蜡烛图是否足够？技术指标在股票收益预测中的增量经济价值

刘鹏（pengliu@xaufe.edu.cn）[1,*] 和郑妍妍（yanzheng@whu.edu.cn）[2]

[1]西安财经大学信息学院，陕西省西安市 *710100*，中国 [2]西安工程大学管理学院，陕西省西安市 *710048*，中国 [*]通讯作者：*pengliu@xaufe.edu.cn*，*pengliuhep@outlook.com*

arXiv:2611.30584v1 [econ.GN] 23 Nov 2026

摘要

尽管技术分析在实践中仍被广泛使用，但随着深度学习模型能够直接从OHLC价格数据中提取特征，人们日益质疑是否还需要人工构造指标。本文考察交易量和人工构造的技术指标组的独立经济价值，并探讨将这些指标组加入OHLC蜡烛图能否带来增量经济价值。我们使用2013年至2025年间1,707只中国A股的日度数据，构建约336万个股票窗口样本，并将其编码为多通道图像，其中包含蜡烛图、交易量和七种广泛使用的人工构造技术指标。主要分析使用二维卷积神经网络处理这些图像；补充检验则将逻辑回归、一维卷积神经网络和长短期记忆网络应用于同一样本的数值表示。我们采用十分位投资组合、夏普比率、Fama–French阿尔法和正式的成对检验，评估2021年至2025年的样本外表现。实证结果得出两个核心发现。首先，分别基于OHLC、交易量和各技术指标组的设定，均能产生显著为正的高减低收益和因子调整后的阿尔法，同时夏普比率也具有显著的经济意义；在非线性模型下，仅OHLC设定的表现通常最佳。其次，在我们的研究设定中，将这些技术指标组加入OHLC并不能系统性地改善任何一项绩效指标。总而言之，这些结果首次基于中国A股市场的大规模证据，揭示了这些技术指标组在多种表示方式和模型架构下的独立经济价值与增量经济价值。

关键词： 股票收益预测；CNN；长短期记忆网络；蜡烛图；技术指标；中国股票市场**JEL分类：** G11，G12，G17

1 引言

F金融市场通常被视为复杂适应系统，在这类系统中，价格源于异质性、
b有限理性的投资者之间的相互作用，其信念和策略会随着市场状况而演变（Lo，2004年；Scholl等，2021年；Zhao和Li，2022年）。这些相互作用可能产生非线性且随时间变化的动态，而证券之间的联系意味着
i个股收益产生于相互关联的市场之中，而非孤立的过程（Mantegna，1999年；Liu，2025年，026）。因此，从这样的环境中提取稳定的
2预测关系本质上十分困难。

这种复杂性也反映在资产收益的统计特征中。收益分布呈现厚尾，并且
d 显著偏离高斯基准，这意味着极端价格波动发生的频率高于标准分布假设所暗示的水平（Mandelbrot，1963年；Mantegna 和 Stanley，1995年；Cont，2001年；Liu 和 Zheng，2023年）。在较短期限内，潜在的预测信号必须从一个由噪声、依赖性和偶发大幅波动主导的环境中提取。因此，要确立具有经济意义的收益可预测性，就需要证明这些信号能够在样本外持续存在，并转化为投资组合表现。

关于收益可预测性的研究长期以来一直在探讨，历史价格和交易信息是否包含有关未来收益的信号。尽管有效市场假说（EMH）认为价格反映了可获得的信息（Fama，1970年），但当信息获取成本高昂、投资者具有有限理性，或信息逐步在市场中扩散时，信息未必会被完整且即时地纳入价格（Grossman 和 Stiglitz，1980年；Lo，2004年；Hong 和 Stein，1999年）。更广泛而言，行为金融研究表明，投资者信念、情绪和心理状态能够影响资产价格以及对风险与收益的认知（Barberis 等，1998年；Can 等，2024年；Lonkani 等，2025年）。在这场争论中，技术分析占据着独特且颇具争议的地位。尽管它被从业者广泛使用（Menkhoff，2010年），但其学术地位仍未确定。理论研究解释了为何历史价格可能仍然包含预测信息（Brown 和 Jennings，1989年；Hong 和 Stein

，1999年），实证研究也记录了特定市场和资产类别中基于过去收益、技术信号和价格形态的可预测性（Jegadeesh 和 Titman，1993年；Lo 等人，2000年；Neely 等人，2014年；Han 等人，2016年；Detzel 等人，2021年；Jiang 等人，2019年，2023年）。然而，其他研究发现，

技术规则的经济表现可能受规则选择、数据窥探、交易成本和风险调整的影响（Sullivan 等人，1999年；Bajgrowicz 和 Scaillet，2012年；Eugster 和 Uhl，2023年）。正如Lo 等人（2000年）所指出的，技术分析经久不衰的吸引力，部分可能源于其直观的视觉形式。

收益可预测性也通过使用具有预先指定预测变量和相对结构化函数形式的统计与计量经济模型进行了研究。线性预测回归用于评估滞后变量能否预测后续收益，以及由此产生的预测能否在样本外优于简单的历史基准（Welchand Goyal，2008年；Campbell andThompson，2008年）。非参数方法放宽了部分函数形式假设，也曾用于识别技术价格形态（Lo 等人，2000年）。这些方法对于推断和解释仍然很有价值，但其表现可能取决于研究者对预测变量和函数形式的选择。这种依赖性自然促使人们采用更灵活的数据驱动方法。

机器学习和监督统计学习的最新进展，为重新审视这一长期争论提供了新工具。在实证资产定价中，基于树的集成方法、监督降维技术和神经网络已被用于从丰富的信息集中提取预测信号；有证据表明，与传统基准相比，这些方法能够改善样本外收益预测（Gu 等人，2020年；Leippold 等人，2022年；Xu 等人，2026年）。

在这一更广泛的发展背景下，深度学习已成为股票市场预测的一种重要方法（Bao 等人，2025年；Giantsidi 和 Tarantola，2025年）。基于数值市场历史数据的研究采用了深度前馈网络、长短期记忆网络（LSTM）等循环架构、一维卷积神经网络（1D CNNs）、基于注意力的模型以及混合架构，预测目标涵盖未来价格水平、方向和股票收益（Thakkar 和 Chaudhari，2021年）。不同市场中的实证应用通常报告了较强的预测表现（Hiransha 等人，2018年；Fischer 和 Krauss，2018年；G¨ulmez，2023年；Tran 等人，2024年）。然而，解读这些研究结果时，应考虑预测目标和评估设计的差异。特别是，对短期价格水平预测的高准确率，可能部分源于价格序列的持续性，并不一定能转化为具有经济价值的收益预测（Radfar，2025年）。

一个互补研究方向是将市场历史数据表示为可视化图表，尤其是蜡烛图。尽管蜡烛图像包含与数值序列相同的底层开盘价、最高价、最低价和收盘价（OHLC）观测值，但它们以空间方式组织价格历史数据，使相对价格位置、高低价区间、趋势和几何形态能够被共同观察和处理。二维卷积神经网络（二维卷积神经网络）可以利用这种表示来学习分层的非线性模式，而无需研究人员预先指定相关的图表形态（Jiang 等人，2023年）。

在这方面，将二维卷积神经网络应用于蜡烛图，为基于图表的技术分析提供了一种计算类比。技术分析师会检查历史图表，以寻找可能预示未来价格走势的重复形态，而卷积神经网络则从数据中系统地学习能够预测收益的视觉模式（Jiang 等人，2023年；Radfar，2025年）。Jiang 等人（2023年）表明，应用于股票图表图像的卷积神经网络能够识别可预测收益的价格形态，并支持有利可图的样本外投资组合策略；与此同时，Jeong 等人（2026年）在韩国股市中记录了相关证据。

然而，基于图表的技术分析通常会在蜡烛图中加入交易量以及人工构造的指标，以概括趋势、动量和波动率。交易量并非根据开盘价、最高价、最低价和收盘价构造，可能传达仅凭价格统计数据无法推断的市场信号质量信息（Blume 等人，1994）；而本文考察的趋势、动量和波动率指标则由历史 OHLC 数据构造。

尽管这些指标并未引入独立的非价格数据来源，但其基于经济原理的变换仍可能使预测模型更容易利用价格动态的某些特征。然而，尚不清楚在纳入 OHLC 后，这些源自 OHLC 的变换能否带来额外的样本外经济价值，以及答案是否取决于数据表示方式或模型架构。由此引出两个实证问题。第一，单独使用交易量以及趋势、动量和波动率指标组，能否产生具有经济意义的样本外投资组合表现？第二，纳入 OHLC 后，这些技术指标组能否带来额外的样本外经济价值?

为回答这些问题，我们首先评估交易量以及趋势、动量和波动率指标组各自的独立经济价值。随后，我们检验在 OHLC 蜡烛图中加入这些技术指标组，是否能带来额外的样本外经济价值。我们还评估 OHLC + Volume 这一扩展设定作为基准，因为与技术指标不同，交易量并非由 OHLC 构造而来。

我们使用 2013 年至 2025年中国A股市场主板 1,707 只股票的日度数据，根据 20 日市场历史数据构建约 336 万个股票窗口样本，并预测随后五个交易日的累计收益方向。在主要的图像分析中，我们将近期市场历史数据表示为多通道图像，并估计二维卷积神经网络。我们分别比较 OHLC、交易量和三个技术指标组，也比较在 OHLC 中加入额外输入的设定。为确定研究发现是否取决于数据表示或模型架构，我们还对相同样本的数值表示应用经过l_2正则化的逻辑回归、一维卷积神经网络和长短期记忆网络，并重复相同的比较。

我们使用等权重十分位投资组合，在2021—2025年样本外期间评估经济表现；持有期为按计划安排且互不重叠的五个交易日。我们报告高减低（H–L）收益、夏普比率和 Fama–French 因子调整后阿尔法，并进行正式的成对检验。分析还考察了传统交易策略、比例交易成本以及中国A股市场特有的交易限制。

实证结果得出两项核心发现。第一，分别基于开盘价、最高价、最低价和收盘价、交易量及各技术指标组的设定，均能产生显著为正的高–低收益和因子调整后的阿尔法，并具有经济上

有意义的夏普比率；在非线性模型中，仅OHLC设定通常表现最佳。第二，也是本文的核心发现，将技术指标组加入OHLC，并未在四种模型架构下系统性地提高高–低收益、夏普比率或因子调整后的阿尔法。扩展设定中唯一达到统计显著水平的改善，出现在长短期记忆网络对OHLC +成交量和所有特征的夏普比率上。不过，无论是高–低收益还是夏普比率，所有特征设定的表现都没有显著优于OHLC + 成交量。这一模式与以下解释相符：长短期记忆网络夏普比率的改善主要与交易量有关，而非技术指标组。采用基准的仅使用OHLC的二维卷积神经网络进行的其他基准比较和实施分析表明，该模型的表现优于四种传统交易策略。在单边成本最高为10个基点时，高–低投资组合和仅高组投资组合的净收益仍为正且具有统计显著性；在单边交易成本为10个基点时，筛选后的多头投资组合也仍有正净收益，且通常具有统计显著性。

本文在两个方面对现有文献作出了贡献。首先，本文首次基于中国A股市场提供了大规模证据，考察了本文所研究技术指标组的独立经济价值和增量经济价值。其次，本文还在图像表示与数值表示之间，以及线性层、卷积和循环模型架构之间，对这些独立价值和增量价值进行了比较评估。总体一致的证据表明，这些技术指标组有限的增量价值并非蜡烛图图像表示或二维卷积神经网络架构所特有。

本文其余部分安排如下。第2 节介绍数据、输入表示和样本构建。第3 节介绍预测模型和估计程序。第4 节报告基于二维卷积神经网络的投资组合结果，第5节介绍数值输入模型的相应证据。第6 节考察交易成本和交易限制。第7节总结全文。

2 数据准备

2.1 数据来源与预处理

本研究选取在上海证券交易所（SSE）和深圳证券交易所（SZSE）主板上市的 1,707 只 A 股作为样本。样本涵盖所有于 2011 年 1 月 1 日之前首次上市的股票。尽管样本依据 2011 年之前的上市截止日期选取，实证分析仅使用 2013 年 1 月 1 日至 2025 年 12 月 31 日的日度观测数据。这一要求确保每只样本股票在样本期开始前均已上市至少两年，从而降低首次公开募股（IPO）后短期内异常高波动率可能造成的偏差。日度开盘价、最高价、最低价、收盘价和成交量（开盘价、最高价、最低价、收盘价和成交量）数据取自 Baostock 数据库（https://baostock.com）。最终样本期共包含 3,157 个交易日。

为处理股息分配和配股等公司行动，我们采用基于收益率的向后调整方案。该方法通过缩放价格来重构历史价格序列，以确保日收益率的连续性，从而有效消除非市场因素造成的非自然价格跳变。重要的是，这种调整并不假设股息再投资。相反，它对应一种假设策略：投资者在除息（或除权）日前立即平仓，并在除息日以相同价格将全部资金重新投入。在此假设下，股息支付不会减少投资资本，配股也不需要额外的资本注入。因此，调整后的价格序列反映纯粹基于价格的收益，并提供一致的资本增值衡量标准，同时不考虑公司行动相关的实际现金流。

为确保时间上的一致性，我们删除对应于停牌的观测值。删除停牌记录后，每只股票都表示为按时间顺序排列的活跃交易观测值序列，这对于正确计算滚动窗口统计量和技术指标至关重要。

基于清理并调整后的开高低收量数据，我们使用 Python 库 ta（https://github.com/bukosabino/ta）计算一组常用的传统技术指标。这些指标分为三类：趋势、动量和波动率。由于计算这些指标需要历史观测值，因此在每只股票时间序列的开头，如果尚未达到所需的回溯期，可能会出现缺失值。

