



价格理论与实践
Price: Theory & Practice
ISSN 1003-3971, CN 11-1010/F

《价格理论与实践》网络首发论文

题目： 沪深 300 股票配对交易策略优化研究——基于 LSTM 动态参数调整和市值筛选方法
作者： 刁海璨，张延群
DOI： 10.19851/j.cnki.CN11-1010/F.2024.03.113
网络首发日期： 2024-06-19
引用格式： 刁海璨，张延群. 沪深 300 股票配对交易策略优化研究——基于 LSTM 动态参数调整和市值筛选方法[J/OL]. 价格理论与实践.
<https://doi.org/10.19851/j.cnki.CN11-1010/F.2024.03.113>



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

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

沪深 300 股票配对交易策略优化研究

——基于 LSTM 动态参数调整和市值筛选方法

刁海璨 张延群

内容提要: 构建有活力、有韧性的资本市场,对于促进上市企业高质量发展和优化金融市场投融资功能具有重要意义。在传统配对交易策略中,相对固定的交易参数和缺乏灵活性的预筛选规则限制了策略对市场变化的动态响应。为了克服这些限制,本文提出了一种结合市值筛选规则与多股票配对交易框架的优化策略,确保选取的股票能够有效识别低估值优质标的。该策略采用长短期记忆网络(LSTM)算法动态调整交易参数,以提升预测精度。实证分析发现:与固定参数策略相比,本文所构建的优化策略不仅增强了对我国股票市场的价格发现能力,还实现了更高的投资回报。研究拓展了配对交易的理论范畴,为挖掘我国股票市场中的优质及低估值资产提供了模型与算法指导,有助于提振市场信心和改善长期投资预期。

关键词: 多支股票配对交易;协整检验;交易参数;市值筛选;LSTM

DOI: 10.19851/j.cnki.CN11-1010/F.2024.03.113

2024年3月,中国证监会集中发布四项有关推动资本市场高质量发展的政策文件,突出“强本强基”和“严监严管”,强调推动上市公司提升投资价值,通过强监管防风险和搭建“一基五柱”体系,提升资本市场的内在稳定性^①。随着金融市场稳定性的重要程度日益凸显(刘宇轩等,2022),基于长期均值回归预测股价回报,从而避免短期频繁同向交易的配对选股策略(Goldkamp等,2019)重新受到关注。基于此,本文构建了多只股票的优化配对模型,并引入权重市值筛选规则和LSTM动态参数调整算法,解决传统策略可能存在的稳定性和有效性不足的问题,持续挖掘并配置优质标的,以期增强市场的价格发现功能,减少市场波动。

一、相关研究文献评述

国内外学者对配对交易策略的研究主要集中在两个方面:配对组合的构建和交易参数的优化。其中,前者进一步细分为配对模型构建以及筛选规则

设计这两个维度。

在配对组合构建方面,经典的配对模型主要包括 Gatev 等(2006)提出的最小距离模型以及 Vidyamurth (2004)改进的协整检验方法。这些方法通过分析股票之间的距离和协整关系来进行匹配。近年来,由于金融市场中风险偏好差异的显著增加,Markowitz 的均值方差方法再次引起投资者的关注。陈荣达(2022)认为,该方法通过凸二次规划来最小化风险,并求解投资组合权重,尤其适用于风险厌恶型投资者。在配对资产的筛选规则设计方面,Zhao 和 Palomar (2018)通过优化模型和调整交易规则来提升交易策略性能,傅毅等(2019)采用动态规划管理高维动态配对资产。然而,这些方法通常缺乏广泛适用的筛选规则和对净空头头寸的约束,限制了其在市场中的实际应用效果。

在交易参数优化方面,金融系统的动态性以及数据的非线性和非平稳性特征(Wu等,2020)使得传统交易策略难以适应复杂市场,这要求配对策略需

^①新华网.强监管防风险 推动资本市场高质量发展——证监会有关负责人解读四项“两强两严”政策文件[EB/OL].(2024-04-12). www.news.cn/fortune/20240315/9b23ad4e9b83461a97d5818ea1fb58e2/c.html.

基金项目: 国家自然科学基金重大项目“宏观大数据建模和预测研究”(项目编号:71991475);“中国社会科学院经济大数据与政策评估实验室”(2024SYZH004);中国社会科学院学科建设“登峰战略”资助计划数量经济学优势学科(DF2023YS29)。

主要作者简介: 张延群(1968-),女,内蒙古包头人,德国柏林自由大学经济学博士,中国社会科学院数量经济与技术经济研究所研究员,博士生导师,中国社会科学院大学教授。研究方向:经济预测、大数据模型研究。

