

分类号 \_\_\_\_\_  
U D C \_\_\_\_\_

密级 \_\_\_\_\_  
公开  
编号 \_\_\_\_\_  
10741



# 硕士 学位 论文

论文题目 基于多维度信息的黄金期货价格

短期预测及交易效果评估

研究 生 姓 名: 尹晨曦

指导教师姓名、职称: 孙景云 教授

学 科、专 业 名 称: 统计学 数理统计学

研 究 方 向: 复杂数据分析

提 交 日 期: 2023 年 5 月 30 日

## 独创性声明

本人声明所呈交的论文是我个人在导师指导下进行的研究工作及取得的研究成果。尽我所知，除了文中特别加以标注和致谢的地方外，论文中不包含其他人已经发表或撰写过的研究成果。与我一同工作的同志对本研究所做的任何贡献均已在论文中作了明确的说明并表示了谢意。

学位论文作者签名: 尹晨曦 签字日期: 2023.5.30

导师签名: 孙景云 签字日期: 2023.5.30

## 关于论文使用授权的说明

本人完全了解学校关于保留、使用学位论文的各项规定, 同意 (选择“同意”/“不同意”) 以下事项:

- 1.学校有权保留本论文的复印件和磁盘, 允许论文被查阅和借阅, 可以采用影印、缩印或扫描等复制手段保存、汇编学位论文;
- 2.学校有权将本人的学位论文提交至清华大学“中国学术期刊(光盘版)电子杂志社”用于出版和编入 CNKI《中国知识资源总库》或其他同类数据库, 传播本学位论文的全部或部分内容。

学位论文作者签名: 尹晨曦 签字日期: 2023.5.30

导师签名: 孙景云 签字日期: 2023.5.30

# **Short Term Forecast of Gold Futures Price and Evaluation of Trading Effect Based on Multi-dimensional Information**

**Candidate : Chenxi YIN**

**Supervisor : Jingyun Sun**

## 摘要

黄金是金融市场上最重要的商品之一，它是一种兼具货币和金融属性的特殊贵金属，同时拥有高流动、高安全和低收益的特性。黄金期货价格的变化受到多种因素的综合影响，例如供需关系、全球经济状况、国家政策、汇率、股市指数与原油价格等。黄金期货价格波动较为复杂，再加上突发事件的干扰，使黄金期货价格预测变得越来越具有挑战性。传统的预测方法难以满足当前环境下对黄金期货价格短期预测的要求。因此本文从特征选择与特征融合两个角度出发分别对黄金期货价格及其影响因素进行分析，旨在探索提高黄金期货价格预测精度的新方法。主要工作如下：

在特征选择方面，首先选用弹性网络对中国黄金期货及其影响因素进行选择和降维，利用相空间重构法与时差相关分析法分别确定黄金期货本身的滞后期及压缩变量的滞后期；预测模型方面，在 BP、ELM、LSSVR 三种模型的基础上，选用粒子群优化算法(PSO)和灰狼优化算法(GWO)对基础模型参数进行优化并进行滑动窗口预测。预测结果表明，GWO-ELM 模型相较于其他模型有着更快的寻优速度，具有鲁棒性，在此基础上为了提高黄金期货价格预测方向精度，对已选 GWO-ELM 模型进行再次优化，设定方向精度与水平精度结合的适应度函数去训练网络模型，结果表明更改适应度函数的预测模型在一步预测与多步预测的方向精度都要好于原有的 GWO-ELM 模型，最后针对一步预测与多步预测的实验结果，设计不同的交易策略进行回测，通过策略收益率等相关指标进一步验证了更改适应度函数的 GWO-ELM 模型有着良好的预测效果。

在特征融合方面，不仅考虑黄金期货价格及市场等因素的影响，同时在影响因素中纳入投资者关注度量指标即百度指数数据集，通过 Pearson 相关系数、MIV 和 KPCA 方法对混合数据进行筛选及特征融合，对比分析信息贡献率来确定 MIV 与 KPCA 最佳阈值，选用对比得出稳健性较强的 GWO-ELM 模型进行一步预测，对比特征选择方法在混合数据集中的预测效果，得出特征选择方法在多维度信息的黄金期货价格预测方面更加适用。

**关键词：** 黄金期货 弹性网络 核主成分 时差相关分析 交易

## Abstract

Gold is one of the most important commodities in the financial market. It is a special precious metal that combines both currency and financial attributes, while possessing the characteristics of high liquidity, high security, and low yield. The change in gold futures prices is influenced by various factors, such as supply and demand, global economic conditions, national policies, exchange rates, stock market indices, and crude oil prices. The fluctuation of gold futures prices is quite complex, and the interference of unexpected events makes gold futures price prediction increasingly challenging. Traditional prediction methods are difficult to meet the requirements for short-term prediction of gold futures prices in the current environment. Therefore, this thesis analyzes the gold futures prices and their influencing factors from the perspectives of feature selection and feature fusion, aiming to explore new methods to improve the accuracy of gold futures price prediction.

The main work is as follows:

Regarding feature selection, the elastic net is first used to select and reduce the dimensionality of the Chinese gold futures and their influencing factors. The phase space reconstruction method and time-lagged correlation analysis method are used to determine the lag period of the gold futures themselves and the lag period of the compressed variables, respectively. In terms of prediction models, based

on the BP, ELM, and LSSVR models, the particle swarm optimization algorithm (PSO) and gray wolf optimization algorithm (GWO) are used to optimize the basic model parameters and conduct sliding window prediction. The prediction results show that the GWO-ELM model has a faster optimization speed and robustness compared to other models. To improve the directional accuracy of gold futures price prediction, the already selected GWO-ELM model is further optimized by setting an adaptive function that combines directional and horizontal accuracy to train the neural network model. The results show that the prediction model with the modified fitness function has better directional accuracy in both one-step and multi-step prediction than the original GWO-ELM model. Finally, different trading strategies are designed to backtest the experimental results of one-step and multi-step prediction, and relevant indicators such as strategy yield are used to further verify the good prediction performance of the modified fitness function GWO-ELM model.

Regarding feature fusion, not only the impact of gold futures prices and market factors is considered, but also the investor attention measurement index, namely the Baidu search index dataset, is included in the influencing factors. The Pearson correlation coefficient, MIV, and KPCA methods are used to screen and fuse the mixed data, and the information contribution rate is compared and analyzed to determine the

optimal threshold for MIV and KPCA. The GWO-ELM model with strong robustness is selected for one-step prediction, and the prediction effects of feature extraction methods are compared for the mixed dataset. It is found that feature extraction methods are more suitable for predicting gold futures prices in multi-dimensional information.

**Keywords:** Gold futures; Elastic network; Kernel principal component analysis; Time difference relevance analysis; Trading

# 目 录

<b>1 绪 论</b> .....	1
1.1 研究背景.....	1
1.2 研究意义.....	1
1.3 国内外研究现状.....	2
1.3.1 黄金价格影响因素研究 .....	2
1.3.2 金融领域多维信息的降维方法研究 .....	4
1.3.3 黄金价格预测相关研究 .....	5
1.3.4 交易策略相关研究 .....	6
1.3.5 文献述评 .....	7
1.4 研究内容及创新点.....	8
1.5 研究结构安排.....	9
<b>2 研究方法</b> .....	11
2.1 备选变量的选取方法.....	11
2.1.1 特征选择—正则化方法 .....	11
2.1.2 特征融合—核主成分分析法(KPCA).....	12
2.1.3 平均影响值法(MIV).....	13
2.2 预测变量的确定方法.....	15
2.2.1 相空间重构(PSR) .....	15
2.2.2 时差相关分析法(TDR) .....	16
2.3 智能优化算法.....	17
2.3.1 粒子群优化算法(PSO) .....	17
2.3.2 灰狼优化算法(GWO) .....	18
2.4 预测方法.....	20
2.4.1 BP 神经网络 .....	20
2.4.2 最小二乘支持向量回归模型(LSSVR) .....	21
2.4.3 极限学习机模型(ELM) .....	22
2.5 评价指标.....	24

<b>3 基于特征选择的黄金期货价格短期预测及交易效果评估</b>	26
3.1 黄金期货价格的影响因素分析	27
3.2 数据收集及预处理	28
3.2.1 数据收集	28
3.2.2 数据预处理	29
3.3 特征选择	30
3.3.1 正则化方法-弹性网络	30
3.3.2 网络结构的确定	32
3.4 基于特征选择的黄金期货价格预测	32
3.4.1 预测模型及参数设置	32
3.4.2 滑动窗口预测实验结果	34
3.4.3 IGWO-ELM 改进模型	37
3.5 交易效果评估	41
3.5.1 买入-持有-卖出策略	41
3.5.2 针对多步预测的交易策略	45
3.6 本章小结	48
<b>4 基于特征融合的黄金期货价格短期预测及交易效果评估</b>	49
4.1 关键词筛选	50
4.2 特征融合	52
4.2.1 平均影响值法(MIV)	52
4.2.2 核主成分法(KPCA)	54
4.3 基于特征融合的黄金期货价格预测	56
4.4 交易效果评估	58
4.5 本章小结	59
<b>5 总结与展望</b>	61
5.1 总结	61
5.2 展望	61
<b>参考文献</b>	63

后 记 .....	67
-----------	----

# 1 绪 论

## 1.1 研究背景

预测是指根据已有数据和客观规律，通过一定的分析、模型建立和预测算法等方法，对未来某一对象或现象的发展趋势进行推断或预估的过程。数据预测涉及众多领域，如经济、金融、能源、环境、自然科学与社会科学等，由于不同领域的数据，其特征不尽相同，针对不同数据集挖掘其潜在的价值，并根据预测结果做出合理的规划。

2008年1月上海期货交易所正式推出黄金期货产品，中国作为全球最大的黄金生产国和消费国，黄金在国内金融中扮演着十分重要的角色。随着中国经济与国际经济联系日益紧密，中国黄金市场已成为全球黄金市场中不可或缺的一部分，但中国期货业所面临的挑战也变得越来越严峻，中国期货业需要不断改进和创新，提高自身竞争力，积极开拓国际市场，以适应全球化市场的机遇和挑战。

黄金期货由于其抗风险能力高、保值性强、操作简便、资金结算周期短等优势，已经成为我国期货交易市场中最主流、最大众化的产品之一。黄金期货的价格涨跌情况，是投资者在做出预期决策前做出判断最重要依据，因此有必要构建合理有效的期货预测模型来揭示黄金期货价格的走势。由于黄金价格自身的多重属性且影响黄金价格变化的因素繁多复杂，导致黄金期货价格具有非线性、非平稳、高波动性等特征，因此难以准确的对黄金期货收盘价的走势进行预测，这也促使了投资界和学术界高度重视黄金期货价格的预测与研究。

建立有效的预测模型和风险管理机制，是确保黄金期货市场健康稳定发展的关键。作为基金经理和投资者，必须把握市场趋势、把控风险并制定相应的投资策略和风险控制方案，以确保投资风险最小化并实现可持续的收益。无论是投资期货市场还是进行投机操作，都需要通过预测和分析来制定相应的交易原则，并根据交易原则进行风险控制，预测行为对于期货市场的健康发展有着重要的意义。

## 1.2 研究意义

理论意义：1.针对多维度信息的黄金期货价格短期预测构建两种不同的模型，

一种是基于特征选择对黄金期货进行预测，利用弹性网络从原始数据中抽取出有用的特征，降低数据复杂性以便机器学习算法能够对数据进行学习。另一种是基于特征融合对黄金期货进行预测，利用 MIV 与 KPCA 进行结合，将不同来源的特征结合起来，充分利用不同特征的优点，通过实验得出百度指数可以有效提升模型的预测性能。比较分析两个模型对相同数据集的处理情况，在多维度黄金期货预测方面特征选择要优于特征融合模型。2.在预测模型优化方面，选用粒子群与灰狼优化智能优化算法对模型参数进行优化，通过对比 BP、LSSVR、ELM、PSO-BP、PSO-LSSVR、PSO-ELM、GWO-BP、GWO-ELM 与 GWO-LSSVR 九种模型滑动窗口预测的结果，GWO-ELM 模型具有较强的稳健性，并更改灰狼优化算法的适应度函数以提高模型的预测精度，通过多步预测以及交易回测结果表明更改适应度算法的预测效果优于其他模型。

现实意义：1.黄金市场保值性和流动性使其成为一个相对稳定的投资领域，尤其与房地产、基金、股票市场相比，在经济波动时期黄金成为了投资者的首选产品。黄金有着相对特殊的作用，黄金储备有助于稳定国民经济，抵御经济危机、控制通货膨胀、提高信誉度、稳定汇率、确保国家经济水平平稳运行，这对于国家和企业的发展都是至关重要的。此外，根据期货市场发展走势可以调整企业生产黄金的规模和数量，优化产业结构，降低成本并提高产品利润，增强黄金产品的多样性，这对于发展和完善黄金期货市场也具有重要的意义。2.黄金期货在市场中扮演着多种重要的角色，无论是在投资、避险还是在金融市场稳定性的维护方面都具有重要作用。无论学术界还是投资界都对黄金期货进行了深入的研究。通过预测黄金价格的趋势，投资者可以根据市场规则构建出更为理性的投资策略，随着大环境的变化，黄金期货在不同时间段内受到不同因素的影响，并且突发事件也会对黄金期货价格产生巨大的影响，因此需要使用组合预测模型进行系统分析，以便更好地预测黄金期货价格的变动情况。

### 1.3 国内外研究现状

#### 1.3.1 黄金价格影响因素研究

国内外众多学者已对黄金价格的影响因素进行了研究，这些因素包括多种因

素共同作用影响黄金价格以及单一因素对黄金价格的影响。由于黄金期货价格波动较大，所以受到其他相关市场的影响较为明显。导致黄金价格变动的原因主要有三个方面：一是替代品市场的影响，例如黄金、白银和铜等市场的价格波动。杨胜刚等<sup>[1]</sup>利用线性回归、Breush-Godfrey LM 与 VAR 模型等多种检验方法发现中国黄金期货价格主要受到上海、伦敦黄金现货价格及美元指数的影响；曹辉与张士云<sup>[2]</sup>构建 GARCH 族模型检验上期所黄金期货价格波动的特征，结果表明交易量的当期和滞后期都对价格波动产生显著影响，而持仓量的影响仅在当期显著；Kumar<sup>[3]</sup>研究发现，石油价格与黄金价格之间存在着非线性关系；黄健柏等<sup>[4]</sup>构建 VAR 模型系统的研究了美元、石油对中国铜、黄金、白银等有色金属价格的影响，以及三种有色金属价格间的相互影响关系；Alameer 等<sup>[5]</sup>选用三种汇率、铜价、银价以及西德克萨斯中质原油价格等作为输入有效预测了黄金价格；Weng 等<sup>[6]</sup>选用白银价格、原油价格、普尔 500 指数以及黄金历史价格为输入预测黄金期货价；刘飞等<sup>[7]</sup>利用协整理论等多种方法研究了我国黄金期货与现货之间存在的引导关系，中国黄金期货市场相对于欧美黄金期货交易市场成立时间较短，市场机制尚待完善。

二是黄金市场的供需变化会受到宏观经济环境的影响，这也意味着黄金价格的变动会受到其他市场的宏观经济因素的影响。冯辉与张蜀林<sup>[8]</sup>利用 Frankel 模型建立了黄金期货价格决定要素模型，得出国际黄金期货价格决定要素为世界 GDP、美元指数、利率、美国经济状况；Beckman 等<sup>[9]</sup>研究了黄金价格变动一定程度上取决于汇率的波动幅度；杨柳勇与史震涛<sup>[10]</sup>研究发现，道琼斯指数、通货膨胀率、汇率和利率是影响黄金价格的长期决定因素；Lawrence<sup>[11]</sup>研究发现黄金的投资回报率与大宗商品、股票指数之间存在显著的相关关系，宏观经济变量与道琼斯工业平均指数、标准普尔 500 指数以及十年期国债的收益都存在显著相关关系；Li 和 Diao<sup>[12]</sup>将与黄金有关的宏观经济影响因素分为金融市场指数、能源市场和宏观经济指标三类，发现黄金价格与金融市场指数、宏观经济指标之间存在负相关关系，而黄金价格与能源市场之间则存在正相关关系。黄金价格不仅受到能源市场因素、现货市场因素和宏观环境因素的影响，同时还受到股票、证券等市场的影响。董杰等<sup>[13]</sup>发现 WTI 原油期货与现货市场、股票市场、黄金市场之间存在动态相关性；徐照宜等<sup>[14]</sup>利用小波变换分析出黄金价格与上证指数之间

存在负相关的关系；袁晨与傅强<sup>[15]</sup>通过 GARCH 模型研究不同阶段股票-债券-黄金市场三者之间的关系。将与黄金有关的影响因素可分为能源市场因素、期货市场因素、现货市场因素、宏观环境因素与市场指数因素五类。

黄金作为一种金融产品，其价格影响不仅受到市场环境的影响，投资者对黄金期货进行大量频繁的交易行为，也会对黄金期货的价格走势造成一定的影响，因此有必要从投资者的角度，对黄金期货价格的影响因素进行系统的分析。例如，Balciilar 等<sup>[16]</sup>与 Smales 等<sup>[17]</sup>发现了黄金市场受投资者情绪的影响；姚德权等<sup>[18]</sup>对投资者收益与投资者情绪进行了研究，投资者情绪在短时间内会对股票收益造成一定的影响；Mbang 等<sup>[19]</sup>发现金融市场的关注度和投资者情绪之间是因果关系，投资者关注度会对金融市场的收益造成影响，这说明投资者关注度会对黄金期货市场产生影响。关注度作为一种主观感受，难以直接进行量化，随着互联网的兴起，可以利用互联网时代下的产物来观察和分析人们的兴趣和关注度。例如王耀君与高扬<sup>[20]</sup>使用 360 搜索指数来衡量股票的网络关注度，并探讨了搜索指数在股票市场的作用。梁超等<sup>[21]</sup>构建 GARCH-MIDAS 探究了百度指数、谷歌趋势与中国黄金价格波动率之间的关系。

### 1.3.2 金融领域多维信息的降维方法研究

在建立黄金期货价格预测系统模型时，选择过多的影响因素构建模型会增加数据的维度以及模型的计算难度，当模型中加入某些不重要因素进行训练会影响模型的最终预测效果，在预测文献中存在多种数据降维的技术，主要可以分为特征选择与特征融合。特征选择旨在寻找一组与预测对象相关且具有代表性的特征进行模型构建，特征选择的方法主要有岭回归、LASSO 回归法、逐步向后回归法与弹性网络法等。黄冰洁和张同斌<sup>[22]</sup>基于岭回归和 LASSO 方法，在多变量中筛选出企业绩效分化的重要影响因素并对其进行研究；贾尚晖和兰盈<sup>[23]</sup>选用 LASSO 回归的方法从定性分析所选的 10 个变量中选取与对伦敦现货黄金价格收益率有关的 4 个变量进行分析；吴俊洋<sup>[24]</sup>对多个地区房价进行拟合的实验，并比较了 LASSO 回归、岭回归和弹性网络回归的结果，实验结果显示弹性网络结合了岭回归与 LASSO 回归的优点，能筛选出更具有代表性的指标；Liu 和 Li<sup>[25]</sup>先选取道琼斯工业平均指数、美国十年期债券期货、标准普尔 500 指数等 7 个宏观

经济指标为影响因素并采用逐步向后回归法选取道琼斯工业平均指数等 4 个变量为模型的关键影响因素；梁超等<sup>[26]</sup>在标准回归模型的基础上，利用主成分法提取预测因子并构建五种不同的组合模型，最终利用 LASSO 与弹性网络对中国黄金期货波动率进行样本外预测。胡聿文<sup>[27]</sup>提出了一种基于 PCA-LASSO-LSTM 模型的股票价格预测模型，相对于 LASSO-LSTM 模型和 LSTM 模型，该模型可以显著减少数据冗余，并获得更优异的预测精度。特征选择通过设置一定的参数来保留有效变量，但同时丢弃了大量有用信息，特征融合则将原始特征空间转换为保留更多信息的更简单的特征空间。

特征融合是在没有剔除任何特征的前提下，将原始数据进行降维，基于特征融合对变量进行处理的方法主要有偏最小二乘法、主成分法与核主成分法等。高振斌与秦轩<sup>[28]</sup>采用了偏最小二乘法来解决多元回归中的多重共线性问题，并用篇最小二乘法选取回归变量的主成分；徐龙博等<sup>[29]</sup>将平均影响值(MIV)和主成分(PCA)方法相结合，以优化预测模型；陈盟<sup>[30]</sup>利用核主成分(KPCA)对所选影响股票的技术指标进行特征降维，支持向量回归(SVR)模型进行预测。Yang 等<sup>[31]</sup>用 K-means 与 KPCA 对与石油有关谷歌趋势指数和宏观数据集进行特征融合，选用 KELM 对油价月度数据进行预测。

### 1.3.3 黄金价格预测相关研究

从预测方法分析，预测方法大致可分为两类：传统时间序列预测模型和人工智能算法预测模型。传统的时间序列模型建立在大数定律的基础上，同时也是最早应用于预测价格的模型。传统的时间序列模型主要包括灰色预测法、广义自回归条件异方差模型(GARCH)以及自回归移动平均模型(ARIMA)等。许贵阳<sup>[32]</sup>选用灰色预测方法对中国黄金期货价格进行短期预测；毛从芹<sup>[33]</sup>建立了 GARCH(1,1)模型预测黄金价格走势；许立平与罗明志<sup>[34]</sup>选用 ARIMA 对伦敦现货黄金月度价格进行了短期预测；彭潇熟等<sup>[35]</sup>对比 GARCHX、ARMA、ARMAX 与单纯 GARCH 等模型对国际黄金价格预测的预测效果，由于 GARCHX 模型引入了油价、美元指数等外生变量，预测效果要好于其他对比模型。传统的时间序列模型主要采用函数的形式对问题进行定量分析，从而挖掘数据的特性。时间序列方法通常需要满足严格的假设条件，例如变量之间存在线性关系、平稳性和同

方差性等，然而时间序列模型在构建过程可能会忽略变量之间的性质，并且假设条件往往无法满足实际经济系统的复杂性和动态变化，导致传统时间序列模型在处理非线性、非平稳性和复杂性数据时表现不佳，导致预测结果的准确性不高。

