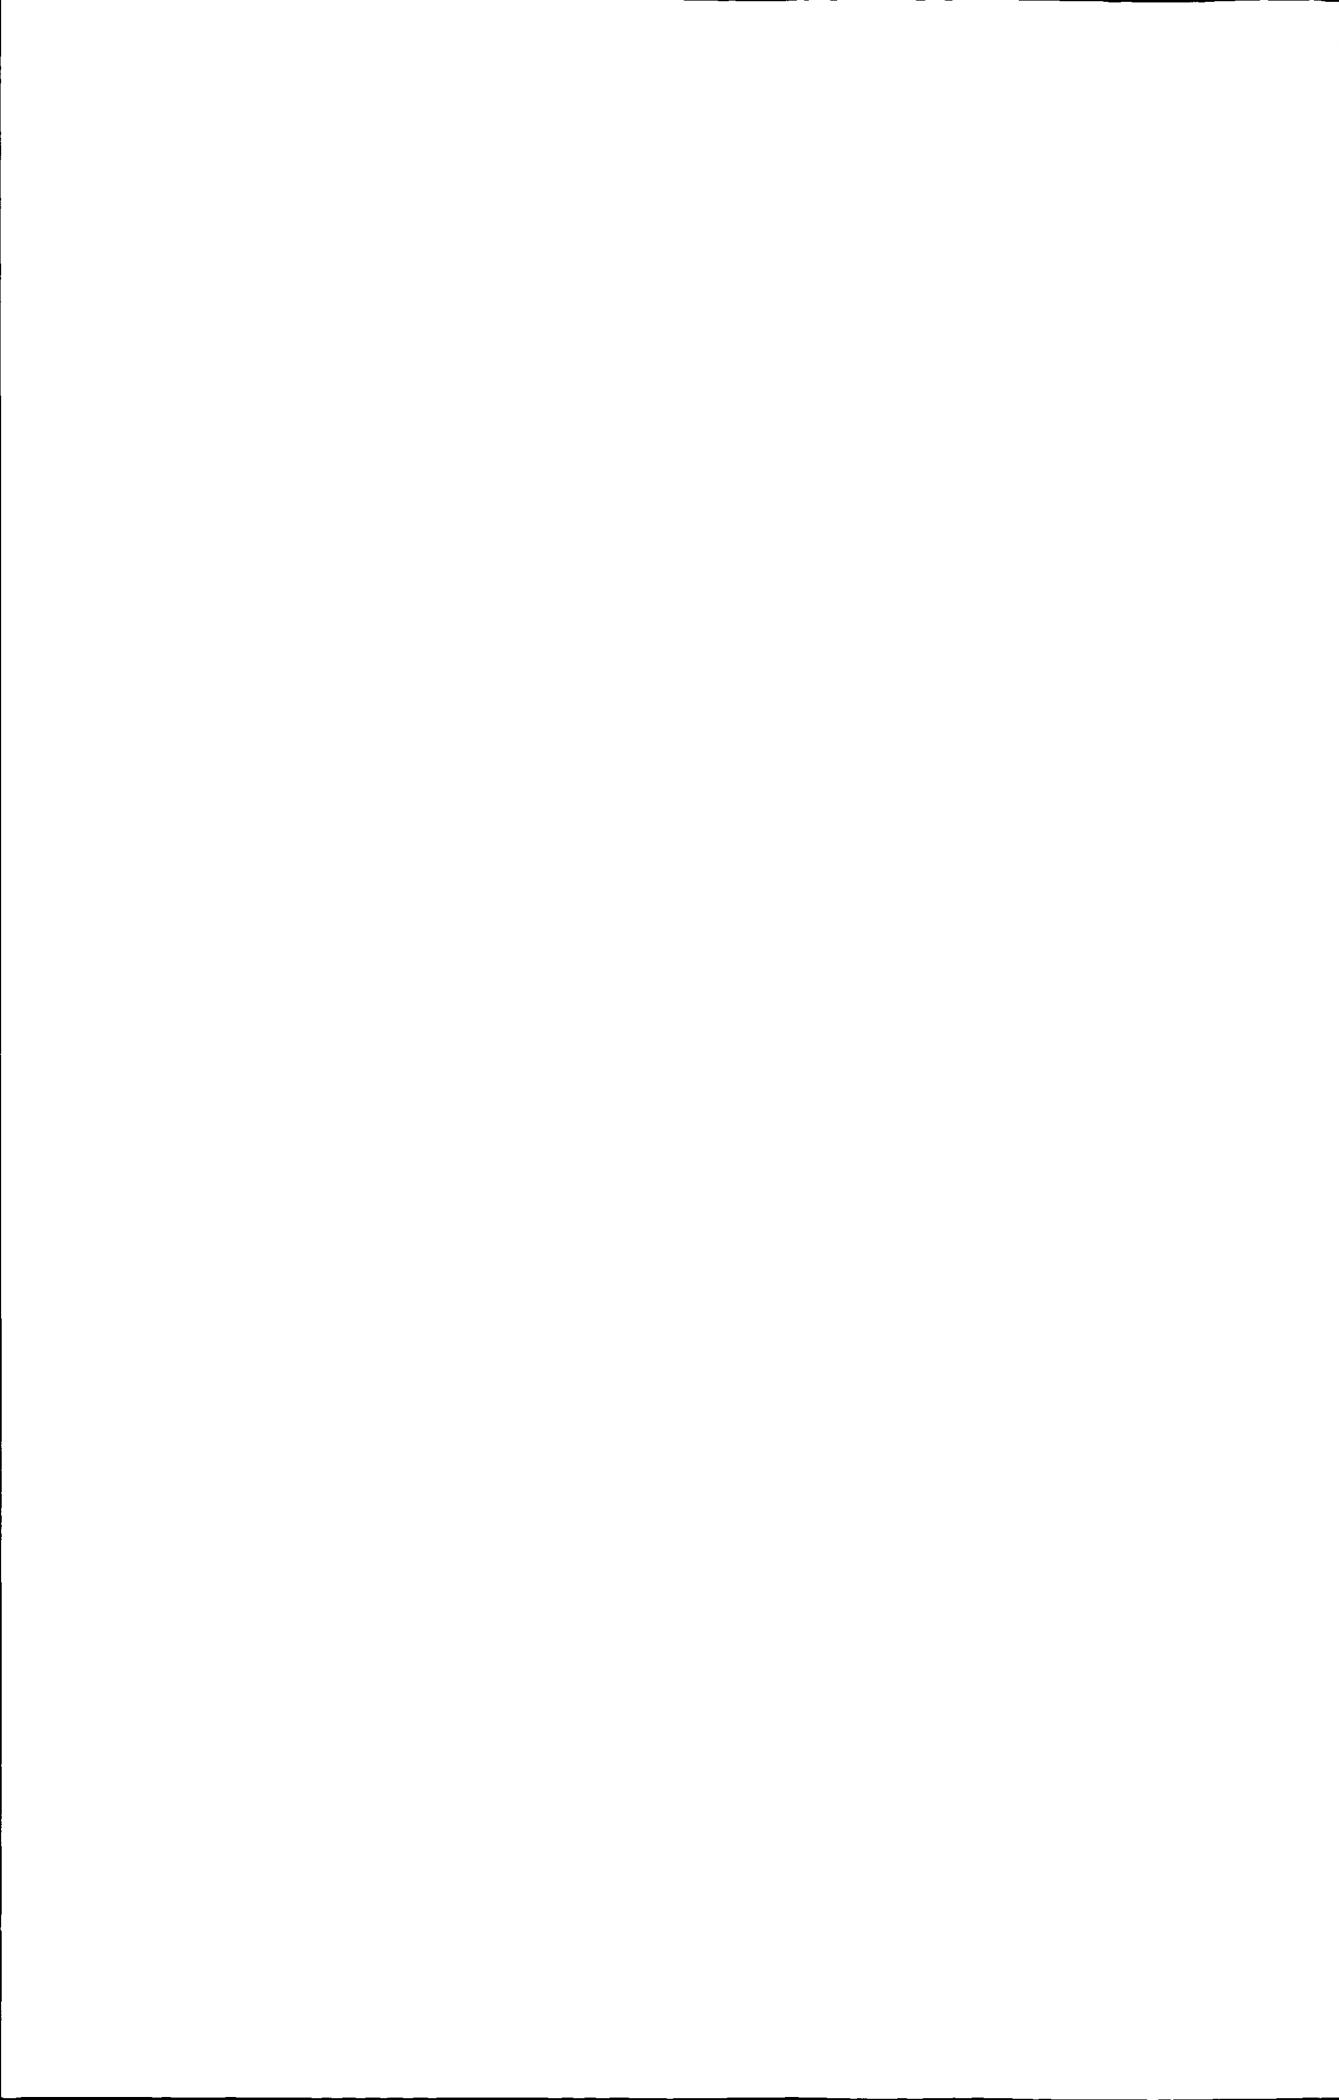
摘要

股票市场是一个高度复杂的非线性动态系统，其变化规律即有一定的自身的趋势性。它不但受到价值规律的制约，同时又受到政治的、经济的、心理的诸多因素的影响。而传统的定量预测方法是建立在数理统计基础上的，在这么多因素的影响下，其在对股市走势的研究中正面临着许多困难。

针对目前股市分析中存在的问题，本文对股票操作决策支持的这一课题进行了深入研究和探索。设计了一个双神经网络系统，并提出了一个股票决策支持模型。文中首先对目前所采用的股市预测的基本研究方法作了描述，给出了现存各类股票分析方法的优缺点。其次，提出了动力指数的概念，并用此指数来分析和判断股票的涨跌与拐点。规避了通过预测股票价格来预测趋势的问题。再次，提出了双神经网络系统，用判断网络的预测结果进行判断，提高了预测的准确度和可信度。最后，在建立的基于双神经网络的决策支持模型的基础上，针对此模型的缺点，提出了一个改进的方法，使得此模型具有更好的适用性。

最后笔者采用 MATLAB7 对上述系统和模型进行了模拟仿真预测，并得到了许多真实有效的研究数据和分析结果。

关键词： 遗传算法；投资决策；动力指数；BP 神经网络；股市预测



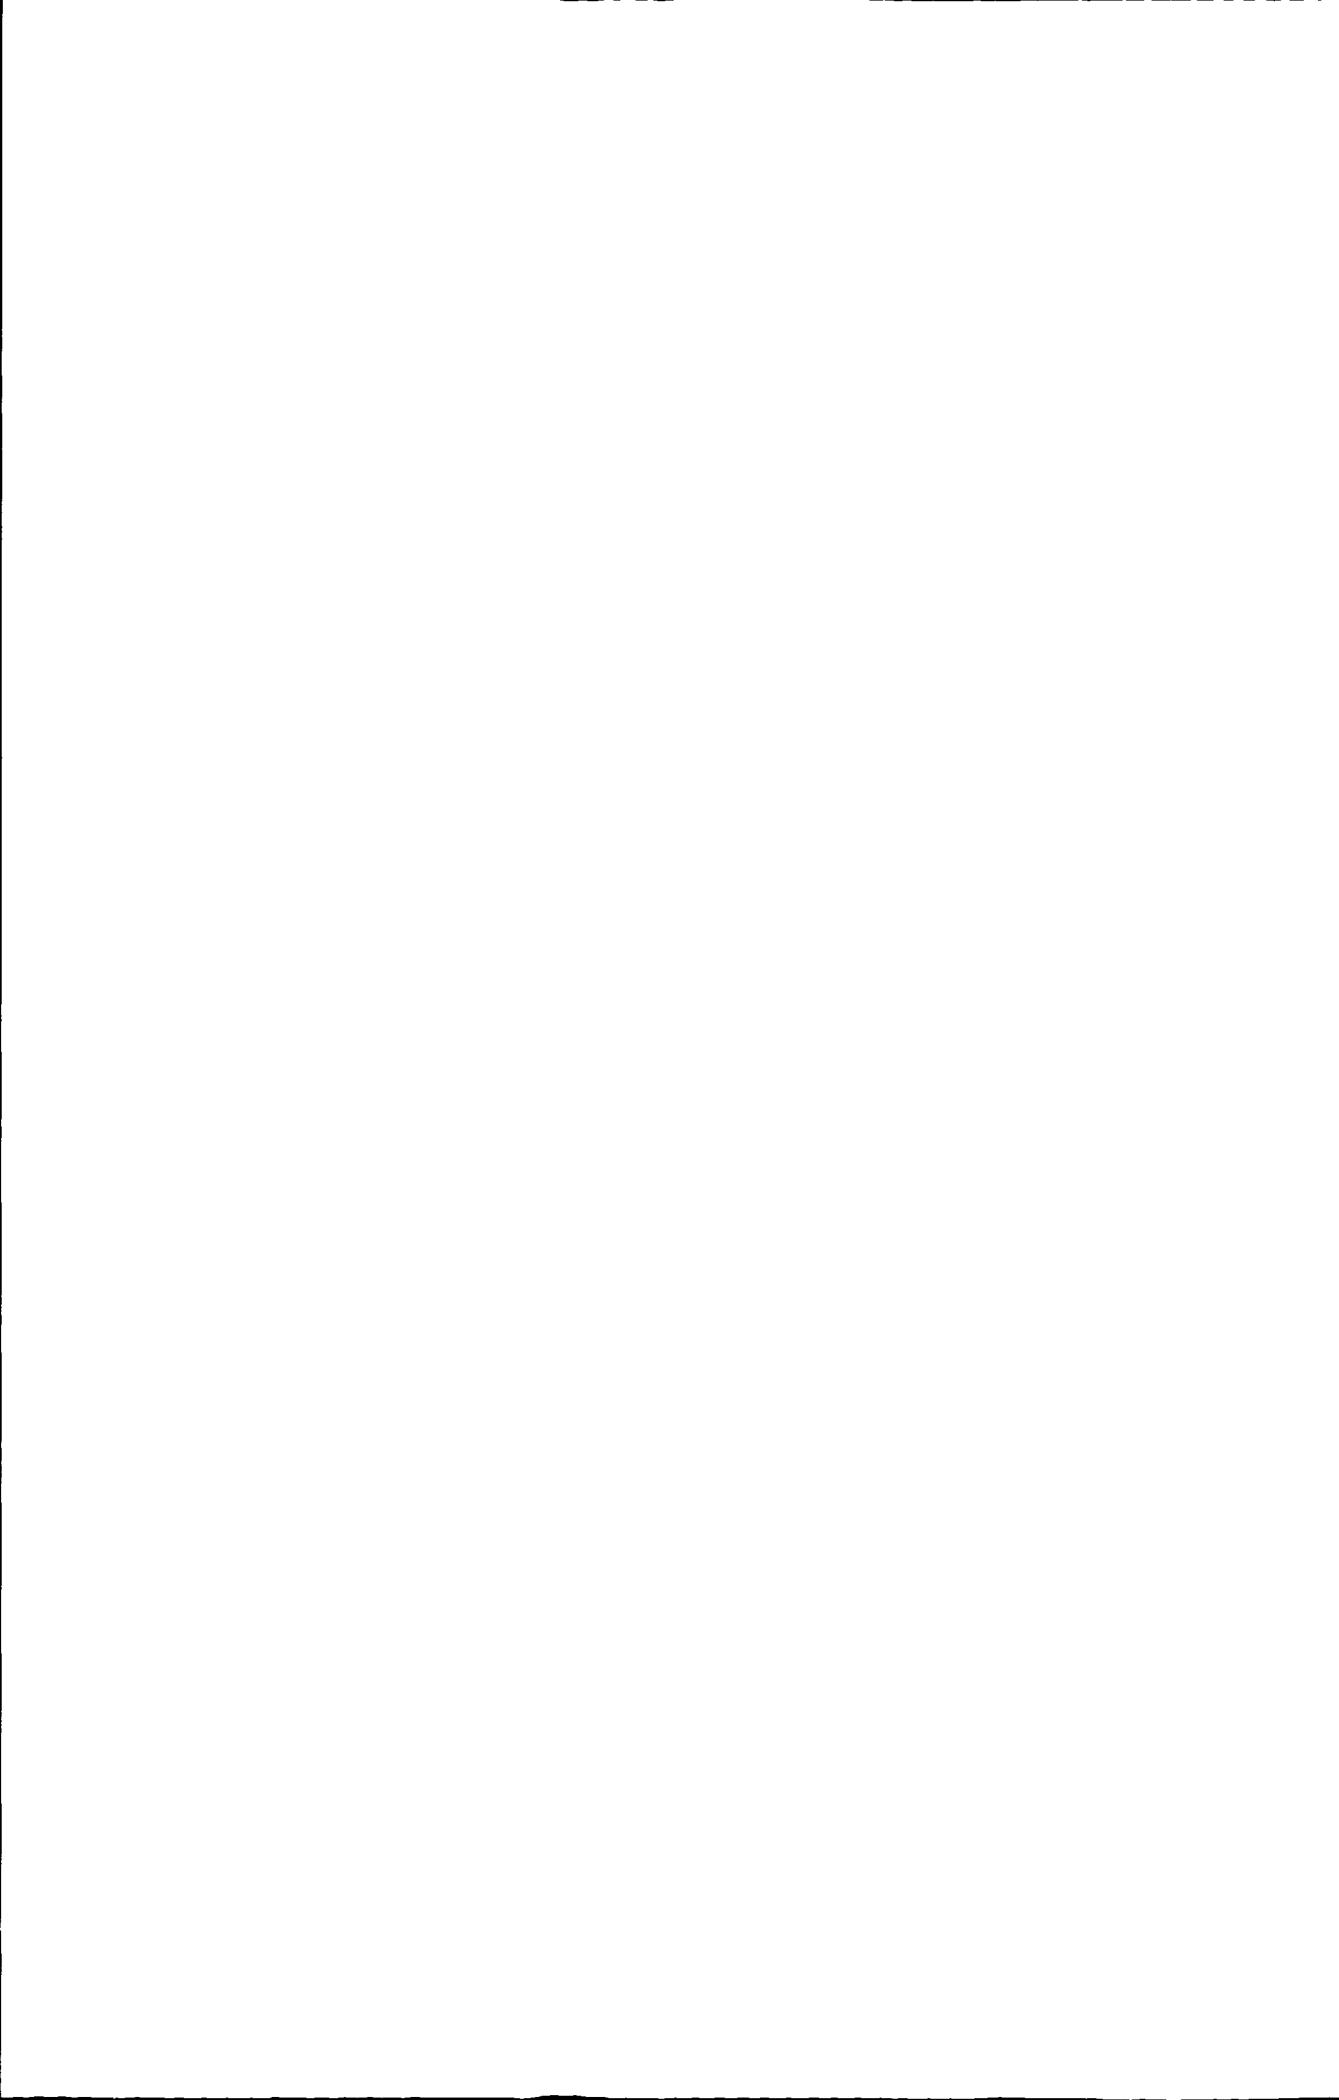
Abstract

Stock market is a highly complex non-linear dynamic system. The law has certain auto trendy. The law is not only restricted by the value law, but also influenced by political, economical, psychological and several extra elements at the same time. While conventional quantitative predictive method is based on the mathematical statistics, there are lots of difficulties faced of researching the stock market trend under so many uncertain elements.

Focus on lots of problems during the process of stock market prediction. such as: the nonlinear character of stock market, the difficult of stock price predictions etc. this essay is aiming to give deeply research and explore the question which is supported by the stock operation, also designed a double ANN system and mentioned a stock decision support model. At first, the essay gave a simple description of the basic research method of adapted stock market prediction. And then gave the advantages and shortcomings of the analyzing method for existed all kinds of stocks. Secondly, the essay mentioned the concept of dynamic index, also used this index for analyzing and judging the rise and fall and knee point of stock. This avoids the prediction problems through predicting the stock price. Again mentioned double nerve network system, making judgment by using the judgment of network predicting results, increasing the accuracy and reliability. In final, the author builded up a decision support model based on nerve network, by aiming at the shortcomings of the model, the author brought out an improving method, which made this decision support model more adaptable.

At last, the author used MATLAB7 to make demo prediction to above system and model and get lots of real data.

Key words: GA, decision-making, dynamic index BPANN Stock prediction.