要在不同场景下调整至最佳交易参数。传统的参数设定往往基于经验使用固定阈值，这种做法虽然操作简单，但在极端市场条件下，其预测精度和策略表现往往不佳。为解决这一问题，部分学者基于最优化思想和均值回归特性优化交易参数，例如，Buehler 等(2019)使用效用函数作为优化目标以实现最优交易策略。毕秀春等(2019)则将最优阈值问题转化为随机控制问题求解。Wu 等(2020)基于均值回复速度和已实现波动率筛选股票对，并依据异质自回归模型和 OU 过程预测股票对价差的波动率。Li 等(2021)使用背离策略构建最优平仓点问题。这些研究不仅证明了动态参数调整的必要性和有效性，还为配对交易提供了参数精度和稳定性方面的优化基础。

尽管国内外学者对配对组合构建和交易参数优化进行了多维度的探讨，但大多数研究仍是基于单只股票配对模型，且通常将筛选规则和交易参数分开讨论，缺乏系统性。本文以沪深 300 指数成分股的日收盘价数据为样本，采用非凸二次规划的多只股票配对模型，引入权重市值筛选规则挖掘低估值优质标的，同时引入非净空头头寸约束，旨在通过增强预测精度降低模型面临的市场风险，从而提升配对交易策略的性能。本文研究贡献在于，第一，构建了多只股票配对交易框架并设计了权重市值筛选规则，为特定投资偏好下的配对交易策略提供了创新理论支持；第二，从动态参数寻优的角度改进了基于长短时记忆网络(LSTM)的价差预测方法，构建了基于 LSTM 的交易参数优化算法，不仅提高了模型效率和精度，而且减少了配对阶段因数据处理不足造成的精确度问题。实证结果验证了该优化策略的有效性，证明了其在捕捉交易时机和增强市场价格发现能力方面的优势。

二、A 股市场交易策略优化的理论分析

当前我国持续推动经济高质量发展，A 股市场政策体系持续优化，这为寻找具有投资价值的股票提供了良好机遇。本文通过采用权重市值预筛选的多只股票配对策略，能够有效识别复杂金融市场中的优质标的，找到更为稳定、价格更能反映市场整体情况的股票对。此外，通过筛选市值较大且通常伴随较低波动性的股票，投资者可以减少投资组合的波动风险，实现更加稳健的投资回报。

(一) 配对交易相关理论

配对交易起源于 20 世纪 20 年代的华尔街，不同于传统的股票交易，该策略是对股票之间的相对价格进行投资，通过在同一行业或市场中寻找历史价格趋向于一起移动的相似股票对，从而在价格出

现分歧时捕捉投资机会。利用股票对之间的价格关联性来构建投资组合，属于市场中立策略。不同于当前市场主流的短期量化择时策略，配对交易利用股票之间的长期均值回归预测股价回报，通常在买入相对被低估股票的同时，卖出相对被高估股票，利用有效市场未来价格差异的自我纠正来获取利润。

配对交易策略建立在一价定律(Law of One Price, L00P)和股票价格的均值回归基础上。其中，一价定律假设在金融市场中考虑货币兑换后，同一资产在不同市场的价格应保持一致(Marshall 等, 2013)；均值回归是指资产价格在经历波动后能够返回其长期平均水平的现象，然而这种回归可能因技术变革、企业重大事件等因素失效，导致原本稳定的价差序列遭受持续冲击。传统的配对交易多采用单只股票配对模式，如 GGR 模型计算欧式距离，按照距离最小化的标准进行股票匹配，协整模型匹配存在长期协同关系的股票对，并通过协整检验验证这种关系。但在市场波动性增大或股票间关系突变的情况下，均值回归存在一定失效风险。为了增强策略的稳健性和适应市场的变动，本文构建了多只股票的配对选股策略，能够识别并利用市场中更广泛的均值回归机会，更好地分散特定股票或行业的风险，增加策略的稳定性和有效性，能够为减少股票市场的短期波动作出贡献。

(二) LSTM 模型

传统神经网络通常用于处理股票因子的截面数据，这种数据虽能反映某一时刻的股票特征，但难以捕捉随时间演变的信息。相较之下，循环神经网络(RNN)通过反馈机制实现对过去信息的短期记忆，在处理时间序列数据方面具有独特优势。LSTM 记忆模型(Long Short Term Memory)作为一种时间循环神经网络，其独有的输入门、遗忘门和输出门结构能够有效地捕捉和学习股票数据的长期趋势，对非线性序列进行更加精确的建模(沈蕾和罗梦丝, 2022)。凭借其强大的非线性映射和自学习能力，已被广泛用于捕捉长期数据特征和优化交易策略参数。如胡文伟等(2017)采用基于强化学习的动态参数优化法实现配对交易超额收益。考虑到传统的 LSTM 容易面临训练时间长和易陷入局部最优的问题，一些学者基于智能优化算法和协整方法改进 LSTM 算法(Hu 等, 2021)，提高了其在激进型股票上的预测精度(Chang 等, 2021)。为了防止模型对于某些神经元过于依赖，导致构建的神经网络出现过度拟合的情况，可以设置 LSTM 网络中的神经元随时失活，从而使得构建模型更具有稳健性，在样本外预测中取得更加有效且稳健的效果。本文通过在多只股票配对交易模型中使用 Python 的 Keras 包构建多隐含层的 LSTM 模型^①预测股票价差序列，为投资者提供基于