随着人们对金融市场的研究不断深入，传统时间序列模型在预测方面存在明显不足。为了提高预测精度，人们开始探索利用机器学习、人工智能技术对金融时间序列进行预测。其中，BP 神经网络、人工神经网络(ANN)、随机森林(RF)和多层次感知器神经网络(MLP)等就是常见的机器学习预测方法，另一种则是通过智能优化算法对神经网络的参数进行优化，提高神经网络的预测精度。宋策<sup>[36]</sup>用灰色关联度对影响我国黄金期货价格的 5 个影响因素进行分析，选取关联度高的因素构建 BP 神经网络预测模型，结果表明预测效果要好于 GM(1,1)和 ARIMA(0,2,1)模型；Ur 与 Junejo<sup>[37]</sup>选用了多变量预测黄金价格，其中人工神经网络的预测效果好于线性回归模型；Pierdzioch 和 Risse<sup>[38]</sup>在随机森林中引入多元变量对金等四种贵金属进行样本外预测，结果表明引入多变量构建预测模型的精度要高于单变量预测的精度；Alameer 等<sup>[39]</sup>考虑汇率、油价、铜价、银价及黄金过去的月度价格等 10 个变量定为输入变量预测，建立鲸鱼优化算法优化的多层次感知器神经网络预测黄金月度价格。

### 1.3.4 交易策略相关研究

交易策略通常分为两类：趋势策略与套利策略。趋势交易策略注重技术指标和价格走势，通过技术指标或数学模型对未来价格涨跌的走势进行判断，并基于判断结果进行交易，在趋势策略中，选择合适交易时机介入市场对该策略就显得至关重要。相比之下，套利策略主要利用不同交易所、不同证券或期货等金融工具价格之间的差异，通过买卖交易来获取风险低、收益稳定的利润。例如，均值回归策略就是一种常见的套利策略，该策略通过计算价格的偏离程度来预测未来价格的走势并进行相应的交易。季晨洋与林杰<sup>[40]</sup>通过随机森林预测甲醇期货价格，选用基于均线突破技术的 Aberration 策略进行回测；周星月<sup>[41]</sup>构建基于布林线理论设定交易策略对沪深 300 指数进行回测，高宁波与张鸿<sup>[42]</sup>利用套期保值策略对钢材期货进行回测；彭乐<sup>[43]</sup>选用 MACD、MA、KDJ、RSI 多个指标进行组合对螺纹钢期货的量化交易策略进行优化；高妮等<sup>[44]</sup>选用 EEMD-SVR 对沪深 300 指

数进行分解集成，选用 MACD、基于涨跌分布统计的择时策略、指数择时策略等 4 种策略进行对比评估；Li 等<sup>[45]</sup>构建 VMD- ICSS -BiGRU 的混合模型预测黄金期货价格，并制定交易买卖持有策略、SMA 策略与 RSI 策略测试黄金期货市场的交易表现。总的来说，趋势策略更注重技术指标和价格走势的分析，而套利策略则更侧重于市场的供需关系和相关性分析。

### 1.3.5 文献述评

通过对现有黄金价格预测方法及相关研究的有序梳理，不难得出以下结论及启示：在大数据时代背景下，高维时间序列预测已经成为了热门的研究领域，而如何从海量的变量中选择出真正影响因变量的协变量，已经成为高维数据分析中最基本也是急需解决的问题，现在主流的数据降维方法有：特征选择与特征融合。特征选择主要通过剔除某些不相关变量达到降维目的，特征融合在一定程度上保留了变量的特征，针对不同的变量选择方法所得到的预测结果也是截然不同的。从预测的角度分析，现有的主流时序预测方法可大致分为两类：传统时间序列预测模型与机器学习模型。其中，传统的时间序列预测模型理论成熟，主要是对规律性较强、线性特征明显的数据有较高的预测精度，但黄金期货价格是一组高波动、非线性、非平稳的时间序列数据，使用多元线性回归模型和 ARIMA 等传统的时间序列的预测方法均未能很好的处理模型中非线性、高波动等问题，而灰色模型只适用于小样本，并且其预测精度很大程度上取决于灰色参数的设置。相比之下，人工智能模型具有更高的灵活性，不需要对研究样本设定过多的假设，但也存在着一些不可避免的缺陷，如参数敏感性、过拟合、欠拟合、容易出现局部最优解等，本文通过设计滑动窗口预测模型，找到稳健性较强的预测模型，针对该模型进行模型改进。

从数据降维的角度提出两个框架来处理黄金价格预测问题，第一个框架从特征选择的角度出发，利用弹性网络提取重要影响因素，基于不同变量之间与黄金期货价格的领先滞后关系，寻找最优滞后期与最优预测网络，另一个框架中选用特征融合的方式对变量进行处理，首先选用相关系数对变量进行粗选，对于粗选的变量，利用 MIV 方法对变量进行再次筛选，剩余变量利用 KPCA 提取有用信息，该方法从信息贡献度的角度出发选择 MIV 与 KPCA 之间阈值的最优组合，

尽可能保留有用信息，最终利用灰狼优化算法的神经网络模型进行预测，并用交易策略进行回测。

## 1.4 研究内容及创新点

基于“多维度”信息的黄金价格等金融时间序列的预测成为近年来时序预测领域的热点问题，研究者们从预测出发与量化交易策略相互佐证，极大程度上发挥了预测的作用，从而使预测更加具有现实意义。然而“数据特征”在时序预测中起着关键作用，在数据的预测方面，不论是新的预测方法提出，框架的完善，均围绕研究样本的数据特征展开。基于数据特征构建相对应的预测模型，有利于提升模型的预测精度，同时为预测的研究提供一些新的思路。

研究内容：从数据降维的角度提出两个框架来处理黄金价格预测问题并制定相应的交易策略。第一个框架从特征选择的角度出发，采用弹性网络对中国黄金期货及其影响因素进行选择和降维，利用相空间重构法和时差相关分析法确定各个变量的滞后期，然后采用合适的神经网络模型进行一步预测与多步预测并针对结果制定相应的交易策略。第二个框架中从特征融合的角度出发，在已有变量的基础上增加百度指数数据集，首先通过 Pearson 相关系数对所选变量进行初步筛选，在此基础上利用 MIV 方法对变量进行再次筛选，次要变量则采用 KPCA 提取数据特征，通过在预测模型中加入少量的主元变量来提高信息的总利用率，最终选用灰狼优化算法的神经网络模型进行预测，并用买入-持有-卖出交易策略进行回测。

论文的创新主要表现在以下三个方面：

(1) 在模型构建方面，选用两种不同的数据降维方式，分别从特征选择与特征融合的角度对不同数据集进行分析。在特征选择的模型中，通过时差相关分析法与相空间重构法，充分挖掘影响因素与黄金期货收盘价之间的关系，避免通过主观经验选择输入维数，从而进一步提高模型的预测性能；其次在特征选择所用的金融数据集中加入度量投资者关注度的百度指数数据集，形成混合数据集，通选用 MIV 与 KPCA 构建特征融合模型，比较分析两个模型对混合数据集的处理情况，其中特征选择要优于特征融合模型。

(2) 在预测优化方面，考虑到人工智能预测方法。本文选用粒子群与灰狼优

化智能优化算法对模型参数进行优化，通过对比 BP、LSSVR、ELM、PSO-BP、PSO-LSSVR、PSO-ELM、GWO-BP、GWO-ELM 与 GWO-LSSVR 九种模型滑动窗口预测的结果，最终选择构建基于灰狼优化算法的神经网络预测模型，并更改灰狼优化算法的适应度函数以提高模型的预测精度，通过滑动窗口预测、一步预测与多步预测的实证结果证明灰狼优化算法的预测效果优于其他模型。

(3)在交易策略方面，针对一步预测结果设计 2 种买入-持有-卖出策略；针对多步预测的实验结果，设计 4 种不同的交易策略进行回测，通过对比策略收益率等相关指标进一步验证了预测结果的优劣。

## 1.5 研究结构安排

本文从特征选择与特征融合两个方面对黄金期货价格构建相对应的预测模型，研究内容总共分为五章进行阐述，论文的主要内容结构如图 1.1 所示：

第 1 章为绪论，该章节旨在阐述研究背景、意义以及国内外研究现状，分析目前黄金价格预测方面相关研究的发展现状，阐释现有黄金价格预测模型中所存在的一些问题与不足，说明本文的创新之处。

第 2 章为研究方法，主要对文章中所用到的特征选择、特征融合、预测方法、优化算法、交易策略等模型建立过程中涉及的理论基础进行详细阐述。

第 3 章为基于特征选择的黄金期货价格预测及交易效果评估，即利用弹性网络、时差相关分析等方法对黄金期货价格的影响因素进行降维处理及价格预测，制定相应的交易策略。

第 4 章为基于特征融合的黄金期货价格预测及交易效果评估，在黄金期货的影响因素中加入百度指数并对黄金期货价格序列利用 MIV 与 KPCA 分析法进行分析数据处理，选用 GWO-ELM 模型进行预测。

第 5 章为文章的总结与展望。

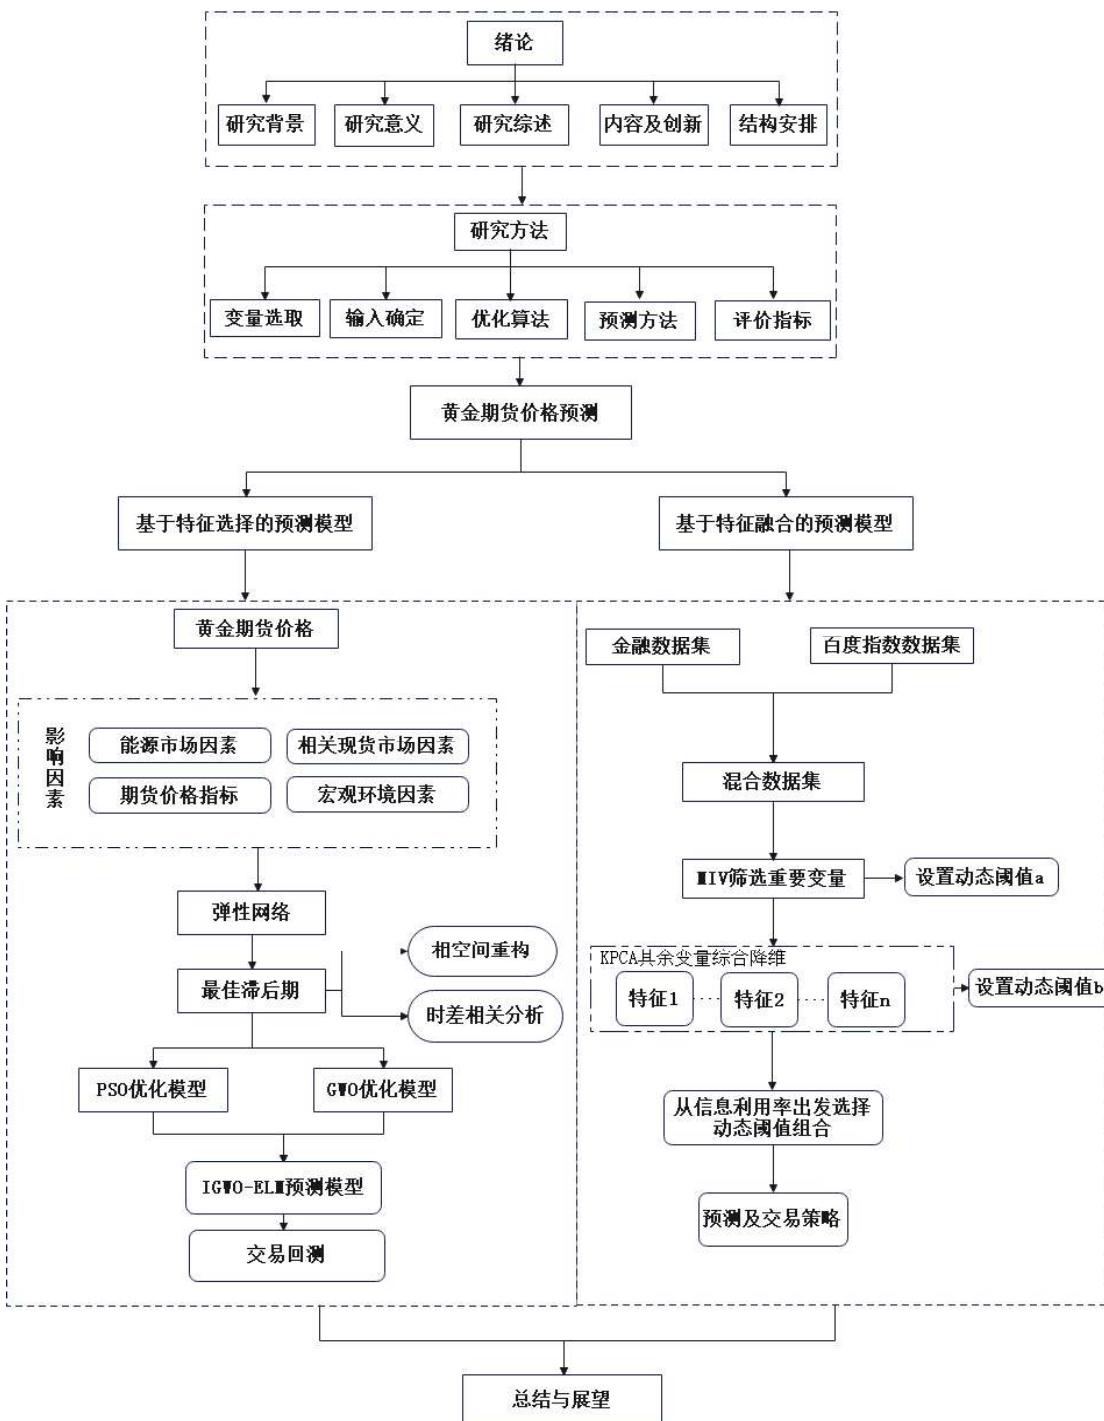


图 1.1 论文主要内容结构图

## 2 研究方法

本章介绍本文中所用到的研究方法。它主要包括几种特征筛选方法(弹性网络、核主成分分析法与平均影响值法); 输入变量确定的方法(相空间重构法和时差相关分析法); 两种智能优化算法(PSO 与 GWO); 三个预测模型(BP、ELM、LSSVR); 模型优劣评判用到的评价指标(MAE、MAPE、RMSE、DS、DM 检验与 IR)。

### 2.1 备选变量的选取方法

#### 2.1.1 特征选择—正则化方法

特征选择旨在寻找一组与预测对象相关且具有代表性的特征进行模型构建，常见的特征选择方法有：岭回归、LASSO、弹性网络(Elastic Net Regression)。岭回归通过在损失函数中添加 $L_2$ 惩罚项，在训练求解参数过程中使得模型中的回归系数趋近于 0，岭回归无法对变量进行筛选，但却可以缓解变量之间存在多重共线性的问题；LASSO 回归通过在表达式中添加 $L_1$ 惩罚项，使得绝对值较小且对因变量解释能力较弱的变量系数被压缩为 0，从而达到降维的目的，弹性网络结合了岭回归与 LASSO 的优点，表达式如下<sup>[46]</sup>：

$$\hat{\beta} = \operatorname{argmin} \left\{ \|Y - X\beta\|^2 + \lambda_1 \sum_{j=1}^n |\beta_j| + \lambda_2 \sum_{j=1}^n |\beta_j|^2 \right\} \quad (2.1)$$

其中，惩罚项表达式如下：

$$P(\beta) = \lambda_1 \|\beta\|_1 + \lambda_2 \|\beta\|_2^2 \quad (2.2)$$

式中 $Y$ 是 $n \times 1$ 的向量， $X$ 是 $n \times p$ 的矩阵， $\beta = (\beta_1, \beta_2, \dots, \beta_p)$ 是 $p \times 1$ 的回归系数向量， $\lambda \sum_{j=1}^n |\beta_j|$ 是惩罚项， $\lambda$ 是正则化参数，惩罚函数 $\sum_{j=1}^n |\beta_j|$ 是所有因子系数的绝对值求和所得。弹性网络通过将惩罚项中 $L_1$ 范数和 $L_2$ 范数进行结合，使得弹性网络兼具了 LASSO 回归与岭回归的优势，当两两变量之间相关度较高时，可以有效剔除无关变量，保留相关性大的变量，从而增强模型的可解释性；同时解决了当样本维数大于样本个数时，忽略部分变量的问题。

### 2.1.2 特征融合—核主成分分析法(KPCA)

基于特征融合选择变量的方法主要有主成分分析法与核主成分分析法，主成分分析法(Principal Component Analysis, PCA)是一种基于线性映射进行特征提取的传统降维方法，该方法通过从大量原始信息中提炼出多个具有代表性的变量重构为几个互不相关的主成分指标来反映原始中的信息。主成分分析法是一种常用的线性数据降维方法，但是针对非线性数据进行处理时，主成分分析法无法全面的保留数据的特征。在主成分的基础上，加入核函数进行非线性的扩展即为核主成分分析法(Kernel Principal Component Analysis, KPCA)。核主成分分析法通过一个核函数将原始数据映射到一个高维特征空间中，在该空间中原始数据变得更容易分离，在通过传统的 PCA 方法来提取主成分，并将数据投影回低维空间中。KPCA 法可以有效摒弃高维数据间的冗杂信息并充分保留数据的特征，核主成分分析法的主要步骤如下<sup>[47]</sup>：

#### 步骤 1：数据结构化转化

假设存在样本矩阵  $X'_{n \times m}$ ，并对样本矩阵进行标准化得到  $X_{n \times m}$ ，式中  $x = \{x_1, x_2, \dots, x_n\}, x_i \in R^N, x_i = \{x_{i1}, x_{i2}, \dots, x_{im}\}$  其中  $n$  为样本数据个数， $m$  为样本维度，

#### 步骤 2：构造样本数据的协方差矩阵

利用函数  $\varphi$  将样本进行非线性映射，将样本映射到高维空间  $R^F$  中，样本所得映射值为  $\varphi(x_1), \varphi(x_2), \dots, \varphi(x_n)$ ，并利用 PCA 方法对样本矩阵进行处理得到协方差矩阵为：

$$C = \frac{1}{n} \sum_{i=1}^n \varphi(x_i) \varphi(x_i)^T \quad (2.3)$$

#### 步骤 3：计算特征向量及特征值

特征方程为：

$$Cv = \lambda v \quad (2.4)$$

式中  $v$  为特征向量， $\lambda$  为协方差矩阵的特征值，则有

$$v = \sum_{i=1}^n \varphi(x_i) \frac{\varphi(x_i)^T v}{\lambda n} = \sum_{i=1}^n \varphi(x_i) \alpha_i \quad (2.5)$$

其中：

$$\alpha_i = \frac{\varphi(x_i)^T v}{\lambda n} \quad (2.6)$$

利用核函数简化  $v$  的计算, 核函数表示如下:

$$k(x_i, x_j) = \phi(x_i)^T \phi(x_j) \quad (2.7)$$

对于式(2.4), 任意的  $k = 1, 2, \dots, n$  有:

$$\varphi(x_k)^T C v = \lambda \varphi(x_k)^T v \quad (2.8)$$

可得

$$K \alpha = \lambda n \alpha \quad (2.9)$$

式中  $K$  为核矩阵,  $K = k(x_i, x_j)$ ,  $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_n)$ 。通过(2.9)式, 求得特征值  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$  以及对应特征向量  $\varphi_1, \varphi_2, \dots, \varphi_n$ 。并选取  $p$  ( $p \leq n$ ) 个特征值, 且满足贡献率大于设定值。

#### 步骤 4: 确定主成分

计算新样本  $\varphi(x_i)$  投影后的第  $j$  ( $j = 1, 2, \dots, p$ ) 维坐标表述如下:

$$y_i = \sum_{i=1}^n \alpha_i^j (\varphi(x_i)^T \varphi(x_j)) = \sum_{i=1}^n \alpha_i^j k(x_i, x_j) \quad (2.10)$$

$\alpha_i$  规范化要求为:

$$\alpha_i^T \alpha_i = \frac{1}{\lambda_i} \quad (2.11)$$

式中  $\alpha_i^j$  表示  $\alpha_i$  的第  $j$  个分量。

### 2.1.3 平均影响值法(MIV)

神经网络模型的应用过程中, 没有特定的理论方法来确定神经网络模型的输入变量, 但如果在神经网络模型中加入一些不重要的变量, 则会对模型的准确性产生负面影响, 因此寻找与研究对象有关的重要变量对神经网络模型的应用有着非常重要的意义, 常用的数据降维方法有 LASSO 法、弹性网络法、主成分分析法、核主成分法与平均影响值法等。

MIV(Mean Impact Value, MIV) 平均影响值法, 是用来评估输入影响因素对研究对象所起重要程度大小的评判指标, MIV 的正负表示影响因素对研究对象产生影响, 其绝对值大小代表该影响因素对研究对象的重要程度。MIV 主要对所

选影响因素的特征值指标进行同比例加减，得到两个不同的训练样本，并将两次输出影响因素的差值定义为影响变化值(IV)，对影响值进行平均即得到该影响因素的 MIV 值，最终将所有影响因素都按照上述过程进行处理并按照绝对值大小对每个影响因素进行排序，所得排序即为影响因素对研究对象重要程度的排序。MIV 算法流程如下<sup>[48]</sup>：

### 步骤 1：构建初始网络模型

若有自变量数据集  $X = \{x_1(t), x_2(t), \dots, x_n(t)\}$  为输入变量， $n$  为特征指标， $t$  为序列个数，特征指标因子  $x_i(t), i = 1, 2, \dots, n$ ，因变量  $y(t), t = 1, 2, \dots, m$  为输出变量。为消除变量之间量纲大小对实验结果产生的影响，首先对数据集进行归一化处理，选用 BP 神经网络模型构建仿真预测模型来筛选特征指标。

### 步骤 2：建立新的训练样本集

对样本数据集  $X$  中的每个影响因素的数值进行增加或者减少 10% 的变化，仅限于每次只更改一个影响因素，其他变量保持不变，通过增加变量 10% 数值的数据集用  $Q$  表示， $Q_i$  则表示当其他变量保持不变时，数据集  $X$  中第  $i$  个影响因素数值增加 10% 的情况，通过减少变量 10% 数值的数据集用  $P$  表示， $P_i$  则表示当其他变量保持不变时，数据集  $X$  中第  $i$  个影响因素数值减少 10% 的情况。