第1章 绪论

1.1 研究背景、目的及意义

1.1.1 研究背景

在西方国家，证券市场已经有了几百年的发展历史。并且证券市场已经通过其实际行动充分证明了它已经成为了是整个社会经济的“晴雨表”和“报警器”和其对整个社会经济发展有着不可估量的重要作用。随着中国上个世纪的改革开放的逐步进行，中国的资本市场也有了很大的发展变化。1990年11月26日，国务院授权中国人民银行批准的上海证券交易所宣告成立，并于1990年12月19日正式营业，成为我国第一家证券交易所；1991年4月11日，我国另一家由中国人民银行批准的证券交易所——深圳证券交易所也宣告成立，并于同年7月3日正式营业。两家证券交易所的成立，标志着我国证券市场由分散的场外交易进入了集中的场内交易。自从上个世纪九十年代初期初步形成并逐渐发展壮大起来后，中国的证券市场成为整个亚洲甚至全球的证券市场中起到了很重要的作用。在中国，证券市场主要有股票市场、债券市场、基金市场等部分组成。而随着时间不断的推移，中国的股票市场已经越来越成熟起来。目前主要发行了三种股票类型：由我国境内的公司发行，供境内机构、组织或个人以人民币认购和交易的普通股股票，即A股；以人民币标明面值，以外币认购和买卖，在境内证券交易所上市交易而投资人限于外国的自然人、法人和其他组织的人民币特种股票，即B股；注册地在内地、上市地在香港的外资股，即H股。

股票市场由于能够反映整个国民经济的好坏，所以它非常受到政府的重视。除了政府，各个大中小投资者对于股票市场也是非常看重的，而他们看重的并不是股票市场的调节作用，而是通过股票市场投资者们能够获得高额的利润。但是股票市场不是一个钞票印刷机，它是一个利润与风险并存的市场，用“一把双刃剑”来描述股票市场是再恰当不过了。如果投资者利用好股票的波动走势低买高卖，那么他会赚的泼盆全满幸福的数钱。但是如果没有利用好这个市场波动，他可能也会输的分文不剩，抹脖子上吊。所以在投资股票的圈里经常会听到一句话“股市有风险，入市须谨慎。”。在目前的股票研究领域，如何预测股票价格的走势，帮助投资者规避风险、提高收益已经成为了一个新的研究方向^[1]。

1.1.2 研究目的及意义

本文研究的目的在于把人工神经网络技术和股票的一些理论结合起来引入到股票价格拐点趋势预测中。利用股票指标理论，可以从大量原始数据中抽象出核心知识，从而能够大大提高研究效率。而人工神经网络技术具有高度的非线性特征，能够进行复杂的逻辑操作和实现复杂的非线性关系，因而能够模拟大量人类尚未完全认知的知识领域，从而能够避免人们由于自身知识限制而可能导致的在投资股票市场过程中的片面性。

基于股票指标理论和神经网络的股票拐点预测模型的研究有利于增强金融证券投资的科学性，有利于降低投资者的风险。理性投资者在风险和收益并存的证券市场中追求的目标是利润最大化、风险最小化。把神经网络模型的拐点预测精准性和传统的金融证券分析方法相结合更容易规避投资风险，为广大的金融证券投资者提供更好的决策分析、获得预期收益和实现投资目标

1.2 研究方法

为了在证券市场中获利，许多投资者在无数次的成功和失败之后都会参考别人的经验总结自己的教训研究出很多方法，如道氏分析法、 k 线图分析法、柱状图分析法，甚至抛硬币、算卦等方法^[2-5]来预测市场的波动。

国内外研究者经过研究提出了许多股票价格趋势预测方法，归结起来主要有以下四种：

(1) 基础分析法

基础分析法^[6]以经济学、财政金融学、财务管理学和投资学为理论基础，研究影响股市走势的基本要素。该方法认为股票的实际价值即理论价值，是与投资报酬率和资金利润率有直接、真实的联系；股票价值的升降反映了人们从各种途径得到的预期报酬的信息的变化，当信息不全面、不充分或股票市场受供求关系、心理及政策因素影响时，股票价格即会与理论价格背离。因此，当市价低于理论价格时，即为购买股票的最佳时机，而当市价高于理论价格时，即为抛售的最佳时机。

基础分析能够比较全面地把握证券价格的基本走势，应用也简单。但是，它对市场的反应迟钝，预测时间跨度相对较长，因此对市场短线操作缺乏指导意义。并且应用基础分析，要对统计数据进行整理和归纳，需要有较高的分析能力和专

业技巧,因而对散户投资者而言,熟练地利用基础分析法指导投资操作比较困难。

(2) 时间序列分析法

时间序列是按时间顺序的一组数字序列。时间序列分析就是利用这组数列,应用数理统计方法加以处理,以预测未来事物的发展。时间序列分析是定量预测方法之一,它的基本原理:一是承认事物发展的延续性。应用过去数据,就能推测事物的发展趋势。二是考虑到事物发展的随机性。

证券波动的价格是一个时间序列,因此证券预测的问题可以借助于时间序列分析的方法。常用的时间序列分析法是基于统计理论,使用回归分析手段,建立子回归模型、移动平均模型、自回归—移动平均模型和齐次非平稳模型等统计模型,用来对证券价格及综合指数进行预测,通过选择模型的参数和辨识模型的系数实现对时间序列的拟合,进而用拟合好的模型对未来进行预测^[7]。任何事物发展都可能受偶然因素影响,为此要利用统计分析中加权平均法对历史数据进行处理。该方法简单易行,便于掌握,但准确性差,一般只适用于短期预测。时间序列预测一般反映三种实际变化规律:趋势变化、周期性变化、随机性变化。

(3) 股票技术分析方法

人们在长期实践和研究基础上总结出一套技术分析方法,它们基本上是建立在统计基础上的,这是分析和预测股价变化方向和趋势的方法。技术分析方法可以分为四种类型^[8-13]。

① 判断股价趋势为主的趋势分析,如切线理论、趋势线法、移动平均线等。

② 形状分析,如K线系统、江恩理论、波浪理论、支撑与阻力以及箱型理论等。

③ 技术指标,如MACD、OBV、KDJ、BOLL等。

④ 其它分析,如王国强的时间之窗,唐能通的老鸭嘴理论、缠中说禅理论。

传统方法事先知道各种参数,以及这些参数在什么情况下应作怎样的修正。因此,这种方法存在着很大的缺陷。

(4) 混沌动力学预测股票

自从六十年代,气象学家E.N.lorenz发现了非线性系统的混沌现象之后^[14],美国的E.E.Peter1991年研究了“标准普尔500指数”,通过空间重构发现了系统混沌现象的存在^[15]。我国学者也研究了上证综合指数,并发现了混沌现象的存在^[16]。

近年来,混沌理论的研究结果不断地被应用到经济学和工程学的各个领域,混沌理论刻划了混沌系统的运行机理和性质,与此同时经济系统中混沌现象不断被发现,因此自然而然地发展起来了利用混沌理论对股票预测进行研究。美国 Matsuba 在 1992 年国际神经网络年会上,发表了关于混沌系统奇异吸引子的相关维数和用于市场预测神经网络的训练数据、训练次数之间经验关系的论文。在 1995 年的世界神经网络年会上,总共 500 余篇文章中就有 20 多篇研究预测的应用。在 1997 年智能信息处理年会上,神经网络同混沌动力学理论结合已成为神经网络的一个发展方向。

(5) 数据挖掘技术分析法。

数据挖掘技术的出现为股票的分析研究近年来注入了新的活力,为股票市场建模与预测提供了众多的新技术和新方法。采用数据挖掘技术,对原始的股市数据进行处理,挖掘蕴涵在交易数据背后,反映股市变化的强规则,以实现股票未来变化趋势预测,最终达到指导投资的目的。

(6) 神经网络方法

人工神经网络(Artificial Neural Network)是目前人工智能研究领域的一个重要分支,是人类在对其大脑神经网络进行研究与理解的基础上人工构造的一种新型的信号处理系统,它是理论化的人脑神经网络的数学模型,是为模仿人脑神经网络的结构和功能而建立的一种由大量简单元件相互连接而成的复杂网络,具有高度的非线性,能够进行复杂的逻辑操作和实现复杂的非线性关系。因其吸取了生物神经网络的许多优点,在许多研究领域都取得了很好的运用效果。

神经网络的快速发展,为股票市场建模与预测提供了许多新技术和新方法。它是目前国际上进行股票预测研究的热点。最早的研究是 1988 年 White 利用 BP 网络对 IBM 股票进行预测^[17],其目标是未来一个月内买进和卖出的最佳时机;1995 年 Chen 等用神经网络预测了史坦普 500 种指数的变化^[18],但以上这些均是单纯应用神经网络进行股票市场的预测。这些预测都不够准确。

1.3 国内外研究状况

1.3.1 国内研究现状

90年代以来,我国计算机技术、尤其是数据库技术和网络技术在股票市场中得到充分应用,使得作为证券市场的重要组成部分的股票市场更加蓬勃发展起来,逐步成为证券业乃至整个金融业的必不可少的组成部分,显示出强大的生命力。早期市面流行的预测方法很多,其中技术分析便包括了均线、KD指标、RSI等30余种指标。这些预测方法大多使用了统计学知识。近两年,随着数据挖掘技术的日趋成熟,更多的国内学者采用了数据挖掘方法预测股市走势。常用的如:时间序列分析法,独立分量分析法、人工神经网络等。有些在算法方面对分析方法提出改进,如离散小波的学习算法、BP算法、正交最小二乘法、决策树算法、粗糙集算法等^[19-21]。有些在模型建立上提出创新,如建立混合型的神经网络模型^{[22][23]}、多变量函数估计小波网络和模糊小波阿络模型、运用最小描述长度原则选取显效因子建立模型等。

1.3.2 国外研究现状

相比国内,国外对股票预测方面的研究要早很多。1987年,Ledes和Farbor首次将神经网络引入到预测领域中,无论是从思想上、还是技术上都是一种拓宽和突破。它解决了传统预测模型难以处理高维非线性,偏重定量指标、难以处理定性指标、缺少自适应和自学习能力的预测问题。随后,RefeneS等人将神经网络预测方法和多重线性回归方法在股票市场预测中的应用进行了比较研究,指出神经网络的平滑内插特性使其能较好的拟合数据并能更好地泛化,其预测精度比统计预测方法有较大的提高。1992年由美国的Patl和shnaprasad首次正式提出小波神经网络,通过小波函数作为神经元的映射函数,充分利用小波基的局域特性及具有自适应的时频特点,构造了离散仿射小波神经^[24],目前,国内外研究现状基本相同,都是对以往研究成果进行改进。其中比较有影响的是Last.M提出的首先对时间序列进行预处理,然后从中抽取关键的预测属性(p.edictillgattributes)。这些属性对时间序列的发展趋势影响较大,将其组成属性集,这些预测属性表征了时间序列的某种特性,这种特性与时间没有关系,因此可以采用普通的静态的数据挖掘工具对时间序列进行行为趋势的分类预测^[25]。此外有些专家也将态势理论

引入了股票走势预测中根据军事领域的数据融合理论，将所观测的多空力量分布与活动和当前的证券投资环境、对方投资操作意图及操作机动性有机地联系起来，分析证券涨跌的原因，得到关于个股，板块和大盘的估计，最终形成证券综合态势图。

1.4 本文主要研究内容

在导师的指导下，作者阅读了大量有关股票知识、股票预测、神经网络和决策树的书籍和资料。对股票预测技术，尤其是神经网络技术在股票预测中的应用做了大量的细致的研究，在研究期间提出了多种研究方案，最终决定利用决策树技术辅助 BP 神经网络对股票进行预测。并在股票分析期间，插入股票指标的运用，充分利用前人留下的知识经验和新技术给我们带来的便利条件来对股市进行预测。

目前对神经网络的研究主要包括神经网络的基本理论研究、神经网络模型的研究、神经网络学习算法的研究、神经网络的计算机模拟及硬件实现和神经网络模型的应用研究^[26]。而在这里面神经网络算法是其中研究最多的一个课题。近年来出现了研究学者们提出了多种神经网络的算法。这些算法可分为两类：有导师学习和无导师学习。在这些算法中，在理论和实际应用中都成熟的有三种：模拟退火算法，BP 算法和竞争学习与相互激励学习算法。在这三种算法中，多层前馈网络的误差反向传播 (Error Back Propagation, 简称 BP) 算法具有可逼近任意非线性连续函数的学习能力和对杂乱系统的综合能力，还可根据历史数据进行自调节，这是其它方法所不具有的。并且 BP 算法是到目前为止最具影响力的算法之一，因此它被用来训练多层前向神经网络。本文也采取了这种算法来对股票进行预测。

神经网络用于非线性预测的基本原理是将观测值数据作为神经网络的输入向量，将预测值作为神经网络的输出向量；然后用足够的样本模式训练这个神经网络，使不同的输入向量得到不同的输出值。这样，神经网络所具有的连接权值，便是网络经过适应学习所得到的正确的内部表示；训练好的神经网络便可以作为—种定性与定量相结合的有效工具，对不同的预测对象进行预测。

用于非线性预测的神经网络模型通常为 BP 神经网络模型。BP 神经网络模型的学习算法 (也称逆传播学习算法)，其学习过程是一个误差边反向传播边修正的

过程,通常分为两个阶段进行:第一阶段按前向传播方向进行,按照输入层至隐含层至输出层的方向,可以得到各神经元的输入值和最后输出层的输出值;第二阶段按反向传播方向进行,根据输出层的实际输出和期望输出之间的误差,来调整节点间的连接权植,使误差达到最小。

基于 BP 算法的证券预测技术研究就是选择股票的一些比较重要的技术指标作为训练样本,将某些交易日的这些股票技术指标作为输入向量,按照前向传播方向,得到输出层的实际输出值;然后按反向传播方向,根据输出层的实际输出和期望输出之间的误差,来调整节点间的连接权值,使误差达到允许的最小值。经过调整的最后的权值,就是 BP 网络经过自适应学习所得到的正确的内部表示。使用训练后的 BP 网络模型对股价走势进行预测,从而达到增加投资收益和降低投资风险的目的。

当然 BP 网络模型也存在着一定的缺点。收敛速度慢和目标函数存在局部极小值两个问题。针对此问题本文运用遗传算法进行优化并且我们采用了决策树和 BP 算法相结合的方法。它有效地解决了在股票预测过程中寻找经验数据的困难,大大提高了股票预测系统的可实现性,并比 BP 网络有着更好的泛化性。

在数据挖掘的知识模式中,分类是比较重要的一种。决策树是数据挖掘中功能相对比较全面的一种分类工具。决策树按功能划分,主要有两种类型:对测试数据进行标记并把它们正确分类的分类树;对数值型的目标变量进行估计的回归树。本文介绍的决策树是分类树。本文利用分类树解决了 BP 模型在实际应用系统中很多因不知道最优策略而无法得到输入输出对的困难。实验证明这种方法是有效的,并能在股票预测系统中取得比单纯用 BP 算法的预测模型更加理想的效果。

本文组织结构

本论文总体上分为 5 章,具体内容安排如下:

第 1 章介绍本课题的研究背景,目前国内外的研究状况和本课题进行研究的主要内容。

第 2 章介绍了股票的一些基本概念,介绍了什么是股票,股票的分析方法的种类及特点,技术分析方法的原理,最后介绍了一些技术参数的概念。

第 3 章介绍了神经网络,并着重介绍神经网络中应用最广,影响最大,更能相对完善的的 BP 算法。

第4章根据道氏理论的三大假设我们知道，股票的历史是可以重现的，这就是股票预测有了可能行。介绍了股票预测的解释和神经网络对非线性函数拟合功能的可行性的证明，这就是股票预测在技术上有了支持。接下来，介绍了通过BP算法对非线性函数的拟合拓扑结构的确定，确定了使用三层BP网络模型。最后通过遗传算法对规避BP算法的缺点。以上就是对神经网络能否建立进行可行性分析。接下来通过实践确定出输入，中间层端点个数，然后根据数据归纳出拐点的公式作为输出。确定神经网络结构。

第5章是系统设计实现部分，讲述了基于遗传BP算法的双网络的股票预测系统的通过MATLAB的实现。

第6章是实验部分，通过实验数据验证了本文突出的模型与其它模型相比是否具有优势。

最后，总结了本文的工作并提出了下一步设想。

第 2 章 股票知识

2.1 股票

股票是一种有价证券，是股份有限公司在筹集资本时向出资人公开发行的、用以证明出资人的股本身份和权利，并根据股票持有人所持有的股份数享有权益和承担义务的可转证的书面凭证。股票代表其持有人（即股东）对股份公司的所有权，每一股股票所代表的公司所有权是相等的，即我们通常所说的“同股同权”。由于股票包含有经济利益，且可以上市流通转让，股票也是一种有价证券。股票具有以下几个特点：

(1) 不可偿还性

股票是一种无偿还期限的有价证券，投资者认购了股票后，就不能再要求退股，只能到二级市场卖给第三者。股票的转让只意味着公司股东的改变，并不减少公司资本。从期限上看，只要公司存在，它所发行的股票就存在，股票的期限等于公司存续的期限。

(2) 参与性

股东有权出席股东大会，选举公司董事会，参与公司重大决策。股票持有者的投资意志和享有的经济利益，通常是通过行使股东参与权来实现的。股东参与公司决策的权利大小，取决于其所持有的股份的多少。从实践中看，只要股东持有的股票数量达到左右决策结果所需的实际多数时，就能掌握公司的决策控制权。

(3) 收益性

股东凭其持有的股票，有权从公司领取股息或红利，获取投资的收益。股息或红利的大小，主要取决于公司的盈利水平和公司的盈利分配政策。股票的收益性，还表现在股票投资者可以获得价差收入或实现资产保值增值。通过低价买人和高价卖出股票，投资者可以赚取价差利润。以美国可口可乐公司股票为例。如果在 1983 年底投资 1000 美元买人该公司股票，到 1994 年 7 月便能以 11 554 美元的市场价格卖出，赚取 10 倍多的利润。在通货膨胀时，股票价格会随着公司原有资产重置价格上升而上涨，从而避免了资产贬值。股票通常被视为在高通货膨胀期间可优先选择的投资对象。

(4) 流通性

股票的流通性是指股票在不同投资者之间的可交易性。流通性通常以可流通的股票数量、股票成交量以及股价对交易量的敏感程度来衡量。可流通股数越多，成交量越大，价格对成交量越不敏感（价格不会随着成交量一同变化），股票的流通性就越好，反之就越差。股票的流通，使投资者可以在市场上卖出所持有的股票，取得现金。通过股票的流通和股价的变动，可以看出人们对于相关行业和上市公司的发展前景和盈利潜力的判断。那些在流通市场上吸引大量投资者、股价不断上涨的行业和公司，可以通过增发股票，不断吸收大量资本进入生产经营活动，收到了优化资源配置的效果。

(5) 价格波动性和风险性

股票在交易市场上作为交易对象，同商品一样，有自己的市场行情和市场价格。由于股票价格要受到诸如公司经营状况、供求关系、银行利率、大众心理等多种因素的影响，其波动有很大的不确定性。正是这种不确定性，有可能使股票投资者遭受损失。价格波动的不确定性越大，投资风险也越大。因此，股票是一种高风险的金融产品。

股票投资是指企业或个人用积累起来的货币购买股票，借以获得收益的行为。

股票投资的收益是由“收入收益”和“资本利得”两部分构成的：

(1) 收入收益

收入收益是指股票投资者以股东身份，按照持股的份额，在公司盈利分配中得到的股息和红利的收益

(2) 资本利得

资本利得是指投资者在股票价格的变化中所得到的收益，即将股票低价买入，高价卖出所得到的差价收益。

股票投资一般都伴随着较大的风险。但是正所谓“风险越大，收益越大”，股票投资往往也会带来很大的收益。如何获取收益避免风险，这就诞生了股票投资分析。

2.2 股票投资分析

任何分析都能够对股票的价格进行预测，虽然这些分析都可能会出现这样或那样的差错，但是多种分析相结合，一定可以大大提高准确性的。

股票的分析分为两大派：技术分析和基本面分析。技术分析的精髓就是相信历史会重演。技术分析采用的分析手段比较广，主要包含了趋势分析、形态分析、成交量分析、成交价格分析、指标分析、K线分析和一些经典的股市理论分析等。基本面分析包括了宏观经济分析、行业周期分析、个股的经营状况分析等。

技术分析是不考虑个股的内在价值的，个股的成交价格和成交量包含了所有市场信息。技术分析对短期的市场波动的判断要强于要强于基本面分析。基本面分析通过宏观经济分析和个股业绩的盈利预测，相信股票价格是股票内在价值体现，一旦股票出现低估的时候就是明显的买入机会，而高出内在价格的时候就是卖出的时间。同时坚信股票的价格波动总是围绕其内在价值进行上下波动。

基本面分析包含许多形如政策信息，国际形式等因素，这种因素量化的时候有一定的难度。而相比较而言，技术分析其含有因素量化难度低，条件明显，数据收集相对容易等优点，成为计算机预测股票的首选。

2.3 技术分析

技术这一词汇，在股市应用中，远不是一般辞典中定义的那样，他有其特殊的涵义。它是专指对市场本身行为的研究而非对市场交易的商品的研究。技术分析就是以预测投资品市场价格变动的未来趋势为目的，以图表、技术指标为主要手段对市场行为所进行的研究。其最大宗旨在于掌握投资品价格的波动韵律、脉络。

技术分析理论基础的三个假设：

(1) 市场行为包容消化一切

这是技术分析的基石。这句话的意思是：任何可能影响证券价格的因素，如政治的、心理的、经济的、公司自身的，实际上都会在价格上得到体现。供求关系影响价格变化，供大于求时，价格下跌，供小于求时，价格上涨。因此，只要研究价格的变化规律就够了，而不必去追究造成价格波动的内在原因。