^①LSTM 神经网络模型详见《价格理论与实践》网站(<http://www.price-world.com.cn/>)附件。

预测与实际价差增量的精确交易信号，有效降低模型复杂度，同时保持策略的精度和收益。

三、优化配对选股策略设计

(一) 多只股票优化配对模型构建

与传统 GGR 模型所构建的多组 1 对 1 匹配模式不同，本文通过增加优化配对模型中的约束条件，将距离选股扩大到可以同时实现单股票配对以及多股票配对的范围，构建了更一般化的配对组合框架。假设备选股票池中有 n 只股票，股票配对的形成周期为 m 天，距离配对的目标函数表示为：

$$f(\alpha) = \min \sum_{t=1}^m (\sum_{i=1}^n \alpha_i p_{i,t})^2 \quad (1)$$

其中， $p_{i,t}$ 表示股票 i 在 t 日内的对数化日收盘价， α_i 表示股票 i 在配对组合中的权重。式(1)表示形成期内两个股票组合价格的欧式距离足够小，即认为股票间存在长期均衡关系。考虑到最小化距离的约束条件，增加常数项 α_0 衡量配对股票的残差序列偏离均值水平的程度，故优化配对目标函数表示为：

$$f(\alpha) = \min \sum_{t=1}^m (\sum_{i=1}^n \alpha_i p_{i,t} + \alpha_0)^2 \quad (2)$$

其中， $\alpha_0 \neq 0$ 。由于对数化股票价格 (Dunis 和 Ho, 2005) 可以最大程度保留股票的原始信息，假设 $p_{i,t}$ 和 $p_{j,t}$ 分别表示股票 i 和 j 在 t 日内的对数化价格，满足协整关系：

$$p_{i,t} = \alpha + \beta p_{j,t} + \varepsilon_t \quad (3)$$

其中， β 表示股票仓位的资金比例。为避免多重共线性，在回归估计中增加一定程度的偏差，并对 ε_t 进行 ADF 检验。如果残差序列平稳，即不存在单位根，则可以拒绝无协整的原假设，从而确认股票对具有协整关系。由于多变量之间存在协整关系的情况大致等同于一种特殊的距离表现形式，本文将作为因变量和自变量的股票分别记为 i 和 j ，并加入非净空头头寸限制，令约束条件为：

$$s.t. \sum_{i=1}^n \alpha_i^2 \geq r, r > 0 \quad (4)$$

记式(4)的解为 $\bar{\alpha}$ ，根据 $\bar{\alpha}$ 分量的正负符号得到配对股票对应的权重解为 $\bar{\alpha}_i$ 和 $\bar{\alpha}_j$ 。综合最小距离法和协整关系的选股方法，构建多只股票配对优化模型：

$$f(\alpha) = \min \sum_{t=1}^m (\sum_{i=1}^n \alpha_i p_{i,t} + \alpha_0)^2 \quad (5)$$

$$s.t. \sum_{i=1}^n \alpha_i^2 \geq r, r > 0$$

进一步地，为方便模型求解，将 GPOM 的目标函数作为二次规划模型，为方便求解，将式(3)中目标函数记为：

$$\min \sum_{t=1}^m (\sum_{i=1}^n \alpha_i p_{i,t} + \alpha_0)^2 = \frac{1}{2} a^T Q a + f^T a \quad (6)$$

记这一优化配对模型为 MultiPT 策略。对于非线性规划模型需要借助一些优化器或数学软件采用

数值方法求解，如有效集法、内点法以及序贯二次规划算法等。

(二) 筛选规则设计

对上市公司而言，市值既包含了公司整体规模，又在一定程度上反映了资本市场对公司发展潜力的认可程度，因此股票价格反映了市场价值。

为了提高配对交易策略的整体性能和可靠性，同时挖掘低估值优质标的、增强市场价格发现功能，本文借鉴孟庆斌等(2018)和 Kinlaw 等(2021)的方法构建权重市值筛选指标，采取自由流通市值衡量企业市值，同时进一步参考沪深 300 指数编制方案^①剔除了上市公司股本中的限售股份及基本不流通股份，根据自由流通量所占样本总股本的比例(即自由流通比例)赋予总股本一定的加权比例。根据沪深 300 指数样本的加权比例计算样本期内各成分股的权重，构建以市值权重为核心的配对筛选规则，确保选取的股票具有良好的流动性及稳定性。