### 步骤 3：BP 神经网络进行仿真

对训练数据集  $P$  和  $Q$  统一进行归一化处理，利用已经构建 BP 神经网络分别对数据集进行仿真模拟，数据集  $P_i$  仿真的结果用  $M_i$  表示，最终训练样本集  $P$  的仿真结果用  $M$  表示，数据集  $Q$  的通过 BP 神经网络模拟仿真结果用  $N$  表示，且  $M$  和  $N$  都是  $m \times n$  维的矩阵。

### 步骤 4：计算平均影响值

影响变化值(IV)即为同一影响因素通过增加或减少同等比例之后 BP 神经网络模拟仿真预测值所得的差值，则第  $i$  个影响因素的第  $j$  个样本的影响变化值可表示为  $IV_i^j = M_i^j - N_i^j, j = 1, 2, \dots, m$ ，平均影响值(MIV)是通过对每个输入样本的 IV 值取平均所得，则第  $i$  个影响因素的  $MIV_i$  为：

$$MIV_i = \frac{1}{m} \sum_{m_i}^{m_j} IV_i^j \quad (2.12)$$

### 步骤 5：寻找重要的影响因素及计算相对贡献率

计算出所有影响因素的 MIV 值，并对所有特征的 MIV 值按绝对值大小进行排序，绝对值数值越大，说明该影响因素与研究对象之间存在较高的相关性，正号则表示二者之间呈现正相关， $v_i$  则表示该影响因素的相对贡献率， $n$  表示影响因素个数。

$$v_i = \frac{|MIV_i|}{\sum_{i=1}^n |MIV_i|} \quad (2.13)$$

## 2.2 预测变量的确定方法

### 2.2.1 相空间重构(PSR)

相空间重构(Phase Space Reconstruction, PSR)是由 Takens<sup>[49]</sup>和 Packard<sup>[50]</sup>等在 20 世纪 80 年代所提出，通过对时序数据重构吸引子把数据的时间相关性转换成更高维的空间向量。时间序列  $x(i), i = 1, 2, \dots, N$  的相空间重构可表示如下：

$$X(t) = (x(t), x(t + \tau), \dots, x(t + (m - 1)\tau)) \quad (2.14)$$

其中  $t = 1, 2, \dots, N - (M - 1)\tau$ ,  $m$  为嵌入维度， $\tau$  是延迟参数， $X(t)$  表示为延迟向量。目前关于  $\tau$  和  $m$  的选取有以下两种观点，一种认为二者不存在关联性，相互独立即首先确定延迟时间  $\tau$ ，选用的方法有自相关法与复自相关法等，再确定嵌入维度  $m$ ，主要有 Cao 氏方法与虚假最近邻域法等。另一种观点则认为两个参数是相互影响的不能独立的进行选择，根据此观点衍生出时间窗口法和 C-C 算法等。本文选取 C-C 算法寻找最佳嵌入维度  $m$  和延迟参数  $\tau$ ，取 C-C 算法主要步骤如下：

#### 步骤 1 计算关联积分：

嵌入时间序列  $x(i), i = 1, 2, \dots, N$  的关联积分定义如下：

$$C(m, N, r, t) = \frac{2}{M(M - 1)} \sum_{1 \leq i \leq j \leq m} \Theta(r - \|X_i - X_j\|), \quad r > 0 \quad (2.15)$$

其中  $d_{ij} = \|X_i - X_j\|$  表示向量  $i$  与  $j$  之间的距离， $t$  为时间序列的下标， $r$  为搜索半径， $N$  为数据集合大小。 $M = N - (m - 1)t$  为  $m$  维空间中嵌入点的数目， $\Theta(x)$  为 Heaviside 函数：若  $x < 0$ ，则  $\Theta(x) = 0$ ；当  $x \geq 0$ ， $\Theta(x) = 1$ 。

**步骤 2 检测统计量定义如下:**

$$S(m, N, r, t) = C(m, N, r, t) - C^m(1, N, r, t) \quad (2.16)$$

**步骤 3 得出关联积分的情况下，将序列  $x_i$  拆分成  $t$  个相互独立的子序列，并定义各子序列的检验统计量如下所示：**

$$S(m, N, r, t) = C(m, N, r, t) = \frac{1}{t} \sum_{s=1}^t \left[ C_s \left( m, \frac{N}{t}, r, t \right) - C_s^m \left( 1, \frac{N}{t}, r, t \right) \right] \quad (2.17)$$

当  $N \rightarrow \infty$  时，

$$S(m, N, r, t) = \frac{1}{t} \sum_{s=1}^t [C_s(m, r, t) - C_s^m(1, r, t)], m = 2, 3, \dots \quad (2.18)$$

**步骤 4 定义半径  $r$  的差值，即最大半径与最小半径之差：**

$$\Delta S(m, t) = \max\{S(m, r_j, t)\} - \min\{S(m, r_j, t)\} \quad (2.19)$$

**步骤 5 计算 DBS 统计量：**

$$\bar{S}(t) = \frac{1}{16} \sum_{m=2}^5 \sum_{j=1}^4 \Delta S(m, t) \quad (2.20)$$

$$\Delta \bar{S}(t) = \frac{1}{4} \sum_{m=2}^5 \Delta S(m, t) \quad (2.21)$$

$$S_{cor}(t) = \Delta \bar{S}(t) + |\bar{S}(t)| \quad (2.22)$$

C-C 算法选取  $\bar{S}(t)$  中第一个过零点的值或者  $\Delta \bar{S}(t)$  的第一个局部极小值作为延迟参数  $\tau = t$ ，并选取  $S_{cor}(t)$  的全局最小值为时间窗口  $\tau_b$ ，根据公式  $\tau_b = (m - 1)\tau$  计算得出最佳嵌入维数  $m$ 。

## 2.2.2 时差相关分析法(TDR)

时差相关分析法(Time Difference Relevance Analysis, TDR)以所选的经济活动时间序列作为基准指标，通过计算时差相关系数来寻找其他相关经济时间序列超前、同步或滞后关系的一种常用方法。设基准指标  $y = \{y_1, y_2, \dots, y_k\}$ ，被分析指标  $x = \{x_1, x_2, \dots, x_k\}$ ， $k$  为样本数， $l$  为序列  $x$  和  $y$  之间的时间差， $\bar{x}$  和  $\bar{y}$  分别为  $x$  和  $y$  的平均值， $r_l$  表示时间差为  $l$  时两序列的相关系数。时差相关系数  $r_l$  计算公式如下：

$$r_l = \frac{\sum_{k=1}^s (x_{k+l} - \bar{x})(y_k - \bar{y})}{\sqrt{\sum_{k=1}^s (x_{k+l} - \bar{x})^2 (y_k - \bar{y})^2}} \quad l = 0, \pm 1, \pm 2, \dots, \pm p \quad (2.23)$$

当  $l = 0$  时,  $r_0$  表示  $x_t$  和  $y_t$  之间的 Pearson 相关系数; 当  $l > 0$  时,  $x$  和  $y$  之间的关系为超前; 当  $l < 0$  时,  $x$  和  $y$  之间的关系为滞后。

## 2.3 智能优化算法

### 2.3.1 粒子群优化算法(PSO)

粒子群优化算法 (Particle Swarm optimization, PSO) 是由 Eberhart 和 Kennedy<sup>[51]</sup> 所提出的一种基于鸟群觅食时群体与个体之间的合作与信息共享来寻找最优解的智能优化算法。本文利用 PSO 优化 BP 神经网络中的初始连接权值与阈值, 利用 PSO 优化 LSSVR 模型的正则化参数和核参数, 利用 PSO 优化 ELM 模型的输入权值和阈值, 主要步骤如下:

#### 步骤 1 初始话一粒子群确定相关参数

设置粒子群规模大小为 20; 最大迭代进化次数为 100; 学习因子  $C_1 = 1.8, C_2 = 1.8$ ; 搜索变量的维度  $D = 2$ 。

#### 步骤 2 计算粒子相应的适应度值

适应度函数选用(BP、ELM 或 LSSVR)基准神经网络所得的均方误差, 即所得适应度函数值越小所选粒子适应度越强。

#### 步骤 3 更新迭代过程

粒子通过计算适应度更新个体极值与群体极值从而寻找到个体局部最佳位置与群体中的全局最佳位置, 更新公式如下:

$$V_{ij}^{w+1} = \omega \times V_{ij}^w + c_1 r_1 (P_{ij}^w - X_{ij}^w) + c_2 r_2 (P_{gj}^w - X_{ij}^w) \quad (2.24)$$

$$X_{ij}^{w+1} = X_{ij}^w + V_{ij}^{w+1} \quad (2.25)$$

式中  $V_{ij}^{w+1}$  代表更新的速度;  $\omega$  为惯性系数;  $w$  为迭代次数;  $P_{ij}^w$  代表在第  $w$  次迭代中, 粒子的个体局部最佳位置;  $P_{gj}^w$  代表全局最佳位置;  $X_{ij}^w$  代表粒子所在的位置;  $j$  为搜索空间的维数;  $X_{ij}^{t+1}$  为第  $i$  个粒子更新所处的位置;  $r_1$  和  $r_2$  为服从 0-1 均匀

分布的随机数。

#### 步骤 4 判断是否为最优解

判断满足训练停止条件即达到网络预先设定的训练次数或训练误差到达设定范围内，停止网络训练，输出最终结果。

### 2.3.2 灰狼优化算法(GWO)

灰狼优化(Grey Wolf Optimizer, GWO)算法是 Seyedali Mirjalili<sup>[52]</sup>在 2014 年模仿灰狼捕食猎物过程中的等级制度所提出的一种智能仿生优化算法，该算法遵循灰狼捕食过程中头狼负责领导决策，其他灰狼负责执行决策的系统化规则，当头狼不在狼群中，从下一层的执行者中推选出新的头狼作为决策者，该算法相比于其他优化算法设定参数少且收敛能力强，因此具有较好的仿真模型效果。本文利用 GWO 优化 BP 神经网络中的初始连接权值与阈值，利用 GWO 优化 LSSVR 模型的正则化参数和核参数，利用 GWO 优化 ELM 模型的输入权值和阈值的主要步骤如下：

灰狼优化算法步骤如下所示：

#### 步骤 1 搜索追踪猎物

$$\vec{D} = |\vec{C} \cdot \vec{X}_P(t) - \vec{X}(t)| \quad (2.26)$$

$$\vec{X}(t+1) = \vec{X}_P(t) - \vec{A} \cdot \vec{D} \quad (2.27)$$

式中  $t$  为当前迭代次数， $\vec{A}$  与  $\vec{D}$  为系数向量， $\vec{X}_P$  为被捕食者位置向量， $\vec{X}$  为灰狼此时位置向量，其中  $\vec{A}$  与  $\vec{C}$  为的公式如下：

$$\vec{A} = 2 \cdot \vec{a} \vec{r}_1 - \vec{a} \quad (2.28)$$

$$\vec{C} = 2 \vec{r}_2 \quad (2.29)$$

式中  $\vec{a}$  为收敛因子，取值随着迭代过程从高到低呈现线性地减少，其取值范围为  $[0,2]$ ， $\vec{r}_1$  与  $\vec{r}_2$  为取值为  $[0,1]$  之间的随机向量。

## 步骤 2 包围抓捕

$$\begin{cases} \overrightarrow{D_\alpha} = |\overrightarrow{C_1 X_\alpha} - \vec{X}| \\ \overrightarrow{D_\beta} = |\overrightarrow{C_2 X_\beta} - \vec{X}| \\ \overrightarrow{D_\delta} = |\overrightarrow{C_3 X_\delta} - \vec{X}| \end{cases} \quad (2.30)$$

$$\begin{cases} \overrightarrow{X_1} = \overrightarrow{X_\alpha} - A_1 \overrightarrow{D_\alpha} \\ \overrightarrow{X_2} = \overrightarrow{X_\beta} - A_2 \overrightarrow{D_\beta} \\ \overrightarrow{X_3} = \overrightarrow{X_\delta} - A_3 \overrightarrow{D_\delta} \end{cases} \quad (2.31)$$

式中,  $\overrightarrow{D_\alpha}$  代表头狼与被捕食者之间的距离,  $\overrightarrow{D_\beta}$  代表第二等级的灰狼与被捕食者之间的距离,  $\overrightarrow{D_\delta}$  代表第三等级的灰狼与被捕食者之间的距离向量,  $\overrightarrow{X_\alpha}$ ,  $\overrightarrow{X_\beta}$ ,  $\overrightarrow{X_\delta}$  分别表示  $\alpha$ ,  $\beta$ ,  $\delta$  的当前所在位置向量,  $\overrightarrow{C_1}$ ,  $\overrightarrow{C_2}$ ,  $\overrightarrow{C_3}$  是随机向量,  $\vec{X}$  表示当前灰狼的位置向量。抓捕猎物过程如图 2.1 所示:

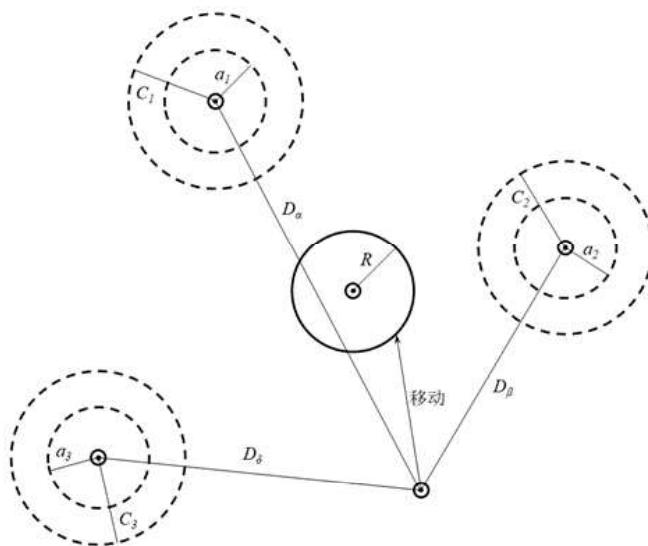


图 2.1 灰狼狩猎图

图 2.1 展示了二维空间灰狼捕食过程中最底层灰狼的位置更新图, 由  $\alpha$ ,  $\beta$ ,  $\delta$  三个不同等级的灰狼判断并确定被捕食者的位置, 其他狼根据  $\alpha$ ,  $\beta$ ,  $\delta$  的位置随机更新位置并对猎物进行包围。

## 步骤 3 攻击抓捕猎物

$$\vec{X}(t+1) = \frac{\overrightarrow{X_1} + \overrightarrow{X_2} + \overrightarrow{X_3}}{3} \quad (2.32)$$

最后便是攻击被捕食者, GWO 优化得到的最优解即为  $\alpha$ , 次优解为  $\beta$ 。

## 2.4 预测方法

### 2.4.1 BP 神经网络

反向传播(Back Propagation, BP)神经网络是 1986 年由 Rumelhart 等<sup>[53]</sup>提出的一种信号通过带权重的全连接进行正向传播, 所得误差进行反向传播各层神经元以误差信号作为调整权重的依据, 当满足停止条件时输出预测结果。典型的 BP 神经网络由三层构成, 即输入层、隐含层与输出层。

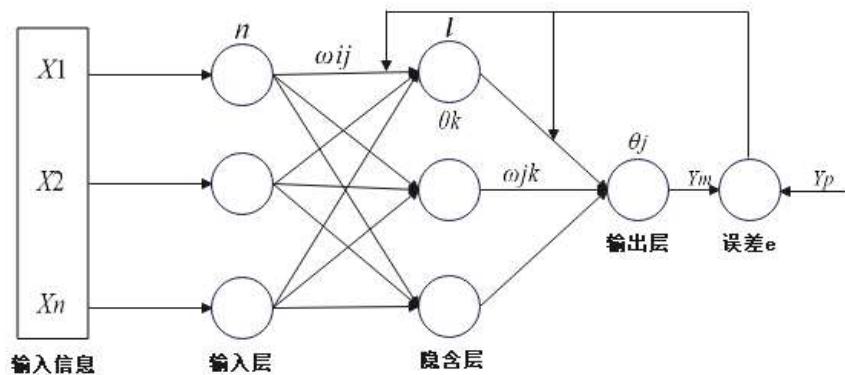


图 2.2 BP 网络的拓扑结构

图 2.2 展示了 BP 网络的拓扑结构,  $X_1, X_2, \dots, X_n$  为 BP 神经网络输入,  $Y_m$  为神经网络预测值,  $\omega_{ij}$  与  $\omega_{jk}$  分别表示输入层与隐含层、隐含层与输出层的连接权重,  $\theta_k$  为隐含层的阈值,  $\theta_j$  为输出层的阈值, 输入节点数为  $n$ , 输出节点数为  $g$ , 隐含层数目为  $l$ ,  $Y_m$  为神经网络预测输出,  $Y_p$  为期望输出,  $e$  为误差。隐含层节点数目的选取影响神经网络的预测精度, 结点数目选取可参考如下公式:

$$l < n - 1 \quad (2.33)$$

$$l < \sqrt{(g + n) + a} \quad (2.34)$$

$$l = \log_2 n \quad (2.35)$$

式中  $a$  的取值范围为  $[0, 10]$ , BP 神经网络拥有较强的非线性映射能力, 但 BP 神经网络的预测效果容易受随机初始化权值和阈值的影响, 本文选取 PSO 与 GWO 优化算法优化 BP 神经网络初始权值与阈值。

## 2.4.2 最小二乘支持向量回归模型(LSSVR)

最小二乘支持向量回归(Least Squares Support Vector Regression, LSSVR)是由 Suykens<sup>[54]</sup>等基于支持向量机模型进行改进，首先在 SVR 模型的损失函数中加入误差的平方项，并且将损失函数的约束条件由不等式约束转化成了等式约束，这使得二次规划问题转变成为方便求解的线性方程组，该方法有效的提高了计算速度与预测精度。LSSVR 的具体过程如下：

给定一组样本数据集 $\{(x_i, y_i), i = 1, 2, \dots, n\}$ ,  $x_i \in R^n$  表示第*i*个输入向量,  $y_i \in R$  表示该变量对应期望输出值,  $n$ 为样本个数。引入非线性映射 $\Phi(x)$ 将训练样本集映射到高维空间中，最优决策函数如下：

$$f(x) = w^T \Phi(x) + b \quad (2.36)$$

其中,  $w$ 为权向量,  $b$ 为阈值。

依据结构化风险最小原理在模型中引入松弛变量 $e_i$ , 该模型优化目标为:

$$\min J(w, e) = \frac{1}{2} w^T w + \frac{1}{2} \gamma \sum_{i=1}^n e_i^2 \quad (2.37)$$

约束条件为:

$$y_i = w^T \Phi(x_i) + b + e_i, i = 1, 2, \dots, n \quad (2.38)$$

式中,  $\gamma$ 为正则化参数,  $e_i$ 为引入的误差, 引入 Lagrange 函数对目标函数进行简化可得:

$$L(w, b, e, \alpha) = \frac{1}{2} \|w\|^2 + \frac{\gamma}{2} \sum_{i=1}^n e_i^2 - \sum_{i=1}^n \alpha_i (w^T \Phi(x_i) + b + e_i - y_i) \quad (2.39)$$

其中,  $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_n]^T$ 为 Lagrange 乘子。

对上式求偏导, 可推得 LSSVR 的预测函数为:

$$f(x) = \sum_{i=1}^n \alpha_i K(x, x_i) + b \quad (2.40)$$

式中,  $K(x, x_i)$ 为核函数, 本文选取核函数的类型为径向基核函数即 $K(x, x_i) = \exp\left(-\frac{x-x_i}{2\sigma^2}\right)$ ,  $\sigma$ 为核密度, LSSVR 模型中对模型预测效果起决定性作用的参数为正则化参数与核参数, 本文通过用 PSO 与 GWO 优化算法来寻找最优参数。

### 2.4.3 极限学习机模型(ELM)

极限学习机(Extreme Learning Machine, ELM)是 Huang<sup>[55]</sup>等学者提出的一种基于单隐含层前馈神经网络(SLFNs)的机器学习方法，该模型可以随机的产生输入层与隐含层之间的连接权值与隐含层的阈值并简化求解得出相应的输出权值，从而具有参数设定少、模型结构简单以及泛化能力强等优势，极限学习机的基本网络结构如图 2.3 所示：

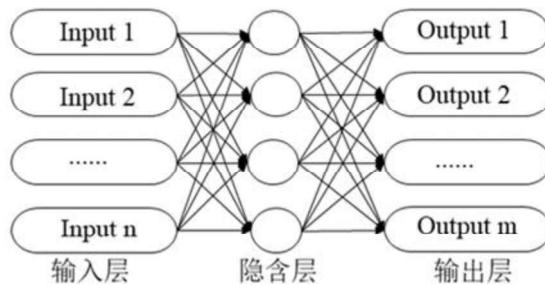


图 2.3 极限学习机基本网络结构

ELM 模型的具体过程如下：

#### 步骤 1：随机生产连接权值与偏置矩阵

一组含有  $N$  个随机样本的数据集  $(x_i, y_i), i = 1, \dots, N$  式中  $x_i = [x_{i1}, x_{i2}, \dots, x_{iN}]^T \in R^n$  表示第  $i$  个输入向量， $y_i = [y_{i1}, y_{i2}, \dots, y_{iM}]^T \in R^m$  表示第  $i$  个输出向量，有  $L$  个隐含层节点数的单层神经网络可表示为：

$$f_L(x) = \sum_{i=1}^L \beta_i g(w_i \cdot x_i + b_i), x_i \in R^n, w_i \in R^n, \beta_i \in R^m \quad (2.41)$$

式中  $g(\cdot)$  为激活函数， $\beta_i$  为是隐含层与输出层的输出权值， $w_i$  与  $b_i$  为随机产生的连接权值与偏置矩阵，当神经网络的测试样本与隐含层神经元数量一致时则有：

$$f_L(x) = \sum_{i=1}^L \beta_i g(w_i \cdot x_i + b_i) = y_i, i = 1, \dots, i \quad (2.42)$$

**步骤 2：计算隐含层输出矩阵 $H$ ，将上式可改写成为矩阵的形式，即**

$$H\beta = Y \quad (2.43)$$

$$H(w_1, \dots, w_L, b_1, \dots, b_L, x_1, \dots, x_N) = \begin{bmatrix} g(w_1x_1 + b_1) & \cdots & g(w_Lx_1 + b_L) \\ \vdots & \ddots & \vdots \\ g(w_1x_N + b_1) & \cdots & g(w_Lx_N + b_L) \end{bmatrix}_{N \times L} \quad (2.44)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times M} \quad (2.45)$$

$$Y = \begin{bmatrix} y_1^T \\ \vdots \\ y_N^T \end{bmatrix}_{N \times M} \quad (2.46)$$