(2) 价格以趋势方式演变

这是技术分析的核心。这句话的意思是：市场有趋势可循，而且市场趋势有势能或惯性，只有当它走到趋势的尽头，它才会调转方向。

(3) 历史会一再重演

这是技术分析的生命。这句话的意思是：每个投资者的交易行为均趋于一定的模式，不同时期的投资者在面临相同环境和背景时会有类似的反映，以至过去的价格走势和变动方式在未来也将不断地发生。

技术分析主要学派：①形态学派（道氏理论）、②波浪理论学派、③统计学派（一般技术指标）、④切线学派（甘氏理论）、⑤自然数字学派（宇宙理论）、⑥K线学派、⑦玄学派（占卜、观星.....）

技术分析人士坚持认为：对某一股票评定一个内在的价值是毫无用处的。市场价格所反映的不仅仅是许多正统证券评估专家的不同价值观，同时还包括许许多多潜在买方与卖方的期望、恐惧、猜测及很多有理或无理的情绪，以及他们的需求与资源——所有这些因素挑战我们的分析，并且许多因素是无法用统计数据加以衡量的。但是，每当买卖双方通过其代理商达成一笔交易时，所以这些因素都已综合反映在其成交的价格上了，而这一价格则包含了一切。

技术分析人士可以走得更远。他可以在根本不知道某一股票的名称的情况下对其图表进行解析，只要其交易的记录是准确的，并且覆盖了足够长的时间以便他能研究其市场背景及习性。他可以在完全不了解某一公司所处行业，它生产什么，或销售什么或者其资本组成方式的情况下，仅仅依靠其技术图表就可进行交易并声称将获利。当然，不用说，这样的行为不值得推荐，但是，如果你的市场分析人士确实在这一行业富有经验，从理论上讲，他可以实现他所夸下的海口。

从事技术分析时，有下述 11 项基本操作原则可供遵循：

（1）股价的涨跌情况呈一种不规则的变化，但整个走势却有明显的趋势，也就是说，虽然在图表上看不出第二天或下周的股价是涨是跌，但在整个长期的趋势上，仍有明显的轨迹可循。

（2）一旦一种趋势开始后，即难以制止或转变。这个原则意指当一种股票呈现上涨或下跌趋势后，不会于短期内产生一百八十度的转弯，但须注意，这个原则是指纯粹的市场心理而言，并不适用于重大利空或利多消息出现时。

（3）除非有肯定的技术确认指标出现，否则应认为原来趋势仍会持续发展。

（4）未来的趋势可由线本身推论出来。基于这个原则，我们可在线路图上依整个头部或底部的延伸线明确画出往后行情可能发展的趋势。

（5）任何特定方向的主要趋势经常遭反方向力量阻挡而改变，但 1/3 或 2/3 幅度的波动对整个延伸趋势的预测影响不会太大。也就是说，假设个别股票在一

段上涨幅度为三元的行情中，回档一元甚至二元时，仍不应视为上涨趋势已经反转只要不超过 2/3 的幅度，仍应认为整个趋势属于上升行情中。

(6) 股价横向发展数天甚至数周时，可能有效地抵消反方向的力量。这种持续横向整理的形态有可辨认的特性。

(7) 趋势线的背离现象伴随线路的正式反转而产生，但这并不具有必然性。换句话说，这个原则具有相当的可靠性，但并非没有例外。

(8) 依据道氏理论的推断，股价趋势产生关键性变化之前，必然有可资辨认的形态出现。例如，头肩顶出现时，行情可能反转；头肩底形成时，走势会向上突破。

(9) 在线路产生变化的关键时刻，个别股票的成交量必定含有特定意义。例如，线路向上挺升的最初一段时间，成交量必定配合扩增；线路反转时，成交量必定随着萎缩。

(10) 市场上的强势股票有可能有持续的优良表现，而弱势股票的疲态也可能持续一段时间。我们不必从是否有主力介入的因素来探讨这个问题，只从最单纯的追涨心理即可印证此项原则。

(11) 在个别股票的日线图或周线图中，可清楚分辨出支撑区及抵抗区。这两种区域可用来确认趋势将持续发展或是完全反转。假设线路已向上突破抵抗区，那么股价可能继续上扬，一旦向下突破支撑区，则股价可能再现低潮。

2.4 技术指标

前面我们了解了，技术分析中是根据图标和技术指标来预测的，下面本文就简单介绍一下主要的技术指标。

移动平均线(MA)

所谓“移动平均线”是指一段时间内的算术平均线，通常以收盘价作为计算值。

其算法：

$$MA(N) = \frac{S_1 + S_2 + \dots + S_N}{N} \quad 2-1$$

其中 $MA(N)$ 表示 N 日移动平均线， S_1, S_2, \dots, S_N 分别表示第 1 日到第 N 日的收盘价。

例如：

把某日的收盘价与前9个交易日的收盘价相加求和，然后再除以10，就可以得到该日的10日移动平均线值 MA(10)。

移动平均线可分为

短期移动平均线（周线）：即 MA（5）以一周的5个交易日为周期的移动平均线

中期移动平均线（月线）：即 MA（30）以一个月为周期的移动平均线

长期移动平均线（年线）：即 MA（280）以一年中的全部交易日的总和为周期的

用法：

葛兰碧（GRANVILLE J）移动平均线运用八大法则

（1）移动平均线从下降趋势转为上升趋势，股价从移动平均线下方向上突破平均线为买入信号。

（2）股价向下跌破移动平均线，但很快又回到移动平均线之上，移动平均线仍然保持上升趋势，为买入信号。

（3）股价位于移动平均线之上，短期下跌但未向下穿越移动平均线，是买入信号。

（4）股价暴跌，跌破移动平均线后远离移动平均线，为买入信号。

（5）移动平均线由上升趋势转为盘局，或下跌，最后一日收市价向下跌破平均线，为卖出信号。

（6）股价向上突破移动平均线但很快又回到平均线之下，移动平均线仍然维持下跌局面，为卖出信。

（7）股价在移动平均线之下，短期向上但并未突破移动平均线且立即转为下跌，为卖出信号。

（8）股价暴涨向上突破移动平均线，且远离移动平均线为卖出信号。

指数平滑移动平均线(MACD)

MACD（Moving Average Convergence Divergence）中文名称：平滑异同移动平均线，是由 Gerald Appel 首先在 Systems And Forecasts 一书中发表，主要是利用长短期的二条平滑平均线，计算两者之间的差离值，作为研判行情买卖之依据。

算法:

DIFF 线 收盘价短期、长期指数平滑移动平均线间的差

DEA 线 DIFF 线的 M 日指数平滑移动平均线

MACD 线 DIFF 线与 DEA 线的差, 彩色柱状线

参数: SHORT(短期)、LONG(长期)、M 天数, 一般为 12、26、9

用法:

- (1) DIFF、DEA 均为正, DIFF 向上突破 DEA, 买入信号。
- (2) DIFF、DEA 均为负, DIFF 向下跌破 DEA, 卖出信号。
- (3) DEA 线与 K 线发生背离, 行情反转信号。
- (4) 分析 MACD 柱状线, 由正变负, 卖出信号; 由负变正, 买入信号。

威廉指标(William's %R)

原理: 用当日收盘价在最近一段时间股价分布的相对位置来描述超买和超卖程度。

算法:

N 日内最高价与当日收盘价的差, 除以 N 日内最高价与最低价的差, 结果放大 100 倍

参数: N 统计天数 一般取 14 天

用法:

- (1) 低于 20, 超买, 即将见顶, 应及时卖出
- (2) 高于 80, 超卖, 即将见底, 应伺机买进
- (3) 与 RSI、MTM 指标配合使用, 效果更好

KDJ

随机指标

原理: 用目前股价在近阶段股价分布中的相对位置来预测可能发生的趋势反转。

算法: 对每一交易日求 RSV(未成熟随机值)

$RSV = (\text{收盘价} - \text{最近 } N \text{ 日最低价}) / (\text{最近 } N \text{ 日最高价} - \text{最近 } N \text{ 日最低价}) \times 100$

K 线: RSV 的 $M1$ 日移动平均 D 线: K 值的 $M2$ 日移动平均

J 线: $3 \times D - 2 \times K$

参数: N 、 $M1$ 、 $M2$ 天数, 一般取 9、3、3

用法:

- (1) $D > 80$, 超买; $D < 20$, 超卖; $J > 100\%$ 超卖; $J < 10\%$ 超卖
- (2) 线 K 向上突破线 D, 买进信号; 线 K 向下跌破线 D, 卖出信号。
- (3) 线 K 与线 D 的交叉发生在 70 以上, 30 以下, 才有效。
- (4) KD 指标不适于发行量小, 交易不活跃的股票;
- (5) KD 指标对大盘和热门大盘股有极高准确性。

如果想要做短线, 技术分析是必不可少的, 因为在很多情况下, 技术分析是可以做到精确的找到价格的低点和高点。如果想做一个稳健投资者就必须在基本面分析上下功夫, 你把上市公司的情况了解的很透彻, 就会很从容的面对的市场日常波动, 从而获得很稳定的中长期收益。如果你的技术分析和基本面分析都很过硬的话就可以采取波段炒作了。具体的分析方法建议去多买几本书看看, 技术分析的基本上每本书上都讲的差不多, 基本面分析则需要有很强的会计知识。

当某只股票没有卖盘时, 主要是因为买入的委托比较多, 造成了封涨停的现象, 虽然时而有小笔卖单, 但是成交价格还是涨停板价格的成交时, 就必须按照时间优先的交易原则, 进行排队买入。当比你买入的委托都成交后, 就可以买入了。

本章小结

本章介绍了股票的基本定义。介绍了股票的意义, 股票的性质, 在股票市场中经常使用的方法, 如技术分析和基本面分析, 其中着重介绍了技术分析。解释了技术分析的重要依据——技术分析理论基础的三个假设。并且介绍了技术分析中十分重要的几项指标。

第3章 神经网络理论

自从1945年第一台数字计算机问世以来,计算机先后经历了电子晶体管计算机,晶体管为基本元件的计算机,集成电路计算机,超大规模集成电路计算机等丝带变化。并且计算机也在越来越多的领域展示并发挥了积极的作用。随着计算机发挥的多用越来越大,人们对其的期望值也就越来越高,尤其是在小说与卡通中有了诸如铁臂阿童木,多啦A梦中的人性化智能独立机器人,如全金属狂潮中的智能辅助型机器人等等。不少研究者曾经用计算机和编程的方法来开发这种机器,这就形成了计算机科学的一个分支,人工智能(Artificial Intelligence,简称AI)。这也成为第五代计算机。而有些研究人员跑开了计算机结构原理,仿照生物大脑的功能和结构建造了一种新型的计算机,这就是第六代计算机,人工神经网络(Artificial Neural Networks,简称ANN)

3.1 人工神经网络概述

3.1.1 什么是神经网络

大家都知道,人类是这个地球上最高级的生物,其高级来源于人类的智慧,而智慧的产生却是来自于大脑。长期以来,人类靠大脑进行记忆,思考,联想,学习,判断,推理等等,这些功能是被称作“电脑”的计算机无法全部实现的。这也促使了许多研究工作者对人脑内部结构和功能的研究,并且试图建立模仿人类大脑的计算机。目前研究工作者们已经对人类的大脑结构有了部分了解。简单说大脑是有大量的神经元组成的,每个神经元有随着所接收到多个激励信号的大小而呈现兴奋或抑制状态。现已明确大脑的学习过程就是神经元之间连接强度随外部激励信息做自适应变化的过程,而大脑处理信息的结果则由神经元的状态表现出来。通过这种工作模式,研究者建立起了模仿生理神经网络的模型,并称它为人工神经网络。

人工神经网络的操作需要两个步骤,一是学习训练,一是正常操作。所谓训练,就是把要交给网络的信息作为网络的输入和要求输出,是网络按照某种规则调节网络各个处理单元之间的连接权值。学习是不断进行的,它的结束条件有两个,一个是学习的时间到了(规定了学习时间或者步骤),一个是学习的效果达标

(网络给出的输出与对应真实输出之间的误差足够小)。这个时候,处理单元之间的各个连接权值已经调节完毕,网络的训练就结束了。所谓正常操作,就是对训练好的网络输入一个信号,它就可以正确回忆出相应的输出。所以这个操作以成为回忆操作。

如今随着硬件和软件的技术飞速的进步,是人们在做这些工作的时候,不必用大型或者中型计算机,而在个人计算机上就可以运行。这意味着任何人都有可能进行人工神经网络实验的实践。

3.1.2 人工神经网络的发展过程

人工神经网络的发展史是一个非常曲折的发展史,从启蒙期到目前可以说是几经风雨。它的发展可以分为四个阶段^[36]:

(1) 启蒙与第一次高潮时期

人类对神经网络的研究最早可以追溯到人类开始研究自己的智能的时期,而到1943年,美国心理学家 Warren McCulloch 和数学家 Walter Pitts 合作总结了生物神经元的一些基本生理特征,并且将其进行形式化描述,提出了一种简单的数学模型与构造的方法。他们将其研究结果写在了一篇名为“A Logical Calculus of Ideas immanent in Nervous Activity”的文章。文中提出了形式神经元的数学模型(即M-P模型)。该模型描述了神经细胞的动作:第一,神经网络所表现书来的活动只有兴奋或抑制可用二值变化来表示;第二,任何兴奋性突触有输入激励后,使神经元兴奋与神经元先前的动作状态无关;第三,任何抑制性突触有输入激励后,使神经元抑制;第四,突触的值不随时间改变;第五,突触从感知输入到传送出一个输出脉冲的延迟时间是0.5ms。由此可见,M-P模型是通过数学逻辑的方法来描述神经网络的。虽然现在来看M-P模型比较简单,而且其观点也并非完全正确。但是在当时不少研究人员在解剖学和生理学中寻找和建立智能机的思路的时候提出这个理论,给人们了一个信念,那就是大脑的活动是靠脑细胞的组合连接实现的。因此,M-P模型被认为开创了神经科学理论研究的新时代。

1949年,心理学家 D.O.Hebb 提出了神经元之间突触联系强度可变的假设,并据此提出神经元的学习规则——Hebb 规则,为神经网络的学习算法奠定了基础。1957年,计算机学家 Frank Rosenblatt 提出了一种具有三层网络特性的神经网络结构,称为“感知器”(Perceptron),它是由阈值性神经元组成,试图模拟动物

和人脑的感知学习能力。1962年 Widrow 提出了自适应线性元件 (Adaline), 它是连续取值的线性网络, 主要用于自适应信号处理和自适应控制。在这个时期, 人们乐观地认为几乎已经找到了智能的关键。并且认为只要其他的技术条件成熟, 科学家们就可以重构人脑。因此许多部门都开始大批地投入此项研究, 希望进款占领制高点。

(2) 低潮反思时期

人工智能的创始人之一 Minkey 和 papert 经过数年研究, 于 1969 年出版了很有影响的《Perceptron》一书, 指出了感知器不可能实现复杂的逻辑函数, 这其中包括最基本的“异或”问题。这对当时的人工神经网络研究产生了极大的负面影响, 从而使不少研究员把经历转向了人工智能。神经网络研究陷入低潮时期。虽然如此, 还是有一些科学家在坚持研究, 但因为其研究结果即使发表也很难被同行看到, 致使这个时期被延长很多。著名的 BP 算法研究就是一个例子。后来人们发现有一类问题单级感知器无法解决但是多级网络可以解决。逐渐的, 一系列的基本网络模型被建立起来, 形成了神经网络的理论基础。而事实也证明了 Minsky 的估计是过分悲观的。

(3) 复兴时期

1982 年, 美国加州理工学院的物理学家 John J.Hopfield 博士发表了一篇对神经网络研究的复苏起了重要作用的文章, 是人们的注意力又投向了人工神经网络。他建议收集和重视以前神经网络所做的工作, 总结与吸取前人对神经网络研究的成果与经验, 把网络的各种结构和各种算法概括起来, 塑造出一种新颖的强有力的网络模型, 称为 Hopfield 网络。1986 年, Rumelhart 及 LeCun 等学者提出了多层网络学习算法——BP 算法。较好的解决了多层网络学习问题。BP 算法的提出, 对人工神经网络的研究与应用起到了极大的促进作用。

(4) 新时期

1987 年 6 月, 首届国际神经网络学术会议在美国加州圣地亚哥召开, 这标志着世界范围内掀起了神经网络开发研究的热潮。在这次会上成立了国际神经网络学会 (INNS), 并于 1988 年在美国波士顿召开了年会, 会议讨论的议题涉及到生物、电子、计算机、物理、控制、信号处理及人工智能等各个领域。自 1988 年起, 国际神经网络学会和国际电气工程师与电子工程师学会 (IEEE) 联合召开了每年一次的国际学术会议。这次会议后不久, 各种神经网络的学术期刊开始不断的涌

现。

从 1987 年以来,神经网络的理论、应用、实现及开发工具均以令人振奋的速度快速发展。神经网络理论已成为涉及神经生理科学、认知科学、数理科学、心理学、信息科学、计算机科学、微电子学、光学、生物电子学等多学科交叉、综合的前沿学科。神经网络的应用已渗透到模式识别、图像处理、非线性优化、语音处理、自然语言理解、自动目标识别、机器人专家系统等各个领域,并取得了令人瞩目的成果。

3.2 基本神经元模型

神经网络是由大量神经元组成的。因此,若要构造一个人工神经网络系统,首先就要对神经元进行构造。对于如何构造神经元的问题,人脑中的神经细胞已经给了我们很重要的提示。仿照人类神经系统的模型,我们可以看出,神经网络是神经元按照大规模并行方式,通过一定的拓扑结构连接而成。神经元的构造即是对人脑神经细胞功能的抽象、简化与模拟,这种单元的状态作为独立的实体来说没有任何符号层次上的对应关系。基本神经元机构如图 3-1 所示:

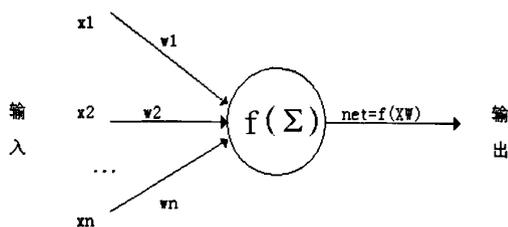


图 3-1 基本神经元模型

基本神经元结构有以下 4 个基本要素:

- (1) 一个求和单元,用于求取各输入信号的加权和(线性组合)。
- (2) 每个神经元有一个阈值。
- (3) 一组连接(对应于生物神经元的突触),连接强度有个连接上的权值表示,权值为正表示激活,为负表示抑制。
- (4) 一个激活函数,起映射作用并将神经元输出幅度限制在一定范围内。

神经元的信息处理过程可分为三个阶段:

- (1) 神经元接受别的神经元或外界的输入,这些输入表现为冲动或刺激,总的效果是加性的。设 x_1, x_2, \dots, x_m 为神经元的 m 个输入;在每个输入连接上附加的

连接权值为 w_1, w_2, \dots, w_m ; 神经元的内部阈值(门限值)为 0。对输入信息与对应的权值进行内积运算:

$$a = \sum_{i=1}^m w_i x_i + \theta \quad (3-8)$$

(2) 把 a 代入激活函数运算, 得到神经元的输出 $y = f(a)$ 。

(3) 对神经元的输出进行判决, 若 y 大于给定阈值, 则该神经元被激活, 处于兴奋状态, 否则, 神经元不激活, 处于抑制状态。

神经元通过这种工作方式, 模拟了脑细胞的生物特性, 而神经元的状态也仅有抑制和兴奋两种状态, 数学上表现为非线性关系。由于单个神经元的输入输出之间具有非线性关系, 致使整个神经网络构成了一个复杂的非线性动力学系统。而这个系统和大脑一样是不断变动, 不断演化的。

3.3 神经网络的特点

神经网络基本上属于结构主义产物, 特殊的结构决定特殊的功能。神经网络与一般的建模和计算相比有如下几个突出特点:

(1) 并行协同的处理信息

人工神经网络与人类的大脑类似, 在结构上和处理顺序上都是同时而且并行的。神经网络中的每个神经元都可以根据接收到的信息进行独立的运算和处理, 并输出结果, 同一层中的各个神经元的输出结果可被同时计算下来, 然后传输给下一层做进一步处理。也就是说, 人工神经网络的计算功能是通过多个处理单元来实现的。计算的最终的结果只是在宏观整体层次上有意义, 而每个节点的操作对整体上并没有清晰的贡献。

(2) 信息的分布存储

分布存储与冗余性 信息在神经网络中的存储是分布于大量的神经元之中, 即一个事物的信息不只是对应于一个神经元的状态进行记忆, 而是分散到很多神经元中进行记忆。而且每个神经元实际上存储着多种不同信息的部分内容。在分布存储的内容中, 有许多是完成同一功能的, 即网络具有冗余性。网络的冗余性导致网络的存储具有容错性, 即其中某些神经元受到损伤或死亡时, 仍不致于丢失其记忆的信息。信息在神经网络中的记忆, 主要反映在神经元之间的突触连接