(三) 权重市值优化配对模型

为验证模型的适用性，本文设计了可应用于 MultiPT 策略的权重市值筛选规则，并求解该筛选规则下的局部最优解作为在特定偏好下的整体最优解。参考 GGR 算法，该策略在形成期内对备选股票池中的股票价格进行标准化处理，并计算累计收益作为股票价格序列之间的欧式距离，以此筛选距离最小的两只股票作为匹配对。此外，运用权重市值筛选规则(Weight-Value Filter)选取特定行业中具有代表性的公司作为样本，计算每只股票对其行业影响程度的大小，以决定是否加入该行业的股票组合，这一策略为 WV-MultiPT 配对策略。策略操作步骤如下：

步骤 1: 在形成期设置备选股票池，并获取每只股票的日收盘价序列；

步骤 2: 选取每个样本池内权重最高、总市值最大的股票作为初步选股基准，依据股票的权重和市值对股票池进行综合降序排列；

步骤 3: 根据设定的组合数量上下限选取每个样本池中的股票；

步骤 4: 将筛选出的股票收盘价序列输入 MultiPT 策略，构建不出现净空头头寸的配对组合；

步骤 5: 完成筛选配对过程，得到各股权重即为配对组合中各股票的最优权重。

四、股票交易参数优化设计

(一) 交易阈值分析

受行业政策调整、公司业务转型以及其他突发事件等多方面影响，配对交易存在股价偏离均衡关系后不会回归均值的风险。因此，需要不断调整交

① 中证指数网. 沪深 300 指数编制方案[EB/OL]. (2023-09). https://csi-web-dev.oss-cn-shanghai-finance-1-pub.aliyuncs.com/static/html/cindex/public/uploads/indices/detail/files/zh_CN/000300_Index_Methodology_cn.pdf.

易阈值以保证策略不会失效,从而避免较大亏损。基于多只股票模型得到的配对组合 (i,j) ,在交易期内,假设组合 (i,j) 的价差序列为 $\varepsilon_t(\varepsilon_t = p_{j,t} - p_{i,t})$,两者价差均值为 $mean(\varepsilon_t)$,标准差为 $std(\varepsilon_t)$,则 t 时刻价差的偏离程度记作:

$$Mspread_t = \varepsilon_t - mean(\varepsilon_t) \quad (7)$$

当 $Mspread_t > k * std(\varepsilon_t)$ 时,股票 j 被相对高估,因此执行卖出 j 买入 i 的交易,此时若 $Mspread_t$ 减小,回到0时,实行平仓;而当 $Mspread_t < k * std(\varepsilon_t)$ 时,股票 j 被相对低估,执行反向交易。此时若 $Mspread_t$ 增加,回到0时,实行平仓。设建仓阈值为 δ_1 ,平仓阈值为 δ_2 。则当 δ_1 和 δ_2 数值增大时,交易次数减少,而潜在获利空间变大;反之,当 δ_1 和 δ_2 数值减小时,交易次数增加,但潜在获利空间变小。

(二) 稳定性分析

配对交易策略的效果受参数设定影响显著,通常设定股票最小持有时间以规避阈值附近的短暂噪音,避免频繁同向交易。考虑到过拟合的策略风险,本文通过每日更新的移动时间窗口进行样本外测试,以最新数据重建策略并评估模型的协整关系、残差和标准差,从而验证优化模型的有效性和市场适应能力。同时,日度数据这类相对低频的数据增强了策略在个人投资者中的可操作性(Pricope, 2021)。

考虑到参数稳定性问题,本文采用滚动窗口数据(Zhang 和 Urquhart, 2019)动态调整策略参数,并利用沪深 300 指数成分股的数据进行回测^①。其中,样本内检验时期为 2015 年 1 月至 2017 年 12 月,样本外检验时期为 2018 年 1 月至 2020 年 12 月,采用 1 年滚动窗口。得到两个样本期内配对交易的策略结果如图 1 和表 1 所示。

综合两段交易周期,本文的优化策略基于日度数据,不会出现日度高频交易,平均持有时间约 20.08 天。结果显示:在第一个交易期内约有 63 个交易日至少进行了一笔交易,占总交易时间的 17.07%;在第二个交易期内约有 233 个交易日至少进行一笔交易,占总交易时间的 62.80%。在这一样本测试频率下,配对交易组合呈现出相对稳定的收益和风险。

(三) LSTM 神经网络搭建

本文选取沪深 300 指数的成分股自 2018 年 1 月 3 日至 2020 年 12 月 31 日共 729 个交易日的股票价差序列进行预测分析。在神经网络的搭建上,

增加经验选择方法,采用两层长短时记忆网络架构,如图 2 所示。




图 1 滑动窗口的配对交易策略表现 (左:2015-2017;右:2018-2020)

表 1 优化配对策略在沪深 300 指数成分股上的表现

交易期	操作	利润	交易次数	每笔交易的平均回报	每笔交易回报的标准偏差
2015 年 -2017 年	买入	-1028.21	85	-0.12%	3.41%
	卖出	-12474.20	85	-1.47%	8.53%
	配对交易	-13502.41	170	-1.59%	9.86%
2018 年 -2020 年	买入	45885.92	477	0.96%	5.75%
	卖出	-33998.52	477	-0.71%	8.00%
	配对交易	11887.40	954	0.25%	7.55%