$H$ 是隐含层的输出矩阵， $\beta$ 为输出数据的权重值， $Y$ 为训练集期望矩阵。

**步骤 3：计算输出权值**

求解方程组： $\min_{\beta} \|H\beta - Y\|$ 其解为 $\hat{\beta} = H^+Y$ ， $H^+$ 即为矩阵 $H$ 的广义逆。

与传统算法相比，ELM 神经网络虽然有运行速率高、参数设定少以及泛化能力高的优点，但也和其他传统算法一样容易陷入到局部最优的困境中，则会对预测精度产生一定的影响，因此本文主要用灰狼优化算法对 ELM 神经网络模型的参数进行优化，其核心思想是：选取合适的适应度函数计算灰狼个体的适应度值，通过 ELM 模型的误差反馈更新迭代最优灰狼个体位置信息，达到全局最优解的效果，并将其作为最优解，其算法流程如图 2.4 所示：

算法中训练模型通常选用 MAE、RMSE 以及 MAPE 等评价指标最小化作为适应度函数追求的目标，智能优化算法中优化问题的目标函数可以根据不同的应用场景设置不同的适应度函数，大部分的目标函数仅仅使用单一的评价指标，本文选用 MAPE 与 DS 相结合的方式设置适应度函数，具体函数设置如下：

$$F = a \times MAPE + b \times (1 - DS) \quad (2.47)$$

式中 $a + b = 1$ ，可以有效提升黄金价格预测的方向精度， $a$ 与 $b$ 的最优组合由多次分组实验进行确定。

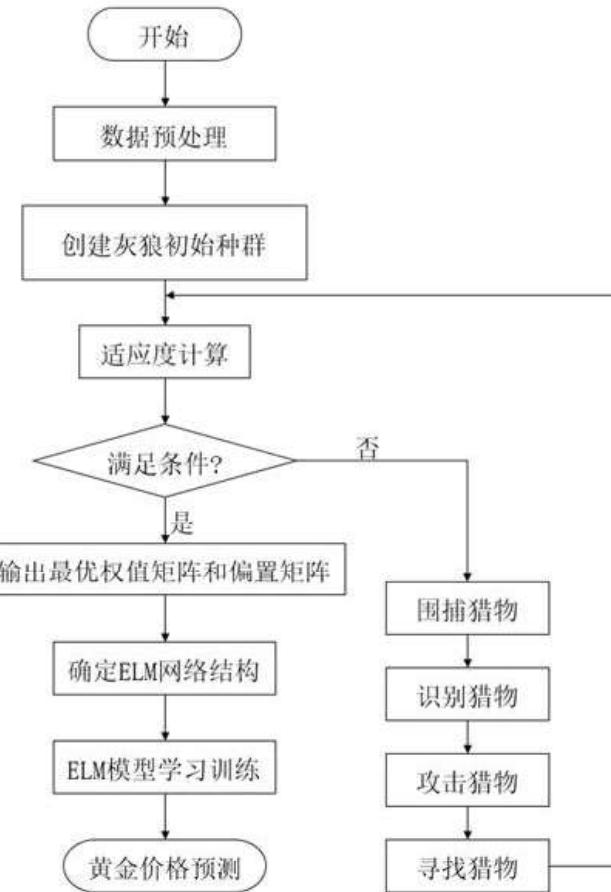


图 2.4 算法流程图

## 2.5 评价指标

本文选取平均绝对百分比误差(MAPE)、均方根误差(RMSE)、平均绝对误差(MAE)与方向精度(DS)等统计指标对模型样本外预测性能进行客观的评价，具体公式如下：

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (2.48)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (2.49)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (2.50)$$

$$D_{stat} = \frac{1}{n} \sum_{i=1}^n a_i \times 100\% \quad (2.51)$$

其中, 如果 $(\hat{y}_{i+1} - y_i)(y_{i+1} - y_i) \geq 0$ , 则 $a_i = 1$ , 表明该模型在 $i + 1$ 时刻的预测方向与真实方向一致, 则 $(\hat{y}_{i+1} - y_i)(y_{i+1} - y_i) < 0$ , 则 $a_i = 0$ , 表明模型在 $i + 1$ 时刻的方向预测错误。上述指标中, 较小的 MAE、MAPE 和 RMSE 值表明模型的预测更加接近实际值, 模型的预测精度越高; 另外, DS 值越大则意味着模型在预测趋势方向上的准确性更高, 能够更好地预测未来数据的发展趋势。

利用 IR 公式可以计算提出模型与基准模型各指标的提升率, 能更加明显的看出所选最优模型与其他对比模型之间的差距。

$$IR_{index} = -\frac{index(\text{提出模型}) - index(\text{基准})}{index(\text{基准})} \quad (2.52)$$

采用 Diebold-Mariano(DM)检验法从统计推断的角度对模型的差异性进行评判, 原假设为不同的两个模型在给定的显著性水平下没有显著的差异即不同的预测模型所得到的预测精度一致, 则 DM 检验统计量定义如下:

$$DM = \frac{E_d}{\sqrt{\hat{V}/n}} \quad (2.53)$$

式中 $d_i = (y_i - \hat{y}_{ti,i})^2 - (y_{ji} - \hat{y}_{ji,i})^2$ ,  $E_d = \sum_{i=1}^n d_i/n$ ,  $\hat{V} = \gamma_0 + 2 \sum_{j=1}^{\infty} \gamma_j$ ,  $\gamma_j = cov(d_i, d_{i-j})$ ,  $\hat{y}_{ti,i}$ 与 $\hat{y}_{ji,i}$ 表示提出模型与基准模型分别对真实值 $y_i$ 的预测结果, 当 $|DM| > Z_\alpha$ 时( $\alpha$ 为显著性水平,  $Z_\alpha$ 表示标准正态分布单侧检验的临界值), 则拒绝原假设, 认为提出模型与基准模型之间存在显著差异即提出模型的预测性能要好于基准模型, 如果 $|DM| \leq Z_\alpha$ 时, 则接受原假设, 即认为提出模型与基准模型的预测性能一致。

### 3 基于特征选择的黄金期货价格短期预测及交易效果评估

在构建黄金期货价格预测的复杂系统时，系统内各因素之间的关系暂时不能用现有理论知识进行完全合理的诠释，即尚不明确所选哪些因素与上海黄金期货价格之间的关系更加密切。这时为了避免相关重要因素被漏选，通常采用定性分析的方式选出有可能对黄金期货价格产生影响的因素，再着手构建系统的预测模型，但是在构建预测模型的过程中，随着数据维度的增加计算量也随之增大，这不仅影响模型的预测效果，同时影响模型的运行速率。对于投资者来说，相对于期货每个交易日结算价格的具体数值，他们更加关注期货价格的涨跌情况，再通过“看涨买进，看跌卖空”的方式进行获利。本文先对影响因素进行特征选择，再根据不同变量的性质为预测模型寻找最佳的输入变量，通过构建多个预测模型获得黄金期货价格短期的预测值，比较分析预测值评判出最佳预测模型，并在该模型的适应度函数中增添方向精度训练模型，以此方式来提升模型预测的方向精度。基于特征选择的黄金期货价格预测及交易效果评估模型的主要步骤概括如下：

**步骤 1** 确定主要变量，粗略选取与黄金期货有关的影响因素，利用弹性网络法确定对上海黄金期货收盘价产生影响的主要变量。

**步骤 2** 确定各变量的滞后期，利用时差相关分析法确定主要影响因素的滞后期，相空间重构法确定上海黄金期货收盘价序列自身的滞后期，最终确定神经网络的拓扑结构。

**步骤 3** 滑动窗口预测，把数据集按照固定窗宽均分成三组样本，对每组样本都分别采用 GWO-LSSVR、GWO-ELM 以及 GWO-BP 神经网络等 9 种预测模型对收盘价进行滑动窗口预测，通过不同时间段的预测值计算出 MAPE、RMSE、DS、MAE 对 9 种模型预测效果进行评价，构建 DM 检验得出最佳预测模型为 GWO-ELM 模型。

**步骤 4** 优化模型，更改 GWO-ELM 的适应度函数，进一步提升模型预测的方向精度。

**步骤 5** 回测与仿真交易，针对一步预测结果制定买入-持有-卖出交易策略，针对多步预测结果设置相应的交易策略，对比更改适应度函数前后的 GWO-ELM 模型的收益情况。

### 3.1 黄金期货价格的影响因素分析

由于单个黄金期货合约存续的生存周期时间有限,仅凭借单个合约无法有效地对黄金期货价格的长期变化趋势进行系统分析。主力合约代表了某一时期内交易量与持仓量最大的期货合约,可以更全面、系统地反映黄金期货价格的走势特征。为了对上海黄金期货进行系统、全面的分析,本文选择连续时间段内上海期货交易所的黄金期货主力合约作为研究对象。

表 3.1 所选变量情况

影响因素分类	序号	名称	单位
能源市场因素	1	英国布伦特原油	美元/桶
	2	美国西德州轻质原油	美元/桶
期货价格指标	3	收盘价	元/克
	4	成交量	手
	5	成交额	元
	6	开盘价	元/克
	7	最高价	元/克
	8	最低价	元/克
	9	伦敦铜价格	美元/吨
	10	伦敦白银价格	美元/盎司
相关现货市场因素	11	伦敦黄金价格	美元/盎司
	12	上海 Au9995	元/克
	13	上海 Au9999	元/克
	14	长江铜价格	元/吨
	15	汇率(美元兑人民币)	%
	16	中债国债 10 年收益率	%
宏观环境因素	17	美国国债 10 年收益率	%
	18	标准普尔 500 指数	点
	19	道琼斯工业平均指数	点
	20	纳斯达克综合指数	点
	21	香港恒生指数	点
	22	上证 A 股指数	点
	23	VIX 市场指数	点

已有研究和市场分析表明,影响黄金期货价格变动的因素主要分为两类,第一类是来自黄金白银等替代品市场的影响,另一类是来自其他市场的宏观经济影响。本文选取黄金白银替代品市场中因素包含上海黄金主力期货合约的收盘价、成交量、成交额、最高价、最低价、开盘价、上海 Au9995 现货价格、上海 Au9999

现货价格、伦敦黄金现货价格、伦敦白银现货价格与伦敦铜现货价与长江铜价。黄金的供需会随着经济的变化而变化，其价格会受到宏观经济的影响，本文选取的可度量的因素包括道琼斯工业平均指数、纳斯达克综合指数、上证 A 股指数、美国 10 年期国债收益率、中债国债 10 年收益率、标准普尔 500 指数、美元兑人民币汇率、香港恒生指数、VIX 市场指数、英国布伦特原油价格与美国西德州轻质原油价格。上述共有 23 个影响因素，根据各个影响因素所处的不同市场，可以把因素分为能源市场因素、期货价格指标、相关现货市场因素与宏观环境因素这四个类别，所选变量分类情况如表 3.1 所示，所有数据均来自于 Wind 数据库。

## 3.2 数据收集及预处理

### 3.2.1 数据收集

本文的研究对象是上海黄金交易所的黄金期货收盘价，研究时间为 2008 年 4 月 25 日到 2021 年 4 月 7 日。除法定节假日外，一共收集到上海黄金期货的有效交易天数为 3150 天，即 3150 条数据，数据的变化趋势和波动特征如图 3.1 所示，描述统计结果如表 3.2 所示，数据的平稳性检验如表 3.3 所示。

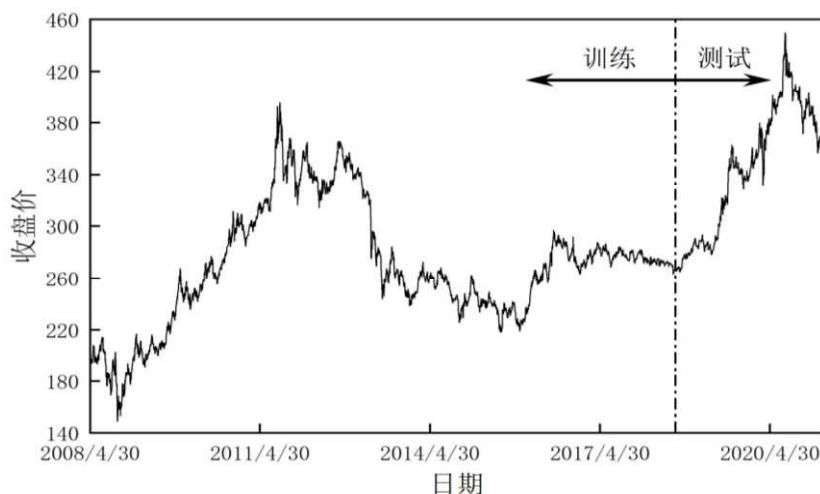


图 3.1 黄金期货价格变化趋势图

表 3.2 相关统计量表

序列	统计量	均值	最大值	最小值	中位数	标准差	峰度	偏度
黄金期货价格		284.022	449.720	148.900	275.225	55.141	0.378	-0.206

从图 3.1 中可以看出上海黄金期货收盘价序列具有高波动性、非平稳性与非线性的特征，表 3.2 中描述了所选时间区间内黄金期货收盘价的统计量，均值为 284.022；标准差为 55.141；峰度为 0.378，则说明黄金期货价格序列中偏离均值的极端值数目较少；偏度为 -0.206，偏度数值小于 0，说明黄金期货价格中左侧偏离均值的数据较多则出现拖尾偏左、峰尖偏右侧的情况。

**表 3.3 数据的平稳性检验表**

	t统计量	p值
ADF 检验统计量	-1.5685	0.4987
1% level	-3.4322	
5% level	-2.8623	
10% level	-2.5672	

对于时间序列数据，可以通过 ADF 检验法从理论的角度判断序列本身是否平稳，表 3.3 中  $p$  值为 0.4987，远大于 0.05，这说明图 3.1 中展示的上海黄金期货收盘价为非平稳时间序列。

### 3.2.2 数据预处理

考虑到影响黄金价格的相关因素宏观经济指标大多数都以月度、季度或者年度为主，若简单的对季度或者月度数据进行平均处理，可能会对预测模型的训练产生消极影响。且国内外交易市场节假日不同，导致所选取的部分影响因素的有效交易日期与黄金期货价格的 3150 条数据日期不吻合，故需要对一些变量进行预处理。

如果仅简单的选取所有变量重叠日期的数据作为研究对象，会大量减少数据样本的长度，为提高已有数据的利用率，本文采用数据插补的方式对空值进行处理。首先以上海黄金期货价格日期为基准，利用 VLOOKUP 函数查找并提取所有影响因素在该日期的样本值，再利用 R 语言编程对空值进行插值填补，当连续两个数据间存在空值时，将空值前一期与后一期的数值取均值填补当前空值；当存在连续  $p$  个空值时，针对前  $p - 1$  个空值，选用出现空值前的最后一个数据填补  $p - 1$  空值，第  $p$  个空值利用前一期与后一期取均值作为当前空值的数据，以插补的方式处理 23 种样本，每种样本均获得完整的 3150 条样本数据。

即使都是日期匹配的样本数据，数据之间的量级也不尽相同，如果某个影响因素数据量级大，那么该影响因素对模型产生较大的影响，但是量级大的影响因素可能不是影响上海黄金期货收盘价的关键因素，消除训练样本数据间的量纲差异有助于提升模型的性能。本文采用归一化的方法将训练集所有输入变量的取值范围限定到 0 与 1 之间。

### 3.3 特征选择

#### 3.3.1 正则化方法-弹性网络

利用弹性网络方法筛选变量的关键在于如何选取参数，当参数 $\alpha$ 取值为 0 时，则为岭回归；当 $\alpha$ 取值为 1 时，则为 LASSO；当 $\alpha$ 取值为[0,1]之间的数时则为弹性网络，本文选取 $\alpha = 0.6$ 。

参数 $\lambda$ 表示对系数的压缩程度，选用 R 语言中 type.measure 函数来指定交叉验证选取模型时 $\lambda$ 的值， $\lambda$ 值越大，对系数的压缩程度越大，图 3.2 横坐标为 $\log(\lambda)$ ，纵坐标为均方误差。图中两条虚线，一条是最小化均方误差所对应的 $\log(\lambda)$ 的取值，此时选择变量数目为 13；另一条是误差在最小标准误差范围之内 $\log(\lambda)$ 值，此时选择变量的数目为 17。选择均方误差最小时的 $\lambda$ 值，将其作为模型参数，期望最小化的目标参数 $\lambda = 0.112$ 。

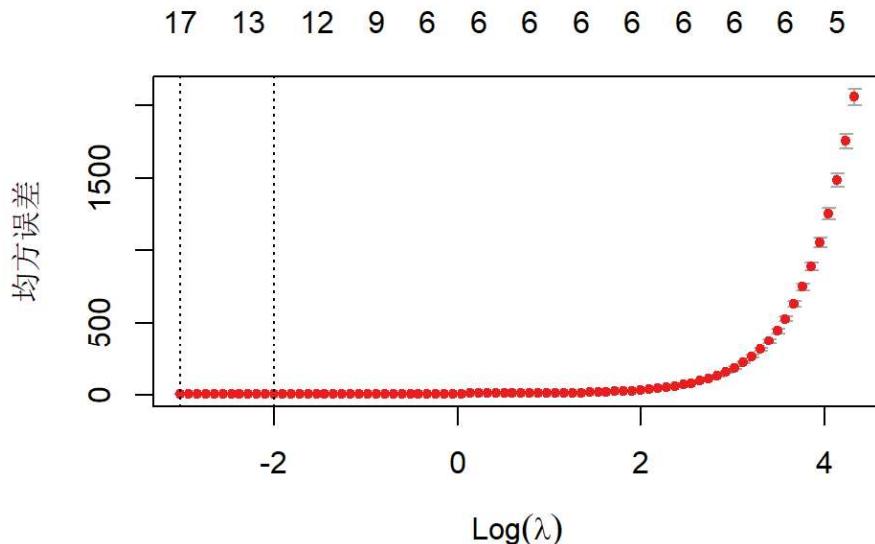


图 3.2 弹性网络交叉验证的结果图

从图 3.3 能够看出，我们选定 $\lambda$ 的取值时，该参数下弹性网络对 22 个变量进行筛选和参数估计的情况，横坐标代表 $\log(\lambda)$ ，纵坐标表示权重系数，特征变量的回归系数随着 $\log(\lambda)$ 的增大而减小，即 $\lambda$ 取值越大对变量系数的压缩程度越大。所选变量的压缩系数见表 3.4 所列，最终选取开盘价、最高价、最低价与伦敦黄金价格等 13 个变量作为黄金期货收盘价的影响因素。

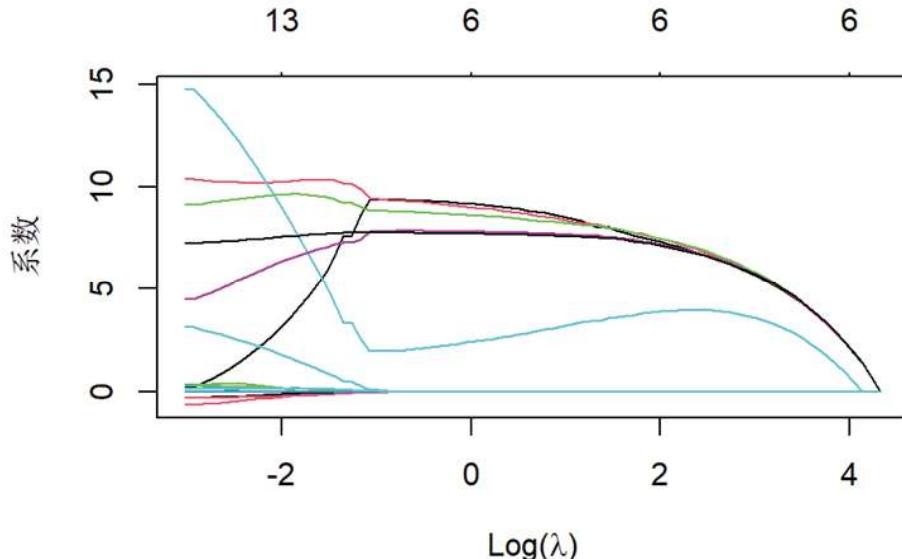


图 3.3 弹性网络系数路径图

表 3.4 黄金期货价格影响因素表

序号	变量名称	压缩系数
1	开盘价	2.359
2	最高价	10.191
3	最低价	9.553
4	伦敦黄金价格	10.381
5	上海 Au9995	5.983
6	上海 Au9999	7.477
7	美国西德州轻质原油	-0.320
8	长江铜价格	0.294
9	汇率(美元兑人民币)	2.104
10	美国国债 10 年收益率	-0.159
11	VIX 市场指数	-0.240
12	纳斯达克综合指数	0.205
13	上证 A 股指数	0.160

### 3.3.2 网络结构的确定

本文将黄金期货收盘价作为基准指标，筛选后的特征视为被影响指标并依次与基准指标做相关性分析，收盘价与所确定的 13 个影响因素之间关系可能存在滞后、领先与同期的关系。通过时差相关分析法确定所选变量与黄金期货收盘价之间的关系，表 3.5 中展示筛选变量滞后 1 期的相关系数值大于滞后 2 期、3 期、4 期以及 5 期的值，选定筛选变量滞后期均为 1 期。除了所选影响因素以外，黄金期货价格自身的波动也会对后续价格造成一定影响，选用 C-C 相空间重构法确定收盘价本身滞后 3 期的数据作为输入，即开盘价、最高价、最低价与伦敦金价等 13 个变量的滞后一期数据与收盘价滞后 3 期数据为输入，确定最终的网络拓扑结构为输入变量个数 16，预测下一期黄金期货收盘价。