强度上。

(3) 容错性和鲁棒性

我们都知道人类自身每天都有许多细胞，脑细胞也不例外。但是我们并没有因为脑细胞的死亡代谢而影响自己的思考和记忆的能力。这是因为大脑中的信息并不是存在于某个脑细胞上，而是存储在多个脑细胞和它们直接连接上。

其信息的存储分布在不同位置，神经网络是用大量神经元之间的连接及对各连接权值的分布来表示特定的信息，从而使网络在局部网络受损或输入信号因各种原因发生部分畸变时，仍然能够保证网络的正确输出，提高网络的容错性和鲁棒性。

人工神经网络也具有类似的功能。神经网络的每一个神经元，都只是整体概念的一个部分，但是到底是怎样的一部分却并不清楚。每一个单元都包含着对整体的贡献，而每一个单元都无法决定整体的状态。也就是其信息的存储分布在不同位置，神经网络是用大量神经元之间的连接及对各连接权值的分布来表示特定的信息，从而使网络在局部网络受损或输入信号因各种原因发生部分畸变时，仍然能够保证网络的正确输出，提高网络的容错性和鲁棒性。

(4) 学习与自适应性

人类对知识的理解不是生来就有的，而是通过不断的学习和积累来逐步获取的。人工神经网络也有相似的能力。这就是人工神经网络的另一个重要特点是具有很强的学习能力。它可以通过学习不断的学习来实现复杂的函数关系，从而适应不断变化的环境。这种学习过程可以是有导师学习，亦可以是无导师学习。而神经网络的学习方法也是非常简单，可以在网络结构不变的情况下，仅仅调整权值即可达到学习的目的。

3.4 神经网络的学习

人工神经网络有一个非常有吸引力的特点那就是它的学习能力。通过向环境学习以获取知识并改进自身性能，是神经网络的一个重要特点。所谓学习，就是在将样本集合输入到人工神经网络的过程中，神经网络按照一定的方式自动调节神经元之间的连接权，从而是网络在得到输入的时候，能够给出适当的满意的输出。当给定输入以后，系统给出的输出与实际输出差距变小时，就可以说学习是有效果。

神经网络中主要有三种学习类型：

(1) 有导师学习

所谓有导师学习，就是要求外界给系统提供一个“导师”，即对于每一组输入要有相对应的一组输出。神经网络根据输入通过网络模型给出一组输出，然后将得到的输出与已知输出做对比，通过差值来调节系统的各个参数。BP 网络、径向基就是典型的有导师学习。

(2) 无导师学习

学习时没有外部“导师”，学习系统完全按照网络的输入信息的某些统计规律来调节自身参数或结构(这是一种自组织过程)，以表示出外部输入的某种固有特性(如聚类或某种统计上的分布特征)。也就是说无导师学习的训练集只包含一些输入量，训练的结果就是相似的输入可以得到相似的输出即可。自组织映射(Self-Organizing)和自适应共振理论(Adaptive Resonance Theory)网络就是典型的例子。

(3) 增强学习

介于上述两种情况之间，外部环境对系统的输出结果只给出评价信息(奖励和惩罚)而不是给出正确答案。学习系统通过强化那些受奖的动作来改善自身的性能。

另外有些网络根本不需要学习，这些网络的权值在处理问题的过程中根本不随时间变化，这种网络的权值需要提前设定。Hopfield 网络和双向联想记忆网络等都是不需要学习的网络。

3.5 BP 算法及缺点

BP 算法属于广义 δ 学习规则，是一种有导师学习算法。它由前向计算和反向计算组成。在前向计算中，一个活动模式(输入向量)作用于网络感知节点，它的影响经过网络一层接一层地传播。最后，产生一个输出作为网络的实际响应，若输出层得到了期望的输出，则学习算法结束；否则转至反向计算。前向计算中网络权值是固定的。而在反向计算中，权值需要根据误差修正规则来调整，特别是从目标响应减去网络的实际响应产生的误差信号。这个误差信号反向传播经过网络，与突触连接方向相反，因此叫反向传播学习算法。权值被调整使得网络的实

际响应从统计意义上接近目标响应。

BP 算法通过给定训练样本 $\{(x(n), y(n))\}_{n=1}^N$ 进行如下循环：

(1) 初始化。假使训练前没有经验知识可以利用，则用随机分布的方法差生权值和阈值，这个分布选择均值等于 0 的均匀分布，其方差应该使得神经元的诱导局部域的标准偏差位于 sigmoid 激活函数的线形部分与饱和部分的过渡处。

(2) 网络对样本学习。网络对样本的学习的一个回合，以某种形式将样本集中的每个样本依次进行下面 (3)、(4) 所说明的向前传播和向后传播。

(3) 向前传播阶段。在该回合中设的训练样本是 $(x(n), y(n))$ ，其中 $x(n)$ 是输入向量，向量 $y(n)$ 是期望输出向量。 $x(n)$ 从输入端输入，然后不断地经由网络一层一层地前进，可以计算网络各层的诱导局部域 $v_j^{(l)}(n)$ 和函数信号 $y_j^{(l)}(n)$ 。计算误差信号 $e_j(n) = y_j(n) - o_j(n)$ ， $y_j(n)$ 是期望响应向量 $y(n)$ 的第 j 个向量。

(4) 向后传播阶段。计算网络的 δ (即局域梯度) 定义为：

$$\delta_j^{(l)}(n) = \begin{cases} e_j^{(l)}(n) \phi_j'(v_j^{(l)}(n)), & \text{对输出层 } L \text{ 的神经元} \\ \phi_j'(v_j^{(l)}(n)) \sum_k \delta_k^{(l+1)}(n) w_{kj}^{(l+1)}(n), & \text{对隐含层 } l \text{ 的神经元} \end{cases} \quad 4-2$$

这里 $\phi_j'(\cdot)$ 是指对自变量的微分。根据广义 delta 规则调节网络第 l 层的权值：

$$w_{ji}^{(l)}(n+1) = w_{ji}^{(l)}(n) + \alpha [w_{ji}^{(l)}(n-1)] + \eta \delta_j^{(l)}(n) y_i^{(l-1)}(n) \quad 4-3$$

这里 η 为学习率参数， α 为动量常数。

(5) 迭代。根据每一回合的提供给网络样本根据(3)、(4)不断进行向前和向后传播，直到满足停止条件。

注意：训练样本的呈现顺序从一个回合到另一个回合必须是随机的。动量和学习率参数随着训练迭代次数的增加而调整(通常是减少的)。

本章小结

本章介绍了神经网络发展经历并且说明了神经网的组成和工作特点。说明了神经网络在学习中的优势，并且介绍神经网络中应用最广，影响最大，更能相对完善的的 BP 算法的原理及其训练过程。

第 4 章 拐点寻找与模型的建立

4.1 引言

投资者们进入股票市场都怀有同一个目的，那就是如何将自己手中的资金通过一系列的操作后，使其能够大幅度的增加。所以投资者最关心的问题一般不是某股票第二天的价格能达到多少钱，最关心的是某一种股票接下来的日子走势趋向是如何。如果投资者发现某一种股票在接下来的一段时间内有上升趋势，那么就进入此种股票等待收取利润；反之，如果发现手中持有的某一种股票在接下来的一段时间内有下降趋势，那么坚决将此种股票出仓，防止损失。鉴于此种情况，可以看出相比较判断股票第二天的价格这种定量判断，判断股票走向趋势这种定性判断更有实际价值，更有意义，也更有必要。

请看图 4-1

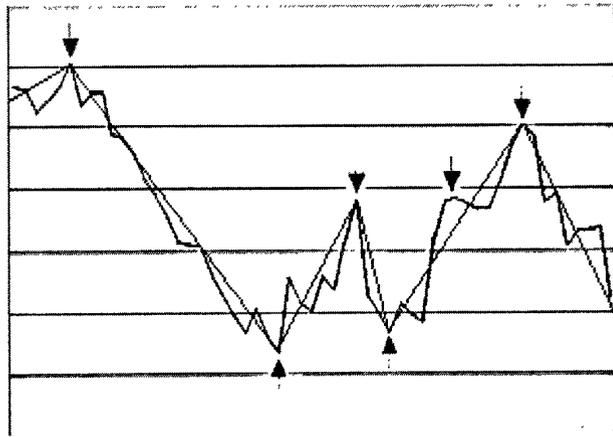


图 4-1 股票走势拐点

这是某一股票一部分的 K 线走势图，蓝色折线表示的是将此种股票每天的收盘价连起来的 K 收盘折线，而黑色折线所表示的是此 K 线图的一个趋势。由此图可以看到收盘价格的变化时非常复杂的，要想准确的掌握这种变化并不是一件非常容易的事情。而价格趋势在此一段时间内只有几次变化，相比较价格的复杂变化这种趋势是可以比较好的掌握的。另外通过这个图我们还可以看到，纵使此 K 线图没有给出纵坐标，也就是没有给出股票的价格，但是若投资者根据此股票的走势趋势进行投资，仍然可以达到获利的目的。无论股票的价格是 10 元，30 元，50 元还是 100 元，只要掌握住了用黑色直线表示的趋势，都能获得不菲的收益。

当然如果投资者只掌握住趋势只能够使投资者获得收益或者避免损失，而不能将受益达到最大化。这就需要掌握一个股票中买卖股票的合理时间。而图中用红箭头所表示的就是收益最大化时的操作时刻。换句话说，如果按照红色箭头的时刻进行低买高卖的方法进行操作能够获得收益最大化。即红箭头所表示的位置就是股票的拐点。

拐点也有真假之分，例如通过图我们还可以看到有一个时间点是由蓝色箭头指出的。在这个时间点之后的几天，股票价格确实下降了几个百分点，在下降之后，股票有继续上升了很长一段时间。相比较此上升的量度，下降的那几个百分点可以忽略不计，换句话说，此点后的下降并没有破坏股票的上升通道，也并没有改变股票的上升趋势，所以说这是一个假拐点。

4.2 可行性分析

道氏理论有三大假设：市场行为涵盖一切信息，价格跟趋势移动，历史终将重演。这个在证券分析理论的历史中有着举足轻重的地位的理论说明了股票市场是可以预测的。而格伦吉(D·Gelengi)在谈到当前股票市场的某些研究时，也曾指出：从长期来看，使用分散具体的数据，剔除意外的事件，使用非线性模式转换模型，股价还是可以预测的。这个给出股票市场的价格可以预测，也告诉了我们跟股票价格有关的股票的走势也是可以预测的。

预测是什么？预测就是对将来的事情的评估。它的评估依据是已知的确定对象以及其相关的理论依据。而根据格伦吉的研究，我们可以看出股票价格就是一种离散的时间序列，预测价格就是依据已知的历史数据和一些理论依据。设有时间序列 $\{X_i\}$ ，其中历史数据 $X_n, X_{n+1}, \dots, X_{n+m}$ 分别表示第 $n, n+1, \dots, n+m$ 时刻的取值，通过它们对未来第 $n+m+k$ ($k>0$) 时刻的取值进行预测，即预测 X_{n+m+k} 的值，方法就是通过神经网络来求出历史数据 $X_n, X_{n+1}, \dots, X_{n+m}$ 与 X_{n+m+k} 的某种关系：

$$X_{n+m+k} = G(X_n, X_{n+1}, \dots, X_{n+m}) \quad 4-1$$

例如通过 $v=at$ ，只要知道加速度 a ，我们可以很容易的预测到第 t 时刻的速度。

当然想要寻找这个非线性映射是非常困难的,许多研究学者都在这个方面做研究。但成果并不十分理想。所以研究学者们通过另一种方法,即寻找一个比较理想的非线性映射来逼近对其进行逼近拟合。我们可以设输入样本集合为 X ,输出样本集合为 Y 。我们可以人为在样本 X 与样本 Y 之间存在一个映射 G :

$R_n \rightarrow R_m$, 使 $Y = G(X)$ 。而如果将神经网络也看做成为一个从 n 个输入到 m 个输出的高度非线性映射,即有 $F: R_n \rightarrow R_m$, 使 $Y = F(X)$ 。我们只需要考虑如何将映射 F 成为 G 的最佳逼近。对于映射 F 的寻找有非常多的方法,其中一个方法就是通过人工神经网络。人工神经网络本身已经给我们提供了方法,这种方法不需要一般数学方法那样面对选择和构造函数,并且求解函数求解系数等困难并且复杂的问题。它只需要对简单的非线性函数进行拟合,经过多次拟合之后即可实现对复杂函数的逼近^[35]。其中BP算法就是其中非常具有代表性的方法。

下面我们来说明一下,BP神经网络可以使用相对简洁的网络结构和较合理的学习时间来能够得出近似复杂的函数。

定理 4.1 给定任一连续函数 $f: [0,1]^n \rightarrow R^m$, f 可以精确地用一个三层前向神经网络实现。此网络的第一层即输入层有 n 个神经元,中间层有 $2n+1$ 个神经元,第三层即输出层有 m 个神经元。

该定理又称Kolmogorov定理,它以定理的形式向我们表述了映射网络是存在的,并且确定了它的层数为3。

定理 4.2 给定任意 $\varepsilon > 0$,对于任意的 L_2 型连续函数 $f: [0,1]^n \rightarrow R^m$,存在一个三层BP神经网络,它可在任意 ε 平方误差精度内逼近 f 。

该定理向我们表述了一个三层的BP网络就可以以任意的精度逼近一个给定的连续函数。

有了上面两个定理的支持,我们可以说有BP神经网络来逼近那些最佳刻画样本数据规律的函数是可行的,而不用研究这些函数具有怎样的形式。这就为我们用神经网络对时间序列进行非线性预测提供了理论上的保证^[24,25]。股价走势是一种高度非线性走势,而成交量,成交价等参数对股价的变化有很强的相关性。通过对历史交易数据的学习,前馈网络就能刻画这些规律或特点,因此,基于BP

网络对股票数据进行实际预测, 预测精度明显高于传统方法, 说明此种方法是可行的。

4.3 BP 学习算法的不足

梯度学习方法在寻找最优值中得到了广泛的应用。但它自身也存在着不可避免的缺点, 那就是在寻找最有值的过程中有很大的可能性陷入到局部极小点, 作为梯度学习算法之一 BP 算法同样具有这个缺点。尽管误差反向传播算法进行网络的权值优化取得了巨大的成功, 特别是各种二阶梯度算法的应用使网络权值搜索的收敛速度大大地加快, 但是如果碰到目标函数在存在这多个局部极小点, 但则梯度搜索过程不可避免的会遇到陷入局部极小点的问题。遇到这种状态, 在不改变梯度搜索的情况下只能重新设置初始权值继续进行搜索。

4.4 遗传算法

遗传算法是一类随机优化算法, 它的两个重要特点是群体搜索策略和群体中个体之间的信息相互交换, 其本质是模拟由个体组成的群体的整体学习过程, 其中每个个体表示给定问题搜索空间中的一个解点。遗传算法从任一初始化的群体出发, 通过随机选择(使群体中优秀的个体有更多的机会传给下一代)、交叉(体现了自然界群体内个体之间的信息交换)、变异(在群体中引入新的个体以确保群体中信息的多样性)等遗传操作, 使群体一代一代地进化到搜索空间中越来越好的区域, 直至抵达最优解点

遗传算法利用生物遗传进化的思想实现优化过程, 区别于传统优化算法, 它具有以下特点^[17,32]:

(1) 传统优化算法通常是直接处理函数和它们的控制变量, 而遗传算法通过编码将优化问题的自然参数编码成有限长度的数字串即染色体后, 再进行进化操作, 而不是针对参数本身, 这使得遗传算法基本上不受函数约束条件(如连续性、可导性、单调性等)的限制, 能在极其广泛的问题求解领域中发挥作用。

(2) 传统搜索算法基本上是点到点的搜索方法, 在多极点的搜索空间里常常陷入局部极小点, 而遗传算法的搜索过程是从问题解的一个集合开始的, 而不是从单个个体开始, 具有隐含并行搜索特性, 从而大大减小了陷入局部极小点的可能。

(3) 在遗传算法的交叉操作过程中, 这种点间的信息交换可明显加速遗传算法的进化过程。Holland 证明了在一个规模为 n 的种群中, $O(n^3)$ 模式是有效的, 即每一代遗传算法在处理 n 个串的模式的同时, 实际上有效地处理了大约 n^3 个模式。这是一个很重要的性质, Holland 称之为隐并行性。

(4) 遗传算法在选择过程中, 依据一定的概率随机地选择个体, 模仿了自然界进化过程中的“适者生存, 优胜劣汰”的竞争规则, 它虽然以随机化的方法进行探索, 但实际上是朝着有可能改进解的质量的搜索方向进行搜索, 即为一种有导向的随机化搜索方法。

大多数传统搜索方法都需要使用较多的附加特性, 而遗传算法仅用适应度函数来评估个体, 并在此基础上进行遗传操作, 且适应度函数不受连续、可微、单调等性质的约束, 其定义域可以任意设定, 因此, 与传统搜索算法相比, 遗传算法具有更强的鲁棒性, 能适用于更广泛的应用领域。

4.5 改进

而遗传算法的出现使神经网络的训练有了一个崭新的面貌, 目标函数既不要求连续, 也不要求可微, 仅要求该问题可计算, 而且它的搜索始终遍及整个解空间, 容易得到全局最优解, 因此特别适合神经网络权值的训练^[47]。许多学者将遗传算法与神经网络结合在一起, 利用遗传算法优化权值参数^[48,49]。

用遗传算法优化神经网络权值的过程如下:

(1) 随机产生一组分布, 采用某编码方案对该组中的每个权值和阈值进行编码, 构造个体码串, 每个码串代表神经网络的一个权值分布, 在网络结构和学习规则已定的前提下, 该码串就对应一个权值和阈值取特定值的神经网络;

(2) 用训练样本集对所产生的神经网络进行前向计算, 将得出的实际输出与期望输出作比较, 求取样本均方误差, 确定其适应度。误差越大, 说明网络的样本逼近精度越差, 相应地适应度就越小;

(3) 选择若干适应度函数值最大的个体, 直接遗传给下一代;

(4) 利用交叉和变异等遗传操作算子对当前一代群体进行处理, 产生下一代群体;

(5) 重复 (2) ~ (4), 使初始权值和阈值的分布得到不断的进化, 直到训练目标得到满足为止。

4.6 拐点的定义

股票市场中对拐点并没有固定的定义，就像有一千个人心中有一千个哈姆雷特一样，每个人心中对于拐点的理解各有不同。但是一千个哈姆雷特都有一个共同的特点，那就是哈姆雷特是一位丹麦王子，不同的仅仅是对其观点的认识的不同。同样，不同的投资者对于拐点的定义虽然也是各不相同，但它们也有一个共同的特点，那就是拐点就是某只股票在未来一定时间内价格趋势做出改变的时间点。而本文所要定义的股票走势的拐点也必须满足这个条件。

对拐点最直观的定义就是找出规定时间内的收盘价的最高值所在的时间点。过去的股票进行决策系统就是基于这个定义的。但是我们还可以看到，股票的价格是由多种因素决定的，其预测的难度和准确性可想而知。所以本文对股票的拐点的定义不是根据价格的最值来定义而是重新进行定义。在股票技术指标中有一个比较有名的指标——移动平均线。通过对走势图的观察，我们可以看到移动平均线的变化有一种累积性。也就是说只有股票走势累计到一定程度以后，移动平均线才能体现出来。这种累积性不但是对确定拐点有益，而且也是避免假拐点的决方法。根据葛兰碧（GRANVILLE J）移动平均线运用八大法则我们知道，价格突破移动平均线的时候，就是采取买卖操作的时候。若价格是向上突破移动平均线则是买入信号；若价格是向下穿透移动平均线则是卖出信号。若 S_2 为第二天的收盘价， MA_2 为第二天的 5 日均线，那么如果 O 满足如下公式，本文就将其定义为第二天的动力指数。

$$O = S_2 - MA_2 \quad 4-4$$

并且定义 $O > 0$ 代表着可以股票价格正处于上升时期。可以进行交易。此数值越大，表示上升动力越大。若 $O < 0$ 说明股票正处于下降期，数值越大表示下降幅度越大。同样我们也可以通过 O 来找出买卖的时机，当 O 由正转变为负的时候就是卖出的好机会；当 O 又负转变为正时，则是卖出的好时机。

这种定义避免了过去寻找拐点的时候多次进行价格预测的情况，而只是通过一个技术指标的预测和一次价格预测就能获得拐点，大大提高了准确率。

表 4-1 是某一段时间的收盘价和买卖指数的表中我们可以看到，2006 年 8 月

18日是买卖指数由负变正的第一天按照定义知道下一个交易日也就是8月19日应该是一个买入股票的日子,可以看到8月21日的收盘价是11.29元。然后持股等候,等到8月30日是买卖指数由正变负的第一天,按照定义我们又可以知道下一个交易日是卖出股票的日子,我们可以看到8月31日股票价格的收盘价为12.83元。如此循环。