图 2 LSTM 网络结构

长短时记忆网络输入变量设为 729*5 矩阵,两个 LSTM 隐藏层分别有 128 和 64 个神经元,即维度为 128 和 64。针对隐藏层神经元数,考虑到因子数目为 70 个,在第二个隐藏层之后设置遗忘层(dropout=0.2),为避免过拟合问题,最后通过一个全连接层预测未来 5 天价差输出。滑动窗口参数表示时间窗长度,即训练 LSTM 网络使用序列的最后 k 个数值 (t_{n-k}, \dots, t_n) 来预测 t_{n+1} 处的值。若该参数数值过大会导致能输入 LSTM 网络且符合要求(如不停牌)的样本过少,参数过小则很难发挥循环神经网络所具有学习和理解股票数据长期趋势的性能,本文参考 Mettenheim 和 Breitner (2014)的滑动窗口参数设置,使用过去 5 天的输入因子预测接下来一天股票的涨跌。同时使用 Adam 优化器基于加权动量更新梯度^②,模型损失函数为 MAE 函数。

基于所构建的备选股票池和网络训练参数,首先利用 LSTM 神经网络预测配对股票之间的价差序列,参照 Sermpinis 等 (2012)的方法计算价差序列预测值与真实值之间的增量,并确定开平仓信号:

$$\Delta spread_t = predicted_spread - true_spread \quad (8)$$

当 $\Delta spread_t$ 为正时,卖出股票 j 买入股票 i ;当 $\Delta spread_t$ 为负时,执行相反交易。通过对价差的准确预测,可以过滤掉小于过滤规则的交易,从而改善模型的风险/回报状况。然而这种价差预测方式比较绝

①利用沪深 300 指数成分股的数据进行回测步骤详见《价格理论与实践》网站(<http://www.price-world.com.cn/>)附件。

②使用 Adam 优化器基于加权动量更新梯度详见《价格理论与实践》网站(<http://www.price-world.com.cn/>)附件。

对,容易过滤到细小的价差变化。本文参照式(8)采用前 $t-1$ 天的价差序列预测第 $t-1$ 天价差,得到相对价差计算公式:

$$\Delta spread_t = \frac{\text{predicted_spread} - \text{true_spread}}{\text{true_spread}} \quad (9)$$

记这一策略为 LSTM-WV-MultiPT 配对策略。

五、基于 LSTM 动态参数调整和权重市值筛选的优化股票配对交易策略实证分析

为验证该参数优化方法的有效性,本文利用我国股市数据构建包含不同类型和规模股票的投资组合模型,构建多只股票配对的优化交易策略。考虑股市的波动性,优化策略优先选择具有较好协整关系的股票对,并在交易期内开展动态协整检验,确保匹配的股票组具有良好的协同变动关系。为了直观对比经典距离和协整匹配策略表现,本文在每个配对组中选择两只股票进行分析。

(一)数据选取与预处理

本文选取沪深 300 指数成分股的日收盘价进行回测,样本区间为 2015-2020 年,覆盖 A 股市场的高峰和低谷期,数据来源为 Wind 数据库,回测采用 Python 和 Matlab 软件。根据经典的配对时期划分,本文将形成期(交易之前的股票组合形成期)定为 24 个月,交易期定为接下来的 12 个月。同时采用样本内和样本外检验评估不同筛选规则下的选股结果,详见表 2。

表 2 配对交易策略样本区间

回测方法	阶段	日期	交易日
样本内检验	形成期	2015 年 1 月 1 日—2016 年 12 月 31 日	488
	交易期	2017 年 1 月 1 日—2017 年 12 月 31 日	244
样本外检验	形成期	2018 年 1 月 1 日—2019 年 12 月 31 日	487
	交易期	2020 年 1 月 1 日—2020 年 12 月 31 日	243

本文采用系数中性算法计算仓位比例,通过模型估计的协整系数进行加权,并基于序列线性组合的偏差生成交易信号^①。此外,将沪深 300 指数年化收益率作为基准收益,使用 10 年期国债收益率作为无风险收益率,其余各类费率均与实际一致。由于配对交易策略高度依赖配对资产的即时价格,交易实施存在显著的不确定性,可能在整个交易期内都未发生交易。因此,本文基于整体交易期统计交易次数,并计算策略收益。

(二)WV-MultiPT 优化策略回测在剔除掉长期停盘的股票之

后,基于 MultiPT 策略和 WV-MultiPT 策略对备选池中的剩余股票进行匹配,基于权重系数的正负号分组,得到权重系数,并按绝对值进行降序排列,选取前 2 只股票作为最能体现组合特征的股票。配对结果如表 3 所示:

表 3 MultiPT 与 WV-MultiPT 策略配对结果

形成期	MultiPT 策略组合				WV-MultiPT 策略组合			
	配对组 1		配对组 2		配对组 1		配对组 2	
	股票代码	股票权重	股票代码	股票权重	股票代码	股票权重	股票代码	股票权重
2015 年	000001	0.47	601939	-1.04	601398	0.90	601288	-0.81
-2016 年	000069	0.53	000725	-1.12	000725	0.10	601939	-0.33
2018 年	000001	0.69	600028	-0.40	601398	0.97	601288	-0.48
-2019 年	601857	0.31	000725	-1.75	601390	0.03	601939	-0.55

为了防止出现过拟合情况,本文设置回溯期为 240 天,再平衡期为 20 天,交易成本为 1%。得到 WV-MultiPT 策略与 MultiPT 策略的表现如表 4 所示:

表 4 WV-MultiPT 策略与 MultiPT 策略表现对比

交易期	配对选股方法	年化收益率	Sharpe	最大回撤	最大回撤发生时间
2017 年	MultiPT 策略	21.04%	1.91	47.86%	2017-05-26
	WV-MultiPT 策略	44.78%	2.16	87.86%	2017-05-26
2020 年	MultiPT 策略	3.84%	0.65	60.62%	2020-07-06
	WV-MultiPT 策略	28.39%	0.47	71.23%	2020-12-02

可以发现,WV-MultiPT 策略的年化收益率和最大回撤水平均高于 MultiPT 策略。在第一个交易期内,WV-MultiPT 策略组合的收益和 Sharpe 比率较高,这表明虽然筛选后的配对组合能够有效捕捉交易机会,但同时也需要承担较高的风险。值得注意的是,在 2020 年的牛市行情中,该策略的收益表现与此相反。整体策略趋势与沪深 300 指数基本保持一致。由策略的描述性统计结果可知^②,尽管两个策略收益的均值和标准差指标接近,但在 2017 年交易期内 MultiPT 策略的偏度和峰度明显高于 2020 年,整




图 3 基于 Dunis 方法的 LSTM 模型误差及预测价差变化 (左:MultiPT 策略;右:WV-MultiPT 策略)

①建仓规则详见《价格理论与实践》网站(<http://www.price-world.com.cn/>)附件。

②描述性统计结果详见《价格理论与实践》网站(<http://www.price-world.com.cn/>)附件。

体呈右偏斜分布形态,且具有更重的尾部风险。

(三)LSTM-WV-MultiPT 优化策略回测

为了避免 LSTM 算法过拟合,本文按照 70%、15%、15%的比例将数据划分为训练集、验证集和测试集,通过训练集数据拟合参数,并将拟合得到的模型在验证集上进行调整,最后通过测试集对模型进行无偏化估计。基于 Dunis 绝对价差方法对 MultiPT 策略和 WV-MultiPT 策略的选股结果进行预测,得到模型误差与预测价差的变化趋势如图 3 所示。

由图 3 可知,在迭代次数接近 5 次时,两组数据的误差变化便很快趋于平缓。针对不同样本集而言,训练集中两类策略的选股结果在 LSTM 网络中误差水平比较接近,验证集中 MultiPT 策略在 LSTM 网络中误差水平略低于 WV-MultiPT 策略,预测精度较好。

随后依据改进价差方法对两类配对策略进行预测,得到模型误差与预测价差的变化趋势如图 4 所示:

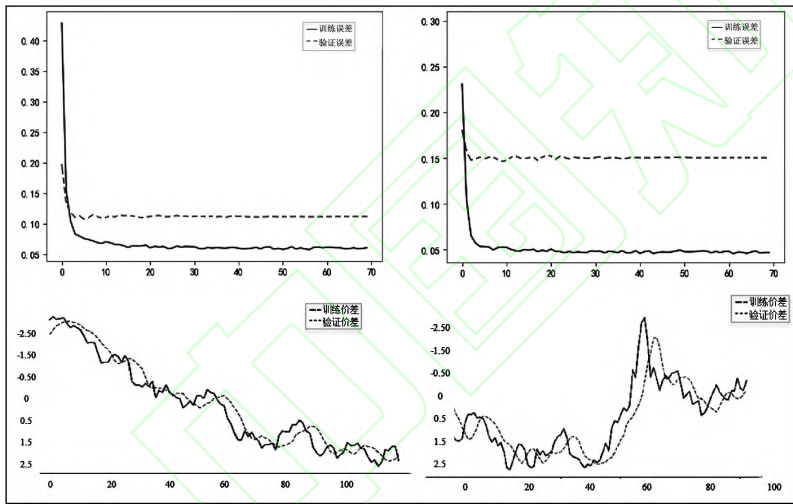


图 4 基于改进价差方法的 LSTM 模型误差及预测价差变化(左:MultiPT 策略;右:WV-MultiPT 策略)