表 3.5 变量相关系数表

序号	变量	1 期	2 期	3 期	4 期	5 期
1	开盘价	<b>0.9973</b>	0.9953	0.9932	0.9912	0.9893
2	最高价	<b>0.9976</b>	0.9956	0.9935	0.9915	0.9896
3	最低价	<b>0.9975</b>	0.9955	0.9935	0.9915	0.9896
4	伦敦黄金价格	<b>0.9773</b>	0.9751	0.9728	0.9705	0.9683
5	上海 Au9995	<b>0.9973</b>	0.9954	0.9935	0.9915	0.9897
6	上海 Au9999	<b>0.9973</b>	0.9954	0.9935	0.9915	0.9897
7	美国西德州轻质原油	<b>0.2754</b>	0.2735	0.2718	0.2701	0.2685
8	长江铜价格	<b>0.5431</b>	0.5427	0.5423	0.5421	0.5419
9	汇率(美元兑人民币)	<b>0.1105</b>	0.1094	0.1082	0.1071	0.1059
10	美国国债 10 年收益率	<b>0.3343</b>	0.3323	0.3304	0.3284	0.3264
11	VIX 市场指数	<b>0.5190</b>	0.5182	0.5172	0.5161	0.5148
12	纳斯达克综合指数	<b>0.3387</b>	0.3373	0.3361	0.3352	0.3346
13	上证 A 股指数	<b>0.1817</b>	0.1811	0.1807	0.1803	0.1799

### 3.4 基于特征选择的黄金期货价格预测

#### 3.4.1 预测模型及参数设置

为了研究黄金期货市场不同的规律特征，对所选时间窗口的黄金期货收盘价

及影响因素数据通过设定滑动步长为 450，将数据均分成三组样本，并针对不同的数据集进行滑动窗口预测，表 3.6 中展示了滑动窗口预测样本数据集划分情况，第一组样本为 2008 年 4 月 25 日到 2017 年 7 月 25 日，共 2250 条数据；第二组样本 2010 年 3 月 2 日到 2019 年 5 月 31 日，共 2250 条数据；第三组样本 2012 年 1 月 4 日到 2021 年 4 月 7 日，共 2250 条数据，所有数据集的前 80% 为训练集，后 20% 为测试集。

表 3.6 滑动窗口预测样本数据集划分

样本	总时间跨度	训练集时间跨度	测试集时间跨度
样本一	2008.4.25-2017.7.25	2008.4.25-2015.9.17	2015.9.18-2017.7.25
样本二	2010.3.2-2019.5.31	2010.3.2-2017.7.25	2017.7.26 -2019.5.31
样本三	2012.1.4-2021.4.7	2012.1.4-2019.5.31	2019.6.30-2021.4.7

选择不同的机器学习模型对三组样本分别进行预测，所选机器学习模型有 BP、ELM、LSSVR、通过粒子群优化算法优化的机器学习模型即 PSO-BP、PSO-ELM、PSO-LSSVR 以及通过灰狼优化算法的机器学习模型即 GWO-BP、GWO-ELM、GWO-LSSVR，总共 9 种机器学习模型，本章节所有数据预测均使用 MATLAB 2020a 软件。通过滑动窗口预测选择主要预测模型，所选 9 种模型设定的参数如表 3.7 所示：

表 3.7 模型参数设置

序号	模型	参数设置
1	BP	隐含层节点数:15
2	ELM	隐含层节点数:18
3	LSSVR	gam=1100;sig2=600
4	PSO-ELM	$C_1 = 1.8, C_2 = 1.8$ ;种群规模:20;最大进化次数:100
5	PSO-LSSVR	$C_1 = 1.8, C_2 = 1.8$ ;种群规模:20;最大进化次数:100
6	PSO-BP	$C_1 = 1.8, C_2 = 1.8$ ;种群规模:20;最大进化次数:100
7	GWO-ELM	狼群数量:20;最大进化次数:50
8	GWO-LSSVR	狼群数量:20;最大进化次数:50
9	GWO-BP	狼群数量:20;最大进化次数:50

### 3.4.2 滑动窗口预测实验结果

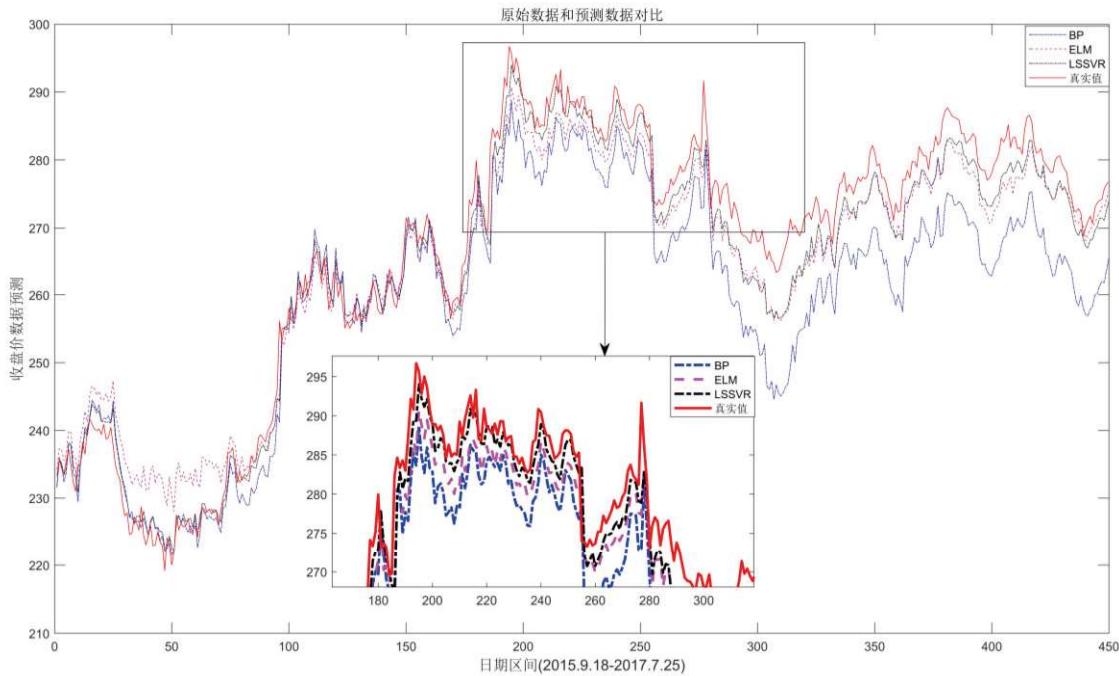


图 3.4 BP、ELM、LSSVR 预测模型样本一数据预测图

图 3.4 展示了 BP、ELM、LSSVR 预测模型对样本一数据的预测图，其中 LSSVR 模型的效果较好，其次是 ELM 模型，BP 神经网络效果一般。ELM 模型的预测结果优于 BP 神经网络这可能是由于 BP 神经网络参数存在随机性导致的，且 BP 神经网络需要进行大量迭代计算，计算量大于 ELM 神经网络；LSSVR 模型优于 ELM 模型可能是因为 LSSVR 模型通过核函数将非线性数据映射到更高维的空间中，使该算法有更强的预测能力。

图 3.5 展示了样本一数据在 ELM 神经网络与 PSO-ELM、GWO-ELM 的预测效果图，其中 GWO-ELM 的预测效果好于单一 ELM 模型与 PSO-ELM 神经网络。这可能是由于不断迭代导致粒子群优化算法种群多样性逐渐降低，出现早熟收敛现象并且粒子群优化需要自主设置的参数较多，算法性能受到参数取值的影响较大。相比之下 GWO-ELM 优化算法存在位置更新且迭代更新的空间复杂度远小于粒子群优化算法，这使得灰狼优化算法有操作简单、设置参数少、鲁棒性强、收敛速度更快、求解精度高等优点。GWO-ELM 模型的预测曲线走势能更好的贴合真实数据，这说明 GWO-ELM 能很好的捕捉黄金期货收盘价的非线性。

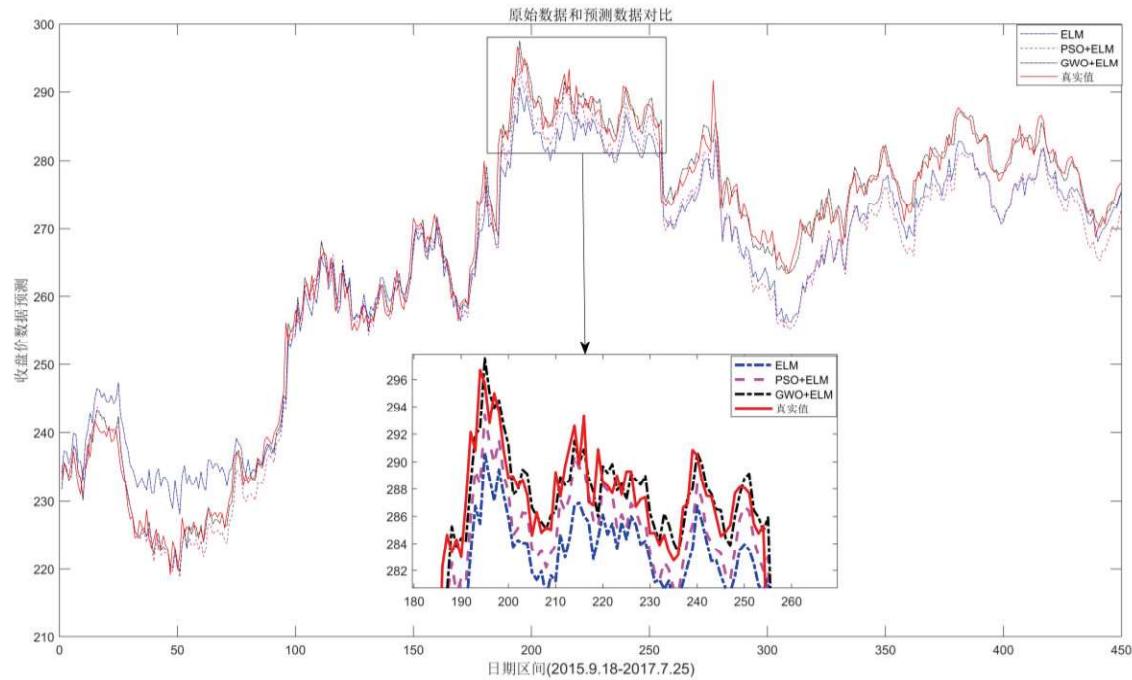


图 3.5 ELM 与 PSO-ELM、GWO-ELM 模型样本一数据预测图

表 3.8 展示了样本一数据所选 9 组模型预测结果的评价指标，其中 GWO-ELM 模型有较高的预测精度，较小 RMSE、MAPE 与 MAE。利用粒子群优化算法优化过的 BP、ELM、LSSVR 模型在 RMSE、MAPE 与 MAE 的数值均小于单一 BP、ELM 与 LSSVR 模型；然而 GWO-BP 与 GWO-LSSVR 的预测效果较差，可能是由于灰狼优化所选参数并不适用该组模型。

表 3.8 样本一预测评价指标(2015.9.18-2017.7.25)

方法	BP	ELM	LSSVR	PSO-BP	PSO-ELM	PSO-LSSVR	GWO-BP	<b>GWO-ELM</b>	GWO-LSSVR
RMSE	9.22	5.02	3.67	3.42	4.53	3.44	9.37	<b>2.04</b>	6.12
MAPE/%	2.75	1.63	1.08	1.00	1.38	1.05	2.86	<b>0.55</b>	1.96
MAE	7.52	4.27	2.90	2.65	3.71	2.79	7.78	<b>1.45</b>	5.29
DS/%	53.11	53.56	56.89	58.44	53.78	55.33	53.11	<b>67.11</b>	52.67

表 3.9 展示了样本二数据所选 9 组模型预测结果的评价指标，其中 GWO-ELM 模型有较高的预测精度，较小 RMSE、MAPE 与 MAE。GWO-ELM、GWO-LSSVR、PSO-BP、PSO-ELM 及 PSO-LSSVR 的评价指标 RMSE、MAPE 与 MAE 均好于其对应的单一模型，这说明智能优化算法可以有效提升模型的预测能力。

表 3.9 样本二预测评价指标(2017.7.26 -2019.5.31)

方法	BP	ELM	LSSVR	PSO-BP	PSO-ELM	PSO-LSSVR	GWO-BP	<b>GWO-ELM</b>	GWO-LSSVR
RMSE	6.18	4.02	2.64	3.89	3.42	2.26	6.95	<b>1.23</b>	1.48
MAPE/%	1.89	1.21	0.79	1.23	0.93	0.67	1.75	<b>0.34</b>	0.41
MAE	5.25	3.34	2.18	3.37	2.61	1.84	4.85	<b>0.93</b>	1.15
DS/%	51.33	54.22	55.78	50.67	55.33	53.3	54.89	<b>64.89</b>	59.11

表 3.10 展示了样本三数据所选 9 组模型预测结果的评价指标，其中 GWO-ELM 模型的方向精度远大于其他模型，其 RMSE、MAPE 与 MAE 均小于其他对比模型。

表 3.10 样本三预测评价指标(2019.6.30-2021.4.7)

方法	BP	ELM	LSSVR	PSO-BP	PSO-ELM	PSO-LSSVR	GWO-BP	<b>GWO-ELM</b>	GWO-LSSVR
RMSE	10.22	12.40	11.52	10.71	7.84	14.67	17.59	<b>3.55</b>	4.94
MAPE/%	2.16	2.41	2.49	2.48	1.62	3.16	3.64	<b>0.70</b>	1.01
MAE	7.94	9.36	9.56	8.83	6.20	12.22	13.74	<b>2.59</b>	3.70
DS/%	53.33	53.56	48.00	51.33	48.89	46.40	48.44	<b>62.00</b>	52.00

表 3.8、3.9 和表 3.10 分别展示了在不同时间段，9 组模型的预测效果，GWO-ELM 在三组不同时间段均展现了较好的预测效果，其中 RMSE、MAPE 与 MAE 在同组对比模型中数值最小，方向精度 DS 最大。从评价指标的角度对所选模型进行分析，说明 GWO-ELM 预测模型具有稳健性，对于三组不同的样本进行滑动窗口预测预测均展现出良好的预测性能，因此本文选用 GWO-ELM 模型作为主要预测模型。

表 3.11 样本一 DM 检验

目标模型	GWO-ELM	DM 值	P 值
对比模型	PSO-BP	-9.2333393	1.1323E-18
	PSO-LSSVR	-12.636924	1.7896E-31
	LSSVR	-11.467481	7.9327E-27
	PSO-ELM	-14.673777	4.9481E-40
	ELM	-16.927289	5.5034E-50
	GWO-LSSVR	-20.134914	1.2858E-64
	BP	-18.063197	3.978E-55
	GWO-BP	-17.57923	6.273E-53

为了从理论意义上判断 GWO-ELM 模型与其他 8 个对比模型之间是否有显著性差异，采用 DM 检验判断其差异性，表 3.11 展现了以 GWO-ELM 模型为目标模型与其他对比模型得出的 DM 值与 P 值，其中 8 组对比模型的 P 值都接近 0，这说明 GWO-ELM 模型显著优于其他 8 组对比模型，更加印证了 GWO-ELM 模型在黄金期货收盘价预测中的合理性与有效性。

表 3.12 展现了 GWO-ELM 模型与其他模型在统计指标方面的提升率，从统计指标中能更加直观看出 GWO-ELM 模型明显优于其他对比模型。从滑动窗口预测角度出发，在三组样本中 GWO-ELM 都预测效果都好于其他 8 种对比模型，从统计检验的角度，GWO-ELM 的预测效果在理论上要优于其他模型。综上所述，从多角度均证明了 GWO-ELM 模型的优越性。

**表 3.12 GWO-ELM 指标提升率**

优化算法预测模型	序号	$IR_{RMSE}$	$IR_{MAPE}$	$IR_{MAE}$
PSO-BP	样本一	40.35%	45.00%	45.28%
	样本二	68.38%	72.36%	72.40%
	样本三	66.85%	71.77%	70.67%
PSO-ELM	样本一	54.97%	60.14%	60.92%
	样本二	64.04%	63.44%	64.37%
	样本三	54.72%	56.79%	58.23%
PSO-LSSVR	样本一	40.70%	47.62%	48.03%
	样本二	45.58%	49.25%	49.46%
	样本三	75.80%	77.85%	78.81%
GWO-BP	样本一	78.23%	80.77%	81.36%
	样本二	82.30%	80.57%	80.82%
	样本三	79.82%	80.77%	81.15%
GWO-LSSVR	样本一	66.67%	71.94%	72.59%
	样本二	16.89%	17.07%	19.13%
	样本三	28.14%	30.69%	30.00%

### 3.4.3 IGWO-ELM 改进模型

神经网络模型通过设置不同的适应度函数，可以根据期望目标训练出不同的预测模型，由于黄金期货价格具有特定性、预期性以及交易敏感性，其方向精度指标可以体现出预测模型的预测涨跌方向是否与真实数据一致。在训练模型的过程中，通常使用单一水平精度的指标对模型进行训练，相对于期货在预测数据上

的精确度，投资者更加关注期货的涨跌情况。考虑到方向指标精度准确性对投资者的重要性，在训练模型的过程中加入方向精度这一指标对模型进行训练从而提升模型在方向精度上的预测效果。水平精度主要从数据的数值方面体现预测值与真实值之间的接近程度，现通过结合方向精度与水平精度的方式训练模型从而提升模型的预测性能。

本节对全样本的数据按照 8 比 2 划分训练数据与测试数据，训练集样本为 2008 年 4 月 25 日到 2018 年 8 月 29 日，共 2520 条数据，测试集为 2018 年 8 月 30 日到 2021 年 4 月 7 日，共 630 条数据。本文选取 MAPE 与 DS 相结合的方式对模型适应度函数进行修改如式(2.47)，MAPE 作为预测模型在数值精度中的代表，DS 作为预测模型在方向精度上的代表。

$$F = a \times MAPE + b \times (1 - DS) \quad (2.47)$$

本文通过多次实验的方式确定 MAPE 与 DS 之间的最佳比例，表 3.13 中展现了更改 GWO-ELM 模型适应度函数后所得预测模型的评价指标。

表 3.13 更改适应度函数预测模型评价指标

	1 比 9	2 比 8	3 比 7	4 比 6	5 比 5	6 比 4	7 比 3	8 比 2	9 比 1	原始
RMSE	3.13	<b>2.99</b>	3.00	3.26	4.00	3.70	3.15	3.72	3.30	3.08
MAPE/%	0.61	<b>0.56</b>	0.59	0.62	0.72	0.70	0.63	0.72	0.67	0.61
MAE	2.18	<b>2.00</b>	2.09	2.22	2.58	2.52	2.24	2.57	2.37	2.13
DS/%	68.25	<b>71.75</b>	68.57	68.73	66.51	67.14	67.46	67.78	66.19	64.44

表 3.13 中展现了更改适应度函数预测模型的评价指标，通过设定不同比例的适应度函数与仅用水平精度(原始模型)对预测模型进行训练结果如表 3.13 所示，其中 1 比 9 为 MAPE 占比 10%，(1-DS)占比 90%时所得预测模型的评价指标。当 MAPE 占比为 20%，(1-DS)占比为 80%时所得预测模型相比于其他比例的预测模型有较小的水平精度以及较好的方向精度，即确定该比例为更改适应度函数的最佳比例。

图 3.6 展示了适应度函数为 20%MAPE 与 80%(1-DS)相结合的 GWO-ELM 模型与原始 GWO-ELM 模型的预测结果，图中更改适应度函数的 GWO-ELM 模型记作 IGWO-ELM；原始模型预测结果用 GWO-ELM 表示，从图 3.6 中能够直观的看出 IGWO-ELM 模型的预测值能更好的贴近真实值的走势。

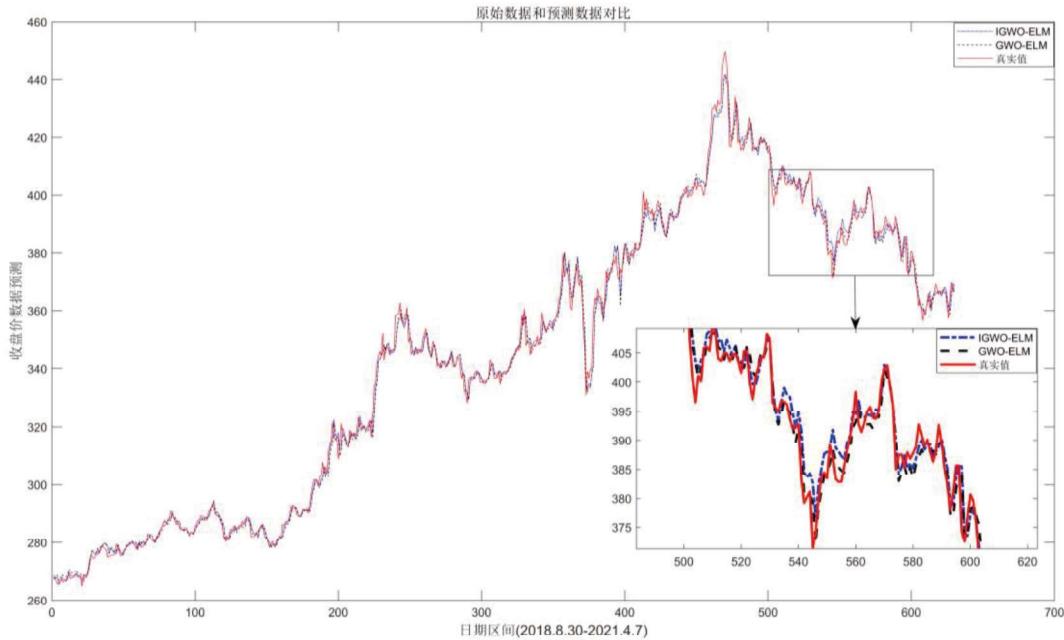


图 3.6 IGWO-ELM 与 GWO-ELM 模型的预测结果

选取适应度函数为 20%MAPE 与 80%(1-DA)GWO-ELM 模型即 IGWO-ELM 为最优预测模型，预测结果如图 3.6 所示，利用该适应度函数的模型对所选数据段数据进行一步预测、两步预测与三步预测。一步预测即利用 T 时刻历史信息预测 T+1 时刻的收盘价，两步预测即利用 T 时刻的历史信息预测 T+2 时刻的收盘价，三步预测即利用 T 时刻的历史信息预测 T+3 时刻的收盘价。