对于趋势指标，我们使用5日、10日和20日窗口计算收盘价的简单移动平均线（SMA）。所得的简单移动平均线反映了不同时间跨度下的潜在价格趋势。我们还使用10日窗口计算平均趋向指数（ADX），以及正向和负向趋向指标（+DI 和 –DI）。ADX 衡量当前趋势的强度，而不考虑其方向； +DI 和 –DI 则分别反映正向和负向趋向运动。此外，我们还构建平滑异同移动平均线（MACD）指标（快线 = 8、慢线 = 20、信号线 = 6），通过移动平均线的收敛与发散来捕捉趋势动态的变化。

对于动量指标，我们计算窗口长度分别为 5 天、10 天和 20 天的相对强弱指数（RSI），用于衡量近期价格走势的变化速度和持续性。我们还计算回溯窗口为 10 天、平滑窗口为 3 天的随机振荡指标（STOCH），用于反映收盘价在近期交易区间中的相对位置。

对于波动率指标，我们使用10日移动平均线和2倍标准差乘数构建布林带，以捕捉价格围绕趋势的离散程度。我们还计算基于平均真实波幅（ATR）的通道，采用10日窗口，以5日移动平均线为中心，并定义为$\mathrm{SMA}_5 \pm \mathrm{ATR}$，从而捕捉随时间变化的价格波动率。

2.2 图像表示

为构建二维卷积神经网络的输入，我们将每个20日窗口内的开盘价、最高价、最低价和收盘价、交易量及技术指标转换为结构化的九通道灰度图像。每幅图像的尺寸为 $61 \times 60 \times 9$ (高度 $\times$ 宽度 $\times$ 通道)，如图 1 所示。横轴表示时间，20个交易日中的每一天占据连续的三个像素，因此图像宽度为60像素。纵轴表示各通道对应的缩放后价格、交易量或指标值。所有通道均使用黑色背景（像素值为0），并通过不同的灰度强度区分图形元素。与RGB图像相比，这种表示方式既保留了输入数据中的结构模式，又降低了存储和计算成本。

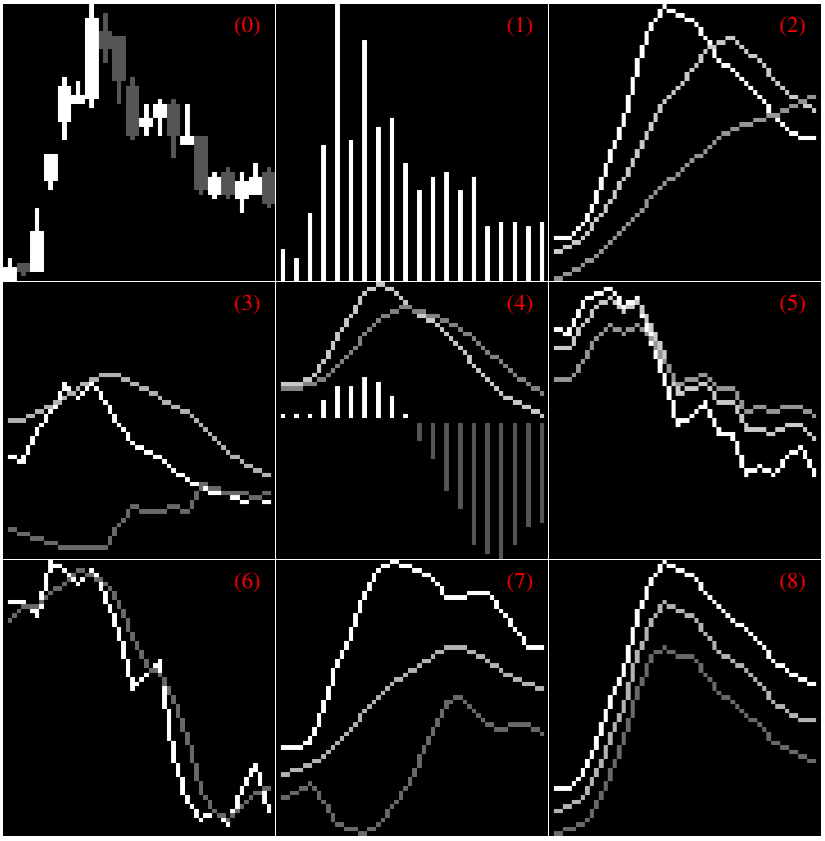

图 1|二维卷积神经网络模型中使用的多通道图像表示。 该图展示了作为二维卷积神经网络输入的九个灰度通道。通道 (0) 和 (1) 分别展示 20 日 OHLC 蜡烛图和成交量柱；通道 (2) 绘制收盘价的 5 日、10 日和 20 日移动平均线；通道 (3) 展示平均趋向指数以及正向和负向趋向指标；通道 (4) 展示指数平滑异同移动平均线；通道 (5) 展示窗口长度为 5 日、10 日和 20 日的相对强弱指数；通道 (6) 展示随机指标；通道 (7) 展示布林带；通道 (8) 展示基于平均真实波幅的通道。这些通道共同捕捉每日股票数据中的趋势、动量和波动率信息。

这九个通道旨在捕捉市场动态的互补方面，并分为市场数据、趋势、动量和波动率几组。通道 (0) 表示 OHLC 蜡烛图，通道 (1) 则捕捉交易量。通道 (2) 至 (4) 捕捉趋势信息，包括简单移动平均线、平均趋向指数和指数平滑异同移动平均线。通道 (5) 和 (6) 通过相对强弱指数和随机指标捕捉动量。通道 (7) 和 (8) 通过布林带和基于平均真实波幅的通道表征波动率。

我们在每个输入窗口内进行通道特定归一化。蜡烛图、SMA、布林带和基于 ATR 的通道分别根据该通道中显示的价格序列的最小值和最大值进行缩放。成交量按窗口内的最大值归一化，而 RSI、STOCH、平均趋向指数、 +DI 和 –DI 则绘制在 0 到 100 的固定刻度上。对于指数平滑异同移动平均线，差离值（DIF）、讯号线（DEA）和柱状图序列共用一个基于其最大绝对值的对称刻度，零值位于图像垂直中心。

图像生成过程采用直接处理像素数组的自定义渲染函数。蜡烛图通过高低点垂直线和矩形实体绘制，并以灰度强度编码价格方向。交易量以垂直柱状图表示，并根据窗口内的峰值交易量进行归一化。连续的指标曲线通过布雷森汉姆直线算法栅格化，以连接相邻观测值。

对于指数平滑异同移动平均线指标，差离值和讯号线绘制为连续曲线，而柱状图则以垂直柱体表示，向零线的上方或下方延伸。对于随机指标中的K线和D线等多分量指标，则使用不同的灰度强度来区分各个分量。这种确定性的构建方法确保了数据构建过程的可重复性。

2.3 对图像 underlying 数据进行缩放

为了构建逻辑回归、一维卷积神经网络和长短期记忆网络模型的数值输入，我们对图像表示所依据的数据进行缩放。这些数据在不同变量之间的尺度各异，在不同股票和时间窗口之间的数值大小也不相同。因此，我们采用针对各窗口的线性缩放，使数值输入具有可比性，并避免模型结果受到这些差异的影响。使用相同的基础变量，也使数值模型与基于图像的二维卷积神经网络具有可比的信息基础。

除指数平滑异同移动平均线外，所有变量均在线性层面缩放至 $[0,1]$，且缩放范围限定在每个20天输入窗口内。开盘价、最高价、最低价和收盘价根据窗口内的最低低价和最高高价进行联合缩放。交易量除以其所在窗口内的最大值，而5天、10天和20天简单移动平均线则根据它们整体的最小值和最大值进行联合缩放。平均趋向指数及其方向性指标、相对强弱指数和随机指标均除以100。

由于指数平滑异同移动平均线可以取正值和负值，其差离值、讯号线和柱状图序列根据窗口内的最大绝对值联合缩放至 $[-1,1]$，其中零值保持不变。布林带和基于平均真实波幅的通道以缩放后的中线和半宽度表示。对于每个指标，中线根据最低下轨和最高上轨进行缩放，半宽度则除以相同的范围。所有特定于窗口的缩放参数均仅根据相应输入窗口内的观测值计算，从而避免前视偏差。

最终的数值数据将每个样本表示为一个 20×23 矩阵，行对应交易日，列对应各个特征。这 23 个特征包括四项开盘价、最高价、最低价和收盘价、交易量、三条简单移动平均线、平均趋向指数及其两个方向性指标、指数平滑异同移动平均线的差离值（DIF）、讯号线（DEA）和柱状图序列、三项相对强弱指数指标、随机指标的 K 线和 D 线、布林带中线及半宽度，以及基于平均真实波幅（ATR）的带状指标中线及半宽度。这与九通道图像表示有所不同，因为单个图像通道可能包含多个序列，而数值表示中每个序列都作为单独的数值特征存储。

2.4 样本构建与预测设置

我们利用股票层面数据的滚动 20 个交易日窗口构建预测样本。为便于说明，以下讨论主要聚焦于图像样本的构建。逻辑回归、一维卷积神经网络和长短期记忆网络模型所使用的数值样本，完全基于相同的股票窗口观测值构建，并遵循相同的标签设定、筛选和时间划分流程。二者唯一的区别在于输入表示：每个窗口要么转换为二维卷积神经网络使用的多通道图像，要么转换为上一小节所述的缩放数值矩阵。因此，图像输入和数值输入是对同一底层观测值的不同表示，而非不同的样本。

遵循Jeong 等人（2026年）的每日滚动窗口方法，训练集和验证集样本通过每次将20天输入窗口向前推进一个交易日来生成。与其随机划分训练集和验证集的做法不同，我们按时间顺序将样本分配到不同的训练期和验证期。这一程序显著增加了可用于模型估计和验证的样本数量，并使模型能够从每个符合条件的窗口结束日期中学习。因此，相邻窗口的20个观测值中有19个重叠，其五个交易日的预测区间也可能重叠。因此，这些样本不被视为统计独立观测值；相反，采用这种重叠构造是为了在模型训练中提供密集的输入模式。

在样本外评估中，测试样本的窗口结束日期每隔五个市场交易日推进一次。这一设计使样本外预测频率与投资组合策略相一致：每个预测日期都会对股票进行排序，随后持有相应投资组合五个市场交易日，再进行再平衡。因此，相邻的预定投资组合持有期不会重叠。

仅当候选窗口包含 20 个有效交易观测值、不包含股票被归类为特别处理（ST）的任何日期，且所有必需输入变量的值均完整时，才予以保留。在构建窗口之前，会先剔除停牌对应的观测值。因此，在市场日历对齐测试集中，若某只股票在指定窗口内的交易观测值不足，则会从该窗口中排除。这些筛选是在股票窗口层面进行的，因此某个窗口无效，并不意味着需要剔除同一股票的其他有效观测值。

对于每个以交易日 t结束的有效窗口，输入包含此前 20 个活跃交易观测值的信息，包括交易日 t。预测目标是从交易日 t 至之后第五个活跃交易日$t+5$的股票累计收益率。如果第 $t+5$ 日的复权收盘价高于第 t 日，则二元标签为 1，否则为 0。因此，所有输入变量的观测时间均不晚于第 t 日，而标签仅取决于之后的收益，从而避免前视偏差。

除图像或数值输入及其二元标签外，我们还保留窗口结束日期、股票代码和已实现五日收益率。这些变量用于对齐不同模型的预测结果，并构建样本外分析中的十分位投资组合。

样本被分为三个日历时段：2013–2018年用于训练集，2019–2020年用于验证集，2021–2025年用于测试集。该程序共产生约336万个股票窗口观测值。由于训练集和验证集中相邻窗口存在重叠，因此这些数量指的是模型输入，而非统计独立观测值。表 1汇总了时间划分以及各子集中正五日收益率的比例。各比例均接近50%，表明这三个子集适用于二分类，且类别分布均衡。

表 1|数据集划分摘要。

数据集	时间段	样本数量	正收益率
训练集	2013–2018	2,219,123	50.5%
验证集	2019–2020	751,829	49.7%
测试集	2021–2025年	388,914	48.4%

3 预测模型与估计程序

本节介绍 二维卷积神经网络、逻辑回归、一维卷积神经网络和长短期记忆网络模型，并介绍其估计程序 .