由图 4 可知,同样在迭代次数接近 5 次时,样本的误差变化快速趋于平缓。值得注意的是,MultiPT 策略的误差水平在两个数据集中的差异低于 WV-MultiPT 策略,这在一定程度上说明对样本数据的预筛选可能会导致过拟合,降低整体预测精度。MultiPT 策略可能具有更好的泛化能力,在不同的数据集上保持相对稳定的表现,受特定样本选择偏差的影响较弱。因此,其能够更好地捕捉市场的基本规律,在未知数据上表现更佳。

表 5 不同价差预测方式下的配对策略表现对比

价差预测方法	配对策略	收益率	年化收益	Sharpe	最大回撤
Dunis 绝对价差	MultiPT 策略	8.39%	8.78%	2.55	0.50
	WV-MultiPT 策略	15.82%	16.59%	2.56	0.53
改进价差	MultiPT 策略	39.61%	41.72%	1.42	0.53
	WV-MultiPT 策略	53.10%	56.06%	1.13	0.55

基于 Dunis 的价差计算和改进价差计算两种方式,得到不同配对策略表现如表 5 所示。

在同一样本期内,Dunis 绝对价差预测的配对策略收益远低于改进价差预测结果,且策略的波动性比较大,夏普比率较高,而最大回撤指标基本一致。此外,在相同价差预测方法下,WV-MultiPT 策略收益均高于 MultiPT 策略,同时最大回撤水平较低,组合收益率趋于稳定。对策略收益展开描述性统计发现,在同一样本时期内,采用 Dunis 绝对价差预测方式得到的收益偏度和峰度明显高于改进价差预测方式,其收益分布呈现出更重的尾部和右偏斜的分布形态。相比之下,改进的价差计算方法在 LSTM 参数优化下表现出更好的预测精度和收益。

六、结论与政策启示

本文选择中国股票市场的沪深 300 指数成分股为研究对象,构建多只股票优化配对模型并引入 LSTM 算法优化交易参数,回测结果表明:(1)基于权重市值筛选的多只股票配对策略能够

有效识别优质低估值资产,并带来更高的投资回报;(2)基于 LSTM 的动态参数调整方法显著提高了交易信号的预测精度,增强了策略动态适应市场和价格发现的能力。基于本文研究结论,得到以下启示:

1.持续优化量化交易监管规则。短期高频同向交易会放大市场“噪音”,加剧市场波动。监管部门应持续推进强监管、防风险,应对程序化交易和高频量化交易实施更严格的监管措施,设定明确的交易规则以识别和防止市场操纵行为。同时,建议加强对量化交易的引导,对中

长期持股、聚焦相对低估值股票的量化交易制定差异化监管措施,充分挖掘和利用量化交易资金对股市价格发现、提供流动性的正向作用。

2.积极培育长期投资理念。基于多只股票优化配对模型的投资策略能够在 A 股实现不错的投资回报,表明股票价格能够在中长期逐步向其价值回归,我国股市有效性持续提升,因而买入并坚定持有优质上市公司股票能够获得较好的中长期回报。未来仍需要监管机构引导、各金融机构参与,共同营造和培育中长期投资理念,推动市场向长期投资和价值投资的方向发展。如,持续提升中长期收益在考核中的权重,吸引社保基金、银行理财及保险资金等机构投资者进入市场。

3.营造有利于价值投资的政策环境。以沪深 300

为代表的流动性好、市值大的股票,相比于高波动的小市值股票,通常具有更高的分红比例、更低的波动性和操纵股价的可能性,不仅适合作为长期量化投资策略构建投资组合的理想选择,也适合普通投资者中长期持有。建议继续营造有利于价值投资的整体环境,持续提升价值投资的吸引力。如,鼓励上市公司通过发展主业、兼并收购等做大做强做优,形成具有较强国际竞争力的优质企业;加强上市公司质量评价,引导上市公司提升经营质量;持续优化上市公司的分红标准,加大对长期不分红企业的监管力度并采取相应的限制举措;推动公募基金等投资机构优化风险管理和选股规则,将更多资金投向大市值、行业龙头股票。

参考文献:

- [1]刘宇轩,金伟译,袁亮.多因子量化选股模型优化与实证研究——引入金融周期指标的分析[J].价格理论与实践,2022(4):141-145.
- [2]陈荣达,俞静婧,徐敏,等.投资者本地偏好对股票市场信息效率影响研究[J].系统工程理论与实践,2022,42(4):879-896.
- [3]傅毅,郭润楠,张寄洲.基于O-U过程的基金配资产动态管理策略研究[J].管理评论,2019,31(6):23-35.
- [4]毕秀春,袁吕宁,刘博,张曙光.带止损条件的配对交易最优阈值[J].系统科学与数学,2019,39(7):1117-1141.
- [5]沈蕾,罗梦丝.基于LSTM算法的碳排放权交易价格多因素预测研究[J].价格理论与实践,2022(07):64-68.
- [6]胡文伟,胡建强,李湛,周剑峰.基于强化学习算法的自适应配对交易模型[J].管理科学,2017,30(2):148-160.
- [7]孟庆斌,侯德帅,汪叔夜.融券卖空与股价崩盘风险[J].管理世界,2018(4):40-54.
- [8]Goldkamp J, Dehghanimohammadabadi M. Evolutionary multi-objective optimization for multivariate pairs trading[J]. Expert Systems with Applications, 2019, 135: 113-128.
- [9]Gatev E, Goetzmann W N, Rouwenhorst K G. Pairs trading: Performance of a relative-value arbitrage rule[J]. Review of Financial Studies, 2006, 19(3): 797-827.
- [10]Vidyamurthy G. Pairs trading: quantitative methods and analysis[M]. Hoboken: John Wiley & Sons, 2004: 118-136.
- [11]Zhao Z, Palomar D P. Mean-Reverting Portfolio With Budget Constraint[J]. IEEE Transactions on Signal Processing, 2018, 66(9): 2342-2357.
- [12]Wu L, Zang X, Zhao H. Analytic value function for a pairs trading strategy with a Lévy-driven Ornstein-Uhlenbeck process[J]. Quantitative Finance, 2020, 20(8): 1285-1306.
- [13]Buehler H, Gonon L, Teichmann J, et al. Deep hedging[J]. Quantitative Finance, 2019, 19(8): 1271-1291.
- [14]Wu X, Chen H, Wang J, et al. Adaptive stock trading strategies with deep reinforcement learning methods[J]. Information Sciences, 2020, 538: 142-158.
- [15]Li H L, Huang Y H, Fang S C, et al. A Prime-Logarithmic Method for Optimal Reliability Design[J]. IEEE Transactions on Reliability, 2021, 70(1): 146-162.
- [16]Marshall B R, Nguyen N H, Visitanachoti N. ETF arbitrage: Intraday evidence[J]. Journal of Banking & Finance, 2013, 37(9): 3486-3498.
- [17]Hu Z, Zhao Y, Khushi M. A Survey of Forex and Stock Price Prediction Using Deep Learning[J]. Applied System Innovation, 2021, 4(1): 9-43.
- [18]Chang V, Man X, Xu Q, et al. Pairs trading on different portfolios based on machine learning[J]. Expert Systems, 2021, 38(3): 1-25.
- [19]Dunis C L, Ho R. Cointegration Portfolios of European Equities for Index Tracking and Market Neutral Strategies[J]. Journal of Asset Management, 2005, 6: 33-52.
- [20]Kinlaw W, Kritzman M, Page S, et al. The myth of diversification reconsidered[J]. Journal of Portfolio Management, 2021, 47(8): 124-137.
- [21]Pricope T V. Deep Reinforcement Learning in Quantitative Algorithmic Trading: A Review[J]. arXiv preprint arXiv:2106.00123, 2021.
- [22]Zhang H, Urquhart A. Pairs trading across the mainland and Hong Kong stock markets[J]. International Journal of Finance and Economics, 2019, 24(2): 698-726.
- [23]Mettenheim H J, Breitner M H. Forecasting Daily Highs and Lows of Liquid Assets with Neural Networks[C]. Operations Research Proceedings Operations Research Proceedings 2012, 2014: 253-258.
- [24]Serpiniis G, Dunis C, Laws J, et al. Kalman Filters and Neural Networks in Forecasting and Trading[J]. Communications in Computer and Information Science, 2012, 311: 433-442.

(作者单位:中国社会科学院数量经济与技术经济研究所)

Research on Optimization of Paired Trading Strategies for Shanghai and Shenzhen 300 Stocks

—Based on LSTM dynamic parameter adjustment and market value filtering

DIAO Haican and ZHANG Yanqun

Abstract: Building a dynamic and resilient capital market is crucial for promoting the high-quality development of listed companies and optimizing the investment and financing functions of the financial market. Traditional pair trading strategies, with their relatively fixed trading parameters and a lack of flexible pre-screening rules, are limited in their dynamic response to market fluctuations. To overcome these limitations, this paper proposes an optimized strategy that integrates market value screening rules with a multi-stock pairs trading framework, ensuring that selected stocks can effectively identify undervalued, high-quality targets. The strategy employs Long Short-Term Memory (LSTM) networks to dynamically adjust trading parameters, enhancing prediction accuracy. Empirical analysis reveals that, compared to strategies with fixed parameters, the optimized strategy developed in this study not only enhances price discovery capabilities in the Chinese stock market but also achieves higher investment returns. This research expands the theoretical domain of pair trading and provides model and algorithmic guidance for uncovering high-quality and undervalued assets in the Chinese stock market, thereby helping to boost market confidence and improve long-term investment expectations.

Keywords: multi-stock pairs trading; cointegration test; trading parameters; market capitalization filtering; long short-term memory (LSTM)