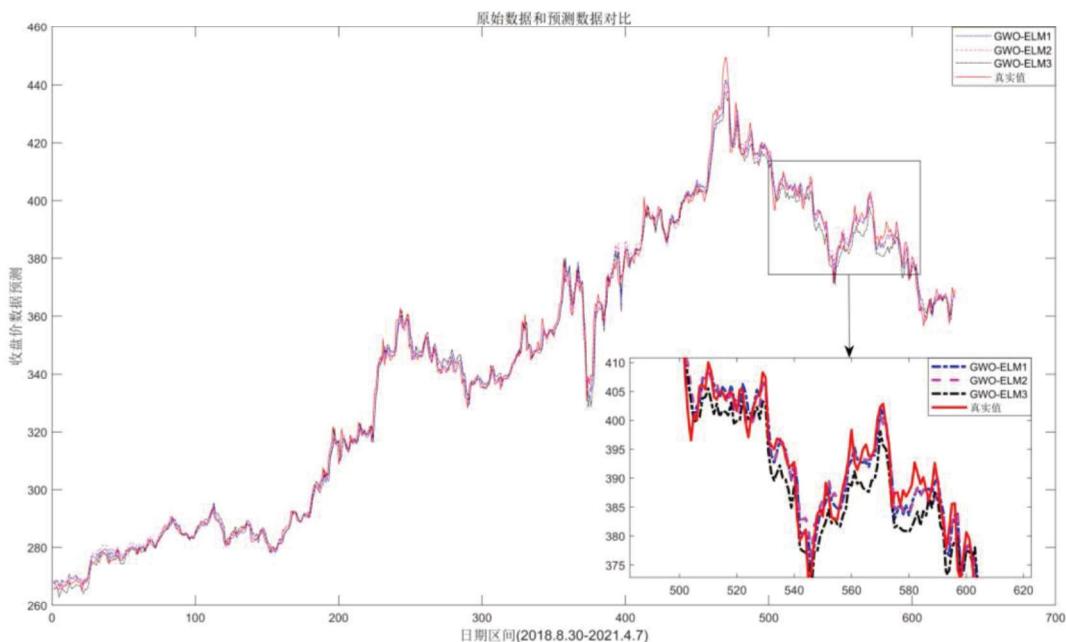


图 3.7 GWO-ELM 多步预测结果

图 3.7 展示了真实数据与利用原始 GWO-ELM 模型进行一步预测、两步预测及三步预测的结果。从图 3.7 中可以看出相对于多步预测，一步预测的折线走势更加贴近原始数据的走势，两步预测与三步预测随着预测步数的增加误差也有所增加。

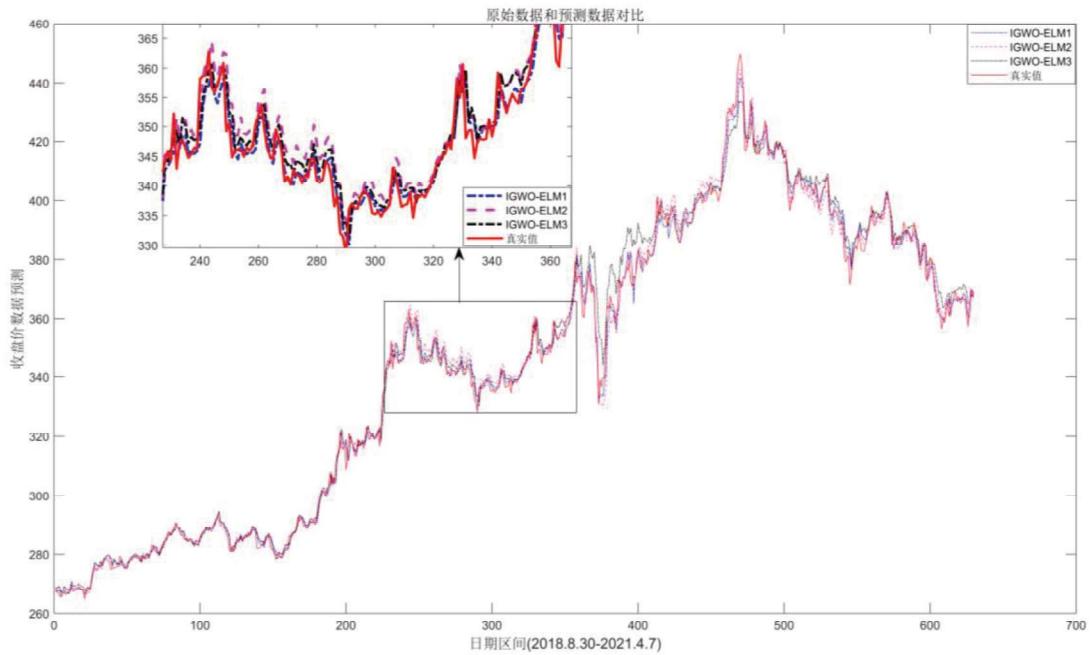


图 3.8 IGWO-ELM 多步预测结果

图 3.8 展示了真实数据与 IGWO-ELM 一步预测、两步预测及三步预测的结果，从图 3.8 中可以看出一步预测的预测曲线即 IGWO-ELM1 与真实数据之间更加贴合，两步预测曲线 IGWO-ELM2 与三步预测曲线 IGWO-ELM3 在走势上大体与真实数据保持一致。

表 3.14 与表 3.15 主要从评价指标的角度对预测结果进行分析，IGWO-ELM 模型一步及多步预测的方向精度指标都要好于原始 GWO-ELM 模型的结果。更改适应度的 IGWO-ELM 模型在一步预测中的评价指标都要好于原始模型，但其两步预测与三步预测的 RMSE、MAPE 与 MAE 数值要略大于原始模型，这可能是在训练模型的过程中考虑方向精度导致模型训练过程中不再仅仅追求数值上的精确性。更改适应度函数的模型在多步预测中的方向精度都能稳定高于 55%，该模型在多步预测中的稳健性为期货交易策略铺垫了坚实的基础。

**表 3.14 GWO-ELM 多步预测评价指标对比**

方法	一步预测	两步预测	三步预测
RMSE	3.08	4.48	6.16
MAPE/%	0.61	0.90	1.23
MAE	2.13	3.19	4.35
DS/%	64.44	52.62	51.43

**表 3.15 IGWO-ELM 多步预测评价指标对比**

方法	一步预测	两步预测	三步预测
RMSE	2.99	4.82	6.55
MAPE/%	0.56	0.95	1.25
MAE	2.00	3.34	4.43
DS/%	71.75	58.19	56.53

## 3.5 交易效果评估

### 3.5.1 买入-持有-卖出策略

在金融市场上，期货交易者通常会利用一系列技术分析工具，例如图表分析、趋势线分析、技术指标并结合自身经验和市场趋势对未来的期货价格进行预测。当投资者依据自身经验判断价格走势上涨时，买进相应的期货合约；但是当判断期货价格有下降迹象时，卖出相应的期货合约即做出空头的交易策略，投资者从差价中赚取利润。期货投资者的预测可能受到个人情感因素及偏见影响导致投资者判断失误造成投资失败。

本文选用买入-持有-卖出策略，针对 GWO-ELM 与 IGWO-ELM 的模型数据进行交易回测，设定该策略为策略 1。首先将实际值与一步预测价格进行对比，当今天实际值小于明天的预测值，则评定第二天期货价格呈现上涨趋势；当实际值大于一步预测所得预测值时，则判定第二天价格有下降迹象，以预测结果推断出期货上涨下跌为交易信号并对下阶段持仓状态做出相应调整，做出开仓或者平仓的决策，设置初始交易金额为 50 万，暂不考虑交易费用，设定每次买入卖出为交易资金的 70%，按照买入-持有-卖出策略对 2018 年 8 月 30 日到 2021 年 4

月 7 日，即预测所得 630 条数 IGWO-ELM 所得黄金期货一步预测数据进行交易回测，最后对该策略回测表现进行系统性分析，买入-持有-卖出具体流程如下：

(i)  $\hat{X}_{t+1}$  表示  $t + 1$  时刻的预测价格， $X_t$  表示  $t$  时刻的真实价格。若  $\hat{X}_{t+1} > X_t$  则判断  $t$  时刻价格为上涨，在  $t$  时进行开多仓， $\hat{X}_{t+2} > X_{t+1}$  判断价格持续上涨继续持有，当首次出现  $\hat{X}_{t+i+1} < X_{t+i}$  则进行平仓，并反向开同等仓位空仓。

(ii) 若  $\hat{X}_{t+1} < X_t$  则判断  $t$  时刻价格为下跌，在  $t$  时进行开空仓， $\hat{X}_{t+2} < X_{t+1}$  判断价格持续上涨继续持有，当首次出现  $\hat{X}_{t+i+1} > X_{t+i}$  则进行平仓，并反向开同等仓位多仓。

(iii) 在交易期即将结束时，若仓位中还有期权合约则进行强制平仓，并计算出整个交易期的收益率、最大回撤、交易次数等交易策略评价指标。

最大回撤率是指在某一段时间内，投资组合或资产价格从高点到低点的最大跌幅，即从高峰到低谷之间的最大百分比下降幅度，该指标可以帮助投资者评估投资组合或资产的风险水平和波动性，最大回撤率的公式如下：

$$\text{Max Drawdown} = \frac{\text{Max}(P_x - P_y)}{P_x} \quad (3.1)$$

其中  $P_x$  为第  $x$  天的价格， $P_y$  为第  $y$  天的价格，式中  $x < y$ 。

夏普比率(Sharpe Ratio): 表示策略表示单位风险所获得的超额收益，是一个无单位数值。 $R_p$  是投资组合的预期收益率， $R_f$  是无风险收益率， $\sigma_p$  是投资组合收益率的标准差，夏普比率越高，说明投资组合单位风险所获得的超额收益越高，夏普比率的公式如下：

$$\text{Sharpe Ratio} = \frac{(R_p - R_f)}{\sigma_p} \quad (3.2)$$

年化收益率(Total Annualized Returns, TAR): 表示在一个投资周期内投资策略的平均年化增长率，它可以帮助投资者更好地比较不同投资策略表现， $R$  表示策略累计收益率， $N$  表示该策略回测时间，年化收益率公式如下：

$$\text{TAR} = \left( (1 + R)^{\frac{1}{N}} - 1 \right) \times 100\% \quad (3.3)$$

图 3.9 是基于 IGWO-ELM 模型预测结果，设定买入-持有-卖出的多头交易回测得到的结果。在此过程中，采用该策略共完成了 466 次交易，整个阶段的盈利

总额约为 1315881 元，总收益率达到了 163.18%，此外该策略的总体回撤率为 2.236%，表明该策略具有一定的投资价值。利用买入-持有-卖出策略对 GWO-ELM 一步预测效果进行回测，在 630 天中进行了 410 次交易，总盈利约为 1173483 元，总收益率为 134.67%，该策略的总体回撤率为 4.223%。

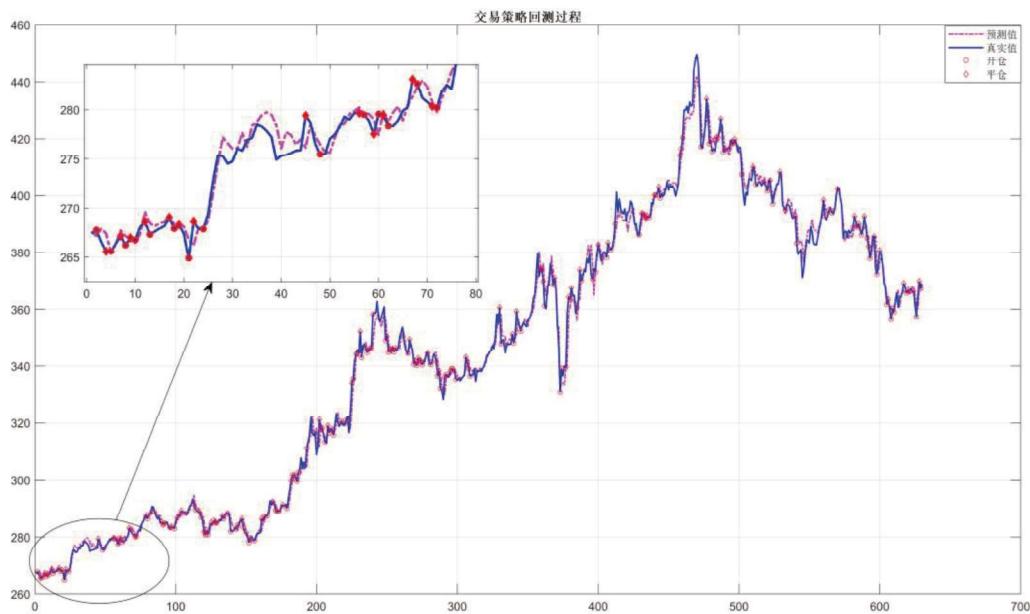


图 3.9 买入-持有-卖出交易策略回测过程

表 3.16 一步预测交易回测结果

模型	最终金额/元	收益率	交易次数	最大回撤率
GWO-ELM	1173483	134.67%	410	4.223%
IGWO-ELM	1315881	163.18%	466	2.236%

表 3.16 展示了针对 IGWO-ELM 与原始 GWO-ELM 模型一步预测结果进行回测的结果，利用买入-卖出-持有策略都能在回测中获益，表明该策略具有一定的投资价值。其中 IGWO-ELM 的回测结果交易次数与最大回撤小于 GWO-ELM 模型、收益率与最终金额高于 GWO-ELM 模型，这是因为更改适应度函数的预测模型有较高的方向精度，在交易方面能够更精确地判断市场的走势，减少错误的交易判断，从而有效减少交易次数并获得更大的收益。如果预测模型方向精度高，那么交易策略就能在交易方面获得更好的表现，这也进一步证明了预测模型精度对于交易策略的影响。图 3.10 展示了基于 IGWO-ELM 模型通过买入

-持有-卖出策略进行回测的收益曲线、仓位变化情况以及最大回撤率。

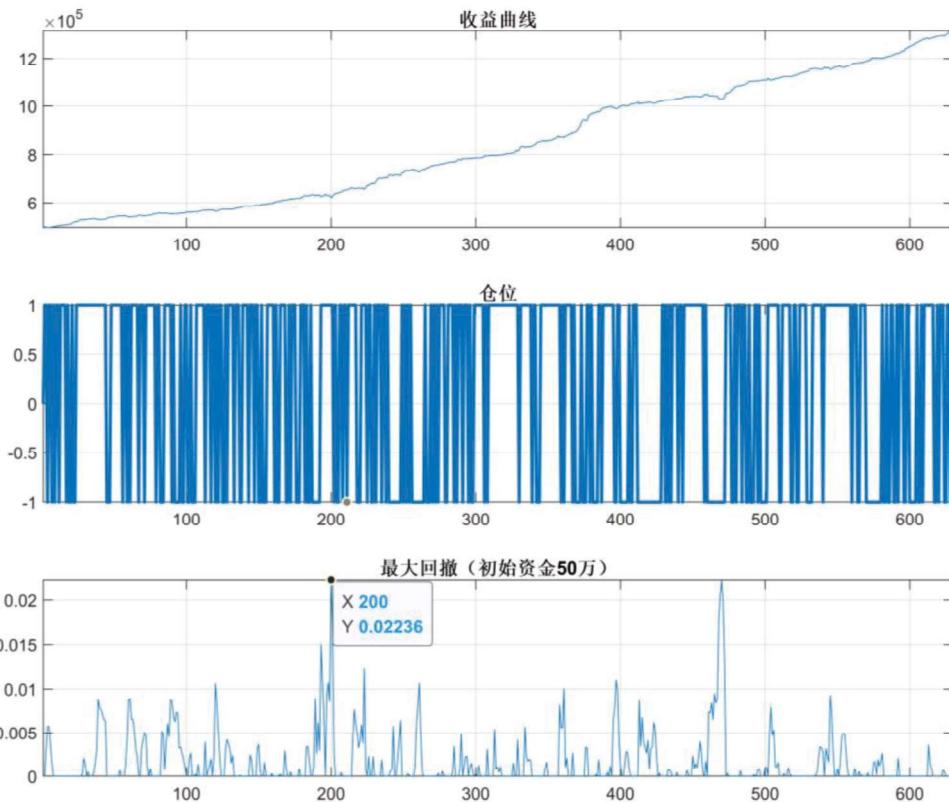


图 3.10 策略 1 收益曲线、仓位、最大回撤回测展示图

策略 2 是针对策略 1 的买入-持有-卖出策略进行优化，设置初始交易金额为 50 万，暂不考虑交易费用，设每次买入卖出为本金与每次所得利润的 70% 而非设定固定资金的 70%，选 IGWO-ELM 模型 2018 年 8 月 30 日到 2021 年 4 月 7 日的预测结果进行回测。所得交易收益曲线、仓位、最大回撤如图 3.11 所示，所得评价指标由表 3.17 所示。

表 3.17 一步预测交易回测结果

策略	最终金额/元	收益率	交易次数	最大回撤率	年化收益率	夏普比率
策略 1	1315881	163.18%	466	2.236%	94.54%	8.0217
策略 2	2603006	420.60%	466	4.837%	243.68%	7.6369

表 3.17 展示了买入-持有-卖出策略设定不同的交易资金，策略 2 在策略 1 的基础上提高了所得资金的利用率，在相同的交易次数下，策略 2 能获得更高的收

益。策略 2 的最大回撤率大于策略 1，夏普比率小于策略 1，但年化收益率与最终金额均高于策略 1，提高资金利用率可以获得更高的收益。

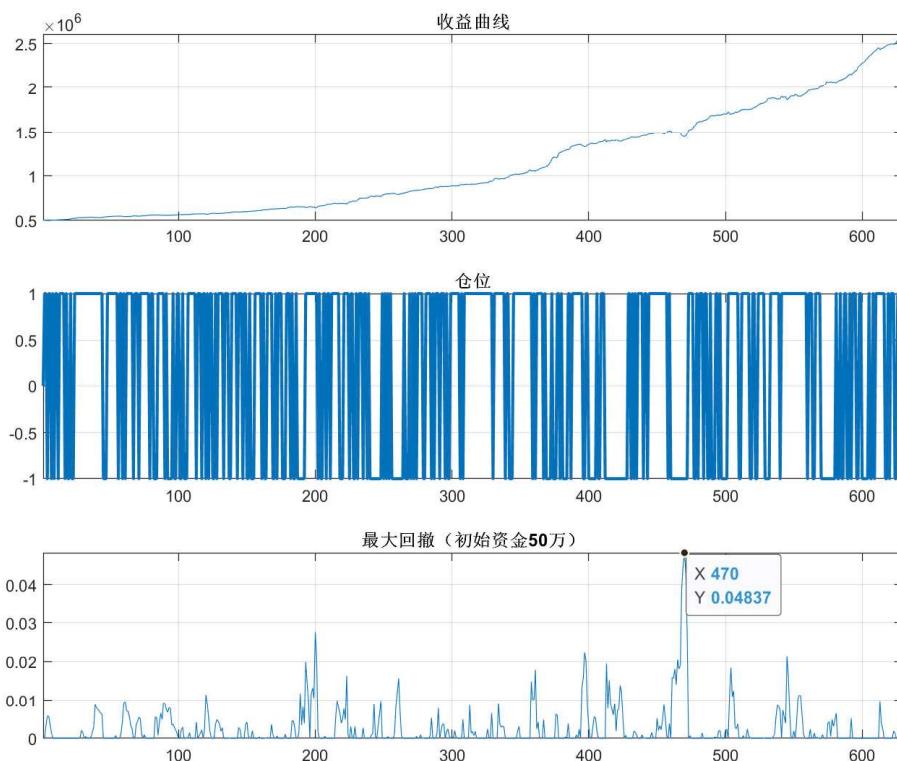


图 3.11 策略 2 收益曲线、仓位、最大回撤回测展示图

### 3.5.2 针对多步预测的交易策略

在买入-持有-卖出交易策略中，仅针对一步预测结果设定了相对应的交易策略，即当预测价格高于当日真实价格时，进行买入；当预测价格低于当日真实价格时，进行卖出。针对两步预测和三步预测结果，也可以设置不同的交易策略。例如，针对两步预测结果，可以考虑在一步预测策略的基础上，增加一个判断条件；对于三步预测结果，可以再次增加判断条件，根据预测的价格变化趋势选择更加灵活的交易策略。总之，在交易策略中，需要根据预测结果和市场变化情况，灵活地选择不同的交易策略以提高交易的收益和风险控制能力。针对 2018 年 8 月 20 日至 2021 年 4 月 7 日所得一步预测、两步预测与三步预测结果设置 4 种不同的交易策略，基于未来两步预测信息的策略分为策略 A 与策略 B，基于未来三步预测信息的策略分为策略 C 与策略 D，具体策略如下：

**策略 A:**

(i) 对比真实价格与所选模型预测价格并对 T+1 与 T+2 日的价格涨跌情况进行分析, 如果 T 日真实价格 < T+1 日预测价格且 T 日真实价格 < T+2 日预测价格, 则判断未来价格上涨, 在 T 日进行开多仓; 当未来一天的预测价格大于当日真实价格时, 则一直持有; 当预测未来某天的价格低于当日真实价格且价格下降趋势明显, 进行平仓操作。

(ii) 如果 T 日真实价格 > T+1 日预测价格且 T 日真实价格 > T+2 日预测价格, 则判断未来价格下跌, 在 T 日进行开空仓; 当未来一天的预测价格小于当日真实价格时, 则一直持有; 当未来某天的预测价格高于当日真实价格且上升趋势明显, 此时进行平仓操作以获得收益。

**策略 B:**

(i) 如果 T 日真实价格 < T+1 日预测价格且 T+1 日预测价格 < T+2 日预测价格, 则判断未来价格上涨, 在 T 日进行开多仓; 当未来一天的预测价格大于当日真实价格时, 则一直持有; 当预测未来某天的价格低于当日真实价格且下降趋势明显, 进行平仓操作。

(ii) 如果 T 日真实价格 > T+1 日预测价格且 T+1 日预测价格 > T+2 日预测价格, 则判断未来价格下跌, 在 T 日进行开空仓; 当未来一天的预测价格小于当日真实价格时, 则一直持有; 当未来某天的预测价格高于当日真实价格且上升趋势明显, 此时进行平仓操作以获得收益。

**策略 C:**

(i) 对比真实价格与所选模型预测价格并对 T+1、T+2 与 T+3 日的价格涨跌情况进行分析, 如果 T 日真实价格 < T+1 日预测价格且同时小于 T+2 日与 T+3 日预测价格, 则判断未来价格上涨, 在 T 日进行开多仓; 当未来一天的预测价格大于当日真实价格时, 则一直持有; 当预测未来某天的价格低于当日真实价格且下降趋势明显, 进行平仓操作。