表 4-1 某一股票一段时间的收盘价格与动力指数表格

| 时间 | 收盘价 | 动力指数 | 下一交易日操作建议 |
|----------|-------|----------|-----------|
| 20060817 | 11.35 | -0.064 | |
| 20060818 | 11.45 | 0.27 | 买入 |
| 20060821 | 11.29 | 0.099999 | |
| 20060822 | 11.73 | 0.021999 | |
| 20060823 | 11.58 | 0.035999 | |
| 20060824 | 11.54 | 0.394001 | |
| 20060825 | 11.58 | 0.624001 | |
| 20060828 | 12.1 | 0.532 | |
| 20060829 | 12.48 | 0.514 | |
| 20060830 | 12.59 | -0.152 | 卖出 |
| 20060831 | 12.83 | -0.146 | |
| 20060901 | 12.31 | -0.3 | |
| 20060904 | 12.37 | -0.028 | |
| 20060905 | 12.15 | -0.122 | |
| 20060906 | 12.38 | -0.386 | |
| 20060907 | 12.15 | -0.46 | |
| 20060908 | 11.78 | -0.258 | |
| 20060911 | 11.54 | -0.254 | |
| 20060912 | 11.64 | -0.188 | |
| 20060913 | 11.46 | 0.158 | |

我们可以发现一下几点:

1. 买卖指数由负变正的状况与由正变负的状况是成对出现的,在形式上正好可以股票的购入与卖出做对应;

2. 给出买入建议的收盘价一半是一个上升时期的相对低点, 给出卖出建议是
的收盘价一般是股票价格的相对高点;

3. 动力指数指的是股票上升或者下降的动力, 这个数值的绝对值越大, 则其
第二天的价格变化越大。

这只是某一段时间的对比, 我们再将时间段拉长一些。运用的数据是中集集
团 (000039) 数据来自大智慧软件。在 2005 年 2 月 28 日到 2009 年 9 月 30 日
期间,

经过统计, 此阶段共给出 133 次买入建议, 其中相对低点 129 次, 约占 97%。
绝对低点 102 次, 约占 76.6917%。另外公给出 133 次卖出建议, 其中相对高点
126 次, 约占 94.7368%。绝对高点 99 次, 约占 74.4361%。

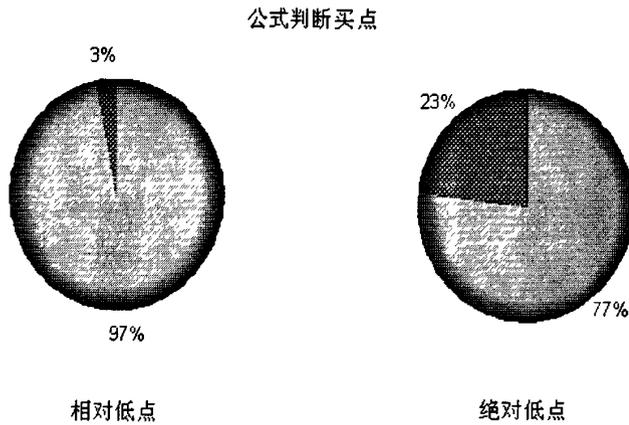


图 4-2 公式买点相对低点与绝对低点各自占有之比例

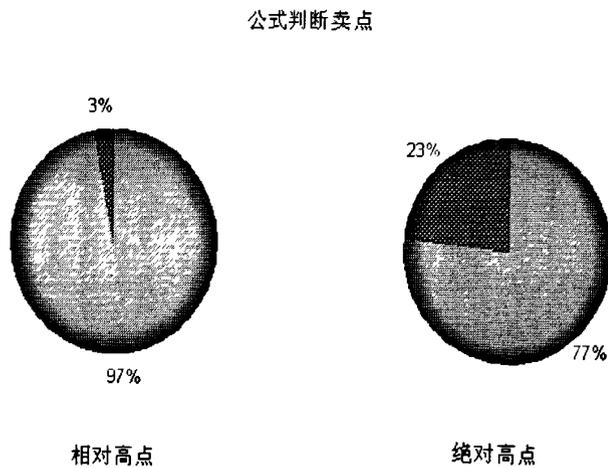


图 4-3 公式判断卖点相对高点与绝对高点各自占有之比例

通过分析观察数据可以得出用此方法能够比较有效的表现出股票拐点的时间。对于股票投资者们来说是非常有效的一系列数据。

继续观察此系列数据，我们可以看出相对高点的出现率之所以不等于或者接近于 100%，那是因为股票的价值变动所决定的。我们知道，商品的价格是由其价值决定的。价格虽然是变化的，但总体来说它的变化是围绕其价值进行波动性变动的。影响价格走势的因素有很多，如供求关系等。但是价值是决定其价格走势的根本原因和根本因素。而股票虽然是一种有价证券，但它也是商品的一种。它同样也满足价值规律。而技术分析是对股票这种商品价格的一种分析和对其走势的一种预测，并不能够对价值的一种分析。所以，当股票的价值发生改变的时候，技术分析就有点力不从心了。而给出错误建议的那几次恰恰是股票价值发生变化的时候。这其中有公司进行对股东进行分红，公司对股民开始提供配股，公司增发股票等等，这些行为都会影响股票的价值，从而进一步影响股票的股价。所以这个是不可避免的。万幸此种影响股票价值的行为并不常见，所以是可以忽略的。

那么接下来就是研究如何提高绝对极值点的占有比例。

通过观察我们知道如果公式推导出来的买卖点与绝对极值点并不是一个点的情况下，绝对极值点其实是存在于买卖点的周围两三天时间段内。也就是说，如果买卖点在周围两三天的时间段内是最高点的话，那么它其实就是此阶段的绝对机制点。

所以，本文采用双神经网络同时对股票进行预测，又定义了一个判断是否为真拐点的表达式。

$$B = \frac{\text{Max}(S_T, S_{T+1}, S_{T+2}, S_{T+3}) - S_T}{\text{Max}(S_T, S_{T+1}, S_{T+2}, S_{T+3}) - \text{Min}(S_T, S_{T+1}, S_{T+2}, S_{T+3})} \quad 4-5$$

其中 $\text{Max}(Y_T, Y_{T+1}, Y_{T+2}, Y_{T+3})$ 是从第 T 天到第 T+3 天期间出现的最高的股价。

$\text{Min}(Y_T, Y_{T+1}, Y_{T+2}, Y_{T+3})$ 是从第 T 天到第 T+3 天期间出现的最低的股价。 S_T 是第 T 天的收盘价。 B 的取值范围为 [0,1]。它代表的意思是，当 B 的取值接近于 1 时，说明未来几天的股票价格可能会比现在高，现在的股价处于比较低的位置，股票呈上升趋势；若 B 的取值靠近 0，说明未来几天的股票价格可能比现在要低，现在的股价

正处于比较高的位置，股票呈下降的趋势。而在预测的时候 B 的值等于1或者0的情况一般不会出现，所以我们一般规定若 B 大于某一定值 a 时，我们就认定其值为1，若 B 小于某一定值，我们就认定其值为0；

下面将上面两个公式结合一下。即当公式4-5给出正值时若 B 其值为1我们就

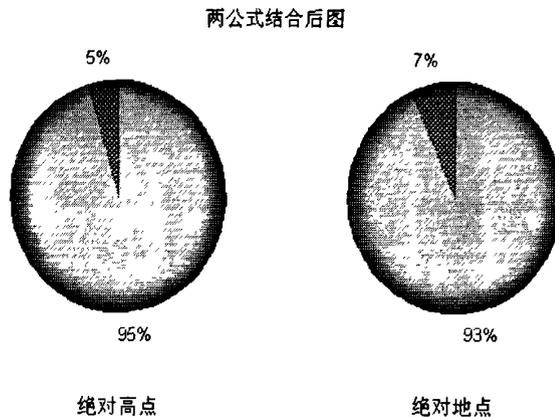


图 4-4 两公式结合后判断绝对极值占有率示意图

通过股票趋势的变化，就可以找出投资进仓或者获利出仓的拐点所在。

当预测模型同时由下跌转向上升或者由上升转向下跌时，并判断模型此时也有相同判断，则意味着此时刻是买入或者的最佳时机，此时间点为真拐点；

反之意味着此时间点是假拐点。

4.7 泛化

反响传播模型在训练的时候，一般是尽可能多的装在训练样本，然后通过对训练样本使用 BP 算法调整多层潜亏神经网络模型的权值。并且希望通过这种方式设计出来的神经网络能够得到泛化（推广）。所谓泛化，其实就是通过对已知的条件和结果，通过训练归纳出一个定论（训练后的权值）。然后根据得出的定论，对其他条件进行推理论证，得出的结果与理论结果的近似程度。如果近似程度高，我们说网络泛化是很好的。这里假定测试数据是从用于生成训练数据的相同数据集中抽取出来的。

学习过程(即神经网络的训练)可以被看作是一个曲线拟合的问题。网络本身可以被简单地认为是一个非线性输入-输出映射。这个观点让我们把神经网络的泛

化看作关于输入数据非线性插值的结果。这种网络能够完成有意义的插值过程主要是因为具有连续激活函数的多层前馈神经网络导致输出函数也是连续的。

一个神经网络设计得具有很好的泛化能力，即使在输入与训练网络的样本稍有不同的情况下也能够产生一个正确的输入-输出映射。然而，当一个神经网络对太多的样本进行学习的时候，它可能会完成对训练数据的记忆。这种情况可能会出现在找到一个存在于训练数据中但对于将要建模的固有函数却为假的特征(例如，由于噪声)的时候。这种现象称为过拟合或者过训练。当网络被过训练的时候，就失去了在相近输入-输出模式之间进行泛化的能力。

通常，用这种方法把数据装载到多层前馈神经网络要求使用比实际需要更多的隐含层神经元，结果导致在网络的权值中存储了输入空间中由于噪声引起的非期望因素。记忆本质上是一个查询表，这意味着由神经网络计算的输入-输出映射是非光滑的。输入-输出映射的光滑性在没有相反的先验知识的情况下它的核心本质是选择最简单函数。这里，最简单函数是指在给定的误差标准下逼近一个给定映射的函数中最光滑的函数，因为这个选择总体上要求最少的计算资源。依赖于研究现象的规模范围，光滑性在许多应用上同样是自然的。因而为不适定的输入-输出关系寻找一个光滑的非线性映射是重要的，使得网络能够根据训练模式将新模式正确分类。

下面的三个因素将对神经网络的泛化能力产生影响：(1)训练集的大小，以及它如何表示感兴趣的环境；(2)神经网络的体系结构；(3)当前问题的物理复杂度。无疑地，对后者进行控制。在另外的两个因素中，可以从两个不同的方面考察泛化问题：

(1) 网络的体系结构是固定的(可期望与固有物理复杂度一致)，需要解决的问题是决定一个产生好的泛化必须的训练集的大小。

(2) 训练集的大小是固定的，感兴趣的问题是决定最好的网络体系结构使其具有好的泛化。

基于第一种观点，VC 维数为适度的训练样本大小或样本复杂度问题的原则性解决方法提供了理论基础。在实践中，看来一个好的泛化事实上我们所需要的全部是训练集的大小 N 满足条件：

$$N = O\left(\frac{W}{\epsilon}\right) \quad 4-6$$

在这里 W 是指网络中自由参数(即权值和阈值)的总数, ε 表示测试数据中容许分类误差的部分(正如在模式分类中一样)。

在实际应用中遇到最多的是第二种观点, 这样提高泛化能力的问题转化为结构的优化问题。我们知道: 神经网络的输入-输出关系定义了一个从 m_0 维欧几里德输入空间到 M 维欧几里德输出空间的映射, 当激活函数是无限连续可微的时候, 这个映射也是无限连续可微的。在用这种输入-输出映射观点来评价多层前馈神经网络泛化能力的过程中, 提出了下面这样一个基本的问题:

一个多层前馈神经网络的输入-输出映射能够提供任何一个连续映射的近似实现, 它的隐含层层数的最小数目是多少?

这个问题可以用一个非线性输入-输出映射的通用逼近定理来具体表达, 该定理陈述如下:

定理 3.1: 令 $f(\cdot)$ 为有界、非常量的单调增连续函数, I_p 代表 p 维单位超立方体 $[0,1]^p$ 。 $C(I_p)$ 表示定义在 I_p 上的连续函数构成的集合, 则给定任何函数 $\varphi \in C(I_p)$ 和 $\varepsilon > 0$, 就存在这样的—个整数 M 和—组实数 a_i 、 θ_i 和 w_{ij} , 式中, $i=1, 2, \dots, M$, $j=1, 2, \dots, p$, 使我们可以定义:

$$F(x_1, \dots, x_p) = \sum_{i=1}^M a_i f\left(\sum_{j=1}^p w_{ij} x_j - \theta_i\right) \quad 4-7$$

作为 $\varphi(\cdot)$ 函数的—个近似实现, 即:

$$\left| F(x_1, x_2, \dots, x_p) - \varphi(x_1, x_2, \dots, x_p) \right| < \varepsilon, \quad \forall (x_1, x_2, \dots, x_p) \in I \quad 4-8$$

通用逼近定理可直接用于多层前馈神经网络。我们首先注意到在一个作为多层前馈神经网络的神经元模型中作为非线性部分的 logistic 函数 $1/[1 + \exp(-v)]$ 是—个真正有界、非常量的单调增连续函数, 满足函数 $f(\cdot)$ 的上述条件, 因此, 对任意给定的函数 $\varphi(\cdot)$ 和误差精度 $\varepsilon > 0$, 总存在—个三层前馈神经网络, 其隐含层神经元作用函数为 logistic 函数, 输出层为线性函数, 使得网络的输入—输出关系 $y = F(x_1, x_2, \dots, x_p)$ 总能以给定的精度逼近给定的函数 $\varphi(x_1, x_2, \dots, x_p)$ 。这说明只含有—个隐含层的前馈神经网络是—个通用的函数逼近器, 有—个隐含层已足够。

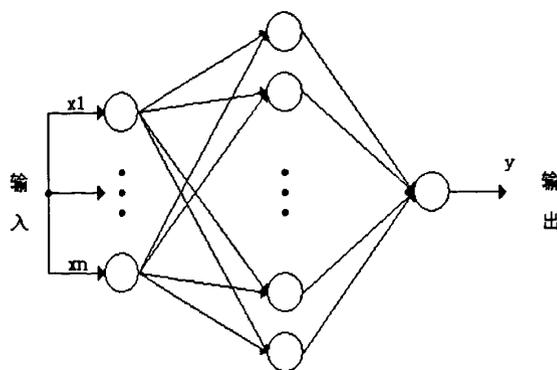


图 4-5 三层前馈神经网络结构

目前对神经网络的设计一般是先确定神经网络的结构，再根据网络结构对权值进行训练，但是没有权值信息的结构进化很难准确计算基因个体的适应度，从而使进化效率非常低，进化结果不准确，这是由神经网络权值初始化的随机性所决定的：不同的初始权值将导致不同的训练结果，因此，相同的基因描述由于初始权值的不同可能有不同的适应度。而采用同时进化网络结构及权值的方法则避免了在计算结构进化的个体适应度时引入噪声。因此，本文在神经网络的优化设计过程中，采用网络结构及权值同时进化的策略。

由通用逼近定理可知：三层前馈神经网络是一个通用逼近器，能以任何精度逼近任何非线性函数。因此，本文以三层前馈神经网络作为优化设计对象，同时优化神经网络结构及权值。由于前馈神经网络的输入输出层节点的个数由目标函数的结构确定，而各层之间采用全连接方式，层内没有连接，因此只要确定了隐含层节点个数，就得到了三层前馈神经网络的结构。

一个三层 BP 神经网络可以逼近任何连续函数，所以本文选择三层 BP 神经网络 ($n-r-m$) 作为主要网络结构，其中 n 是神经网络输入层的节点个数， r 为中间层的节点个数， m 为输出层的节点个数。

而 r 的取值却是一个十分复杂的问题。它不仅和输入层和输出层的个数有关，还与需要处理的具体问题也有很大的关系。而 Eberhart 更是在他的书中对寻找中间层的节点个数的行为评价为“这是一种艺术”^[77]。中间层节点的个数的确定不仅难而且重要，因为这个数字直接关系到模型的性能和效率，理论上个数越多，模型的强壮度越高，换句话说模型的性能越高。但相对应的学习时间过长即效率过低，得到的结果页不一定是最佳结果。反过来，如果个数越少，学习效率上去了，但是有可能出现不能识别从前没有看到过的样本，容错性太差也就是强壮度

不够。

虽然并没有公式能够直接获得 r 取值, 但一些先行者们已经给了我们总结了
许多范围公式。通过这些公式, 我们可以找出 r 的取值范围。

$$(1) \quad k < \sum_{i=0}^n C \binom{n_i}{i} \quad 4-9$$

式中 k 为样本数, n_i 为中间层结点个数, n 为输入层结点个数。

$$(2) \quad n_i = \sqrt{n+m} + \alpha \quad 4-10$$

其中 n 为输入层结点个数, m 为输出层结点个数, n_i 为中间层结点个数 α 为
1~10 之间的常数。

$$(3) \quad n_i = \log 2n \quad 4-11$$

n 为输入层结点个数。

本文运用的方法是根据 Homik 提出下列公式来确定中间层结点个数的范围,
然后再根据试验的数据来最终确定中间层结点的个数

$$n_i = [\sqrt{2n+m}, 2n+m] \quad 4-12$$

其中 n, m 分别表示为输入层和输出层的结点个数。

4.8 股票的选择

股票的选择也是一个非常重要的前提。因为如果选择了的股票在某个期间受到外部影响剧烈。那么, 它的技术数据会产生一种特殊数据, 网络学习的时候将其当作一般现象来学习。其结果不言而喻, 并不是想我们所希望的方向发展。例如, 当 GOOGLE 公司平时的股票走势是非常平稳的。但是当其宣布将退出中国内陆市场以后, GOOGLE 的股票价格一路震荡走弱, 而 GOOGEL 在中国内陆最大的竞争对手百度公司的股价在一路上升。这个时期的两公司由于其股票价值发生变化影响了股票的价格。所以在技术分析数据在起初是以一种不合理的方式出现。而后来经过了市场的运作, 价值逐渐稳定, 它们的技术数据区域合理化。这样的数据才能反映出

所以本文选择的时机是股票是价值相对稳定, 也就是非指标因素比较少的。
具体条件如下

- 1、 公司近期并没有大型动作，如收购、被收购、重大决策等；
- 2、 公司近期并没有分红，配股等行为；
- 3、 未有对公司有相对较大影响的政策出台；
- 4、 有一个相对稳定的证券市场环境；
- 5、 公司运行相对稳定。

本文的研究对象是股市中的个别股票(个股)，本文将选取国内有一定知名度的上市股票的数据。对于个股的研究如果能够取得一定的成果，将会对投资起到非常大的指导性作用^[3]，但是个股自身的特点也给研究带来了很大的困难，通过本文的研究，希望能够得到一套解决方案，使该方案能够适用于一些典型的个股股票，也为将来的进一步研究打下一定的基础。

4.9 股票数据的预处理及分析

模型训练和学习都是通过数据来进行的，所以用来训练的数据的好与坏直接决定了模型学习的结果。

4.9.1 输入变量的处理

包含股票市场行为信息有很多很多，为了找出影响股票走势的规律而研究全部股票市场的信息显然是不可取的。我们需要做的是找出部分的、重点的、相关性打的行为并将其记录然后进行研究即可。万幸，在此之前许多的研究工作者提出了相当多的技术参数。其中不乏有许多反应走势的指标，如MACD等。本文既是需要找出重点能够包含趋势的参数即可。技术指标即可满足这些要求，因此可以选择技术指标作为输入变量。

经过本人长时期进行炒股实验，总结经验，发现了7个与股票走势非常密切的技术指标第一个神经元为10日平均成交量VOL10，第二个神经元为MACD，第三个神经元为威廉指标(William's)，第四个神经元为J线，第五个神经元为顺势指标CCI，第六个神经元为MA5，第七个神经元为BIAS乖离率。

4.9.2 规范化处理

模型选用的输入数据均为某一些时间段内沪深股市的历史数据在过去不同时间段的历史数据。这些原始数据值的大小往往相差很大，如收盘价和成交金额这两个数据甚至不在同一个数量级上。这样的情况就会造成此节点的对应权值变得