3.1 二维卷积神经网络的架构

该模型以多通道图像作为输入，这些图像编码了历史市场数据，包括蜡烛图、交易量以及本文考察的技术指标。这些通道共同呈现了近期市场动态的不同方面，使二维卷积神经网络能够联合学习价格、成交量、趋势、动量和波动率模式。形式上，每个观测值都会被转换为张量 $\mathbf{X} \in \mathbb{R}^{C\times H\times W}$，其中 C 表示通道数量， H 和 W 表示空间维度（高度和宽度）。

如图 2 所示，该网络架构采用了由一系列卷积块和一个全连接层（FC）头部组成的深层二维卷积神经网络结构。每个卷积块均由卷积层、批归一化、带泄漏的修正线性单元（Leaky ReLU）激活函数和最大池化操作组成。卷积层提取局部空间模式，批归一化稳定训练集过程，而 Leaky ReLU 激活则引入非线性，以增强模型的灵活性。最大池化可降低空间维度，并有助于缓解过拟合。

经过卷积骨干网络后，提取的特征图被展平并输入全连接头。全连接层采用Dropout正则化，以缓解过拟合。最终层输出两个logits，用于执行二分类任务，预测未来收益是正还是非正。

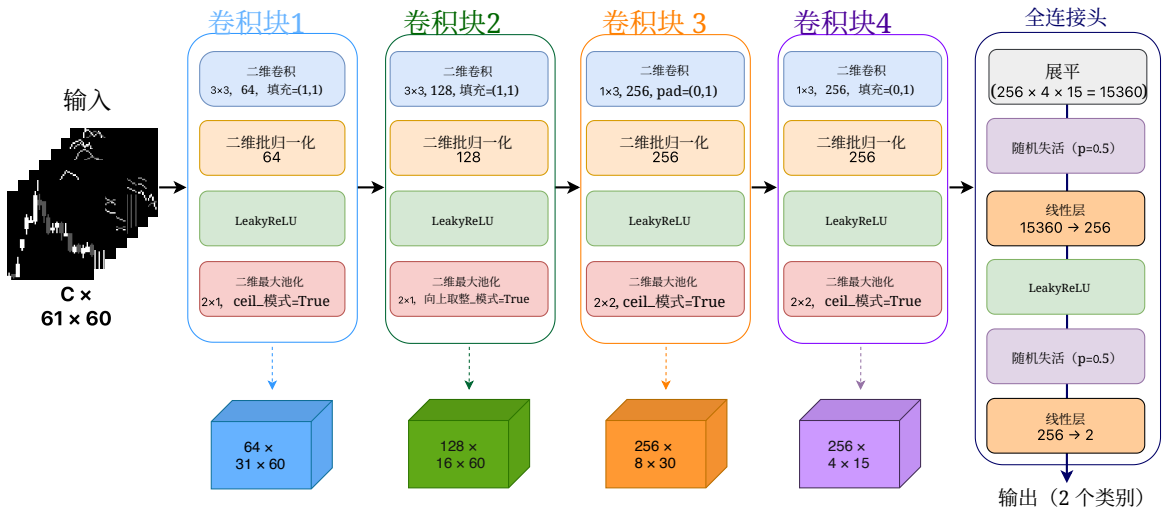

图 2|所提出的二维卷积神经网络架构。 模型以尺寸为 $C \times 61 \times 60$ 的多通道图像作为输入，其中 C表示输入通道数。模型由四个卷积块组成，每个卷积块均包含一个卷积层、批归一化、Leaky ReLU激活和最大池化。前两个卷积块采用卷积核大小为2×1的非对称池化，在保留水平维度的同时沿垂直维度对特征图进行下采样。后两个卷积块则采用标准的 2×2 池化，对两个空间维度进行下采样。提取的特征经过展平后输入带有Dropout正则化的全连接头，生成二分类输出。

3.2 逻辑回归设定

作为线性基准，我们采用基于缩放后的数值数据的l_2正则化逻辑回归，使用第2节所述的整个20天输入窗口中的观测值。对于每个样本期，按时间顺序将输入中的日变量串接起来，形成单个预测变量向量。由于MACD柱状图可由差离值和讯号线线性确定，因此将其排除。

按照针对各窗口的缩放流程，使用根据训练集估计的均值和标准差对预测变量进行标准化。随后将相同的变换应用于验证集和测试集。逆

正则化参数通过最小化验证集上的对数损失来选取。拟合后的模型会生成未来五个交易日收益为正的预测概率。

3.3 一维卷积神经网络和长短期记忆网络架构

为考察研究结果是否能够推广到图像表示和二维卷积神经网络架构之外，我们进一步使用缩放后的数值数据，采用一维卷积神经网络和长短期记忆网络模型。每个数值样本被组织成一个 $20 \times K$ 矩阵，其中行表示交易日，K 表示给定设定中所包含的特征组中的变量数量。特征组与基于图像的分析中使用的特征组相对应：OHLC 组包含四个价格变量；成交量组包含交易量；趋势组包含 SMA、平均趋向指数和指数平滑异同移动平均线序列；动量组包含相对强弱指数和随机指标序列；波动率组包含布林带和基于平均真实波幅的通道的中线及半宽度。我们还考察了将 OHLC 与其他各特征组分别结合的设定，以及包含全部 23 个数值特征的设定。不同于九通道图像（其中一个通道可能显示多个序列），在数值输入中，每个序列都构成一个独立特征。

一维卷积神经网络将数值变量视为输入通道，并沿 20 天的时间维度进行卷积。为便于与二维卷积神经网络进行比较，它采用相同的四个模块结构，通道数依次为 64、128、256 和 256。每个模块由一个卷积核大小为 3 的一维卷积、批归一化、Leaky ReLU激活，以及卷积核大小为 2 的最大池化组成。连续的池化操作将时间维度从 20 缩减至 2。随后将得到的特征展平，并输入分类头；分类头由一个随机失活层、一个包含 256 个单元的全连接层、Leaky ReLU激活、第二个随机失活层，以及最后一个包含两个单元的输出层组成。

长短期记忆网络将数值输入直接作为由 20 个每日观测值构成的序列进行处理。它由一个隐藏维度为 256 的单向长短期记忆网络层组成。输入窗口最后一天对应的长短期记忆网络层输出用作序列表示。该输出经过层归一化后，传入一个分类头；分类头由一个随机失活层、一个包含 256 个单元的全连接层、Leaky ReLU激活、第二个随机失活层，以及最后一个包含两个单元的输出层组成。因此，一维卷积神经网络和长短期记忆网络均会输出两个 logits，分别对应后续五个交易日收益为正和非正的情况。

3.4 神经网络训练流程

我们将收益预测任务表述为一个二分类问题：如果随后五个交易日的累计收益为正，则标签为1，否则为0。每个神经网络都会生成两个logits，作为交叉熵损失函数的输入。

我们使用Xavier均匀分布（Glorot和Bengio，2010）初始化卷积层和全连接层，并采用AdamW算法（Loshchilov和Hutter，2019）进行优化，该算法将权重衰减与梯度更新解耦，有助于控制模型复杂度。为稳定长短期记忆网络的训练，我们将梯度范数裁剪为1.0。训练采用小批量随机优化。为促进收敛，我们实施余弦退火学习率调度（Loshchilov和Hutter，2017）。该方法允许在训练初期进行相对较大的参数更新，并随着训练推进进行更精细的调整。为减少过拟合，我们根据验证集表现采用早停策略。每轮次结束后，模型都会在验证集上进行评估；如果验证准确率在预先设定的连续若干轮次内未能提升，则终止训练，并恢复验证表现最佳时对应的参数。关键训练配置和超参数汇总于表2中。对于每种神经网络架构，所有输入设定均采用固定的训练配置。

鉴于深度神经网络训练具有随机性，我们采用不同的随机初始化进行多次独立重复。每次重复中，我们保留验证准确率最高的模型参数。在预测阶段，最终预测概率通过对五个已训练模型的正类软最大概率取平均获得。这种集成方法可降低估计方差，增强预测的鲁棒性。

表 2|训练配置和超参数。

配置 / 超参数	值
批大小	128
最大训练轮数	50
独立训练重复次数	5
优化器	AdamW
学习率调度器	余弦退火
余弦退火周期	100 轮次
初始学习率	5×10^{-4}
学习率下限	10^{-6}
权重衰减	10^{-2}
梯度裁剪阈值	1.0（仅适用于长短期记忆网络）
丢弃率	0.5
早停耐心值	5 轮次

4 基于二维卷积神经网络预测的投资组合表现

4.1 十分位投资组合表现

我们使用等权重十分位投资组合，评估二维卷积神经网络预测的横截面排序能力和经济价值。如第 2 节所述，样本外投资组合形成日期之间相隔五个市场交易日。在每个形成日期，我们对五个独立训练模型给出的正的五个交易日收益率的样本外预测概率取平均。随后根据平均概率将股票从低到高排序，分为十个投资组合，并持有五个交易日，直至下一次再平衡。因此，相邻的预定投资组合持有期不会重叠。通过这种构建方式，我们可以考察实现收益是否随模型隐含排序而上升。然后，我们使用高减低投资组合概括与该排序相关的收益差；该组合做多高组，做空低组。

表3 报告年化平均收益（收益率）、年化夏普比率（夏普比率）和月均换手率（Gu 等人，2020年；Jiang 等人，2023年）。A面板展示基于个体特征组的模型，面板 B 则展示将 OHLC 与其他特征组结合的模型。标记为 Δ 的行报告仅 OHLC 模型的表现减去每种替代设定的表现，因此正值表示仅 OHLC 模型表现更好。对于本研究中的所有投资组合表现分析，平均高低收益及其两两差异的显著性均通过采用 Newey–West标准误的双侧检验进行评估（Newey 和 West，1987），夏普比率两两差异则采用双侧 HAC Δ 方法检验进行评估（Lo，2002）。所有基于 HAC 的检验均使用一个滞后项。

表 3|基于二维卷积神经网络预测的十分位投资组合绩效。 本表报告了不同输入设定下等权重十分位投资组合的样本外表现。A面板展示个体特征组，面板 B 展示OHLC与额外输入的组合，其中包括涵盖所有输入组的全特征设定。Ret和SR分别表示年化平均收益和年化夏普比率，而换手率表示高减低投资组合的月均换手率。第 Δ 行报告相对于仅OHLC设定的相应表现差异。***、**和*分别表示在1%、5%和10%的水平上显著。

A面板：个体特征组										
	OHLC		成交量		趋势		动量		波动率	
	Ret	SR	Ret	SR	Ret	SR	Ret	SR	Ret	SR
Low	-0.06	-0.29	-0.02	-0.07	0.01	0.04	0.04	0.21	0.08	0.37
2	0.05	0.25	0.16	0.73	0.10	0.47	0.07	0.32	0.07	0.32
3	0.08	0.39	0.18	0.85	0.14	0.67	0.09	0.43	0.12	0.61
4	0.13	0.62	0.15	0.73	0.13	0.62	0.12	0.58	0.14	0.70
5	0.19	0.92	0.16	0.79	0.14	0.68	0.12	0.58	0.17	0.82
6	0.20	1.00	0.19	0.97	0.18	0.91	0.18	0.89	0.17	0.85
7	0.21	1.01	0.21	1.05	0.19	0.89	0.20	0.95	0.19	0.90
8	0.24	1.18	0.20	0.99	0.22	1.03	0.26	1.22	0.22	1.02
9	0.27	1.29	0.20	0.98	0.24	1.12	0.25	1.16	0.22	1.03
High	0.31	1.40	0.18	0.88	0.28	1.24	0.30	1.32	0.24	1.08
H–L	0.38***	3.37	0.20***	1.54	0.27***	2.29	0.26***	2.22	0.17***	1.43
Δ	–	–	0.18***	1.83***	0.11**	1.08**	0.12***	1.15***	0.21***	1.95***
换手率	676%		615%		653%		670%		681%	
面板 B：组合特征组										
	开盘价、最高价、最低价和收盘价 + 成交量		开盘价、最高价、最低价和收盘价 + 趋势		开盘价、最高价、最低价和收盘价 + 动量		开盘价、最高价、最低价和收盘价 +波动率		所有特征	
	Ret	SR	Ret	SR	Ret	SR	Ret	SR	Ret	SR
Low	-0.10	-0.45	-0.03	-0.14	-0.02	-0.11	-0.05	-0.22	-0.06	-0.29
2	0.06	0.29	0.06	0.31	0.05	0.26	0.05	0.23	0.06	0.26
3	0.14	0.64	0.08	0.38	0.09	0.44	0.10	0.48	0.09	0.44
4	0.13	0.65	0.13	0.65	0.12	0.59	0.13	0.64	0.11	0.55
5	0.19	0.91	0.15	0.76	0.15	0.75	0.18	0.88	0.18	0.86
6	0.20	0.98	0.19	0.92	0.19	0.92	0.21	1.02	0.21	1.02
7	0.21	1.01	0.20	0.98	0.22	1.05	0.21	1.07	0.22	1.08
8	0.25	1.22	0.28	1.32	0.24	1.14	0.22	1.05	0.25	1.17
9	0.26	1.27	0.26	1.23	0.29	1.32	0.27	1.26	0.26	1.26
High	0.29	1.34	0.30	1.30	0.30	1.34	0.30	1.33	0.31	1.42
H–L	0.39***	3.54	0.33***	2.96	0.32***	2.81	0.35***	2.94	0.38***	3.63
Δ	-0.02	-0.17	0.05*	0.41	0.06*	0.56*	0.03	0.43*	0.00	-0.26
换手率	666%		668%		667%		670%		668%	

在两个面板中，已实现的投资组合收益总体上从低到高递增，不过在某些设定下，中间十分位组并非完全单调。尤为值得注意的是，仅OHLC设定下，低组的年化收益率为–0.06，高组为0.31。其他所有设定下，高组的收益也高于低组。这种总体排序表明，二维卷积神经网络的预测包含有助于对股票进行横截面排序的重要信息。

与这一排序模式一致，A面板显示，二维卷积神经网络基于每个单独的特征组均能产生具有经济意义且在统计上显著的收益价差。仅 OHLC 模型的年化高低组合收益为 0.38，夏普比率为 3.37，平均收益在 1% 水平上显著。分别基于成交量、趋势、动量和波动率的模型也产生了显著为正的高减低收益，分别为 0.20、0.27、0.26 和 0.17。这些结果表明，每个特征组都包含可用于对未来股票收益进行排序的独立信息。尽管如此，仅 OHLC 模型的表现仍显著优于其他所有单独特征组设定。在四组比较中，高减低收益和夏普比率的差异均具有统计显著性。因此，尽管人工构造的技术指标本身具有预测能力，但其独立表现弱于 OHLC 表示。

面板 B 直接评估额外特征组是否能提升仅 OHLC 模型的表现。加入成交量后，年化高低组合收益从 0.38 升至 0.39，夏普比率从 3.37 升至 3.54，但这两项差异在统计上均不显著。相反，加入趋势或动量后，高减低收益分别降至 0.33 和 0.32；两项收益差异在 10% 水平上均显著。OHLC + 动量设定的夏普比率也在 10% 水平上显著较低。加入波动率后，高减低收益为 0.35，夏普比率为 2.94。其收益与 OHLC 相比的差异在统计上不显著，但夏普比率在 10% 水平上显著较低。最后，全特征模型的高减低收益为 0.38，夏普比率为 3.63；这两项指标与仅 OHLC 模型的相应结果相比均无显著差异。

月度换手率普遍较高，介于615%至681%之间，但在不同设定之间的差异相对较小。这相似性表明，总投资组合表现的差异不太可能主要由交易强度的差异所驱动。然而，绝对换手率水平意味着需要进行大规模再平衡，并可能产生显著的交易成本，从而降低这些策略可实施的收益。高换手率和交易成本对策略实施的影响将在后文中讨论。