(ii) 如果 T 日真实价格 > T+1 日预测价格且同时大于 T+2 日与 T+3 日预测价格, 则判断未来价格下跌, 在 T 日进行开空仓; 当未来一天的预测价格小于当日真实价格时, 则一直持有; 当未来某天的预测价格高于当日真实价格且上升趋势明显, 此时进行平仓操作以获得收益。

### 策略 D:

(i)如果 T 日真实价格<T+1 日预测价格<T+2 日预测价格<T+3 日预测价格，则判断未来价格上涨，在 T 日进行开多仓；当未来一天的预测价格大于当日真实价格时，则一直持有；当预测未来某天的价格低于当日真实价格且下降趋势明显，进行平仓操作。

(ii)如果 T 日真实价格>T+1 日预测价格>T+2 日预测价格>T+3 日预测价格，则判断未来价格下跌，在 T 日进行开空仓；当未来一天的预测价格小于当日真实价格时，则一直持有；当未来某天的预测价格高于当日真实价格且上升趋势明显，此时进行平仓操作以获得收益。

表 3.18 不同策略对比

策略	最终金额/元	交易次数	收益率	最大回撤率	年化收益率	夏普比率
策略 A	572201	172	14.44%	10.59%	8.37%	0.5466
策略 B	582053	144	16.41%	10.3%	9.51%	0.7340
策略 C	572152	157	14.43%	9.042%	8.36%	0.5959
策略 D	583740	55	16.748%	3.032%	9.70%	1.2950
策略 1	1315881	466	163.18%	2.236%	94.54%	8.0217
策略 2	2603006	466	420.60%	4.837%	243.68%	7.6369

表 3.18 展示了上述四种交易策略的最终金额、交易次数、收益率与最大回撤率，相较于针对一步预测设定的买入-持有-卖出策略，针对两步与三步预测设定 4 的种交易策略条件更加严苛，可能导致收益上的不如买入-持有-卖出策略，但是却能够在交易次数方面进行有效的优化，基于多步预测结果设定的交易策略有助于降低交易成本，同时也能够更好地适应市场的波动和变化，从而提高交易的稳定性。

制定交易策略需要综合考虑多种因素，如预测精度、风险、收益等指标并根据市场情况进行动态调整，通过不断评估和优化交易策略，可以进一步提高其有效性和适应性，从而实现更好的投资收益。

### 3.6 本章小结

选用多变量对上海黄金期货收盘价构建弹性网络-IGWO-ELM 预测模型，结果表明：

(1)在金融领域中，数据往往具有高维度和多重共线性等特点，采用弹性网络方法对影响因素进行筛选，可以将模型中不相关的变量进行降维处理，从而在模型中少噪声和冗余信息的干扰，该方法也能有效减少预测模型的训练时间并提升模型的预测性能。

(2)从数据驱动角度分析特征选择的变量与研究黄金期货价格之间的领先-滞后关系，选用 C-C 相空间法确定黄金期货收盘价本身的滞后期，最终通过时差相关分析法选定输入变量的维度，最终确定神经网络预测模型的拓扑结构。

(3)鉴于传统预测方法在处理非线性金融时间序列时存在一定的局限性，本研究采用极限学习机理论作为研究基础，旨在利用该方法进一步提高金融时间序列预测的准确性。即构建灰狼优化算法优化极限学习机的上海黄金期货价格预测模型对其进行分析预测。通过滑动窗口预测的方式分别对三组样本的 BP、LSSVR、ELM、PSO-BP、PSO-LSSVR、PSO-ELM、GWO-BP、GWO-ELM 与 GWO-LSSVR 模型预测结果进行对比分析，充分证明了 GWO-ELM 模型的稳健性。

(4)利用 GWO 优化传统 ELM 神经网络的参数并通过设置方向精度与水平精度相结合的适应度函数训练预测模型能更好的捕捉收盘价的非线性特征，设置买入-持有-卖出策略对传统 GWO-ELM 模型与 IGWO-ELM 的预测结果进行回测，更改适应度函数的 IGWO-ELM 最大回撤小于对比模型且收益率要高于对比模型。

(5)通过买入-持有-卖出交易策略对一步预测结果进行回测分析，进一步说明更改适应度函数的预测模型有助于提高投资收益率，针对多步预测设计的交易策略可以有效减少交易次数，但其最大回测率高于买入-持有-卖出策略，文中设计的交易策略都能获得收益，因此弹性网络-IGWO-ELM 模型为黄金期货收盘价以及其他金融类时间序列的预测提供了一种可行有效的方法。

## 4 基于特征融合的黄金期货价格短期预测及交易效果评估

仅使用单一的历史市场数据及部分宏观经济因素指标可能存在忽略的因素，随着大众接受信息方式的多元化，互联网搜索量可以从一定程度上反映出大众对某些事物的关注度。例如，Google 率先推出搜索趋势指数查询，2006 年百度启动百度搜索指数查询服务，百度指数是基于使用百度搜索页面的海量用户行为进行统计的数据结果，百度指数主要由 PC 端与移动端的搜索数据加和形成，移动端的百度指数直到 2011 年正式推出。百度指数作为衡量投资者关注度的指标具有多方面的优势，其一：百度是中国境内最大的中文搜索引擎，据统计百度占据了国内搜索引擎市场约 80% 的市场份额，该搜索引擎有绝大多数中国网民的用户群体；其二：百度搜索指数主要以天为单位进行统计，谷歌搜索指数以周为单位进行统计，百度指数更加精确的反映用户对特定关键词或主题的搜索趋势、热度变化，有助于进一步挖掘和开发用户的搜索行为、兴趣和需求；其三：百度指数具备主题明确、直接性强的特点。例如，在百度浏览器中输入关键词“黄金期货价格”，能够最直接地反映投资者对该主题的关注程度，并且投资者的搜索行为很有可能转化成为实质的投资行为，从而对股票或期货的价格、收益率等产生影响。因此，使用百度浏览器搜索量作为投资者关注度的反映指标更加符合当前用户的习惯，通过观察百度浏览器搜索量的变化，可以推测投资者对相关股票或期货的关注程度和市场情绪，从而为投资决策提供一定的参考。基于以上分析，本章主要以黄金期货收盘价作为研究对象，在已搜集到的黄金期货价格影响因素之外，将投资者关注度量化并加入模型，该方法可以为金融数据的预测提供一种新的视角，该模型的主要步骤概括如下：

**步骤 1** 确定主要变量，粗略选取与黄金期货有关的影响因素，采用 Pearson 相关系数选取黄金期货收盘价的主要影响因素，建立初始特征集。

**步骤 2** 确定重要变量与补充变量信息，选用 MIV-KPCA 模型对预测模型进行优化，通过设置 MIV 方法的动态阈值对变量进行首次筛选，利用 KPCA 设置不同的动态阈值对特征权重较小的剩余变量提取主元。

**步骤 3** 确定网络的拓扑结构，通过信息贡献率的计算并确定 MIV 与 KPCA 之间动态阈值的最优组合。

**步骤4** 预测，利用 GWO-ELM 神经网络分别对仅 MIV 筛选变量、仅 KPCA 筛选变量等模型进行预测，选用 MAPE、RMSE 和 MAE 指标对模型进行评价。

**步骤5** 交易策略，设置买入-持有-卖出交易策略，对比 GWO-ELM 与仅使用 MIV 选择变量、仅使用 KPCA 选择变量等模型的收益效果、预测效果。

## 4.1 关键词筛选

2002 年 10 月 30 日，上海黄金交易所正式成立，主要为投资者提供现货黄金交易服务，直到 2008 年 2 月，上海黄金期货市场才正式开始运营。这标志着中国黄金市场进入了全新的时代，通过引入期货交易工具为国内投资者提供了更加多元化和灵活的投资方式，促进了中国金融市场的发展和壮大，为中国金融市场的发展注入了新的动力。百度指数由 PC 端与移动端的加和组成，移动端的百度指数由 2011 年正式推出，本文选用的百度指数数据为 2001 年 1 月到 2021 年 4 月并以黄金期货收盘价序列的日期为基准，对数据进行插补处理，考虑黄金期货市场受替代品的与其他因素的影响，选用 33 个百度指数与 22 个金融影响因素总共 55 个变量进行研究，表 4.1 对所选 33 个百度指数进行了汇总。

表 4.1 百度指数汇总

序号	名称	序号	名称	序号	名称
1	LEM 铜	12	黄金期货	23	石油期货
2	白银价格	13	黄金现货	24	铜期货
3	白银价格走势	14	汇通网	25	银价
4	白银期货	15	今日黄金价格	26	原油价格
5	布伦特原油	16	金价	27	原油期货
6	第一黄金网	17	伦敦铜	28	纸白银
7	钢铁期货	18	伦铜	29	纸黄金
8	工行纸白银	19	美股行情	30	纸黄金价格
9	国际金价	20	美元指数	31	纸金网
10	黄金价格	21	山东黄金	32	中国黄金
11	黄金价格走势	22	石油价格	33	中科金财

本章选取黄金期货收盘价及其影响因素 2011 年 1 月 4 日至 2021 年 4 月 7 日共 2494 条数据为研究对象，其中训练集选取 2011 年 1 月 4 日至 2019 年 3 月 19 日，共 1995 条数据，测试集为 2019 年 3 月 20 日至 2021 年 4 月 7 日，共 498 条

数据。为了对所选的 55 个变量进行深入分析，可以选用 Pearson 相关系数来探究它们之间的相关性。但是，如果不对这些变量进行选择和降维处理，直接将它们全部纳入预测模型中，可能会导致一些无关变量对结果产生噪音干扰，从而影响模型的准确性和可靠性。因此，在构建模型之前，需要对变量进行筛选和处理，以提高模型的预测精度。

相关性分析是一种研究变量之间关系的常用方法，它可以帮助我们了解特征变量与目标变量之间的联系。其中，Pearson 相关系数是一种用来计算两组数据之间线性相关程度的常用指标，计算公式为：

$$\rho(X, Y) = \frac{Cov(X, Y)}{\sigma_X \sigma_Y} = \frac{E(X - \mu_X)(Y - \mu_Y)}{\sigma_X \sigma_Y} \quad (4.1)$$

式中  $\sigma_X, \sigma_Y$  分别为  $X$  与  $Y$  所对应的标准差， $\mu_X$  与  $\mu_Y$  分别为  $X$  与  $Y$  所对应的均值， $\rho$  为变量  $X$  与  $Y$  之间 Pearson 相关系数，相关系数的绝对值可以衡量变量之间线性相关程度，相关系数数值越接近于 1 或 -1，所研究变量之间的相关程度越高；数值越接近于 0，则表示变量之间相关性越弱。

表 4.2 相关系数表

序号	变量名称	相关系数	序号	变量名称	相关系数
1	开盘价	0.999	18	伦敦铜	-0.347
2	最高价	0.999	19	美元指数	-0.477
3	最低价	0.999	20	石油期货	-0.497
4	成交量	-0.478	21	原油价格	-0.452
5	成交额	-0.371	22	原油期货	-0.330
6	道琼斯工业平均指数	-0.475	23	纸黄金	0.440
7	标准普尔 500 指数	-0.565	24	纸金网	0.686
8	纳斯达克综合指数	-0.504	25	中科金财	-0.550
9	香港恒生指数	-0.361	26	伦敦黄金价格	0.958
10	上证 A 股指数	-0.429	27	上海 Au9995	0.999
11	VIX 市场指数	0.398	28	上海 Au9999	0.999
12	LEM 铜	-0.303	29	英国布伦特原油	0.578
13	白银价格	0.535	30	美国西德州轻质原油	0.473
14	白银价格走势	0.563	31	长江铜价格	0.673
15	布伦特原油	-0.489	32	伦敦铜价格	0.648
16	第一黄金网	0.457	33	伦敦白银价格	0.841
17	国际金价	-0.372	34	汇通网	-0.310

根据通常的分类标准,相关系数绝对值大于 0.8 时变量之间存在强相关关系; 0.5-0.8 之间表示显著相关; 0.3-0.5 之间表示低度相关; 0-0.3 之间表示微弱相关, 通过计算相关系数可以帮助我们了解不同变量之间的相互关系, 从而为进一步的分析提供依据。当所选变量与黄金期货收盘价之间的相关系数低于 0.3 时, 则把该变量进行剔除, 所得 34 个变量以及各变量与黄金期货收盘价相关系数如表 4.2 所示。从表 4.2 中可知, 与黄金期货收盘价有关变量总共有 34 个, 其中百度指数主要有 15 个变量分别是 LEM 铜、白银价格、白银价格走势、布伦特原油、第一黄金网、国际金价、伦敦铜、美元指数、石油期货、原油价格、原油期货、纸黄金、纸金网、汇通网与中科金财; 黄金期货收盘价有关的其他金融因素共计 19 个分别为开盘价、最高价、最低价、成交量、成交额、道琼斯工业平均指数、标准普尔 500 指数、纳斯达克综合指数、香港恒生指数、上证 A 股指数、VIX 市场指数、伦敦黄金价格、上海 Au9995、上海 Au9999、英国布伦特原油、美国西德州轻质原油、长江铜价格、伦敦铜价格与伦敦白银价格。

## 4.2 特征融合

### 4.2.1 平均影响值法(MIV)

选择 Pearson 相关系数中绝对值大于 0.3 的变量为研究对象, 将变量个数从 55 个减少到 34 个, 为了避免输入变量维度过高导致神经网络所产生的过拟合问题, 采用特征融合可以将相关性较强的变量进行合并, 减少输入变量的数量。本文采用 MIV-KPCA 方法对所选的解释变量进行特征融合。首先通过平均影响值法来选择最具代表性的特征, 使用核主成分分析法将剩余变量进行降维, 核主成分法保留了变量之间的非线性关系, 通过特征融合的方式提高神经网络的预测精度和泛化性能, 同时可以更准确地预测和分析上海黄金期货收盘价。

利用 MATLAB R2020a 软件中的 MIV 方法计算输入变量对输出变量的贡献率和重要程度, 其贡献率越高代表该变量对目标变量的影响越大, 同时该变量在模型中的重要程度也越高。将输入变量的特征值增加或者减少 10%, 构成两组新的辅助变量分别作为 BP 神经网络的输入, 通过内部计算得到两个辅助变量对应的输出矩阵, 计算两个输出矩阵的差值可以确定不同输入变量对黄金期货价格的

平均影响值。最终将所有变量的 MIV 值按从大到小排序，并计算 MIV 绝对值的累积百分比，具体结果参见表 4.3，MIV 方法可以直观有效的观察到各个输入变量对输出变量的影响程度，并为后续的数据预测和决策提供支持依据。

表 4.3 变量的 MIV 绝对值及其累积百分比

序号	变量	MIV 绝对值	MIV 绝对值累积百分比
1	石油期货	0.1428	14.28%
2	白银价格走势	0.0857	22.85%
3	上海 Au9995	0.0732	30.17%
4	最低价	0.0709	37.26%
5	纸金网	0.0632	43.58%
6	开盘价	0.0571	49.29%
7	上海 Au9999	0.0567	54.96%
8	成交额	0.0530	60.26%
9	伦敦白银价格	0.0468	64.94%
10	上证 A 股指数	0.0401	68.94%
11	伦敦铜价格	0.0317	72.11%
12	原油价格	0.0312	75.23%
13	美元指数	0.0247	77.70%
14	伦敦黄金价格	0.0233	80.03%
15	最高价	0.0231	82.24%
16	纸黄金	0.0224	84.57%
17	英国布伦特原油	0.0200	86.57%
18	长江铜价格	0.0188	88.45%
19	标准普尔 500 指数	0.0169	90.14%
20	美国西德州轻质原油	0.0168	91.82%
21	纳斯达克综合指数	0.0123	93.05%
22	LEM 铜	0.0112	94.16%
23	VIX 市场指数	0.0110	95.26%
24	汇通网	0.0097	96.23%
25	白银价格	0.0061	96.84%
26	布伦特原油	0.0059	97.43%
27	中科金财	0.0055	97.98%
28	国际金价	0.0042	98.40%
29	道琼斯工业平均指数	0.0040	98.79%
30	伦敦铜	0.0038	99.17%
31	原油期货	0.0024	99.40%
32	香港恒生指数	0.0023	99.64%
33	成交量	0.0023	99.87%
34	第一黄金网	0.0013	100%

在表 4.3 中, 可以看出当选择 MIV 绝对值累计百分比为 70%时, 选取前 11 个变量作为输入特征变量的主要变量即为石油期货、白银价格走势、上海 Au9995、最低价、纸金网、开盘价、上海 Au9999、成交额、伦敦白银价格、上证 A 股指数与伦敦铜价格; 选择 MIV 绝对值累计百分比为 80%时, 确定前 14 个变量为输入特征变量, 即在累计百分比为 70%所选变量的基础上加入原油价格、美元指数、伦敦黄金价格; 选择 MIV 绝对值累计百分比为 90%时, 即选择前 19 个变量为输入特征变量, 在累计百分比为 80%所选变量的基础上加入最高价、纸黄金、英国布伦特原油、长江铜价格与标准普尔 500 指数。

#### 4.2.2 核主成分法(KPCA)

当 MIV 选择不同的阈值时, 所选变量个数也会随之发生变化。利用 MIV 方法选择重要变量后, 剩余变量与被解释变量之间存在相对较弱的关系, 但剩余变量中也可能可以提取到部分有用信息。如果直接把剩余变量纳入模型中会增加模型的复杂度, 同时多余变量的引入容易在训练模型中加入较大的噪声, 从而降低模型的预测能力。采用核主成分分析法对剩余解释变量中的有效信息进行提取同时对剩余变量进行降维, 当 MIV 选择阈值为 0.7、0.8、0.9 时, KPCA 选择 0.7、0.8 与 0.9 的阈值结果如表 4.4 所示。

表 4.4 MIV-KPCA 阈值组合

阈值组合	KPCA 主元个数	KPCA 累计贡献率	变量+主元
MIV=0.7,KPCA=0.7	3	72.53%	11+3
MIV=0.7,KPCA=0.8	4	80.49%	11+4
MIV=0.7,KPCA=0.9	8	91.41%	11+8
MIV=0.8,KPCA=0.7	3	72.29%	14+3
MIV=0.8,KPCA=0.8	4	80.99%	14+4
MIV=0.8,KPCA=0.9	7	90.64%	14+7
MIV=0.9,KPCA=0.7	3	70.90%	19+3
MIV=0.9,KPCA=0.8	5	84.47%	19+5
MIV=0.9,KPCA=0.9	7	91.85%	19+7

表 4.4 中展示了 MIV 与 KPCA 在不同的阈值组合下 MIV 选取的主要变量个数与 KPCA 在不同累计贡献率下提取的主元个数。MIV-KPCA 方法是一种基于

核主成分分析(KPCA)和平均影响值法(MIV)相结合的特征融合方法，当选取不同阈值时，MIV与KPCA会随着设定条件的变化而变化。

特征融合方法旨在选择最具信息量的变量作为模型的输入矩阵，通过MIV-KPCA方法选择的变量集，可以在不影响模型性能的前提下，减少模型的复杂度和计算成本，从而提高模型的实用性和效率。总贡献率表示所选变量对目标变量的预测能力的总贡献，通过计算总贡献率对模型的信息利用率进行评判并选择最终的变量集，设变量总数为 $p$ ，MIV-KPCA进行特征融合的总贡献率Ptotal表达式如下：

$$P_{\text{total}} = p_1(s_1) + (1 - p_1(s_1))p_2(s_2) \quad (4.2)$$

式(4.2)中MIV的累计贡献率为 $p_1(s_1)$ ，利用MIV提取前 $s_1$ 个变量，利用KPCA方法提取 $p - s_1$ 个变量构成的主元，KPCA方法的累计贡献率为 $p_2(s_2)$ ，设置MIV方法的动态阈值为 $a^*$ 且 $p_1(s_1) \geq a^*$ ，设KPCA方法的动态阈值为 $b^*$ 且 $p_2(s_2) \geq b^*$ 。

表 4.5 总贡献率

$a^*$	$b^* = 0.7$	$b^* = 0.8$	$b^* = 0.9$
0.7	0.9234	0.9446	0.9739
0.8	0.9456	0.9620	0.9861
0.9	0.9760	0.9813	0.9927

表 4.5 展示了，MIV 的动态阈值 $a^*$ 取 0.7、0.8 与 0.9，KPCA 方法的动态阈值 $b^*$ 取 0.7、0.8 与 0.9 时，计算所得总贡献率。当选取不同阈值 $a^*$ 和 $b^*$ 时，变量数 $s_1$ 与提取主元数 $s_2$ 也同时发生变化，计算所得Ptotal也随之发生变化。Ptotal数值越大说明在模型中引入的变量及主元越多，一个理想的预测模型主要选择在阈值范围内变量数目相对较少的变量作为最佳变量集。

为此，引入综合变量信息利用率指标 $Cu$ 对所选变量信息的利用程度进行量化，该指标使所选变量能够保持较高预测能力和稳定性的同时，尽可能地降低模型复杂度和计算成本，使得模型输入变量具有较高的贡献率和信息利用率，其表达式为<sup>[56]</sup>：

$$Cu = P_{\text{total}}^2 \left[ \frac{p - (s_1 + s_2)}{p} \right]^{\frac{1}{2}} \quad (4.3)$$

表 4.6 不同筛选阈值下的变量信息利用率

$b^*$	$a^* = 0.7$	$a^* = 0.8$	$a^* = 0.9$
0.7	0.6540	0.6134	0.4304
0.8	0.6858	0.6348	0.4717
0.9	<b>0.7306</b>	0.6396	0.4780

通过观察表 4.4 与表 4.5 可以发现，当固定阈值  $a^*$  的取值，随着  $b^*$  取值的增加，在此条件下，信息利用率及输入变量维度也在逐渐增加，这也符合变量与贡献率之间的变化规律。虽然高贡献率意味着输入变量中包含了更多有效信息，但并非输入变量的数量越多越好，当输入变量达到一定数量后，新加入的变量可能会成为噪声导致贡献率降低，同时也导致信息利用率降低。因此，需要找到一个平衡点，在这个点上，能够使输入变量有较高的贡献率及利用率，同时保证输入变量维度最佳。根据综合变量信息利用率指标  $Cu$  的计算，结果如表 4.6 所示，当  $a^* = 0.7, b^* = 0.9$  时，综合变量信息利用率指标  $Cu$  值最大，即此时变量信息利用率最高，输入变量维度相对较少，变量为 19 个，其中利用 MIV 方法选取 MIV 值较大的前 11 个变量以及 KPCA 方法在阈值为 0.9 对剩余变量提取的 8 个主元作为预测模型的输入。