过大，致使隐含层某节点的输出比其他分量大。最后的结果是这些节点丧失了调控的作用。所以，在进行神经网络预测之前，有必要对原始数据进行相应归一化处理，以避免数值间差距过大造成网络麻痹，所谓归一化处理就是将不同尺度、不同量纲的样本矢量的各个分量化到相同区间与量纲，本文采用下式对样本数据进行预处理：

$$x' = \frac{(x - x_{\min})}{(x_{\max} - x_{\min})} \quad 4-13$$

其中 x_{\max} 和 x_{\min} 分别为最大值和最小值， x 为某一原始样本数据， x' 为变换后的数据。

4.10 BP 模型的建立

遗传神经网络用于股市预测的一般流程

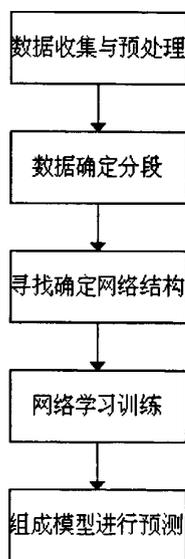


图 4-5 遗传神经网络用于股市预测的一般流程

- (1) 对样本数据进行收集，预处理；
- (2) 对样本集合进行分段，一般可分为训练样本和检验样本；
- (3) 确定网络结构和预测步数，即确定输入层节点数(n)、输出层节点数(m)，隐含层数以及每个隐含层的节点数；
- (4) 运用遗传神经网络训练网络，使该网络尽量拟合时间序列训练数据。
- (5) 用检验数据检验训练好的网络。如果效果很好，便可以利用训练好的网络对未来股市进行趋势预测^[29-34]。

股市趋势预测分为训练和预测两个基本步骤。

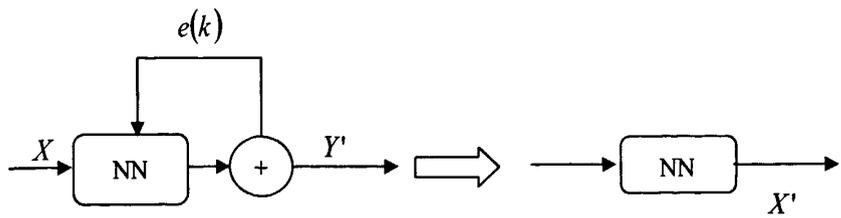


图 4-6 神经网络训练步骤

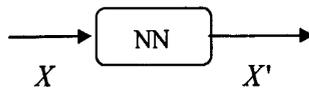


图 4-7 神经网络预测步骤

模型的建立

现将两个模型的输出做一个分段：

1.趋势预测模型

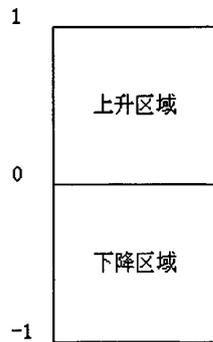


图4-8 趋势预测模型

我们定义如下操作：

投资者持有指数股票

(1) $O > 0$ ，此时处于上升通道，说明股市行情会继续上升，上升动力比较充足，是持股信号；

(2) O 由负变正，此时处于交易活跃期，若手中没有此种股票，建议此时出手购入；

(3) O 由正变负，说明股票此时正处于交易期活跃，若投资者手中有此种

股票，建议此时卖出；

(4) $O < 0$ ，此时处于下降通道，说明行情会继续下探，很难有反弹趋势，是持币的信号，投资者不要买入此股票。

2.判断模型

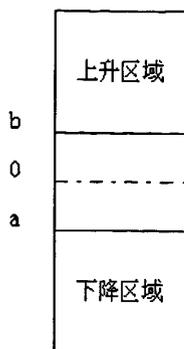


图4-9 判断模型

(1) $B > b$ ，说明此时股价有上升的趋势，建议持有此种股票，等待其有更高的升值。

(2) $B < a$ ，说明此事股价有下降的趋势，建议将此种股票出仓，获得收益。

a 和 b 的具体数值可根据投资的不同倾向来确定。

可以用以下决策

(1) O 由负变正， $B > b$ ，购入；

(2) O 由正变负， $B < a$ ，卖出；

4.11 基于遗传神经网络的双网络股票决策支持模型

本文设计的决策支持模型是以遗传神经网络为基础，辅助以决策树的模块设计模型如图 4-5 所示

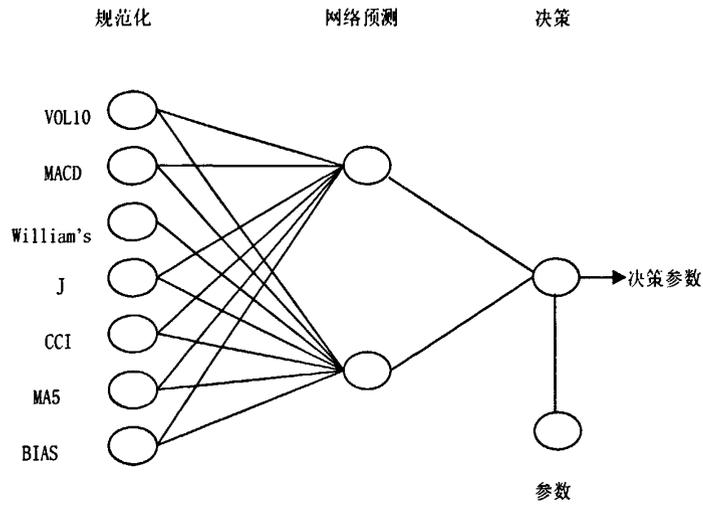


图 4-10 遗传神经网络预测模型图

第一个神经元为 10 日平均成交量 VOL10，第二个神经元为 MACD，第三个神经元为威廉指标(William's)，第四个神经元为 J 线，第五个神经元为顺势指标 CCI，第六个神经元为 MA5，第七个神经元为 BIAS 乖离率。

本章小结

根据道氏理论的三大假设我们知道，股票的历史是可以重现的，这就是股票预测有了可能行。解释了股票预测的在数学方面的形式和神经网络对非线性函数拟合功能的可行性的证明，这就是股票预测在技术上有了支持。接下来，通过 BP 算法对非线性函数的拟合拓扑结构的确定，确定了 BP 网络模型的层数和结构。接着通过遗传算法规避 BP 算法的缺点。然后通过数量统计和技术指标的概念，定义了动力指数，和判断标准。对能否根据以上条件建立起预测决策模型进行了可行性分析。接下来通过实践确定出输入参数，确定神经网络预测模型结构。

第5章 基于遗传神经网络的股票决策

5.1 引言

MATLAB 是美国 MathWorks 公司生产的一个为科学和工程计算专门设计的交互式大型软件, 是一个可以完成各种精确计算和数据处理的、可视化的、强大的计算工具。它集图示和精确计算于一身, 在应用数学、物理、化工、机电工程、医药、金融和其他需要进行复杂数值计算的领域得到了广泛应用。它不仅是一个在各类工程设计中便于使用的计算工具, 而且也是一个在数学、数值分析和工程计算等课程教学中的优秀的教学工具, 在世界各地的高等院校中十分流行, 在各类工业应用中更有不俗的表现。MATLAB 可以在几乎所有的 PC 机和大型计算机上运行, 适用于 Windows、UNIX 等多种系统平台。

MATLAB 原名叫做矩阵实验室 (Matrix Laboratory), 是作为 LINPACK 和 EISPACK 矩阵软件包接口的, 后来逐步成为一个通用科技计算、图视交互系统和语言程序。它在解算问题要比 C 和 FORTRAN 等语言简捷得多

5.1.1 MATLAB 的发展概述

MATLAB 是由美国 New Mexico 大学的 Cleve Moler 博士在讲授线性代数时开发的。Cleve Moler 博士在数值分析领域颇有影响。1980 年前后, 他在讲授线性代数课程时, 发现用其它高级语言编程极为不便, 于是他用 Fortran 语言构思编写了软件包 Linpack 与 Eispack, 旨在使应用人员免去大量经常重复的矩阵运算和基本数学运算等繁琐的编程工作。1984 年, Cleve Moler 博士等一批数学家和软件专家组建了 MathWorks 公司, 并开发出了第二代 MATLAB 语言, 其内核改用速度更快的 C 语言编写, 而且增加了绘图功能, 使数值计算结果可以直接在 MATLAB 环境下用曲线和曲面等可视形式表示出来。从此, 该软件工具被正式推向市场。

1990 年, MathWorks 公司推出了以框图为基础的控制系统仿真工具 SIMULINK, 这一被镶嵌在 MATLAB 语言中的仿真工具, 使得控制工程师可以直接在计算机屏幕上用鼠标构造系统框图进行仿真, 并提供了控制系统中常用的各种环节的模块库, 这就大大方便了系统的研究和开发。

1993年推出的MATLAB4.0版在原来3.x版的基础上又作了较大改进,并推出了Windows版,命令执行和图形绘制可以在不同窗口进行。1994年推出了较为成熟的4.2版,并得到了广泛的重视和应用。1999年1月推出的MATLAB5.3(RELEASE11)真正实现了32bit运算,速度更快,功能更完善,界面也更友好,并且提供了Internet搜索引擎,可协助用户寻求在线帮助。最新版本6.5(RELEASE13)又做了更精细地改进,目前已经被广泛推向市场。MATLAB语言已经成为科学计算、系统仿真、信号与图像处理的主流软件。

5.1.2 MATLAB的主要功能

MATLAB的核心是一个基于矩阵运算的快速解释程序。它以交互式接收用户输入的各项指令,输出计算结果。它提供了一个开放式的集成环境,用户可以运行系统提供的大量命令,包括数值运算、图形绘制等。具体来说MATLAB具有如下功能:

(1) 数据可视化功能。

图形处理功能MATLAB自产生之日起就具有方便的数据可视化功能,以将向量和矩阵用图形表现出来,并且可以对图形进行标注和打印。高层次的作图包括二维和三维的可视化、图象处理、动画和表达式作图。可用于科学计算和工程绘图。新版本的MATLAB对整个图形处理功能作了很大的改进和完善,使它不仅在一般数据可视化软件都具有的功能(例如二维曲线和三维曲面的绘制和处理等)方面更加完善,而且对于一些其他软件所没有的功能(例如图形的光照处理、色度处理以及四维数据的表现等),MATLAB同样表现了出色的处理能力。同时对一些特殊的可视化要求,例如图形对话等,MATLAB也有相应的功能函数,保证了用户不同层次的要求。另外新版本的MATLAB还着重在图形用户界面(GUI)的制作上作了很大的改善,对这方面有特殊要求的用户也可以得到满足。

(2) 强大的数值运算功能。

MATLAB包含了各种数学、统计及工程函数,支持所有常见的工程和科学运算。这些由数学方面的专家开发的函数是MATLAB语言的基础。这些核心的数学函数使用LAPACK和BLAS线性代数子例程库和FFTW离散傅立叶变换库。由于这些与处理器相关的库已针对MATLAB支持的各种平台进行了优化,因此其执行速度比等效的C或C++代码的执行速度要快。

(3) 丰富的工具箱。

MATLAB 对许多专门的领域都开发了功能强大的模块集和工具箱。一般来说,它们都是由特定领域的专家开发的,用户可以直接使用工具箱学习、应用和评估不同的方法而不需要自己编写代码。目前, MATLAB 已经把工具箱延伸到了科学研究和工程应用的诸多领域,诸如数据采集、数据库接口、概率统计、样条拟合、优化算法、偏微分方程求解、神经网络、小波分析、信号处理、图像处理、系统辨识、控制系统设计、LMI 控制、鲁棒控制、模型预测、模糊逻辑、金融分析、地图工具、非线性控制设计、实时快速原型及半物理仿真、嵌入式系统开发、定点仿真、DSP 与通讯、电力系统仿真、数学计算、数字信号处理、自动控制模拟、动态分析等,都在工具箱 (Toolbox) 家族中有了自己的一席之地。

(4) 数据处理。

MATLAB 是一个包含大量计算算法的集合。其拥有 600 多个工程中要用到的数学运算函数,可以方便的实现用户所需的各种计算功能。函数中所使用的算法都是科研和工程计算中的最新研究成果,而前经过了各种优化和容错处理。在通常情况下,可以用它来代替底层编程语言,如 C 和 C++。在计算要求相同的情况下,使用 MATLAB 的编程工作量会大大减少。MATLAB 的这些函数集包括从最简单最基本的函数到诸如矩阵,特征向量、快速傅立叶变换的复杂函数。函数所能解决的问题其大致包括矩阵运算和线性方程组的求解、微分方程及偏微分方程的组的求解、符号运算、傅立叶变换和数据的统计分析、工程中的优化问题、稀疏矩阵运算、复数的各种运算、三角函数和其他初等数学运算、多维数组操作以及建模动态仿真等。

(5) 绘图

2D-3D 的绘图更能具有高层绘图功能,二维、三维绘图具有底层绘图功能,句柄绘图使用 plot 函数可随时将计算结果可视化

除此之外 MATLAB 还拥有与 FORTRAN, C, C++做数据连接等等功能。

5.1.3 MATLAB 的技术特点

(1)界面友好且编程效率高 MATLAB 是一种以矩阵为基本变量单元的可视化程序设计语言,语法结构简单,数据类型单一,指令表达方式非常接近于常用的数学公式。即使那些不太熟悉计算机编程的用户,只要有一点 Windows 操作的

经验,就能在短时间内快速掌握 MATLAB 的主要内容和基本操作,甚至能解决大量复杂的手工难以完成的工作。

MATLAB 不仅能使用户免去大量经常重复的基本数学运算,收到事半功倍之效,而且其编译和执行速度都远远超过了采用 C 和 Fortran 语言设计的程序。可以说, MATLAB 在科学计算与工程应用方面的编程效率远远高于其他高级语言。

(2)功能强大且可扩展性强 MATLAB 语言不但为用户提供了数据分析与可视化、科学计算、系统仿真等强大的功能,而且还具有独树一帜的可扩展性特征。

MATLAB 还拥有—个庞大的、被称之为应用工具箱的特殊应用子程序库。它为某类特殊问题和应用定制了 MATLAB 运行环境。针对不同的应用领域, MathWorks 公司推出了自动控制、信号处理、图像处理、通信、模糊逻辑、神经网络、小波分析、最优化、数理统计、偏微分方程、财政金融等 30 多个具有专门功能的 MATLAB 工具箱。各种工具箱中的函数可以链装,也可以由用户进行更改。

MATLAB 支持用户自由地进行二次开发,用户的应用程序既可以作为新的函数添加到相应的工具箱中,也可以扩充为新的工具箱。近年来,国外许多不同应用领域的专家使用 MATLAB 开发出了相当多的应用程序。

(3)图形功能灵活方便 MATLAB 具有灵活的二维和三维绘图功能,在程序的运行过程中,可以方便迅速地用图形、图像、声音、动画等多媒体技术直接表述数值计算结果,可以选择不同的坐标系,可以设置颜色、线型、视角等,可以在图中加比例尺、标题等标记,可以在程序运行结束后改变图形标记、控制图形句柄等,并且还可以将图形嵌入到用户的 Word 文件中。

5.1.4 MATLAB 神经网络工具箱

MATLAB 拥有很多的工具箱,神经网络工具箱就是其中的一个。它的理论基础是神经网络技术,然后经过 MATLAB 语言构造出多种神经网络激活函数(如 S 型、线性、竞争层、饱和线性等),使设计者不必每使用一次神经网络就需要设计一次。使用网络时直接调用相应的工具箱即可。另外,根据各种典型的修正网络权值的规则,加上网络的训练过程,用 MATLAB 编写出各种网络设计与训练的子程序,网络的设计者可以根据需要去调用工具箱中有关神经网络的设计训练程序,使自己能够从繁琐的编程中解脱出来,集中精力去思考和解决问题,从而提

高效率和解题质量^[42]。

目前 MATLAB 最新版本几乎完整地概括了神经网络的基本成果, 所涉及到的网络模型有:

- (1) 感知器
- (2) 线性网络
- (3) BP 网络
- (4) 径向基函数网络
- (5) 自组织网络
- (6) 回归网络

对于各种网络模型, 神经网络工具箱集成了多种学习算法。为用户提供了极大的方便。此外, 神经网络工具箱中还给出了大量的示例程序, 为用户轻松地使用工具箱提供了生动实用的范例。

MATLAB 的其它工具箱(如模糊逻辑工具箱、样条工具箱等)也为人们在神经网络工具箱的基础上开发研究模糊与神经网络的结合、神经网络的样条算法等问题提供了辅助手段。

5.2 用 MATLAB 实现遗传算法

虽然, 遗传算法在不同应用场合具有并不完全相同的形式, 但遗传算法必须解决下述共性问题: 参数编码、种群初始化、个体适应度确定和遗传算子运算。

针对上述共性问题, 人们开发了遗传算法工具箱。在工具箱中把遗传算法模块化, 设计者可以不去考虑遗传算法的内部结构, 只需根据设计的要求编出适应度函数即可。因此遗传算法工具箱把原本复杂的遗传算法设计过程简单化, 给广大的设计者带来了极大的方便。实践证明, 遗传算法工具箱在数值优化方面的确取得了非常好的效果。

有人采用 C 语言编写遗传算法程序^[64]。如孙树栋^[65]等人编写的基于 C 语言的遗传算法工具箱, 既包括了遗传算法的基本算子, 又包含了最新改进算子, 可用于单种群、多种群遗传算法。

尽管 C 语言作为一种高效的编程语言有它的许多优点, 但对于编写遗传算法程序来说, 它的优越性却没有体现出来, 相比较而言, 用 MATLAB 语言实现遗传算法编程却具有简单、灵活、快捷、程序篇幅小等优点。由于遗传算法的诸多

算子(如选择、交叉、变异等)都是针对染色体位串进行的,而染色体实质上是一个向量,可将其看成一个 $1 \times n$ 的矩阵,因此这些算子实质上是一些矩阵运算,而 MATLAB 的基本数据单元就是一个维数不加限制的矩阵,在这种编程环境下,用户无需考虑大量的有关矩阵的运算该采用何种算法等低层问题,更不必深入了解相应算法的具体细节,因而对用户算法语言方面的要求十分宽松,用它编写遗传算法程序,比用 C 等其它高级语言要简单、灵活、快捷得多,程序篇幅也将缩小许多。

由于 MATLAB 的上述优点,使得在 MATLAB 环境下开发遗传算法工具箱得到广泛的认可。1996 年 Christopher R. Houck 在 MATLAB 环境下编写了遗传算法工具箱(GAOT)。其函数可以通过图形界面或 MATLAB 命令行来访问,并对用户开放,用户可以查看算法、修改源代码或生成用户函数。图形用户界面和命令行函数可用来快速地描述问题、设置算法选项以及监控进程;具有多个选项的遗传算法工具箱可用于问题创建、适应度计算、选择、交叉和变异操作等。

利用遗传算法工具箱提供的多个选项函数,可以针对不同的优化问题构造其适用的遗传算法。

由于遗传算法工具箱是一个开放的体系,而遗传算法也在被不断地改进,因此,很多用户在自己应用需要的基础上,对遗传算法工具箱进行修改。针对本文对遗传算法优化前馈神经网络算法的改进,本章用 MATLAB 语言实现其算法程序。

matlab 实现神经网络算法

GA 训练 BP 权值的主函数

```
function net=GABPNET(XX,YY)
```

```
%数据归一化预处理
```

```
nntwarn off
```

```
XX=premnmx(XX);
```

```
YY=premnmx(YY);
```

```
%创建网络
```

```
net=newff(minmax(XX),[7,25,1],{'tansig','tansig','purelin'},'trainlm');
```

```
%下面使用遗传算法对网络进行优化
```

```
P=XX;
```

```

T=YY;
R=size(P,1);
S2=size(T,1);
S1=25;%隐含层节点数
aa=ones(S,1)*[-1,1];
popu=50;%种群规模
initPpp=initializega(popu,aa,'gabpEval');%初始化种群
gen=100;%遗传代数
%下面调用 gaot 工具箱，其中目标函数定义为 gabpEval
[x,endPop,bPop,trace]=ga(aa,'gabpEval',[],initPpp,[1e-6 1 1],'maxGenTerm',gen,...
    'normGeomSelect',[0.09],['arithXover'],[2],'nonUnifMutation',[2 gen 3]);
function net=GABPNET(p,t)
global P
global T
global R
global S2
global S1
global S
P=premnmx(p);
T=premnmx(t);
R=size(P,1);
S2=size(T,1);
S1=25;%具体数值需通过实验确定
S=R*S1+S1*S2+S1+S2;%遗传算法编码长度
net=newff(minmax(p),[R,S1,S2],{'logsig','logsig','purelin'},'trainlm');
aa=ones(S,1)*[-1,1];
popu=50;%种群规模
initPpp=initializega(popu,aa,'gabpEval');%初始化种群
gen=100;%遗传代数
%调用GAOT工具箱，其中目标函数定义为gabpEval

```

```

[x,endPop,bPop,trace]=ga(aa,'gabpEval',[],initPpp,[1e-6 1 1],'maxGenTerm',gen,...
'normGeomSelect',[0.09],['arithXover'],[2],['nonUnifMutation',[2 gen 3]]);
    %下面将初步得到的权值矩阵赋给尚未开始训练的BP网络
[W1,B1,W2,B2,P,T,A1,A2,SE,val]=gadecod(x);
net.IW{1,1}=W1;
net.LW{2,1}=W2;
net.b{1}=B1;
net.b{2}=B2;
    XX=P;
    YY=T;
    %设置训练参数
net.trainParam.show=25;%两次显示之间的训练步数
net.trainParam.epochs=2000;%显示计算次数
net.trainParam.goal=1.0e-28;%目标误差
%//net.trainParam.max.fail=5;
net.trainParam.lr=0.3;%学习速率
%训练网络
net=train(net,XX,YY);