总体而言，与分别基于成交量、趋势、动量或波动率的设定相比，仅 OHLC 设定呈现出模型排名与实现收益之间更强的关系，这一点体现在其显著更高的高减低收益和夏普比率上。这一证据表明，与单独使用其他输入相比，二维卷积神经网络能够从 OHLC 图像中学习到更具经济意义的收益预测模式。同时，在 OHLC 的基础上增加其他特征组，并未使高减低收益或夏普比率获得统计上可检测的改善。

4.2 随时间推移的累计表现

图 3 展示了仅 OHLC 模型和增强输入二维卷积神经网络设定生成的高减低投资组合的累计波动率调整对数收益，以及相应五个交易日评估期内沪深300指数的累计对数收益。每个高减低投资组合收益均按相应五个交易日沪深300指数收益序列的滚动波动率与策略滚动波动率之比进行缩放；这两项波动率估计值均滞后一个投资组合构建期，以确保缩放仅依赖于相应投资组合收益实现之前可获得的信息。随后，将调整后的投资组合收益和相应的沪深300指数收益转换为对数收益并进行累加。

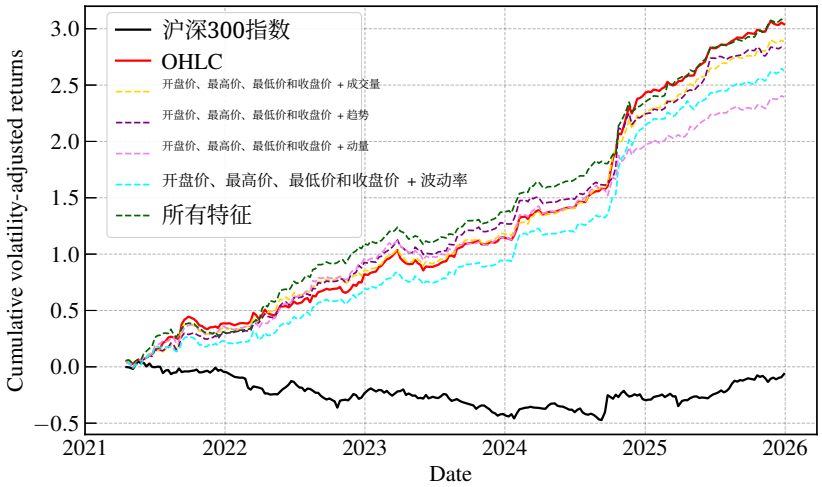

图 3|基于二维卷积神经网络预测的高减低投资组合的累计波动率调整对数收益。 该图绘制了在不同输入配置下，根据二维卷积神经网络预测构建的波动率调整高减低投资组合的累计对数收益，以及作为波动率调整基准的沪深300指数的累计对数收益。红色实线表示仅 OHLC 模型，黑色实线表示沪深300指数。彩色虚线表示在 OHLC 基础上加入交易量或技术指标组的模型，以及使用所有特征的模型。

包含 OHLC 的设定在时间上总体呈现相似走势，但在整个测试期内，其累计收益路径并非始终接近。它们的相对排名随时间变化，且没有任何增强输入设定始终优于仅 OHLC 模型。到样本期末，仅 OHLC 模型和所有特征设定的累计波动率调整对数收益分别为 3.04 和 3.07。相应数值分别为：OHLC +成交量为 2.89，OHLC + 趋势为 2.82，OHLC +动量为 2.39，OHLC + 波动率为 2.63。因此，所有特征设定在样本期末的表现与仅 OHLC 模型接近，而若干扩展设定在测试期后段逐渐落后于该模型。

这一时间序列证据补充了表 3中的投资组合结果。尽管扩展设定在某些子时期的表现优于仅 OHLC 模型，但在整个测试期内，没有任何一种设定能持续获得更高的累计收益。这一发现与高减低收益或夏普比率未出现统计显著改善的结果一致。累计收益曲线的最终排名未必与基于年化收益和夏普比率的排名完全一致，因为这些曲线纳入了随时间变化的波动率缩放和对数复利。基于模型构建的投资组合在测试期内累积的收益也远高于沪深300指数，进一步表明二维卷积神经网络生成的横截面排名包含具有经济价值的样本外预测信息。

4.3 与传统交易策略的比较

前述结果是在同一二维卷积神经网络框架下比较不同输入。接下来，我们将评估基于OHLC的预测相对于四种传统的基于价格的交易信号的经济价值：12–2动量（MOM）、短期反转（STR）、周度短期反转（WSTR）和趋势（TREND）。设 P_t 表示股票在投资组合形成日期 t的复权收盘价。MOM 定义为 $P_{t-20}/P_{t-250} - 1$，因此衡量的是投资组合构建前约一年至一个月期间的价格涨幅（Jegadeesh 和 Titman，1993）。STR 和 WSTR 分别定义为 $-(P_t/P_{t-20} - 1)$ 和$-(P_t/P_{t-5} - 1)$（Jegadeesh，1990；Lehmann，1990）。反转信号的方向经过调整，因此数值越高，表示股票近期收益越低。

根据 Han 等人 (2016)，趋势指标结合了以 3、5、10、20、50、100、200、400、600、800 和 1,000 个交易日为窗口计算的标准化移动平均线。在每个月末，使用前一个月末的移动平均价比对实现月度收益进行横截面回归。对最近 12 个月的回归系数取平均，并将最新可用的平均系数应用于当前标准化移动平均线，以生成趋势信号。该过程每月更新回归系数、每日更新趋势信号，同时确保每个投资组合形成日期仅使用截至该日期可获得的系数。为与二维卷积神经网络投资组合进行比较，所有四种信号均在相同的样本外构建日期上，采用相同的等权重十分位数组合构建方法和五个交易日持有期进行评估。

表 4 报告了由此得到的投资组合表现。在每个投资组合形成日期，根据各信号将股票排序并划分为十分位组。与仅使用OHLC的二维卷积神经网络所产生的结果相比，十分位组的模式明显不那么规整。在测试期内，动量未能产生正的赢家减输家价差：高组的年化收益为 0.06，低组为 0.11，因此高减低收益为 −0。06，且夏普比率为 −0。29。相比之下，STR、WSTR 和趋势指标产生的高减低收益显著为正，分别为 0.31、0.23 和 0.25，夏普比率分别为 1.36、1.03 和 1.22。然而，根据传统信号对股票排序所构建的投资组合，其后续实现收益并未呈现单调模式，表明其横截面排序能力有限。相比之下，根据仅使用OHLC的二维卷积神经网络生成的样本外预测概率对股票排序，可见实现收益从低组到高组单调递增，说明该模型具有更强的横截面排序能力。

第 Δ 行正式比较了各传统策略与仅使用OHLC的二维卷积神经网络；后者的高减低投资组合年收益为0.38，夏普比率为3.37。 Δ中的数值由仅OHLC设定对应的数值减去所列策略对应的数值得出。因此，正值表示仅使用OHLC的二维卷积神经网络表现更佳。与动量相比，仅 OHLC 模型使高减低收益提高了0.44，夏普比率提高了3.66，且这两项差异在1%水平上均具有统计显著性。相较于短期反转、WSTR和趋势，其收益优势分别为0.06、0.15和0.12。相对于WSTR，这一收益优势在10%水平上具有统计显著性，但相对于短期反转或趋势则不具有统计显著性。相比之下，相对于这三种策略，夏普比率分别提高了2.02、2.34和2.15，且均在1%水平上具有统计显著性。因此，基于OHLC的二维卷积神经网络在风险调整后表现方面始终更强，但其平均收益优势是否具有统计显著性，取决于所选的传统基准。

MOM 的月均换手率为 154%，WSTR 为 685%，而仅使用 OHLC 的二维卷积神经网络为 676%。因此，MOM、STR 和 TREND 所需的交易量明显低于 CNN 策略，而 WSTR 的换手率则相近。由于报告的收益未计入交易成本，部分传统策略较低的换手率可能会缩小其净表现劣势。

总体而言，反转和TREND信号产生了具有经济意义的投资组合表现，而在这一样本期和预测期限内，MOM表现不佳。尽管如此，仅使用OHLC的二维卷积神经网络在风险调整后表现方面仍显著优于全部四种传统规则，并呈现出更为有序的横截面收益排序。这些比较揭示了各竞争信号的相对投资组合表现，但无法确定收益价差是否可由对共同股票因子的暴露所解释。因此，我们接下来考察因子调整后表现。

表 4传统交易策略的十分位投资组合绩效及其与仅使用OHLC的二维卷积神经网络的比较。
本表报告了基于MOM、STR、WSTR和TREND信号构建的等权重十分位投资组合的样本外表现。Ret和SR分别表示年化平均收益和年化夏普比率，Turnover表示高减低投资组合的月均换手率。 Δ 行报告了相对于仅使用OHLC的二维卷积神经网络设定的相应表现差异。***、**和*分别表示在1%、5%和10%的水平上显著。

	MOM		STR		WSTR		趋势	
	Ret	SR	Ret	SR	Ret	SR	Ret	SR
Low	0.11	0.46	-0.15	-0.57	-0.12	-0.52	-0.07	-0.28
2	0.15	0.69	0.14	0.66	0.15	0.75	0.14	0.66
3	0.18	0.86	0.21	1.05	0.19	0.96	0.17	0.84
4	0.20	0.97	0.19	0.95	0.20	1.07	0.18	0.92
5	0.19	0.95	0.23	1.15	0.23	1.19	0.22	1.09
6	0.24	1.16	0.22	1.11	0.21	1.02	0.22	1.07
7	0.19	0.94	0.21	1.01	0.25	1.20	0.19	0.95
8	0.17	0.80	0.22	1.00	0.21	0.92	0.21	0.97
9	0.14	0.64	0.20	0.84	0.21	0.85	0.18	0.78
High	0.06	0.23	0.17	0.62	0.10	0.38	0.19	0.73
H–L	-0.06	-0.29	0.31***	1.36	0.23**	1.03	0.25***	1.22
Δ	0.44***	3.66***	0.06	2.02***	0.15*	2.34***	0.12	2.15***
换手率	154%		391%		685%		417%	

4.4 因子调整后表现

上述收益价差可能部分反映了系统性因子暴露，而非异常投资组合表现。为评估这一可能性，我们对每个高减低投资组合估计 Fama–French三因子模型（FF3）（Fama 和 French，1993）和 Fama–French五因子模型（FF5）（Fama 和 French，2015）。FF3 包含市场超额收益因子（MKT–RF）、规模因子（小盘减大盘，SMB）和价值因子（高减低，HML）。FF5 在此基础上加入盈利能力因子（强健减疲弱，RMW）和投资因子（保守减激进，CMA）。我们使用来自中国股票市场与会计研究（CSMAR）数据库（https://data.csmar.com/）的中国A股日度因子收益。因子的具体构建方法遵循两项原始研究（Fama 和 French，1993，2015）。

对于每个投资组合形成日期，将随后第一个至第五个市场交易日的每日因子收益进行复合，以匹配投资组合收益的五个交易日持有期。我们将每个高减低投资组合的收益率对相应的 FF3 或 FF5 因子进行回归，其中阿尔法定义为回归截距，并采用与投资组合收益一致的方式进行年化。由于高减低投资组合是零成本组合，其收益率直接用作因变量，不扣除无风险利率。对于每种备选设定或传统策略 j，我们对配对的高减低收益差采用相同的因子回归；该收益差定义为仅OHLC组合的收益率减去比较组合的收益率。该回归的截距即为 $\Delta\alpha_j = \alpha_{\text{OHLC}} - \alpha_j$，因此，若其为正，则表明仅使用OHLC的二维卷积神经网络具有更高的因子调整后表现。直接估计配对收益差可考虑两个投资组合之间的同期依赖性，并检验它们的阿尔法是否存在差异。阿尔法估计值和阿尔法差异的显著性均采用双侧检验评估，标准误使用一个滞后阶数的 Newey–West 标准误，与上文所述的收益检验一致。

表 5报告了年化阿尔法估计值和阿尔法差异。整个表中，FF3 和 FF5 的估计值几乎完全相同，这表明加入盈利能力因子与投资因子并未实质性改变对这些短期投资组合异常表现的估计。

A面板显示，五种单独的特征组设定在两种因子模型下均产生显著为正的阿尔法，且显著性达到 1% 水平。仅OHLC设定的年化阿尔法为 0.38，而成交量、趋势、动量和波动率对应的估计值介于 0.17 至 0.27 之间。仅 OHLC 模型相应的阿尔法优势介于 0.11 至 0.22 之间，且每项比较均至少在 5% 水平上显著。因此，经过因子调整后，结论依然成立：与单独使用任何一种替代特征组相比，仅OHLC设定能带来更强的样本外投资组合表现。

面板 B 对进一步加入输入是否能改善 OHLC 的表现进行了更直接的检验。OHLC + 成交量和所有特征设定产生的阿尔法分别为 0.41 和 0.39，略高于仅OHLC的估计值，但其阿尔法差异 −0.03 和 −0.01 在统计上并不显著。加入趋势或动量后，阿尔法降至 0.33 和 0.32；相应的 OHLC 与替代设定之差分别为 0.05 和 0.06，在两种因子模型下均达到 10% 显著性水平。OHLC + 波动率设定产生的阿尔法为 0.36，与 OHLC 的差异同样不显著。因此，增强输入设定均未能在因子调整后表现方面显著优于仅 OHLC 模型。

C面板将仅 OHLC 模型与传统策略进行比较。MOM 在 FF3 下的阿尔法估计值为 −0。04，在 FF5 下为−0。06，二者在统计上均不显著；而 STR、WSTR 和 TREND 则产生显著为正的

阿尔法。仅 OHLC 模型的阿尔法点估计值高于全部四种策略。其相对于 MOM、WSTR 和 TREND 的阿尔法优势在统计上显著，但相对于 STR 的 0.09 差值并不显著。因此，证据并不意味着仅 OHLC 模型相对于每一种传统策略都具有全面的阿尔法优势：与 STR 相比，仅 OHLC 模型的阿尔法点估计值较高，但该差异在统计上无法与零区分。尽管如此，如表4所示，仅 OHLC 模型的夏普比率显著高于 STR。