### 4.3 基于特征融合的黄金期货价格预测

根据选取信息贡献率最大的原则，通过 MIV 方法选取前 11 个变量分别为石油期货、白银价格走势、上海 Au9995、最低价、纸金网、开盘价、上海 Au9999、成交额、伦敦白银价格、上证 A 股指数、伦敦铜价格滞后 1 期数据；KPCA 方法所得 8 个主元滞后 1 期数据以及上海黄金期货收盘价的滞后期为 1 期作为神经网络预测模型的输入变量，最终确定神经网络模型输入为 20，输出为下一期的上海黄金期货收盘价。训练集为 2011 年 1 月 4 日至 2019 年 3 月 19 日，共 1995 条数据；测试集为 2019 年 3 月 20 日至 2021 年 4 月 7 日，共 498 条数据，选用 MIV-KPCA-GWO-ELM 模型(记为 M1)、MIV-GWO-ELM 模型(记为 M2)、KPCA-GWO-ELM 模型(记为 M3)以及 MIV-KPCA-ELM 模型(记为 M4)进行预测，结果如表 4.7 所示：

表 4.7 MIV-KPCA 预测评价指标

方法	M1	M2	M3	M4
RMSE	<b>3.84</b>	3.84	24.29	12.10
MAPE/%	<b>0.76</b>	0.77	5.64	3.04
MAE	<b>2.76</b>	2.76	20.70	10.83
DS/%	<b>58.23</b>	56.22	45.18	46.59

从表 4.7 中可以看出, 模型 M1 即利用 MIV-KPCA 相结合的方式能更好的对黄金期货收盘价进行预测; 其中模型 M2 是 Pearson 相关系数选出的 34 个变量, 再直接使用阈值大于 0.7 的 MIV 方法选取前 11 个变量, GWO-ELM 模型进行预测; 模型 M3 是直接对 34 个变量直接使用值大于 0.9 的 KPCA 方法提取 13 个主元再利用 GWO-ELM 模型进行预测; 模型 M4 是在 MIV-KPCA 提取变量的基础上选用 ELM 模型进行预测。相较于模型 M2、M3、M4, 模型 M1 能够充分利用变量信息提高模型的预测精度。

表 4.8 金融数据集信息利用率

$b^*$	$a^* = 0.7$	$a^* = 0.8$	$a^* = 0.9$
0.7	0.6231	0.6162	0.5360
0.8	<b>0.6508</b>	0.6070	0.5061
0.9	0.6434	0.5930	0.4702

表 4.8 中给出了仅对金融数据集中 22 个变量, 使用 MIV-KPCA 方法进行特征融合  $Cu$  值计算所得结果, 记仅使用金融数据集做 MIV-KPCA-GWO-ELM 模型为 M5。当  $a^* = 0.7$ ,  $b^* = 0.8$  时, 此时的信息利用率最高且预测模型输入变量维度相对较少。选取 MIV 方法的前 8 个变量滞后 1 期数据, 即成交额、上海 Au9999、伦敦黄金价格、最高价、上证 A 股指数、长江铜价格、伦敦铜价格与成交量, 以及 KPCA 提取的 3 个主元滞后 1 期以及上海黄金期货收盘价滞后 1 期数据作为 GWO-ELM 模型的输入进行预测。

选用弹性网络对金融数据和百度指数 55 个变量进行处理, 弹性网络  $\alpha = 0.6$ , 模型期望最小化的目标参量  $\lambda = 0.0833$ , 此时所选变量个数为所选 22 个; 通过时差相关分析法对变量的领先滞后期进行确定, 其中开盘价、最高价、最低价、成交额、白银价格、布伦特原油、今日黄金价格、美元指数、石油价格、纸白银、

中国黄金、伦敦黄金价格、上海 Au9995、上海 Au9999、长江铜价格、美国国债 10 年收益率与上证 A 股指数滞后 1 期；白银期货滞后 4 期；白银价格走势、第一黄金网、汇率(美元兑人民币)与 VIX 市场指数滞后 5 期，黄金期货收盘价本身滞后 3 期，最终神经网络输入为 44，利用 GWO-ELM 模型预测下一期黄金期货价格收盘价，记该模型为 M6。

表 4.9 对比模型预测评价指标

方法	M1	M2	M3	M4	M5	M6
RMSE	3.84	3.84	24.29	12.10	5.30	<b>3.76</b>
MAPE/%	0.76	0.77	5.64	3.04	1.04	<b>0.76</b>
MAE	2.76	2.76	20.69	10.83	3.81	<b>2.76</b>
DS/%	58.23	56.22	45.18	46.59	51.37	<b>62.85</b>

表 4.9 中展示了对混合数据集分别采用 MIV-KPCA-GWO-ELM 模型(M1)、MIV-KPCA-GWO-ELM 模型(M2)、MIV-GWO-ELM 模型(M3)和 KPCA-GWO-ELM 模型(M4)的预测结果；以及仅使用金融数据集 22 个变量采用 MIV-KPCA-GWO-ELM 模型(M5)和利用上章中弹性网络处理金融数据与百度指数的混合数据集使用 GWO-ELM 模型(M6)的预测结果。

结果表明：1.在预测模型中加入百度指数作为投资者关注度的量化指标可以有效提升模型的预测能力。2.相对于仅使用 MIV 方法与 KPCA 方法进行预测的模型，选用 MIV-KPCA 结合的方式能够有效提取信息。3.在预测模型方面，对比 GWO-ELM 与 ELM 模型的预测结果可知，利用灰狼优化算法优化 ELM 参数的预测模型要好于单一 ELM 模型。4.利用特征选择的方式对本章中的金融数据集与百度指数数据集进行处理，对比特征选择与特征融合在同一数据集中的预测效果，弹性网络-GWO-ELM 模型要好于 MIV-KPCA-GWO-ELM 模型。

#### 4.4 交易效果评估

本文设置初始交易金额为 50 万，暂不考虑交易费用，设定每次买入卖出份额为交易资金的 70%，利用买入-持有-卖出策略对 MIV-KPCA-GWO-ELM 以及其他对比模型 2019 年 3 月 20 日至 2021 年 4 月 7 日预测结果进行回测，结果如表 4.10 所示：

**表 4.10 交易结果表**

模型	最终金额/元	收益率	交易次数	最大回撤率
M1	818243	63.65%	286	5.09%
M2	799228	59.85%	330	4.26%
M3	298199	-40.36%	78	47.51%
M4	545378	9.08%	36	13.22%
M5	497761	-0.45%	422	19.40%
M6	1037469	107.49%	364	2.66%

M1 模型最终金额及收益率高于 M2、M3、M4 模型的结果，这是由于 M1 模型预测的方向精度大于 M2、M3 及 M4 模型，交易次数同时也小于 M2 模型，其他对比模型由于方向精度较低所导致交易次数较少，这与该模型的统计评价指标所得结论一致，交易效果与预测效果互相得到的印证。M1 模型与仅用金融数据集 M5 进行回测的结果对比得知，在模型中加入百度指数能有效提高收益率；对比特征选择 M1 与特征融合两种 M6 方法的回测结果，特征选择的回测结果要好于特征融合，说明针对多维度信息的黄金期货价格短期预测特征选择要比特征融合更适用。

## 4.5 本章小结

选用多维度信息对黄金期货收盘价建立 MIV-KPCA-GWO-ELM，结果表明：

(1)从模型构建角度分析，选取黄金期货收盘价的影响因素及其相关百度指数纳入模型，可以增加变量的复杂性与多元性，仅使用金融数据进行预测忽略了其他因素对金融市场的影响，然而单独使用 MIV 与 KPCA 方法来减少输入变量的个数不足以保留足够的有效信息，从而无法获得满意的预测结果。

(2)从模型优化方面，利用 MIV-KPCA-GWO-ELM 模型，在使用 MIV 方法对输入特征进行筛选的基础上，再采用 KPCA 方法对剩余特征进行信息提取和二次筛选，通过将两种方法结合的方式，可以优化预测模型的结构同时提高信息利用率。经过 GWO-ELM 与 ELM 模型的实验证，这种方法不仅可以提高黄金期货收盘价的预测精度，同时也可以使最终获得较高的收益，从而更加实用。

(3)从特征选择与特征融合方面进行分析，利用特征融合的方法对黄金期货收盘价进行预测的结果好于 MIV 与 KPCA 方法，说明该方法可以有效处理多维度信息，但特征选择方法可以将原始数据转化为更具有区分度的特征，从而提高预测模型的精度，特征融合则可能会因为不同特征之间的关联性不同而产生干扰或误差。

## 5 总结与展望

### 5.1 总结

随着神经网络研究的深入和发展，金融行业已成为其应用的重点之一。黄金期货是交易市场中的一个重要投资品种，其价格走势对于投资和学术领域具有重要意义。本文分析表明，黄金期货市场是一个复杂的非线性动态系统，预测其价格变化需要考虑多个因素。因此，本文利用多维信息对黄金期货价格进行短期预测。本文从两个角度对黄金期货收盘价及其影响因素等多维度信息进行处理，首先是基于特征选择的角度利用弹性网络对所选变量进行降维，通过相空间重构与时差相关分析法确定神经网络模型的输入，再对三组样本进行滑动窗口预测，经多模型对比选择 GWO-ELM 为预测模型。在此基础上，更改最优模型的适应度函数有效提高了该模型预测结果的方向精度。最终利用预测数据进行了回测交易，多个交易策略结果均表明修改适应度函数的 GWO-ELM 模型有着良好的预测能力。

第二个角度则考虑的是特征融合，在已有变量的基础上，增加百度指数作为投资者关注的量化指标。首先利用 Pearson 相关系数对所选变量进行粗筛，再采用 MIV 方法对变量进行二次筛选，剩余变量用 KPCA 法提取主成分，最终利用灰狼优化算法的神经网络模型进行预测并通过交易策略进行回测，结果表明 MIV-KPCA-GWO-ELM 方法可以提高黄金期货收盘价的预测精度。

### 5.2 展望

(1) 在变量选取方面，除了可度量的经济指标之外，期货市场的价格变化通常还受到其他许多难以量化的因素的影响，例如市场供需关系、投资者情绪、行业趋势等。因此，在分析期货市场价格时，需要考虑所有可能影响价格的因素并综合评估它们的影响，以便对预测模型进行优化并制定相应的投资策略。

(2) 在数据降维方面，特征选择是从原始数据中提取出最有用的特征，并将其作为输入提供给模型，特征融合则是将不同的特征组合起来，以便训练模型，在后续的研究中可以将二者的实验结果进行组合，进一步对预测模型进行优化。

(3)在预测方面，本文仅对黄金期货收盘价进行短期预测，期货市场的短期、中期和长期规律往往受到不同因素的影响，例如，短期规律可能受到技术面的影响，中期规律可能与经济周期有关，而长期规律可能与结构性因素和宏观经济趋势有关。在后续的研究中，可以在本文的基础上，进一步探索期货市场中长期规律的变化趋势，并将实验结果推广到中期和长期的预测中。

(4)在交易策略方面，本文仅使用历史价格与预测价格制定了相应的趋势交易策略，后续可以基于技术指标和基本面进行分析，寻找市场中的交易信号，如价格突破、均线交叉等，以此进行交易。

(5)在经济政策方面，宏观经济因素的变化会对黄金期货价格造成一定的影响，根据黄金期货价格的预测走势，可以发挥国家储备和商业储备联动优势，调整储蓄品种和库存，以防范重大事件或极端情况对我国经济社会的不良影响。

## 参考文献

- [1] 杨胜刚, 陈帅立, 王盾. 中国黄金期货价格影响因素研究[J]. 财经理论与实践, 2014, 35(03): 44-48.
- [2] 曹辉, 张士云. 我国黄金期货市场价格波动研究[J]. 价格月刊, 2012, 417(02): 1-5.
- [3] Kumar S. On the nonlinear relation between crude oil and gold[J]. Resources Policy, 2017, 51: 219-224.
- [4] 黄健柏, 程慧, 郭尧琦, 邵留国. 美元、石油和金属价格——基于 VAR 模型的实证研究[J]. 经济经纬, 2012, No.148(03): 45-49.
- [5] Alameer, Zakaria, et al. Forecasting gold price fluctuations using improved multilayer perceptron neural network and whale optimization algorithm[J]. Resources Policy, 2019, 61: 250-260.
- [6] Weng, Futian, et al. Gold price forecasting research based on an improved online extreme learning machine algorithm[J]. Journal of Ambient Intelligence and Humanized Computing, 2020, 11(10 ): 4101-4111.
- [7] 刘飞, 吴卫锋, 王开科. 我国黄金期货市场定价效率与价格发现功能测算——基于 5 分钟高频数据的实证研究[J]. 国际金融研究, 2013(04): 74-82.
- [8] 冯辉, 张蜀林. 国际黄金期货价格决定要素的实证分析[J]. 中国管理科学, 2012, 20(S1): 424-428.
- [9] Beckmann J, Czudaj R, Pilbeam K. Causality and volatility patterns between gold prices and exchange rates[J]. The North American Journal of Economics and Finance, 2015, 34: 292-300.
- [10] 杨柳勇, 史震涛. 黄金价格的长期决定因素分析[J]. 统计研究, 2004, (06): 21-24.
- [11] Lawrence C. Why is gold different from other assets? An empirical investigation[R]. World Gold Council, 2003.
- [12] Li L, Diao C. Research of the influence of macro-economic factors on the price of gold[J]. Procedia Computer Science, 2013(17): 737-743.
- [13] 董杰, 潘和平, 姚一永, 李成刚. 基于 DCC-MVGARCH 模型的石油、股票和黄金市场相关性实证研究[J]. 预测, 2012, 31(04): 53-57.
- [14] 徐照宜, 蒋文倩, 杨胜刚. 国际黄金和原油价格波动与上证指数的相关性——基于

- 小波分析方法的研究[J]. 金融论坛, 2019, 24(06): 54-61.
- [15] 袁晨, 傅强. 我国金融市场间投资转移和市场传染的阶段时变特征——股票与债券、黄金间关联性的实证分析[J]. 系统工程, 2010, 28(05): 1-7.
- [16] Balcilar M, Bonato M, Demirer R. The effect of investor sentiment on gold market return dynamics: Evidence from a nonparametric causality-in-quantiles approach[J]. Resources Policy, 2017, 51: 77-84.
- [17] Smales L A, Lucey B M. The influence of investor sentiment on the monetary policy announcement liquidity response in precious metal markets[J]. Journal of International Financial Markets, Institutions & Money, 2019, 60: 19-38.
- [18] 姚德权, 黄学军, 杨光. 中国机构投资者情绪与股票收益关系研究[J]. 湖南大学学报(社会科学版), 2010, 24(06): 46-50.
- [19] Mbanga C, Darrat A F, Park J C. Investor sentiment and aggregate stock returns: The role of investor attention[J]. Review of Quantitative Finance and Accounting, 2018, 53: 397-428.
- [20] 王耀君, 高扬. 网络关注度对我国股票市场信息不对称程度的影响[J]. 财经理论与实践, 2019, 40(01): 44-50.
- [21] 梁超, 魏宇, 马锋, 李薇. 投资者关注对中国黄金价格波动率的影响研究[J]. 系统工程理论与实践, 2022, 42(02): 320-332.
- [22] 黄冰洁, 张同斌. 中国制造业企业绩效分化的关键影响因素识别及传导网络图解——基于机器学习组合算法的研究[J]. 运筹与管理, 2022, 31(04): 224-231.
- [23] 贾尚晖, 兰盈. 中国对国际黄金价格影响的实证分析: 基于 Lasso 回归方法[J]. 中央财经大学学报, 2015(S1): 93-97.
- [24] 吴俊洋. 基于弹性网络的我国住宅价格影响因素研究[D]. 湖南师范大学, 2018.
- [25] Liu D, Li Z. Gold price forecasting and related influence factors analysis based on random forest[C]. Proceedings of the Tenth International Conference on Management Science and Engineering Management. Springer, Singapore, 2017: 711-723.
- [26] 梁超, 魏宇, 马锋, 李霞飞. 我国黄金期货价格波动率预测研究: 来自模型缩减方法的新证据[J]. 中国管理科学, 2022, 30(04): 30-41.
- [27] 胡聿文. 基于优化 LSTM 模型的股票预测[J]. 计算机科学, 2021, 48(S1): 151-157.
- [28] 高振斌, 秦轩. 基于 PLS-GA-SVR 的区域经济预测模型及实证[J]. 统计与决策, 2022,

- 38(18): 54-57.
- [29] 徐龙博, 王伟, 丁煜函, 张滔, 汪少勇. 基于 MIV-PCA 的超短期风电功率预测模型优化[J]. 电力工程技术, 2019, 38(05): 107-113+137.
- [30] 陈盟. 基于核主成分分析和支持向量回归对每日和每分钟股票价格的预[D]. 兰州大学, 2020.
- [31] Yang Y, Guo J, Sun S, et al. Forecasting crude oil price with a new hybrid approach and multi-source data[J]. Engineering Applications of Artificial Intelligence, 2021, 101: 104217.
- [32] 许贵阳. 基于灰色预测方法的中国黄金期货价格预测模型[J]. 黄金, 2014, 35(01): 8-11.
- [33] 毛从芹. 基于 GARCH 模型的黄金价格预测分析与作用机制研究[D]. 苏州大学, 2016.
- [34] 许立平, 罗明志. 基于 ARIMA 模型的黄金价格短期分析预测[J]. 财经科学, 2011, No.274(01): 26-34.
- [35] 彭潇熟, 张德生, 王若星, 陈聪. 国际黄金价格具有外生变量的 GARCH 预测模型[J]. 黄金, 2011, 32(01): 10-14.
- [36] 宋策. 基于 BP 神经网络与灰色关联的黄金期货价格预测[J]. 上海工程技术大学学报, 2017, 31(01): 90-94.
- [37] Ur Sami I, Junejo K N. Predicting future gold rates using machine learning approach[J]. International Journal of Advanced Computer Science and Applications, 2017, 8(12): 92-99.
- [38] Pierdzioch C, Risse M. Forecasting precious metal returns with multivariate random forests[J]. Empirical Economics, 2020, 58(3): 1167-1184.
- [39] Alameer Z, Abd Elaziz M, Ewees A A, et al. Forecasting gold price fluctuations using improved multilayer perceptron neural network and whale optimization algorithm[J]. Resources Policy, 2019, 61: 250-260.
- [40] 季晨洋, 林杰. 基于随机森林方法的甲醇期货价格预测与交易策略研究[J]. 上海管理科学, 2023, 45(01): 113-118.
- [41] 周星月. 基于布林线的股指期货量化模型构建与回测检验[D]. 南京师范大学, 2014.
- [42] 高宁波, 张鸿. 钢材期货交易在工程建设企业中应用的可行性与策略分析[J]. 建筑

- 经济, 2022, 43(S2): 384-387.
- [43] 彭乐. 螺纹钢期货市场价格发现功能与量化交易策略实证[D]. 江西财经大学, 2014.
- [44] 高妮, 贺毅岳, 马新成. 基于低频分量 EEMD-SVR 预测建模的指数择时策略[J]. 统计与决策, 2022, 38(02): 140-145.
- [45] Li Y, Wang S, Wei Y, et al. A New Hybrid VMD-ICSS-BiGRU Approach for Gold Futures Price Forecasting and Algorithmic Trading[J]. IEEE Transactions on Computational Social Systems, 2021, 8(6): 1357-1368.
- [46] Zou H, Hastie T. Regularization and Variable Selection Via the Elastic Net[J]. Journal of the Royal Statistical Society: Series B (Statistical Methodology), 2005, 67(2): 301-320.
- [47] 董雪, 张德平. 基于组合核主成分分析的潜艇威胁度评估模型[J]. 计算机工程, 2018, 44(11): 40-45.
- [48] 刘斌. 基于 MIV-PSO-SVM 的高速公路投资估算方法研究[D]. 长沙理工大学, 2021.
- [49] Takens F. Dynamical systems and turbulence[M]. Berlin : Springer Verlag Press.1981.
- [50] Packard N, Crutchfield J, Farmer J, et al. Geometry from a Time Series[J]. 1980, 45(9): 712-716.
- [51] Kennedy J, Eberhart R C. Particle Swarm Optimization[C]. Proceedings of the IEEE International Conference on Neural Networks. Piscataway, 1995: 1942-1948.
- [52] Mirjalili S, Mirjalili S M, Lewis A D. Grey Wolf Optimizer[J]. Advances in Engineering Software, 2014, 69: 46-61.
- [53] Rumelhart D E, Hinton G E, Williams R J. Learning Representations by Back Propagating Errors[J]. Nature, 1986, 323(6088): 533-536.
- [54] Suykens J A K, Brabanter J D, Lukas L, et al. Weighted least squares support vector machines: robustness and sparse approximation[J]. Neurocomputing, 2002, 48(1-4): 85-105.
- [55] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: Theory and applications[J]. Neurocomputing, 2006, 70( 1-3): 489-501.
- [56] 段海滨, 张祥银, 徐春芳. 仿生智能计算[M]. 科学出版社, 2011.

## 后记

行文至此，感慨万千，求学之路始于金秋，终于盛夏。三年千日，不知不觉间已到毕业之时，回首往昔，心中有无数的感慨。在这段求学的岁月里，我不断学习、成长，收获了无数珍贵的经验和知识，这些宝贵的财富将伴随我一生，指引我前行。

首先感谢孙景云老师，感谢您三年来的教导，本篇论文的选题、框架制定、实验、写作都离不开您悉心的教导，疫情期间，您也一直通过微信、腾讯会议等方式一直与学生保持沟通，在每个关键点上严格把关，老师严谨认真的态度影响着师门中的每一个人。祝愿老师工作顺利，桃李满天下！

其次，感谢我的同门小伙伴何林芸、曹静如，感谢在最好的年华在兰州遇见最好的你们，在科研路上我们一起并肩前行，感谢赵盼盼师姐和于婷师姐在学习和求职中给予的鼓励与支持。愿岁并谢，与友长兮，感谢舍友相伴三年，祝愿大家前程似锦！

在此，特别感谢我的父母和家人们，感谢你们辛勤的付出与支持，谢谢你们让我有了路前行的勇气，谢谢你们对我每个决定的尊重与支持！

最后，感谢各位评审老师与答辩专家！论文在论文撰写过程中难免会出现疏漏和不足之处，恳请各位专家批评指正！