```

这是使用遗传算法对BP网络权值阈值进行优化，再用BP算法训练网络的主函数。其作用如下。首先定义了全局变量P（训练输入样本），T（训练期望样本），R（输入层结点数），S2（输出层结点数），S1（隐含层结点数），S（遗传算法编码长度）。然后输入规范化以后的输入样本，输出样本，通过这两个样本确定输入层和输出层的结点数，确定隐含层的结点数，隐含层结点数具体数值是通过实验来确定的。接下来构造BP网络，定义种群规模，运用initializega函数初始化种群，调用调用GAOT工具箱训练权值。再继续将初步得到的权值矩阵赋给尚未开始训练的BP网络，并设置训练参数。最后训练网络。其中目标函数定义为gabpEval为自定义函数。

程序二：适应值函数

```

function [sol, val] = gabpEval(sol,options)
% val - 个体的适应度

```

```

% sol -当前个体, n+1 个元素的行向量
% options - 是选择编码形式的参数
global P
global T
global R
global S2
global S1
global S
for i=1:S,
    x(i)=sol(i);
end;
[W1, B1, W2, B2, P, T, A1, A2, SE, val]=gadecod(x);
    程序三: 编解码函数
function [W1, B1, W2, B2, P, T, A1, A2, SE, val]=gadecod(x)
load data2
nntwarn off
global P
global T
global R
global S2
global S1
global S
% 前 R*S1 个编码为 W1
for i=1:S1,
    for k=1:R,
        W1(i,k)=x(R*(i-1)+k);
    end
end
% 接着的 S1*S2 个编码 (即第 R*S1 个后的编码) 为 W2
for i=1:S2,

```

```

for k=1:S1,
    W2(i,k)=x(S1*(i-1)+k+R*S1);
end
end
% 接着的 S1 个编码（即第 R*S1+S1*S2 个后的编码）为 B1
for i=1:S1,
    B1(i,1)=x((R*S1+S1*S2)+i);
end
% 接着的 S2 个编码（即第 R*S1+S1*S2+S1 个后的编码）为 B2
for i=1:S2,
    B2(i,1)=x((R*S1+S1*S2+S1)+i);
end
% 计算 S1 与 S2 层的输出
A1=tansig(W1*P,B1);
A2=purelin(W2*A1,B2);
% 计算误差平方和
SE=sumsq(T-A2);
val=1/SE; % 遗传算法的适应值

```

5.3 MATLAB 各参数的确定

(1) 确定数据样本

输入样本： $X = [X_1, X_2, \dots, X_m]$ ，输出样本： $Y = [Y_1, Y_2, \dots, Y_n]$ ；

(2) 建立网络

网络名=newff(PR,SN,TF,BTF,BLF,PF);

net=newff(minmax(p),[R,S1,S2],{'logsig','logsig','purelin'},'trainlm');

网络名=net;

输入取值范围：PR = minmax(p);

每层神经元数：SN =[R,S1,S2];

每层传递函数：TF={'logsig','logsig','purelin'}。MATLAB 提供了三种传递函

数,分别是:对数 S 形 (logsig)、正切 S 形 (tansig)、线性 (purelin) 三种。

网络训练函数: BTF='trainlm'。网络训练函数有很多种例如 trainlm,trainbfg,trainrp 和 traingd 等,在这里网络训练函数可以选择任意一个 BP 训练函数。需要指出的是 BTF 默认所采用的是训练速度很快的 trainlm 函数。但是在速度快的同时它有一个运行过程会消耗大量的内存空间的缺陷。如果计算机内存小的机器上训练的话,建议采用 trainbfg 或 trainrp。他们的共同特点是训练速度比较慢但是占用内存小,不会出现训练过程死机的情况。

网络权值阈值函数: BLF=默认值 "learnngdm"。

网络性能函数,网络输出和目标输出的均方误差: PF=默认值 mse。

(3) 参数设定

网络名=init(网络名);初始化网络权值和阈值(可不设定);

训练状态的显示幅度: 网络名.trainparam.show=25;(默认 25);

学习速率: 网络名.trainparam.lr=0.3;(权值阈值的调整幅度);

训练次数:网络名.trainparam.epochs=2000;(默认 100);

误差精度:网络名.trainparam.goal=1.0e-28;(默认 0);

网络名.trainparam.time=训练秒数;(可不选)。

(4) 训练网络

网络名=train(网络名,输入变量名,目标变量名),此过程反复调整权值和阈值,以减小性能函数的值,直到达到预先设定的误差精度。

(5) 模拟输出

在网络训练结束后,将观测值和拟合值做比较是检验网络预测能力的强弱。在此过程中,我们有多项参数需要比较。

目标精度,也可以称之为网络输出和目标输出的均方误差。当拟合值与目标直线相交时,就应该考虑将目标直线下移,即提高精度,再进行训练。反复调整该参数,使网络更接近实际值。

5.4 确定中间层个数

选取上交所股票中集集团(代码 000039)作为举例。样本选择的是从 2009 年 7 月 23 日到 9 月 30 日期间这 50 个交易日的 50 组数据,数据源取自大智慧证券软件,其中将前 40 组作为训练数据,后 10 组作为检验数据,即预测未来 10

日的收盘价。

表 5-1 隐层结点误差比较

| | | | | | | | |
|-------|--------|--------|--------|--------|--------|--------|--------|
| 隐层结点数 | 3 个 | 5 个 | 7 个 | 9 个 | 11 个 | 13 个 | 15 个 |
| 相对误差 | 0.2279 | 0.1127 | 0.3051 | 0.1431 | 0.1687 | 0.1952 | 0.4024 |

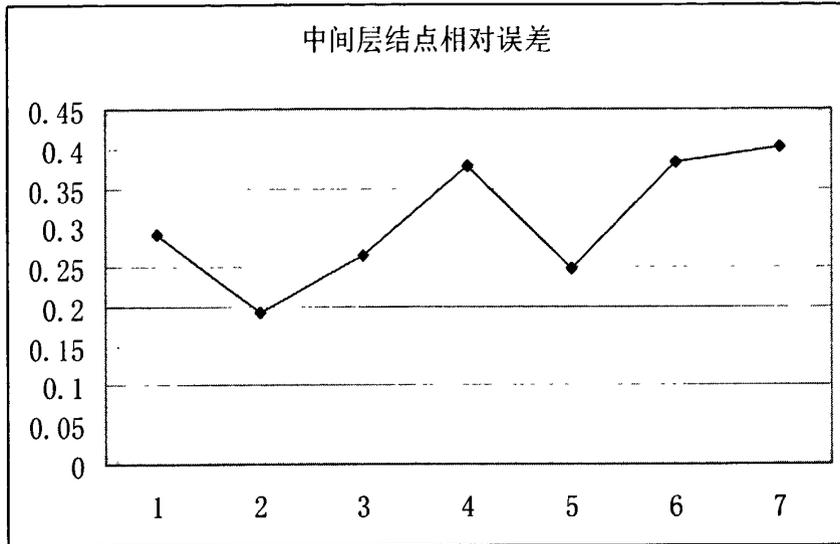


图 5-1 中间层结点相对误差图

由表 5-1 中数据和图 5-1 我们可以清楚的了解到，预测误差与网络的中间层的结点数之间并不是简单的线性关系可以表示出来的。有试验可以知道，当中间层为 5 的时候，模型预测结果的相对误差为 0.1127，是最小的。

所以根据试验数据，我们设置预测神经网络的那个罗的中间层结点数位 5。

本章小结

本章给出了系统模型的建立。系统设计实现部分，讲述了基于遗传 BP 算法建立了预测模型和判断模型的双网络股票预测系统。通过试验确定中中间层的节点个数，并且通过使用通过 MATLAB 的来实现对模型的建立。

第 6 章 基于遗传神经网络的股票决策支持模型仿真

通过上一节我们用 MATLAB 将遗传神经网络的模型建立了起来。本文提出了双神经网络对拐点的决策。相比股票价格决策，此种决策究竟是否有所提高呢。就此问题，本章节进行了股票模拟仿真实验，与股票价格预测模型进行对比。

6.1 通过 MATLAB 建立以价格为输出的 BP 模型。

上一章通过试验测试了基于遗传神经网络的股票模型，发现了预测的不稳定性。然后增加了一个判断模型，并通过试验确定可判断模型的可行性。最后给出了一个决策支持模型。本文就将此模型建立起来然后通过真实数据进行预测检验。对于如何检验此模型的准确性，本章用获利多少来与普通预测价格的神经网络模型做了对比。

6.2 模型训练预测

继续深圳交易所股票中集集团（000039）进行仿真预测。此次增加了输入训练样本和为了提高数据的预测精度和准确性，增大输入训练数据组数和检验数组数。样本选择的是从 2009 年 7 月 23 日到 12 月 18 日期间这 100 个交易日的 100 组数据，数据源取自大智慧证券软件，其中将前 75 组作为训练数据，后 25 组作为检验数据，即预测未来 25 日的收盘价。

由上一节可以确定网络输入层的结点数确定为 7 个，网络中间层的结点数确定为 5 个，网络输出层输出点的个数确定为 1 个。接下来确定选定训练步数，目标误差分别定位 1000 和 0.01。网络训练函数采用的是 MATLAB 默认的 trainlm。goal=1.0e-28，epochs=2000，最大进化数设为 30，种群大小设为 15，交叉概率为 0.55，变异概率为 0.1。

表 5-1 模型训练时间

| 模型名称 | 单网络价格预测模型 | 单网络趋势决策模型 | 双网络趋势决策模型 |
|------|-----------|-----------|-----------|
| 训练时间 | 12.70 | 12.90 | 12.31 |

如上面表格我们可以看出，只看训练时间，无疑是单网络决策模型的所需的时间最短，本文所建立的模型训练所用时间是最长的几乎是单网络决策模型的两倍，而单网络价格预测模型用时排在二者之间，比决策模型稍长，但相比本文提

出的模型来说它的用时还是和单网络决策模型差不多。

下面来看一下三种模型的预测情况

根据单网络价格预测模型的期望值如表 5-2 和图 5-1

表 5-2 根据单网络价格预测模型的期望值

| 预测时间 | 预期结果 | | | | |
|----------|-------|-------|-------|-------|-------|
| 1 to 5 | 12.66 | 12.80 | 12.65 | 12.48 | 12.83 |
| 6 to 10 | 12.70 | 12.90 | 12.31 | 12.61 | 12.20 |
| 11 to 15 | 11.47 | 11.87 | 12.16 | 12.34 | 12.20 |
| 16 to 20 | 12.16 | 12.39 | 12.26 | 11.97 | 12.08 |
| 21 to 25 | 12.22 | 13.05 | 13.00 | 12.41 | 11.93 |

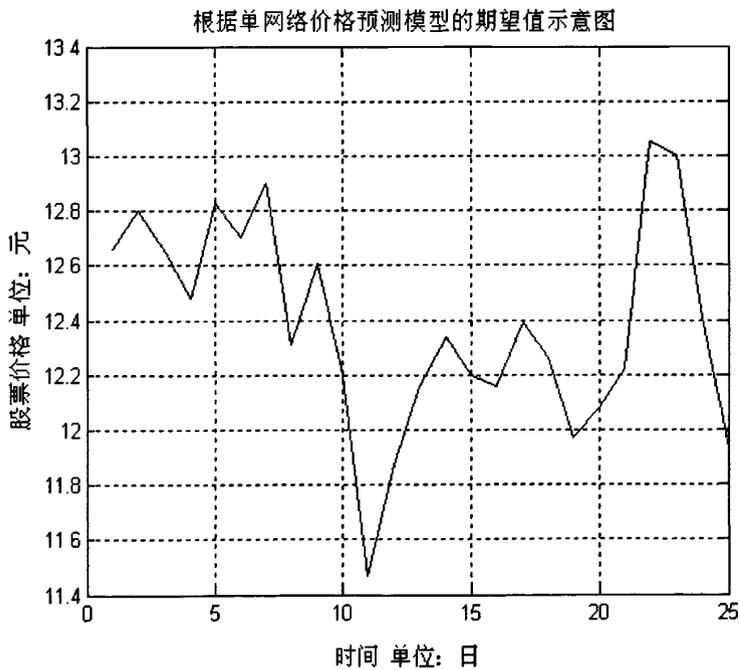


图 5-1 根据单网络价格预测模型的期望值

根据单网络价格预测模型的预测值

表 5-3 根据单网络价格预测模型的预测值

| 预测时间 | 预期结果 | | | | |
|----------|-------|-------|-------|-------|-------|
| 1 to 5 | 13.23 | 11.41 | 11.56 | 15.23 | 12.12 |
| 6 to 10 | 14.11 | 12.56 | 18.12 | 13.83 | 15.14 |
| 11 to 15 | 12.45 | 13.54 | 13.42 | 9.12 | 10.58 |
| 16 to 20 | 13.48 | 11.49 | 15.12 | 18.64 | 13.54 |
| 21 to 25 | 16.12 | 15.22 | 17.02 | 7.1 | 16.2 |

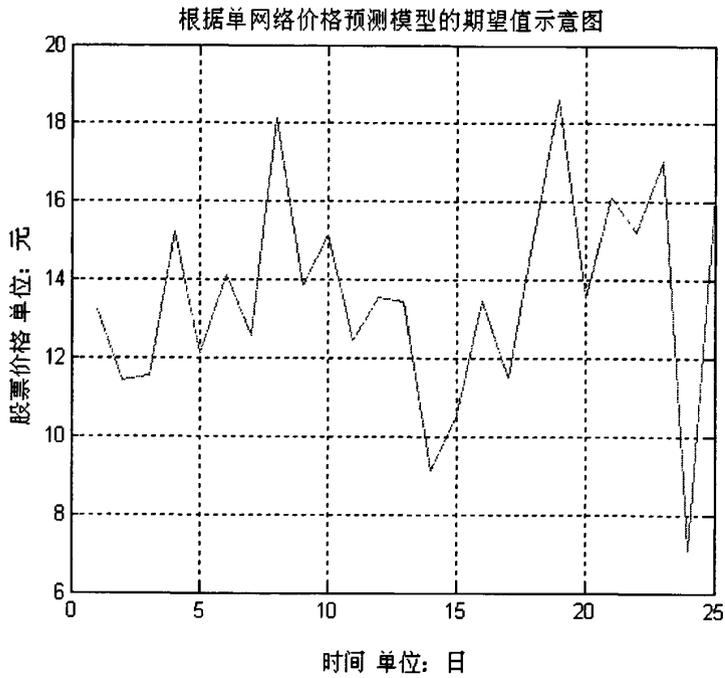


图 5-2 根据单网络价格预测模型的预测值

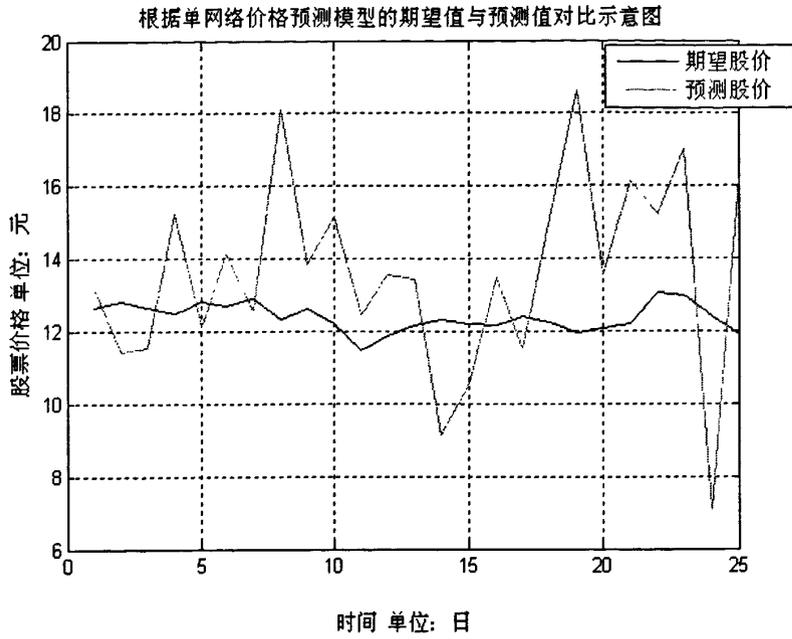


图 5-3 根据单网络价格预测模型的期望值与预测值对比示意图

从示意图里可以看出以下几点:

- 1、价格预测误差开始控制的比较好,但是到后来误差越来越大;
- 2、股票价格的走势与预测的走势误差由比较明显的不同。

单网络决策模型预测值和期望值示意图分别如下图所示

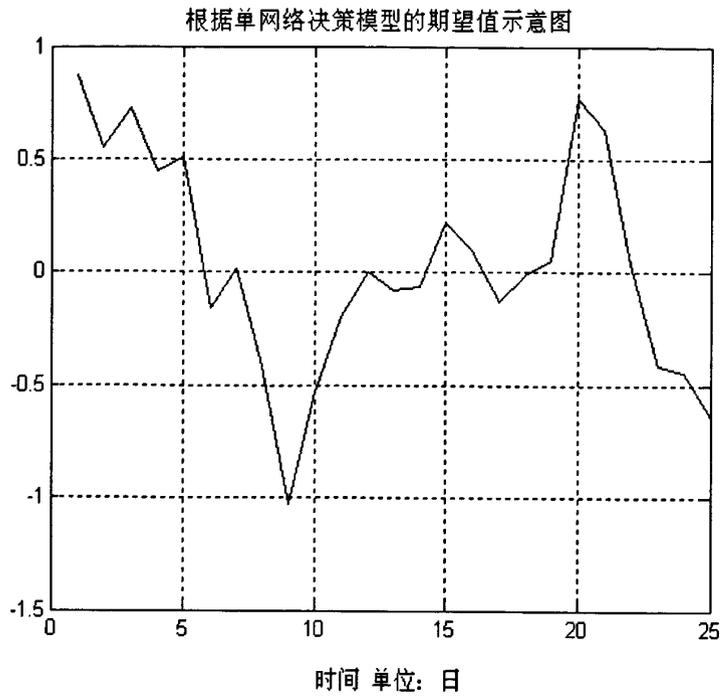


图 5-4 根据单网络决策模型的期望值示意图

单网络决策模型预测值

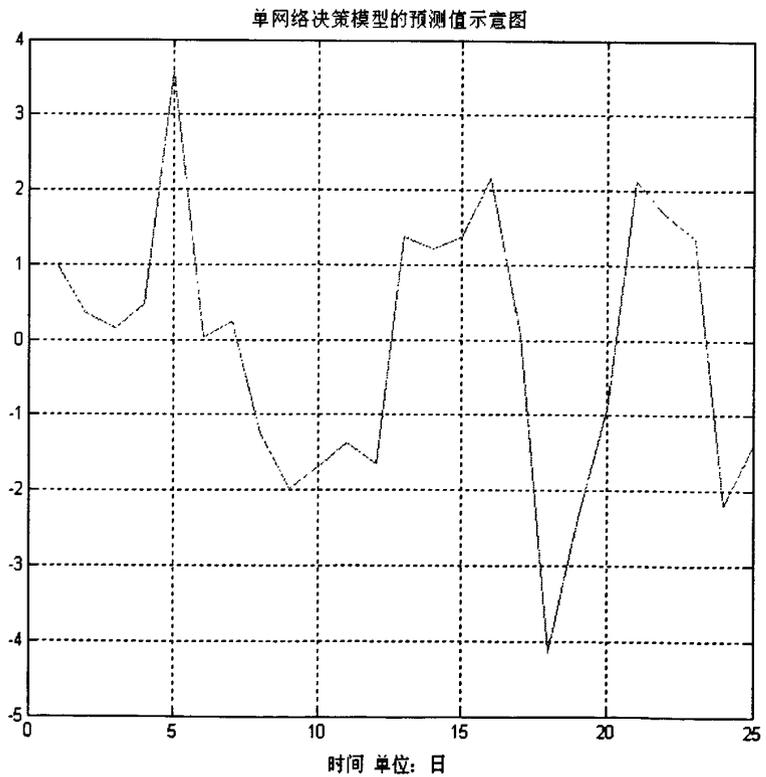


图 5-5 当网络决策模型的预测值示意图

当网络决策模型期望值与预测值对比示意图

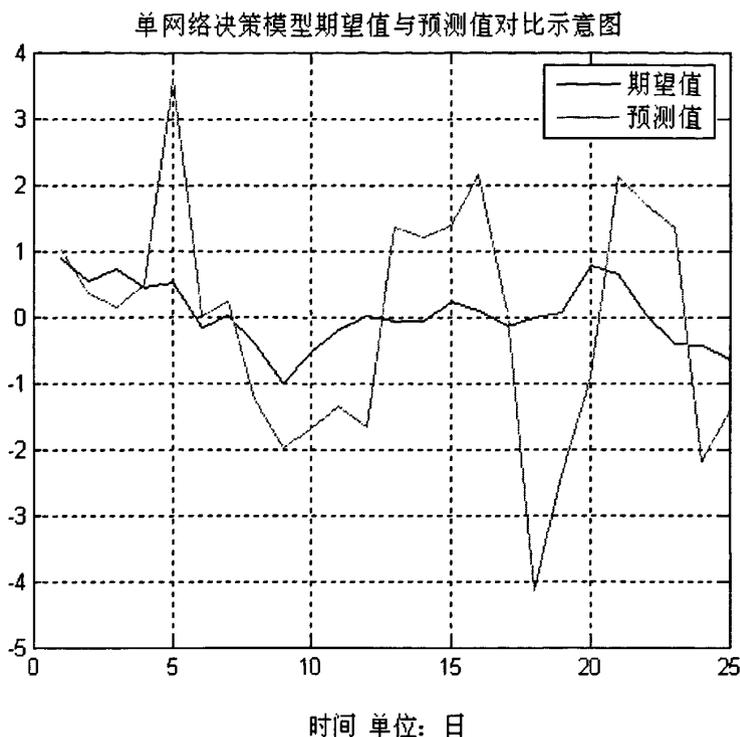


图 5-6 当网络决策模型期望值与预测值对比示意图

从示意图里可以看出以下几点：

1. 预测的动力指数与股票实际的动力指数之间的误差，从开始的比较满意到接下来的不太满意，然后又到最后几一部分是很不满意；
2. 预测的动力指数所表示的股票价格的升高与降低有一定的一致性。