总体而言，在控制共同股票因子后，主要投资组合结论保持不变。仅使用OHLC的设定所产生的阿尔法显著高于独立的替代特征组，其因子调整后表现通常也强于传统策略。更重要的是，就本研究的核心问题而言，在OHLC中加入成交量或技术指标组，并不会带来统计显著的阿尔法增幅。

综合来看，收益、夏普比率和因子调整后的阿尔法比较一致表明，将成交量或技术指标组明确加入OHLC输入，并不会使样本外投资组合表现获得统计上可检测的改善。该结论关注的是额外输入的增量经济价值，而非二维卷积神经网络所学习的内部表征。

表 5|基于二维卷积神经网络预测和传统交易策略的因子调整后高减低投资组合表现。 本表报告表 3 和 4中高减低投资组合的年化FF3和FF5阿尔法估计值。A面板和B面板分别展示使用独立特征组和组合特征组的二维卷积神经网络设定，C面板展示MOM、STR、WSTR和趋势策略。标记为 $\Delta\alpha$ 的列报告相对于仅使用OHLC的二维卷积神经网络设定的相应阿尔法差异。***、**和*分别表示在1%、5%和10%水平上显著。

模型设定 / 传统策略	α		$\Delta\alpha$	
	FF3	FF5	FF3	FF5
A面板：个体特征组				
OHLC	0.38***	0.38***	–	–
成交量	0.24***	0.24***	0.14**	0.14**
趋势	0.27***	0.27***	0.11**	0.11**
动量	0.25***	0.25***	0.13***	0.13***
波动率	0.17***	0.17***	0.22***	0.21***
面板 B：组合特征组				
开盘价、最高价、最低价和收盘价 + 成交量	0.41***	0.41***	-0.03	-0.03
开盘价、最高价、最低价和收盘价 + 趋势	0.33***	0.33***	0.05*	0.05*
开盘价、最高价、最低价和收盘价 + 动量	0.32***	0.32***	0.06*	0.06*
开盘价、最高价、最低价和收盘价 + 波动率	0.36***	0.36***	0.03	0.02
所有特征	0.39***	0.39***	-0.01	-0.01
面板 C：传统交易策略				
MOM	-0.04	-0.06	0.43***	0.44***
STR	0.29***	0.29***	0.09	0.09
WSTR	0.18**	0.17**	0.21**	0.21**
趋势	0.23**	0.22**	0.16*	0.16*

5 基于数值输入模型的投资组合表现

本节考察来自二维卷积神经网络的主要发现，是否能够延伸至采用图像所依据市场数据的数值表示的逻辑回归、一维卷积神经网络和长短期记忆网络模型。

本节中，十分位投资组合构建、绩效测量、因子调整和统计推断均遵循第 4 节所述的程序。对于每个模型，使用相应的样本外预测概率，在相同的投资组合构建日期对相同的股票样本进行排序，构建等权十分位组合，并采用互不重叠的预定五个交易日持有期。Ret、SR、换手率、高–低、 Δ， α和 $\Delta\alpha$ 的定义均沿用第4节中的定义。统计检验和显著性判定惯例也保持不变。

5.1 逻辑回归结果

我们首先考察l_2正则化逻辑回归，它为评估替代特征组的贡献是否取决于非线性模型架构提供了线性基准。表6 报告了相应的样本外十分位投资组合绩效。

在表6的两个面板中，在每一种输入设定下，高的收益都高于低的收益，尽管中间十分位组并不总是呈现完全单调的模式。所有高减低投资组合的年化收益率均为正，且

在1%的水平上具有显著性，这表明每一种输入设定都能在预测概率相对较高和较低的股票之间实现具有经济意义的实现收益区分。

表 6 的 A 面板 展示了个体特征组。仅OHLC设定的年化高低组合收益为 0.30，夏普比率为 1.56。成交量、趋势、动量和波动率对应的高减低收益分别为 0.19、0.26、0.25 和 0.28，夏普比率则介于 1.32 至 1.57 之间。尽管仅OHLC设定的高减低收益点估计最大，但与其他个体特征组相比，其收益或夏普比率的差异均无统计显著性。因此，逻辑回归并未证实OHLC相较于单独使用的替代特征组具有显著的表现优势。

表 6 的面板 B 考察了组合特征组。扩展设定产生的高减低收益介于 0.25 至 0.30 之间，夏普比率介于 1.50 至 1.69 之间。OHLC + 动量和所有特征的高减低收益均为 0.30，与仅OHLC设定相同，而其夏普比率略高。尽管如此，高减低收益或夏普比率的差异均无统计显著性。因此，在线性设定下，明确加入成交量、趋势、动量、波动率或所有额外特征，均未能带来统计上可检测的投资组合表现改善。

个体特征组的月均换手率介于481%至647%之间，组合设定的月均换手率介于498%至636%之间，证实逻辑回归投资组合中的交易强度始终较高。

表 6|基于l_2正则化逻辑回归预测的十分位投资组合绩效。本表报告了不同数值输入设定下等权重十分位投资组合的样本外表现。A面板展示个体特征组，面板 B 展示与额外输入相结合的OHLC，其中包括包含所有输入组的全特征设定。Ret 和 SR 分别表示年化平均收益和年化夏普比率，Turnover 表示高减低投资组合的月均换手率。 Δ 行报告相对于仅OHLC设定的相应表现差异。***、** 和 * 分别表示在 1%、5% 和 10% 水平上显著。

A面板：个体特征组

	OHLC		成交量		趋势		动量		波动率	
	Ret	SR	Ret	SR	Ret	SR	Ret	SR	Ret	SR
Low	-0.08	-0.38	0.00	0.02	-0.03	-0.12	-0.05	-0.24	-0.05	-0.21
2	0.09	0.46	0.17	0.80	0.13	0.65	0.11	0.53	0.13	0.63
3	0.15	0.75	0.16	0.76	0.13	0.65	0.16	0.78	0.13	0.63
4	0.17	0.84	0.18	0.84	0.15	0.71	0.17	0.85	0.16	0.78
5	0.19	0.94	0.16	0.77	0.18	0.85	0.19	0.92	0.18	0.87
6	0.22	1.06	0.18	0.88	0.17	0.84	0.22	1.05	0.19	0.92
7	0.21	0.97	0.19	0.91	0.20	0.94	0.21	1.00	0.20	0.94
8	0.23	1.08	0.19	0.92	0.19	0.89	0.21	0.94	0.22	1.02
9	0.22	1.00	0.20	1.02	0.26	1.19	0.20	0.87	0.23	1.01
High	0.21	0.90	0.20	0.96	0.24	1.06	0.20	0.84	0.24	1.01
H–L	0.30***	1.56	0.19***	1.53	0.26***	1.57	0.25***	1.32	0.28***	1.52
Δ	–	–	0.11	0.03	0.03	-0.01	0.05	0.24	0.02	0.04
换手率	647%		527%		481%		622%		604%	

面板 B：组合特征组

	开盘价、最高价、最低价和收盘价 + 成交量		开盘价、最高价、最低价和收盘价 +趋势		开盘价、最高价、最低价和收盘价 +动量		开盘价、最高价、最低价和收盘价 + 波动率		所有特征	
	Ret	SR	Ret	SR	Ret	SR	Ret	SR	Ret	SR
Low	-0.05	-0.24	-0.03	-0.12	-0.05	-0.26	-0.03	-0.13	-0.05	-0.22
2	0.11	0.54	0.10	0.47	0.08	0.42	0.10	0.50	0.12	0.56
3	0.14	0.66	0.15	0.71	0.15	0.73	0.13	0.66	0.12	0.58
4	0.19	0.89	0.16	0.76	0.17	0.82	0.16	0.76	0.16	0.78
5	0.20	0.97	0.17	0.80	0.18	0.88	0.18	0.86	0.16	0.78
6	0.20	0.93	0.19	0.93	0.21	1.01	0.19	0.92	0.19	0.91
7	0.20	0.98	0.18	0.88	0.21	1.00	0.19	0.93	0.21	0.97
8	0.23	1.07	0.21	0.97	0.20	0.93	0.20	0.93	0.21	0.98
9	0.23	1.05	0.25	1.15	0.23	0.99	0.24	1.07	0.26	1.16
High	0.20	0.88	0.25	1.12	0.24	1.03	0.25	1.06	0.25	1.11
H–L	0.25***	1.57	0.28***	1.64	0.30***	1.69	0.28***	1.50	0.30***	1.64
Δ	0.05	-0.01	0.02	-0.07	0.00	-0.13	0.02	0.06	0.00	-0.08
换手率	556%		521%		636%		594%		498%	

表 7 报告了相应的因子调整后表现。表中 FF3 和 FF5 的估计结果高度一致，表明加入盈利能力因子与投资因子并未实质性改变这些短周期投资组合的异常表现估计。

表 7 的 A面板 显示，在两种因子模型下，所有个体特征组的阿尔法均为正，且在 1% 水平上显著。仅OHLC设定在 FF3 和 FF5 下的年化阿尔法分别为 0.29 和 0.28，而其他个体特征组的估计值介于 0.22 至 0.30 之间。相应的阿尔法差异均无统计显著性。因此，因子调整结果证实，仅OHLC设定的逻辑回归表现与单独使用的替代特征组在统计上无法区分。

表 7 的面板 B 对组合设定得出了类似结论。两种因子模型下，其年化阿尔法介于 0.25 至 0.33 之间，且在 1% 水平上显著。全特征设定的阿尔法点估计值最高，在 FF3 和 FF5 下均为 0.33，而仅OHLC设定下分别为 0.29 和 0.28。然而，相应的阿尔法差异 −0。04 和 −0。05 均无统计显著性。其他扩展设定的阿尔法差异也不显著。因此，没有任何扩展设定能带来可被统计检出的因子调整后表现改善。

表 7 的 C 面板将仅使用 OHLC 的逻辑回归与传统策略进行了比较。其相较于动量和 WSTR 的阿尔法优势分别在 1% 和 5% 水平上显著，而相较于 STR 和趋势的差异在统计上并不显著。因此，仅使用 OHLC 的逻辑回归总体上表现出优于传统策略的因子调整后表现。

表 7|基于l_2-正则化逻辑回归预测和传统交易策略的因子调整后高减低投资组合表现。 本表报告表 6 和 4中高减低投资组合的年化 FF3 和 FF5 阿尔法估计值。A 面板和 B 面板分别展示使用单独特征组和组合特征组的l_2正则化逻辑回归设定，而 C 面板展示动量、STR、WSTR 和趋势策略。标为 $\Delta\alpha$ 的列报告相对于仅使用 OHLC 的l_2-正则化逻辑回归设定的相应阿尔法差异。***、** 和 * 分别表示在 1%、5% 和 10% 水平上显著。

模型设定 / 传统策略	α		$\Delta\alpha$	
	FF3	FF5	FF3	FF5
A面板：个体特征组				
OHLC	0.29***	0.28***	–	–
成交量	0.24***	0.22***	0.05	0.06
趋势	0.29***	0.29***	0.00	-0.01
动量	0.23***	0.22***	0.06	0.06
波动率	0.29***	0.30***	0.00	-0.02
面板 B：组合特征组				
开盘价、最高价、最低价和收盘价 + 成交量	0.26***	0.25***	0.03	0.03
开盘价、最高价、最低价和收盘价 + 趋势	0.30***	0.30***	-0.01	-0.02
开盘价、最高价、最低价和收盘价 + 动量	0.28***	0.28***	0.01	0.00
开盘价、最高价、最低价和收盘价 + 波动率	0.28***	0.28***	0.01	0.00
所有特征	0.33***	0.33***	-0.04	-0.05
面板 C：传统交易策略				
MOM	-0.04	-0.06	0.33***	0.34***
STR	0.29***	0.29***	0.00	-0.01
WSTR	0.18**	0.17**	0.11**	0.11**
趋势	0.23**	0.22**	0.06	0.06

综合来看，逻辑回归结果揭示了两点。第一，所有输入设定均产生显著为正的收益价差，但开盘价、最高价、最低价和收盘价并未显著优于独立的替代特征组。第二，在开盘价、最高价、最低价和收盘价的基础上明确加入交易量或技术指标，并未显著改善高减低收益、夏普比率或因子调整后的阿尔法。因此，未能在统计上显著提升投资组合绩效这一结果，并非非线性二维卷积神经网络或其基于图像的表示所独有。

5.2 一维卷积神经网络结果

接下来，我们考察一维卷积神经网络，它直接对数值输入的时间维度进行卷积。表 8报告了其样本外十分位投资组合绩效。

在表8的两个面板中，在所有输入设定下，高组的收益均高于低组，尽管并非所有情况下中间十分位组的收益都完全呈单调变化。所有高减低投资组合的年化收益均为正，且在

1% 的水平上显著，这表明一维卷积神经网络能够在预测概率相对较高和较低的股票之间，实现具有经济意义的收益区分。

表8的A面板 展示了个体特征组。仅OHLC设定产生的年化高低组合收益为0.34，夏普比率为3.09。相比之下，成交量、趋势、动量和波动率分别产生0.19、0.24、0.19和0.19的高减低收益，夏普比率介于1.39至2.16之间。仅OHLC设定的高减低收益和夏普比率均显著高于其他四个替代特征组。其收益优势介于0.09至0.15之间，夏普比率优势则介于0.92至1.69之间。全部八项差异均在10%或更高的显著性水平上显著。因此，当这些特征组单独使用时，一维卷积神经网络从OHLC中提取的经济价值远高于从成交量、趋势、动量或波动率中提取的经济价值。

表 B8 考察了组合特征组。扩展设定的年化高减低收益介于 0.30 至 0.39 之间，夏普比率介于 2.56 至 3.62 之间。加入成交量后，高减低收益升至 0.36；加入趋势、动量或波动率后，收益分别为 0.32、0.31 和 0.30。所有特征设定的点估计最大，高减低收益为 0.39，夏普比率为 3.62；相比之下，仅OHLC设定的这两项指标分别为 0.34 和 3.09。然而，这些扩展设定均未使高减低收益或夏普比率出现统计显著的提升。此外，OHLC + 波动率的夏普比率在 10% 显著性水平下显著低于仅OHLC设定。因此，组合输入的结果并未提供统计显著的证据，证明明确加入替代特征组能够改善投资组合表现。

表 8|基于一维卷积神经网络预测的十分位投资组合绩效。 本表报告了不同输入设定下等权重十分位投资组合的样本外表现。A面板展示个体特征组，面板 B 则展示将OHLC与额外输入相结合的结果，其中包括包含所有输入组的全特征设定。Ret和SR分别表示年化平均收益和年化夏普比率，Turnover表示高减低投资组合的月均换手率。第 Δ 行报告了相对于仅OHLC设定的相应表现差异。***、**和*分别表示在1%、5%和10%水平上显著。

A面板：个体特征组

	OHLC		成交量		趋势		动量		波动率	
	Ret	SR	Ret	SR	Ret	SR	Ret	SR	Ret	SR
Low	-0.05	-0.22	-0.01	-0.04	0.03	0.13	0.06	0.32	0.06	0.27
2	0.05	0.25	0.15	0.70	0.07	0.35	0.09	0.43	0.08	0.39
3	0.12	0.59	0.17	0.81	0.09	0.45	0.09	0.43	0.13	0.64
4	0.15	0.71	0.18	0.87	0.15	0.72	0.12	0.58	0.13	0.62
5	0.17	0.84	0.19	0.92	0.16	0.78	0.14	0.66	0.15	0.73
6	0.21	1.00	0.18	0.88	0.17	0.84	0.18	0.85	0.19	0.94
7	0.20	0.99	0.21	1.04	0.20	0.98	0.22	1.05	0.18	0.86
8	0.23	1.10	0.18	0.92	0.23	1.12	0.21	1.02	0.22	1.06
9	0.25	1.20	0.19	0.96	0.24	1.15	0.26	1.21	0.24	1.08
High	0.29	1.34	0.18	0.89	0.27	1.23	0.26	1.17	0.25	1.04
H–L	0.34***	3.09	0.19***	1.57	0.24***	2.16	0.19***	1.83	0.19***	1.39
Δ	–	–	0.15**	1.52**	0.09*	0.92*	0.14***	1.25***	0.15***	1.69***
换手率	667%		624%		625%		663%		664%	

面板 B：组合特征组

	开盘价、最高价、最低价和收盘价 + 成交量		开盘价、最高价、最低价和收盘价 +趋势		开盘价、最高价、最低价和收盘价 + 动量		开盘价、最高价、最低价和收盘价 +波动率		所有特征	
	Ret	SR	Ret	SR	Ret	SR	Ret	SR	Ret	SR
Low	-0.09	-0.40	-0.04	-0.18	0.00	0.00	0.01	0.07	-0.09	-0.41
2	0.08	0.35	0.04	0.21	0.04	0.18	0.06	0.28	0.06	0.30
3	0.12	0.55	0.10	0.49	0.10	0.49	0.09	0.44	0.10	0.47
4	0.16	0.80	0.13	0.63	0.12	0.58	0.10	0.48	0.12	0.57
5	0.19	0.92	0.16	0.80	0.19	0.91	0.16	0.78	0.17	0.84
6	0.21	1.03	0.18	0.87	0.17	0.84	0.19	0.91	0.21	1.04
7	0.22	1.09	0.22	1.12	0.23	1.11	0.22	1.10	0.24	1.20
8	0.23	1.10	0.26	1.28	0.23	1.13	0.23	1.11	0.23	1.10
9	0.25	1.18	0.27	1.29	0.24	1.14	0.25	1.19	0.28	1.31
High	0.27	1.25	0.29	1.32	0.31	1.40	0.31	1.39	0.30	1.35
H–L	0.36***	3.20	0.32***	3.24	0.31***	2.97	0.30***	2.56	0.39***	3.62
Δ	-0.03	-0.11	0.01	-0.15	0.03	0.11	0.04	0.53*	-0.05	-0.54
换手率	666%		655%		669%		667%		653%	

个体特征组的月均换手率介于624%至667%之间，组合设定的月均换手率则介于653%至669%之间。因此，各一维卷积神经网络设定的交易强度普遍较高，且差异相对较小。表 9 报告了相应的因子调整后表现。FF3和FF5的阿尔法估计值仍然十分接近。

表 9 的 A 面板 显示，在两种因子模型下，所有个体特征组产生的阿尔法均为正，且在 1% 水平上显著。仅OHLC设定在 FF3 和 FF5 下的年化阿尔法分别为 0.35 和 0.34。成交量、趋势、动量和波动率对应的估计值介于 0.18 至 0.25 之间。仅OHLC设定的阿尔法优势介于 0.10 至 0.17 之间，且在全部四项比较中均达到 10% 或更高的显著性水平。因此，因子调整后的结果仍支持这一结论：与替代特征组相比，OHLC 单独使用时能带来更强的投资组合表现。

表 9 的面板 B 展示了组合设定。两种因子模型下，其年化阿尔法介于 0.29 至 0.40 之间，且均在 1% 水平上显著。全特征设定的点估计再次最高，在 FF3 和 FF5 下分别为 0.40 和 0.39，而仅OHLC设定对应的数值为 0.35 和 0.34。不过，其在两种因子模型下的阿尔法差异均为 −0。05，且在统计上并不显著。其他扩展设定的阿尔法差异也不显著。因此，没有任何额外输入组能在统计上显著提升因子调整后的表现。

表9 的 C 面板比较了仅使用 OHLC 的一维卷积神经网络与传统策略。其相较于动量的阿尔法优势在 1% 水平上显著，而相较于 WSTR 的阿尔法优势在 10% 水平上显著。相较于短期反转和趋势的差异在统计上并不显著。因此，仅使用 OHLC 的一维卷积神经网络总体上表现出优于传统策略的因子调整后表现。

综上，一维卷积神经网络的结果进一步印证了二维卷积神经网络得出的主要发现。与成交量、趋势、动量或波动率相比，OHLC 单独使用时产生的投资组合表现显著更强；而将这些输入明确加入 OHLC，并未使高减低收益、夏普比率或因子调整后的阿尔法出现统计上可检测的改善。因此，当图像表示替换为通过一维卷积处理的数值序列时，这一结论依然成立。

表 9|基于一维卷积神经网络预测和传统交易策略的因子调整后高减低投资组合表现。本表报告表8 和4中所列高减低投资组合的年化 FF3 和 FF5 阿尔法估计值。A 面板和 B 面板分别展示采用单个特征组和组合特征组的一维卷积神经网络设定，C 面板则展示动量、短期反转、WSTR 和趋势策略。标为 $\Delta\alpha$ 的列报告了相对于仅使用 OHLC 的一维卷积神经网络设定的相应阿尔法差异。***、** 和 * 分别表示在 1%、5% 和 10% 水平上显著。

模型设定 / 传统策略	α		$\Delta\alpha$	
	FF3	FF5	FF3	FF5
A面板：个体特征组				
OHLC	0.35***	0.34***	–	–
成交量	0.24***	0.24***	0.11*	0.11*
趋势	0.25***	0.24***	0.10*	0.10*
动量	0.18***	0.18***	0.17***	0.17***
波动率	0.19***	0.19***	0.16***	0.16***
面板 B：组合特征组				
开盘价、最高价、最低价和收盘价 + 成交量	0.37***	0.37***	-0.02	-0.02
开盘价、最高价、最低价和收盘价 + 趋势	0.33***	0.32***	0.02	0.02
开盘价、最高价、最低价和收盘价 + 动量	0.30***	0.29***	0.05	0.05
开盘价、最高价、最低价和收盘价 + 波动率	0.30***	0.30***	0.05	0.05
所有特征	0.40***	0.39***	-0.05	-0.05
面板 C：传统交易策略				
MOM	-0.04	-0.06	0.39***	0.41***
STR	0.29***	0.29***	0.06	0.06
WSTR	0.18**	0.17**	0.17*	0.17*
趋势	0.23**	0.22**	0.12	0.13

5.3 长短期记忆网络结果

接下来，我们考察长短期记忆网络，该网络将数值输入作为时间序列进行处理。表10 报告了其样本外十分位投资组合绩效。

在表10的两个面板中，在每一种输入设定下，高的收益都高于低，尽管在所有情况下，中间十分位组并非完全单调。所有高减低投资组合均产生显著为正的年化收益，显著性达到

5%水平或更高，这表明长短期记忆网络的预测能够有效区分预测概率相对较高和较低的股票之间的实现收益。

表 10 的 A 面板 展示了个体特征组。仅 OHLC 的设定产生的年化高低组合收益为 0.34，夏普比率为 2.10。成交量、趋势、动量和波动率对应的高减低收益分别为 0.27、0.26、0.26 和 0.19，夏普比率介于 1.15 至 2.01 之间。尽管仅 OHLC 的设定在高减低收益和夏普比率的点估计上均最高，但其表现优势的统计显著性因替代特征组而异。相较于趋势，其收益优势在 10% 水平上显著；相较于波动率，则在 1% 水平上显著；但相较于成交量和动量时并不显著。其夏普比率优势相较于动量在 5% 水平上显著，相较于波动率则在 1% 水平上显著；但相较于成交量和趋势时并不显著。因此，仅 OHLC 的长短期记忆网络通常表现出更强的独立表现，但这一优势并非在每项比较中都具有统计显著性。

表10 的 A 面板展示了组合特征组。扩展设定所产生的年化高低组合收益介于 0.24 至 0.35 之间，夏普比率介于 1.75 至 2.86 之间。加入趋势或动量后，高减低收益分别从 0.34 降至 0.24 和 0.27。相应的收益差异分别在 1% 和 5 % 的水平上显著。加入波动率后，高减低收益为 0.29，夏普比率为 2.09；两者与仅使用开盘价、最高价、最低价和收盘价的结果均无显著差异。

表 10基于长短期记忆网络预测的十分位投资组合绩效。 </style}本表报告了不同输入设定下等权重十分位投资组合的样本外表现。A面板展示个体特征组，B面板展示OHLC与额外输入的组合，其中全特征设定包含所有输入组。Ret和SR分别表示年化平均收益和年化夏普比率，Turnover表示高减低投资组合的月均换手率。第 Δ 行报告相对于仅OHLC设定的相应表现差异。***、**和*分别表示在1%、5%和10%的水平上显著。

A 面板：个体特征组

	OHLC		成交量		趋势		动量		波动率	
	Ret	SR	Ret	SR	Ret	SR	Ret	SR	Ret	SR
Low	-0.04	-0.21	-0.07	-0.28	0.02	0.08	-0.03	-0.12	0.02	0.08
2	0.06	0.29	0.13	0.64	0.08	0.39	0.09	0.44	0.08	0.39
3	0.09	0.45	0.18	0.87	0.10	0.49	0.13	0.62	0.14	0.70
4	0.12	0.57	0.18	0.87	0.10	0.50	0.18	0.90	0.15	0.73
5	0.18	0.89	0.19	0.94	0.17	0.84	0.17	0.80	0.16	0.78
6	0.20	0.98	0.18	0.88	0.18	0.89	0.20	0.96	0.19	0.94
7	0.22	1.04	0.20	1.00	0.21	0.99	0.20	0.94	0.23	1.11
8	0.24	1.15	0.22	1.05	0.22	1.04	0.21	0.97	0.23	1.04
9	0.27	1.23	0.21	1.01	0.27	1.28	0.24	1.03	0.22	0.99
High	0.29	1.17	0.20	0.90	0.27	1.17	0.23	0.96	0.20	0.84
H–L	0.34***	2.10	0.27***	1.78	0.26***	2.01	0.26***	1.46	0.19**	1.15
Δ	–	–	0.07	0.31	0.08*	0.09	0.08	0.64**	0.15***	0.95***
换手率	675%		620%		625%		645%		664%	

面板 B：组合特征组

	开盘价、最高价、最低价和收盘价 + 成交量		开盘价、最高价、最低价和收盘价 +趋势		开盘价、最高价、最低价和收盘价 +动量		开盘价、最高价、最低价和收盘价 + 波动率		所有特征	
	Ret	SR	Ret	SR	Ret	SR	Ret	SR	Ret	SR
Low	-0.07	-0.35	0.02	0.12	-0.02	-0.10	-0.02	-0.11	-0.05	-0.24
2	0.06	0.30	0.05	0.25	0.05	0.24	0.03	0.16	0.04	0.19
3	0.11	0.55	0.10	0.49	0.14	0.68	0.12	0.61	0.11	0.53
4	0.14	0.71	0.15	0.73	0.14	0.66	0.13	0.65	0.13	0.64
5	0.20	1.02	0.17	0.82	0.19	0.90	0.18	0.86	0.17	0.81
6	0.20	0.98	0.17	0.82	0.18	0.85	0.21	0.98	0.20	0.97
7	0.23	1.12	0.21	0.98	0.23	1.08	0.22	1.05	0.21	1.04
8	0.24	1.14	0.25	1.22	0.21	1.01	0.24	1.09	0.26	1.24
9	0.24	1.11	0.24	1.10	0.27	1.23	0.25	1.15	0.26	1.18
High	0.27	1.15	0.26	1.12	0.24	1.03	0.27	1.16	0.30	1.36
H–L	0.34***	2.71	0.24***	1.77	0.27***	1.75	0.29***	2.09	0.35***	2.86
Δ	0.00	-0.61**	0.10***	0.33	0.07**	0.34	0.04	0.00	-0.01	-0.77**
换手率	654%		651%		652%		664%		642%	