下面是通过本文所提出的模型进行预测的

双网络决策模型预期值

表 5-4 双网络决策模型预期值

| 预测时间 | 对第二天决策的预期结果 |
|----------|----------------|
| 1 to 5 | |
| 6 to 10 | 卖 |
| 11 to 15 | 买 |
| 16 to 20 | 卖 买 |
| 21 to 25 | 卖 |

双网络决策模型预测值

表 5-5 双网络决策模型预测值

| 预测时间 | 第二天操作的预测结果 |
|----------|------------|
| 1 to 5 | |
| 6 to 10 | 卖 |
| 11 to 15 | 买 |
| 16 to 20 | 卖 |
| 21 to 25 | 买 卖 |

双神经网络预测买卖点示意图

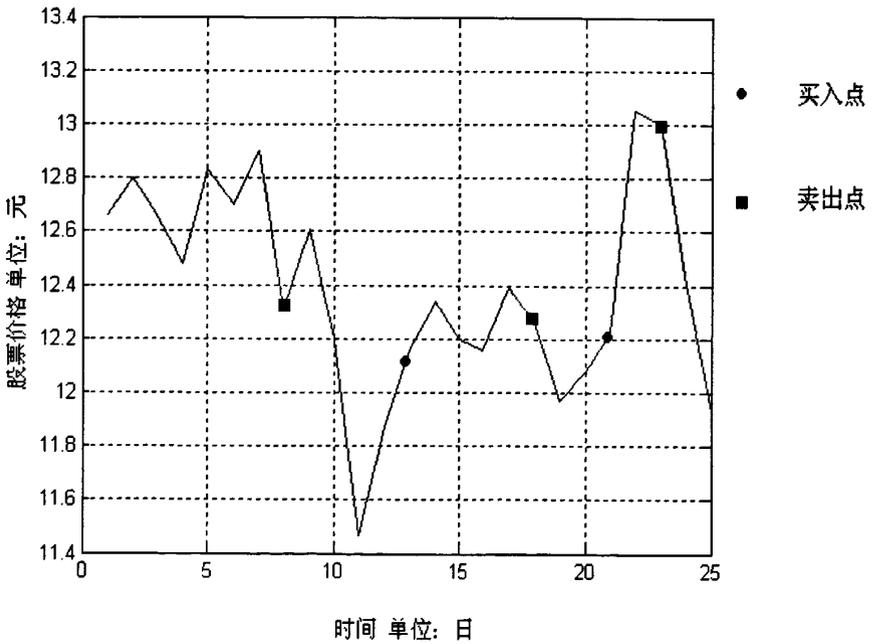


图 5-7 双网络模型预测的买入和卖出点

有以上示意图我们可以得出以下几点:

1. 建议买卖的时间点基本都是买低卖高;
2. 基本能保证在最低点和最高点周围买卖。

由以上对比我们可以看出本文提出的预测模型与以往的几种预测模型相比,有对股票走势的方向掌握准确;给出买卖建议有较好的实际意义;最后还有一点,本文提出的模型的生命周期在三种模型里面是最长久的。

本章小结

本章是实验部分，通过对单网络价格预测模型，单网络决策模型进行的对比，通过对比实验得出的数据，得出以下结论

本文提出的基于遗传 BP 算法的双神经网络模型虽然在训练上方面耗费的时间是其它两个模型的两倍。但是它具有良好的稳定性，良好泛化性等优点。有比较准确的预测结果。相比其他两个模型，本文突出的模型具有一定的优势。

结 论

人工神经网络是 20 世纪 40 年代兴起的用数学模型对神经系统中的神经元进行理论建模, 这个领域在上个世纪末期得到了极大的发展, 成为一个非常活跃的研究领域。随着人工神经网络研究成果的不断出现, 它在实际中的应用也越来越多。

由于人工神经网络高度非线性全局作用和十分强的自适应、自学习功能, 人工神经网络已被广泛应用于包括经济领域内的预测问题, 并已有在股市分析和预测上的成功应用的报道。目前, 人工神经网络已经被应用于对证券市场的价格、走势、涨幅等进行预测。

笔者在对股票走势进行了大量的分析和研究工作之后, 对神经网络理论和其在股票预测领域的应用进行了有益的探索, 主要的工作和研究成果如下:

1. 提出了动力指数的概念, 并将其作为预测股票涨跌动力和趋势的指标。
2. 提出了预测的目标是股票的趋势而不是股价, 根据动力指数, 技术指标的意义, 股票价格与价值的关系给出了股票趋势预测的可行性。
3. 根据单网络预测的不足, 提出了双神经网络决策系统。通过两个神经网络对不同顶以下趋势的预测, 达到相互补充的作用。实验表明, 此系统对预测的准确度和预测时间跨度有了较好的改善。
4. 根据经验确定了中间层结点数的范围, 并用等比例递减的方法, 通过大量实验确定了中间层的结点个数。是网络的泛化能力得到了最好的发挥。
5. 采用多输入变量决策支持模型。确定的实验输入变量并不是 K 线图所表示的量, 而是技术指标。根据操作支持曲线的判定, 可以直接得到网络预测输出的买卖操作。

虽然本课题研究对于基于遗传神经网络在股票预测做了一些有意义的工作, 但是在使用过程中仍然还存在着一些不足之处, 需要进一步研究和改善:

1. 网络在使用一段时间后适应能力有较明显的下降, 例如本文试验的网络在实验后继续对接下来的拐点进行预测时, 命中率出现明显下降。这需要网络重新学习的实用性进行改进。
2. 模型中参数的确定需要进行相应取舍研究, 目前的输入变量都是在已定的经验范围之内, 所以需要发现新的适合网络的输入变量和确定出方便网络的学习。

以上是本人在攻读硕士学位期间所做的工作，由于课题研究时间较短和本人水平有限，文中肯定还存在谬误和不足，请老师和同学批评指正。

参考文献

- [1] 凌毅. 神经网络在证券系统中的应用. 北京工业大学硕士学位论文, 2002
- [2] 彭砚苹. 你能我也能: 股市赢家炒股实战宝典. 首都经济贸易大学出版社, 2003, 1: 65-78
- [3] 施燕杰. 基于支持向量机(SVM)的股市预测方法[J]. 统计与决策, 2005, 2: 123-125
- [4] 杨一文, 杨朝军. 基于支持向量机的金融时间序列预测[J]. 系统工程理论方法应用, 2005, Vol. 14, No. 2: 176-181
- [5] Kou, Samuel. Modeling Growth Stocks. Winter Simulation Conference Proceedings, 2002, 12(5): 1524-1529
- [6] 王定成, 宋良图. LM滚动优化的SVMR预测控制研究[J]. 模式识别与人工智能, Vol. 18, No. 3, 2005: 281-285
- [7] 凌毅. 神经网络在证券系统中的应用. 北京工业大学硕士学位论文, 2002
- [8] Nowrouz Kohzadi, Milton S Boyd, Bahman Kermanshahi, Ieabeling Kaastra. A Comparison of Artificial Neural Network and Time Series Models for Forecasting Commodity Prices. Neurocomputing, 1996(10): 169-181
- [9] R J Kuo, C H Chen, Y C H wang. An Intelligent Stock Trading Decision Support System through Integration of Genetic Algorithm Based Fuzzy Neural Network and Artificial Neural Network. Fuzzy Sets and Systems, 2001(118): 21-45
- [10] Qing Cao, Karyl B Leggio, Marc J Schniederjans. A Comparison between Fama and French's Model and Artificial Neural Networks in Predicting the Chinese Stock Market. Computers and Operations Research, 2005(32): 2499-2512
- [11] 江勇. 图解证券实战分析. 上海: 上海交通大学出版社, 2002
- [12] 缪东君. 技术好当家. 上海: 文汇出版社, 2002
- [13] 中国证券协会. 证券市场基础知识. 北京: 中国财政经济出版社, 2004
- [14] 刘隽, 周涛, 周佩玲. GA优化支持向量机用于混沌时间序列预测[J]. 中国科学技术大学学报, Vol. 35, No. 2, 2005: 285-263
- [15] 焦李成. 神经网络系统理论. 西安: 西安电子科技大学出版社, 1999: 129-231
- [16] Satyadas A, Chen H. An Application of Intelligent Neural Network to Time Series Business Flucatuation Prediction. In Proceedings of IEEE International Conference On Neural Networks, 1994, 6: 3628-3633
- [17] Mohua Banerjee, Sushmita Mitra, Pal Sankar K. Rough Fuzzy MLP: Knowledge Encoding and Classification[J]. IEEE Trans. on Neural Networks, 1998(9): 1203-1216
- [18] Swiniarski R W, Hargis L. Rough Sets as a Front End of Neural - Networks Texture Classifiers[J]. Eurocomputing, 2001(3): 85-102
- [19] Xin Yao, Yong Liu. A New Evolutionary System for Evolving Artificial Neural Networks. IEEE Transaction on Neural Network, 1997, 8(3): 694-713
- [20] 张文修, 梁怡. 遗传算法的数学基础. 西安: 西安交通大学出版社, 2000.5, 3
- [21] 飞思科技产品研发中心. Matlab6.5辅助神经网络分析与设计. 电子工业出版社, 2003
- [22] 杨武. SQL Server编程篇. 北京: 电子工业出版社, 2005
- [23] Kyong Joo Oh, Kyoung-jae Kim. Analyzing stock market tick data using piecewise nonlinear model. Expert Systems with Applications, 2002, (22): 249-255
- [24] 谢冰, 戴盛, 谢科范. 基于遗传神经网络的工业股票指数预测. 湖南大学学报, 2004
- [25] 飞思科技产品研发中心. 神经网络理论与Matlab7实现. 北京: 电子工业出版社, 2005
- [26] Nan Jiang, Zhiye Zhao, Liqun Ren. Design of Structural Modular Neural Networks with Genetic Algorithm. Advances in Engineering Software, 2003(34): 17-24

- [27] 邵道明 . 股市黄金搭档: 股市技术指标最佳经典组合 . 经济管理出版社, 2009 . 9
- [28] Zhou Yancong, Gu Junhua. A New Approach of Rough Attributes Discretization Based on GA[J]. International Symposium on Test and Measurement, 2005, (6): 1-4
- [29] Kyong Joo Oh, Kyoung-jae Kim. Analyzing Stock Market Tick Data using Piecewise Nonlinear Model. Expert Systems with Applications, 2002(22): 249-255
- [30] Xin Yao, Yong Liu. A New Evolutionary System for Evolving Artificial Neural Networks. IEEE Transaction on Neural Network, 1997, 8(3): 694-713
- [31] Fariborz Y Partovi, Murugan Anandarajan. Classifying Inventory using an Artificial Neural Network Approach. Computers & Industrial Engineering, 2002(41): 389-404
- [32] Jeffrey L Callen, Clarence C Y Kwan, Patrick C Y Yip, Yufei Yuan. Neural Network Forecasting of Quarterly Accounting Earnings. International Journal of Forecasting, 1996 (12): 475-482
- [33] Irma Becerra-Fernandez, Stelios H. Zanakis, Steven Walczak. Knowledge Discovery Techniques for Predicting Country Investment Risk. Computers & Industrial Engineering, 2002(43): 787-800
- [34] Tong-Seng Quah, Bobby Srinivasan. Improving returns on stock investment through neural network selection. Expert Systems with Applications, 1999(17): 295-301
- [35] Qinghua Hu, Hui Zhao, etc. Daren Yu. Consistency based attribute reduction[J]. Lecture Notes in Computer Science, 2007, 4426: 96-107
- [37] 田景文, 高美娟. 人工神经网络算法研究及应用[M]. 北京: 北京理工大学出版社, 2006
- [38] 罗来鹏, 刘二根. 一种新的属性重要性度量及其规则获取[J]. 计算机工程与应用, 2007, 43(22): 170-172
- [39] 吴成东. 人工神经元 BP 网络在股票预测方面的应用. 控制工程, 2002, 9(5): 48-51
- [40] 周佩玲. 基于遗传算法的 RBF 网络用于股票短期预测. 数据采集与处理, 2003, 1(1): 16-25
- [41] 周佩玲. 神经网络结构设计的理论与方法. 北京: 国防工业出版社, 2003: 163-221
- [42] 胡冰, 潘福铮, 胡清锋. 遗传算法在股票短期投资决策中的运用. 系统工程理论与实践, 2003, 2(2): 7-13
- [43] 欧阳林群. 基于 GA-BP 的个股超短线预测应用研究. 微计算机信息, 2007, 23(2): 306-307
- [44] M. Dettling, P. Buhlmann. Finding Predictive Gene Groups from Microarray Data. Journal of Multivariate Analysis, 2004, 90: 106-131
- [45] 唐世浩, 朱启疆. 遗传算法中初始种群与交叉、变异率对解的影响及其解决方案. 科技通报. 2001, 17(3): 1-7
- [46] 王小平, 曹立明. 遗传算法—理论、应用与软件实现. 西安: 西安交通大学出版社, 2002: 7-9
- [47] Christopher Mark Coleman, J. Rothwell Edward, E. Ross John. Investigation of Simulated Annealing. Ant-colony Optimization and Genetic Algorithm for Self-structuring Antennas. IEEE Transactions on Antennas and Propagation, 2004, 52(4): 1007-1014
- [48] Yutian Liu, Li Ma, Jianjun Zhang. Reactive Power Optimization by GA/SA/TS Combined Algorithms. Electrical Power and Energy Systems, 2002, 24(9): 765-769

- [49] 翁利民, 靳剑峰. 电力系统无功优化方法综合分析. 电力电容器, 2004. 2(2): 1-6
- [50] 陈明杰, 刘胜. 改进自适应遗传算法在函数优化中的应用研究. 哈尔滨工程大学学报, 2007, 28(8): 875-879
- [51] 李敏强, 寇纪淦等. 遗传算法的基本理论与应用. 北京: 科学出版社, 2002, 15-50
- [52] 吴晓求. 证券投资学. 北京: 人民大学出版社, 2004: 15-16.
- [53] Dennis Olson, Charles Mossman. Neural Network Forecasts of Canadian Stock Returns Using Accounting Ratios. International Journal of Forecasting, 2003, 1(19): 453-456
- [54] Sexton R. S, Gupta J. N. D. Comparative Evaluation of Genetic Algorithm and Backpropagation for Training Neural Networks. Information Sciences, 2000, 129: 45-59
- [55] 陈祥光, 裴旭东. 人工神经网络技术及应用[M]. 北京: 中国电力出版社, 2003
- [56] 阎平凡, 张长水. 人工神经网络与模拟进化计算[M]. 北京: 清华大学出版社, 2000
- [57] Buhmann, Martin D. Radial Basis Functions: Theory and Implementations[M]. Cambridge University Press, 2003
- [58] Yuhua Hou, Jian Cheng. Forecasting Coalmine Gas Concentration Based on RBF Neural Network[J]. Information Acquisition, 2007 International Conference: 192-194
- [59] Hongjian Liu, Hongya Tuo, etc. Rough Neural Network of Variable Precision[J]. Neural Processing Letters, 2004, 19(1): 73-87
- [60] Z. Ali, etc. Radial basis neural network for the classification of fresh edible oils using an electronic nose[J]. Journal of Thermal Analysis and Calorimetry, 2003, 71(1): 147-154
- [61] J. W. Grzymala-Busse. Rough Set Theory with Applications to Data Mining [J]. Studies in Fuzziness and Soft Computing, 2005(179): 221-244
- [62] Le Hoai Bac, Nguyen Anh Tuan. Using Rough Set in Feature Selection and Reduction in Face Recognition Problem[J]. Lecture Notes in Computer Science, 2005, 3518: 226-233
- [63] 陈遵德. Rough Set 神经网络智能系统及其应用[J]. 模式识别与人工智能, 1999, 12(1): 1-5
- [64] Jelonek Jacek, Krawiec Krzysztof, Slowinski Roman. Rough Set Reduction of Attributes and Their Domains for Neural Networks[J]. Computational Intelligence, 1995, 11(2): 339-347
- [65] Ahn B S, Cho S S, Kim C Y. The Integrated Methodology of Rough Set Theory and Artificial Neural Network for Business Failure Prediction[J]. Expert Systems with Application, 2000, 18: 65-74
- [66] Mohua Banerjee, Sushmita Mitra, Pal Sankar K. Rough Fuzzy MLP: Knowledge Encoding and Classification[J]. IEEE Trans. on Neural Networks, 1998, 9(6): 1203-1216
- [67] Lavine B. K. Pattern Recognition Analysis via Genetic Algorithms & Multivariate Statistical Methods. Boca Raton, Fla: CRC Press, 2000: 95-102
- [68] Ishikawa M. Structural Learning with Forgetting[J]. Neural Networks, 1996, 9(3): 509 - 521
- [69] Fu L. Rule Generation from Neural Networks[J]. IEEE Trans. on Systems, Man, Cybernetics, 1994, 24(8): 1114-1124

- [70] Cao Zhiguo, Xiao Yang. The Application of Run-Length Features in Remote Sensing Classification Combined with Neural Network and Rough Set [J]. 2007 IEEE International Conference on Granular Computing: 552
- [71] Lin Jin-Cheng, Wu Kuo-Chiang. Design of Embedded Software Based on Rough Set and Neural Network[J]. 2007 International Conference on FSKD: 141-145
- [72] Ting Chen, Jingqing Luo. Research on Rough Set-Neural Network and Its Application in Radar Signal Recognition [J]. 2007 International Conference, (8): 3
- [73] Tian Ku. Design of a Novel Neural Networks Based On Rough Sets[J]. Chinese Control Conference, 2006, 5: 2078-2082
- [74] Deyou Xu. A Fault Diagnosis Method Combined Neural Network with Rough Set [J]. International Conference on Signal Processin, 2006, 4(8): 1829-1831
- [75] Leung K. S, Sun J. Y and Xu Z. B. Efficiency Speed-up Strategies for Evolutionary Computation: an Adaptive Implementation to be Appeared in Engineering Computation, 2002:92-95
- [76] 白燕娥, 崔广才. 基于遗传算法的属性约简算法研究与实现[J]. 长春理工大学学报, 2005, 28(3): 36-38

攻读硕士学位期间发表的学术论文

卢琇泽, 叶德谦, 南 敏 基于遗传算法和神经网络的股票价格预测
电脑开发与应用 2010 (2)

南 敏, 卢琇泽 基于量子遗传算法的粗糙集属性约简的研究 青岛理工大学学报
已录用

致 谢

本学位论文是在导师叶德谦教授的亲切关怀和指导下完成的。叶老师在学术上给我许多具有开拓性的建议，为我的学术研究开辟了新的道路。导师精湛的专业知识、严谨的治学作风、求实的科研精神深深地感染和激励着我。从课题的选择到课题的完成，叶老师始终给予了我不懈的支持和帮助。在此，对叶老师曾经给予的学术上的指导，生活上的关心和帮助致以最诚挚的感谢！感谢王超峰和王怀彩同学，在论文期间给我的帮助。感谢南敏师妹，杜中国师弟给予我的支持。

感谢计算机工程学院全体老师的辛勤培养和教诲！

最后，向在学习、工作和生活中给予我关心、支持与帮助的所有老师、同学、朋友及亲人表示最诚挚的谢意！