Volum 的结果 e 和所有特征与其他扩展设定的结果略有不同。开盘价、最高价、最低价和收盘价 +Volum e

产生了与单独使用OHLC相同的高减低收益，但将夏普比率从2.10提高至2.71，且夏普比率的提升在5%的水平上显著。全特征设定的高减低收益为0.35，与仅OHLC设定下的收益没有显著差异，但将夏普比率提高至2.86。夏普比率的这一提升同样在5%的水平上显著。

由于这两种设定均包含成交量，并且在夏普比率方面均显著优于单独使用开盘价、最高价、最低价和收盘价，我们进一步将开盘价、最高价、最低价和收盘价 +成交量与所有特征直接进行比较。额外的成对检验表明，全特征设定在高减低收益上仅比开盘价、最高价、最低价和收盘价 + 成交量高出0.01，在夏普比率上高出0.15；即使在10%水平上，这两个差异也均不具有统计显著性。因此，在开盘价、最高价、最低价和收盘价 + 成交量的基础上加入趋势、动量和波动率组，并未在任一绩效指标上产生统计上可检测的进一步改善。这一模式与如下结论一致：纳入成交量可以解释全特征设定所观察到的夏普比率改善，而一旦纳入成交量，技术指标组便不再提供可检测的增量收益。

月均换手率在个体特征组中介于620%至675%之间，在组合规格中介于642%至664%之间。与其他模型架构一样，各LSTM投资组合的交易强度始终普遍较高。

表11报告了相应的因子调整后表现。整个表格中的 FF3 和 FF5 阿尔法估计值几乎相同。

表 11|基于长短期记忆网络预测和传统交易策略的因子调整后高减低投资组合表现。 本表报告表 10 和4 中高减低投资组合的年化 FF3 和 FF5 阿尔法估计值。A 面板和 B 面板分别展示使用个体特征组和组合特征组的长短期记忆网络设定，而 C 面板展示动量、短期反转、WSTR 和趋势策略。标注为 $\Delta\alpha$ 的列报告了相对于仅 OHLC 的 LSTM 设定的相应阿尔法差异。***、** 和 * 分别表示在 1%、5% 和 10% 水平上显著。

模型设定 / 传统策略	α		$\Delta\alpha$	
	FF3	FF5	FF3	FF5
A 面板：个体特征组				
OHLC	0.33***	0.33***	–	–
成交量	0.30***	0.29***	0.04	0.04
趋势	0.25***	0.25***	0.08*	0.08*
动量	0.24***	0.24***	0.09	0.09
波动率	0.18***	0.18***	0.15***	0.15***
面板 B：组合特征组				
开盘价、最高价、最低价和收盘价 + 成交量	0.36***	0.36***	-0.03	-0.03
开盘价、最高价、最低价和收盘价 + 趋势	0.23***	0.23***	0.10***	0.10***
开盘价、最高价、最低价和收盘价 + 动量	0.26***	0.26***	0.07**	0.07**
开盘价、最高价、最低价和收盘价 + 波动率	0.30***	0.30***	0.03	0.03
所有特征	0.37***	0.37***	-0.04	-0.04
面板 C：传统交易策略				
MOM	-0.04	-0.06	0.38***	0.39***
STR	0.29***	0.29***	0.04	0.04
WSTR	0.18**	0.17**	0.16	0.16
趋势	0.23**	0.22**	0.11	0.11

表11的 A面板 显示，在两种因子模型下，所有个体特征组产生的阿尔法均为正，且在1%水平上显著。仅OHLC设定在FF3和FF5下的年化阿尔法均为0.33。成交量、趋势、动量和波动率对应的估计值介于0.18至0.30之间。相较于趋势，仅OHLC设定的阿尔法优势在10%水平上显著；相较于波动率，则在1%水平上显著；但相较于成交量和动量，差异并不显著。因此，从点估计来看，因子调整仍然更 favor 仅OHLC设定，但其优势仅在四项比较中的两项达到统计显著。

表11的面板 B 显示，所有组合设定也都产生了正阿尔法，且在1%水平上显著。OHLC + 成交量和所有特征的阿尔法分别为0.36和0.37，而仅OHLC设定为0.33。然而，它们的阿尔法差异 –0。03和 –0。04在统计上并不显著。因此，这两种设定带来的夏普比率提升，并未转化为因子调整后阿尔法的显著改善。

相比之下，加入趋势或动量会使年化阿尔法分别降至 0.23 和 0.26。在两种因子模型下，相应的阿尔法差异 0.10 和 0.07 分别在 1% 和 5% 的显著性水平上显著。OHLC + 波动率设定得出的阿尔法为 0.30，与仅使用 OHLC 得出的估计值相比，差异并不显著。因此，所有扩展设定均未能显著提高因子调整后表现，而趋势和

加入动量会显著降低阿尔法。

表 11 的 C 面板将仅 OHLC 的 LSTM 与传统策略进行了比较。在两种因子模型下，其相对于动量的阿尔法优势均在 1% 水平上显著。相对于短期反转、WSTR 和趋势的差异为正，但在统计上并不显著。因此，仅 OHLC 的 LSTM 相较于传统策略通常表现出更强的因子调整后表现。

综合来看，LSTM 结果为其他模型架构所得的发现提供了有条件的支持。仅 OHLC 设定通常产生更强的独立表现，且没有任何额外输入组能显著改善平均高低收益或因子调整后的阿尔法。加入趋势或动量反而会显著降低收益和阿尔法。尽管 OHLC + 成交量和所有特征的夏普比率均显著高于仅使用 OHLC 的设定，但这两种扩展设定在高减低收益或夏普比率方面彼此并无显著差异。因此，证据表明，夏普比率的提升主要与成交量有关，而非与技术指标组有关。更广泛地说，额外输入并未在不同绩效指标或模型设定之间带来一致性的改善。

5.4 不同模型架构的比较

结合第 4 节的二维卷积神经网络证据与上述数值输入结果，可以看出不同模型架构之间既有共性，也存在差异。在所有四种架构下，仅使用开盘价、最高价、最低价和收盘价的设定均能产生显著为正的高减低收益和因子调整后的阿尔法。其年化高低组合收益介于 0.30 至 0.38 之间，夏普比率则介于 1.56 至 3.37 之间。二维卷积神经网络在高减低收益、夏普比率和阿尔法方面的点估计最大，一维卷积神经网络的夏普比率则位居第二。尽管如此，逻辑回归、一维卷积神经网络和长短期记忆网络产生的显著收益价差表明，开盘价、最高价、最低价和收盘价的经济价值并非二维卷积神经网络所采用的图像表示所独有。

单独使用时，开盘价、最高价、最低价和收盘价相对于替代特征组的优势因架构而异。在二维卷积神经网络和一维卷积神经网络下，开盘价、最高价、最低价和收盘价在高减低收益、夏普比率和因子调整后的阿尔法方面均显著优于成交量、趋势、动量和波动率。仅使用开盘价、最高价、最低价和收盘价的长短期记忆网络也产生了最大的点估计，但其优势仅在部分替代特征组中达到显著水平。在逻辑回归下，相应差异均无统计显著性。逻辑回归下未发现开盘价、最高价、最低价和收盘价具有显著优势，部分原因可能是其线性设定的表征灵活性有限。

OHLC 历史数据可能包含线性模型难以直接捕捉的非线性交互和局部时间模式，而技术指标则在估计前对这些历史数据进行预先设定的变换。在卷积模型下，OHLC 的优势更为明显，这与此类架构能够直接从 OHLC 数据中提取有用模式的解释相符，但结果并未确凿证实这一机制。

关于额外输入增量价值的主要结果更为一致。在全部四种架构中，与仅使用 OHLC 相比，没有任何扩展设定能显著提高平均高低收益或因子调整后的阿尔法。某些额外输入反而会降低表现。因此，在纳入 OHLC 后，技术指标组并未带来稳健的增量改善。

扩展设定中唯一达到统计显著的改善，出现在长短期记忆网络投资组合的夏普比率上。OHLC +成交量和所有特征的夏普比率均高于仅使用 OHLC 的结果，且两项改善都在 5% 水平上显著。不过，这两种设定均未显著提高平均高低收益或因子调整后的阿尔法。此外，无论在高减低收益还是夏普比率方面，OHLC + 成交量与所有特征之间的差异均不显著。这一模式表明，长短期记忆网络夏普比率的改善主要与成交量有关，而纳入成交量后，技术指标组并未带来可检测到的额外收益。

总体而言，在本文考察的四种模型中，模型架构会影响 OHLC 的独立优势强度，但不会改变核心结论：在所考虑的设定下，明确将技术指标组加入 OHLC，并不能持续改善投资组合收益、夏普比率或因子调整后的阿尔法。这些结果支持这样一种结论：这些指标组的增量经济价值有限，但并不能证明技术指标通常都是冗余的。

6 实际实施与市场摩擦

6.1 交易成本调整后的表现

五个交易日再平衡策略产生的高换手率，使交易成本成为解读投资组合毛收益结果时的重要考量。因此，我们对基准 OHLC单独输入的二维卷积神经网络策略进行交易成本敏感性分析。与相关基于图像的收益预测研究采用的逐笔交易成本调整一致（Jiang 等人，2023年；Jeong 等人，2026年），令 c 表示单向比例交易成本。在每个再平衡日期，我们都将针对该五个交易日持有期构建的投资组合视为已完全清算并重新建立。因此，仅高组投资组合每个持有期需承担$2c$ 的进场与出场成本，而高减低投资组合的多头和空头部分往返交易均需承担 $4c$ 。由于这种完全重新构建惯例不会抵消连续再平衡日期之间保留的头寸，因此与抵消保留头寸相比，它会产生较为保守的成本调整。

经纪佣金因账户而异，而印花税和过户费则统一设定。根据样本期末适用的费率表，印花税仅对卖出交易征收，税率为5个基点；过户费则约为买卖双方各0.1个基点（CSDC，2026年）。按照本文采用的对称单边计费约定，这些非佣金费用相当于约2.6个基点的单向成本。因此，假设成本为5个基点，意味着还为经纪佣金及其他比例交易费用预留了约2.4个基点。2023年8月28日印花税下调生效之前，按照相同约定，相应的非佣金费用约为5个基点（财政部和国家税务总局，2023年）。因此，在2021–2025年样本外期间，5个和10个基点的情景可作为明确交易费用的相关基准，而15个基点的情景则构成更严格的敏感性检验。

表 12 报告了单边成本为 5、10 和 15 个基点时的年化净收益和夏普比率，并列出零成本时的毛收益结果。净夏普比率根据成本调整后的持有期收益率序列计算。净收益均值的显著性采用双侧检验进行评估，使用 Newey–West 标准误和一个滞后项，与第4节所用程序一致。

对于高减低投资组合，年化收益率从扣除成本前的 0.38 降至单边成本为 5 个基点时的 0.28，而夏普比率则从 3.37 降至 2.48。单边成本为 10 个基点时，该投资组合仍实现 0.18 的年化净收益和 1.59 的夏普比率，且净收益在 1% 水平上仍显著。然而，单边成本为 15 个基点时，年化净收益降至 0.08，夏普比率降至 0.69，净收益也不再具有统计显著性。单边盈亏平衡成本为 18.86 个基点。

由于无需为空头腿承担成本，仅高组投资组合对交易成本的敏感度较低。其年化收益率和夏普比率从成本前的0.31和1.40，降至交易成本为5个基点时的0.26和1.17，以及交易成本为10个基点时的0.21和0.95。在假设交易成本为10个基点时，净收益率在5%的水平上仍显著。交易成本为15个基点时，该投资组合仍取得0.16的正年化净收益率，夏普比率为0.73，但净收益率已不再具有统计显著性。其单边盈亏平衡成本为31.43个基点，显著高于高减低投资组合。

表 12|交易成本调整后的投资组合表现。 本表报告了基于仅使用OHLC的二维卷积神经网络所作预测构建的等权仅高组投资组合和高减低投资组合在计入交易成本后的样本外表现。Ret和SR分别表示年化平均净收益率和年化扣除成本后夏普比率。盈亏平衡成本表示使年化净收益率降至零的单边交易成本。***、**和*分别表示在1%、5%和10%的水平上显著。

交易成本	仅高组投资组合		高减低投资组合	
	Ret	SR	Ret	SR
0 基点	0.31***	1.40	0.38***	3.37
5 个基点	0.26***	1.17	0.28***	2.48
10 个基点	0.21**	0.95	0.18***	1.59
15个基点	0.16	0.73	0.08	0.69
盈亏平衡成本	31.43个基点		18.86个基点	

总体而言，比例交易成本会显著降低两种短期策略的盈利能力，其中对高–低投资组合的影响尤为明显。在单边成本最高达到10个基点时，两个投资组合仍保持正的且具有统计显著性的净收益，但随着成本上升，净表现的幅度和统计显著性均显著减弱。由于高减低投资组合的成本调整未纳入证券借贷费用或可借券源限制，其净表现应被视为交易成本敏感性基准，而非完全可实施的多空策略收益。仅高组投资组合具有更强的成本承受能力，因此在中国市场中是更具参考意义的实施基准；在中国市场，建立并维持空头腿受到更为严格的限制。

6.2 中国A股市场的交易限制

除比例交易成本外，中国A股市场中的策略实施还受到涨跌停限制和停牌的影响。由于高减低投资组合的空头腿在实际操作中难以实施，我们将仅高组投资组合作为更具实际意义的实施基准。

第 2 节的样本构建已处理了投资组合构建时可观察到的若干限制。所有样本公司均于 2011 年 1 月 1 日之前上市，实证期间则始于 2013 年，因此排除了新上市股票特有的交易状况。若 20天输入窗口中的任何观测带有 ST标记，则相应的候选股票窗口将被排除；因此，输入窗口中出现 ST 观测的股票不符合投资组合构建的条件。相比之下，构建完成后发生的停牌无法事先知晓。

我们首先考察涨停限制可能造成的入场约束。由于我们的调整后价格数据不包含官方每日涨跌停限制或订单执行指标，因此我们采用保守的接近涨停筛选。在每个形成日期，我们首先选出 N 只仅使用OHLC的二维卷积神经网络概率最高的股票，剔除当日调整后收益率超过9%的股票，并对剩余股票进行等权重配置。表13 报告了 $N = 170$、100、50和10只股票的结果。四个经过筛选的

投资组合均保持正向且具有统计显著性的毛收益。扣除10个基点的单边交易成本后，其年化净收益仍处于0.18至0.21之间，其中四项估计中有三项具有统计显著性。因此，即使剔除形成日调整收益率超过9%的股票，筛选后的多头投资组合仍能持续产生具有经济意义的收益和夏普比率。

表 13|接近涨停筛选后的Top-*N* 多头投资组合表现。 本表报告了根据仅使用OHLC的二维卷积神经网络的预测构建的Top-*N* 投资组合的样本外毛表现和净表现，并剔除了形成日期调整后收益率超过9%的股票。净表现假设单边交易成本为10个基点。Ret和SR分别表示年化平均收益和年化夏普比率，Turnover表示月均换手率。***、**和*分别表示平均收益在1%、5%和10%水平上显著。

Top-*N*	换手率	毛表现		净绩效	
		Ret	SR	Ret	SR
170	333%	0.28***	1.28	0.18*	0.83
100	354%	0.29***	1.29	0.19*	0.85
50	369%	0.31***	1.33	0.21**	0.90
10	390%	0.30**	1.03	0.20	0.69

接下来，我们考察持有期内发生的停牌。在239个样本外持有期中，有48期至少包含一只暂停交易的高组合股票，共出现66起股票—期间暂停交易事件。在这48个受影响的期间中，42期仅有一只股票暂停交易；单个期间内暂停交易的股票最多为7只。对于受影响的股票，停牌日不计入其持有天数；头寸会继续持有，直至恢复交易，并观察完剩余的实际交易日。这种处理方式并不假设股票停牌期间能够成交。尽管如此，由于新投资组合仍按统一的五个市场交易日周期持续形成，回测并未充分反映资本被锁定于暂停交易头寸所产生的资本机会成本，也未充分反映为维持这些头寸并同时持有新形成的投资组合而需要的额外资本。

对于同一投资组合，我们还评估了跌停价可能造成的退出限制。由于现有数据无法识别卖单是否实际未能成交，我们将第五个后续实际交易观察日的调整后日收益率低于 –9%作为代理指标。在239个期间中，有156期未出现此类股票；234期（即样本期的97.9%）此类股票不超过5只。超过5只的情况仅出现在5个期间，但这些期间占所有此类观察的68.5%。这些集中发生的事件体现了一种显著的尾部风险：正常市场状况下较为有限的潜在退出限制，在全市场压力期间可能蔓延至广泛范围。

综合来看，保守的入场筛选并未影响仅高组合结果的稳健性，而停牌和潜在的跌停暴露通常只涉及少量持仓。不过，在极端市场条件下，回测仍无法完全模拟延迟执行、资金锁定或未成交订单。此外，模型未明确纳入市场冲击和流动性约束，也未评估策略容量。因此，只做多结果应被视为小规模、价格接受型实施下预测信号经济价值的证据，而非对所有市场摩擦下交易情况的完整模拟。

7 结论

本研究考察了交易量和三组人工构建的技术指标各自具有的独立经济价值，并探讨将这些指标组加入OHLC蜡烛图能否带来增量样本外经济价值。七项指标分为以下几组：趋势组包括SMA、ADX及其正向和负向指标，以及指数平滑异同移动平均线；动量组包括相对强弱指数和随机指标；波动率组包括布林带和基于平均真实波幅的通道。我们使用2013至2025年中国A股市场主板1,707只股票的日度数据，基于20日市场历史数据构建约336万个股票窗口样本，将每个样本编码为多通道图像和数值表示，并利用这些表示预测随后五个交易日收益的方向。主要分析将二维卷积神经网络应用于多通道图像；补充检验则对相同样本的数值表示应用带有l_2正则化的逻辑回归、一维卷积神经网络和长短期记忆网络。我们通过等权重十分位投资组合、高减低收益、夏普比率、Fama–French 因子调整后阿尔法以及正式的成对检验，评估2021—2025年样本外期间的经济表现。

单独结果表明，在全部四种模型架构下，分别基于 OHLC、交易量和各技术指标组的设定均产生显著为正的高–低收益和因子调整后的阿尔法，同时具有经济意义上的夏普比率。然而，OHLC 单独使用的优势强度因架构而异。在二维卷积神经网络和一维卷积神经网络下，仅 OHLC 设定在高减低收益、夏普比率和因子调整后的阿尔法方面，均显著优于分别基于交易量或任何技术指标组的相应设定。仅 OHLC 的长短期记忆网络也产生了最大的点估计值，尽管其优势仅在部分比较中具有统计显著性。在l_2正则化逻辑回归下，相应的表现差异在统计上并不

显著。这些结果表明，所有单独设定都能产生具有经济意义的投资组合表现，而在本文考察的非线性模型中，仅 OHLC 设定通常表现最佳。

关于增量价值的证据在不同架构间更为一致。在四种模型中，相较于仅使用开盘价、最高价、最低价和收盘价，所有扩展设定均未使平均高低收益或因子调整后的阿尔法显著提高。加入技术指标也未能稳健改善夏普比率，有些设定反而显著降低了高减低收益、夏普比率和因子调整后的阿尔法。相较于仅使用开盘价、最高价、最低价和收盘价，唯一具有统计显著性的改善出现在长短期记忆网络的夏普比率上：开盘价、最高价、最低价和收盘价 + 成交量以及所有特征均产生了显著高于仅使用开盘价、最高价、最低价和收盘价的夏普比率。然而，在收益或夏普比率方面，全特征设定均未显著优于开盘价、最高价、最低价和收盘价 + 成交量。这一模式与如下解释相符：长短期记忆网络夏普比率的改善主要与交易量相关，而非技术指标组。对于二维卷积神经网络，累积波动率调整后的对数收益路径同样未显示增强输入设定能够持续优于仅使用开盘价、最高价、最低价和收盘价。这些结果支持这样的结论：这些指标组的增量经济价值有限，但并不能证明技术指标普遍冗余。

基于基准模型（仅使用OHLC的二维卷积神经网络）进行的基准比较与实施分析，为这些结果的经济学解释提供了限定。与四种传统交易策略相比，该模型能够生成更有序的横截面收益排序，夏普比率也显著更高，不过，其平均收益和阿尔法优势的统计显著性会因基准而异。与此同时，模型投资组合的高换手率使交易成本具有重要的经济影响。高–低和仅高组投资组合在单边成本最高达10个基点时，净收益仍为正且具有统计显著性，但成本上升会显著削弱其表现。经过保守的接近涨停筛选后，仅高组合结果仍为正。停牌和潜在的跌停暴露通常只影响少数持仓，但在全市场压力时期可能会集中出现。报告的高–低净收益未计入证券借贷费用，也未考虑可借券源方面的限制。由于回测未充分纳入市场冲击、流动性约束、延迟执行或停牌头寸占用资金的机会成本，因此，多头结果应被视为小规模、价格接受型实施条件下预测信号经济价值的证据，而非对所有市场摩擦下交易情况的完整模拟。

总的来说，这些结果为本文考察的技术指标组在多种表征和模型架构下，于中国A股市场中的独立经济价值及增量经济价值提供了首个大规模证据。总体一致的证据表明，其有限的增量价值并非仅限于烛形图像表示或二维卷积神经网络架构。

这些发现仅适用于本文考察的趋势、动量和波动率指标、四种模型架构以及中国主板A股样本期。此外，研究结果还取决于本文采用的指标参数、缩放与估计程序、20日窗口和五日预测期限。未来研究可评估这些结果能否推广至其他技术指标设定、市场环境和模型架构。还可考察开盘价、最高价、最低价和收盘价以外的额外输入，例如订单簿变量、文本新闻或投资者关注度指标，并探究这些输入如何与基于价格的表征相互作用。未来还需进一步研究，以阐明模型预测背后的机制。可利用特征归因方法和对学习到的表征的分析，识别驱动投资组合排名的时间与空间模式，并考察这些模式是否随市场状态而变化。这类分析或有助于判断模型依赖的是趋势持续性、反转、波动率还是其他价格形态。最后，更详尽的交易级数据可更全面地评估执行成本、策略容量以及在市场约束具有约束力时的表现。

利益冲突声明

作者声明，他们没有已知的竞争性财务利益或个人关系，可能会对本文所报告的工作产生影响。

数据可用性

数据可从 Baostock（https://baostock.com）和 CSMAR（https://data.csmar.com/）数据库获取，也可向通讯作者提出合理请求后获取。

致谢

本研究获得中国陕西省教育科学研究院（项目编号 SGH25Y2666）、国家自然科学基金委员会（项目编号 72501215）以及教育部人文社会科学青年基金（项目编号 23XJC630014）的资助。

参考文献

Bajgrowicz, P., Scaillet, O., 2012年。重新审视技术交易：假发现、持续性检验与交易成本。《金融经济学杂志》106，473–491。doi：10.1016/j.jfineco.2012.06.001。Bao, W., Cao, Y., Yang, Y., Che, H., Huang, J., Wen, S., 2025年。基于神经网络的数据驱动股票预测模型：综述。《信息融合》113，102616。doi：10.1016/j.inffus.2024.102616。Barberis, N., Shleifer, A., Vishny, R., 1998年。投资者情绪模型。《金融经济学杂志》49，307–343。doi：10.1016/ S0304-405X(98)00027-0。Blume, L., Easley, D., O'Hara, M., 1994年。市场统计与技术分析：成交量的作用。《金融学杂志》49，153–181。doi：10.1111/j.1540-6261.1994.tb04424.x。Brown, D.P., Jennings, R.H., 1989年。论技术分析。《金融研究评论》2，527–551。doi：10.1093/rfs/2.4.527。Campbell, J.Y., Thompson, S.B., 2008年。样本外预测超额股票收益：是否有方法能胜过历史平均值? 《金融研究评论》21，1509–1531。doi：10.1093/rfs/hhm055。Can, T.L., Le, M.D., Yu, K.C., 2024年。音乐情绪与越南股票市场。《亚洲商业与经济研究杂志》31，74–83。doi：10.1108/JABES-07-2022-0170。Cont, R., 2001年。资产收益的实证特征：典型事实与统计问题。《定量金融》1，223–236。doi：10.1080/ 713665670。CSDC, 2026年。上海和深圳市场证券登记与结算服务收费标准。中国证券登记结算有限责任公司。网址：https://www.chinaclear.cn/zdjs/fbzyls/service tlist.shtml。访问日期：2026年9月10日。Detzel, A., Liu, H., Strauss, J., Zhou, G., Zhu, Y., 2021年。通过技术分析学习并实现可预测性：来自比特币和基本面难以估值的股票的证据。《金融管理》50，107–137。doi：10.1111/fima.12310。Eugster, P., Uhl, M.W., 2023年。技术分析：关于逆向交易的新见解。《欧洲金融管理》29，1160–1190。doi：10.1111/eufm.12389。Fama, E.F., 1970年。有效资本市场：理论与实证研究综述。《金融学杂志》25，383–417。doi：10.1111/j. 1540-6261.1970.tb00518.x。Fama, E.F., French, K.R., 1993年。股票和债券收益中的共同风险因子。《金融经济学杂志》33，3–56。doi：10.1016/0304-405X(93)90023-5。Fama, E.F., French, K.R., 2015年。五因子资产定价模型。《金融经济学杂志》116，1–22。doi：10.1016/j.jfineco.2014.10.010。Fischer, T., Krauss, C., 2018年。运用长短期记忆网络进行深度学习，以预测金融市场。《欧洲金融管理杂志》

f

《运筹学》270, 654–669。doi：10.1016/j.ejor.2017.11.054。Giantsidi, S., Tarantola, C., 2025年。用于金融预测的深度学习：近期趋势综述。《国际经济与金融评论》104, 104719。doi：10.1016/j.iref.2025.104719。Glorot, X., Bengio, Y., 2010年。理解深度前馈神经网络训练的困难，载于：《第十三届人工智能与统计国际会议论文集》，第249–256页。网址：https://proceedings.mlr.press/v9/glorot10a.html。Grossman, S.J., Stiglitz, J.E., 1980年。论信息有效市场的不可能性。《美国经济评论》70, 393–408。网址：https://www.jstor.org/stable/1805228。Gu, S., Kelly, B., Xiu, D., 2020年。通过机器学习进行实证资产定价。《金融研究评论》33, 2223–2273。doi：10.1093/ rfs/hhaa009。G¨ulmez, B., 2023年。采用人工兔子优化算法优化的深度长短期记忆网络进行股票价格预测。《应用专家系统》227, 120346。doi：10.1016/j.eswa.2023.120346。Han, Y., Zhou, G., Zhu, Y., 2016年。趋势因子：利用投资期限内的信息能否带来经济收益? 《金融经济学杂志》122, 352–375。doi：10.1016/j.jfineco.2016.01.029。Hiransha, M., Gopalakrishnan, E.A., Menon, V.K., Soman, K.P., 2018年。使用深度学习模型进行印度国家证券交易所股市预测。《计算机科学 Procedia》132, 1351–1362。doi：10.1016/j.procs.2018.05.050。Hong, H., Stein, J.C., 1999年。资产市场中反应不足、动量交易与过度反应的统一理论。《金融学杂志》54, 2143–2184。doi：10.1111/0022-1082.00184。Jegadeesh, N., 1990年。证券收益可预测行为的证据。《金融学杂志》45, 881–898。doi：10.1111/j.1540-6261. 1990.tb05110.x。

Jegadeesh, N., Titman, S., 1993年。买入赢家并卖出输家的收益：对股票市场效率的启示。《金融学杂志》48, 65–91。doi:10.1111/j.1540-6261.1993.tb04702.x。Jeong, J.G., Byun, S.J., Kim, D., 2026年。利用基于图像的卷积神经网络预测收益：来自韩国的证据。《国际商业与金融研究》82, 103231。doi:10.1016/j.ribaf.2025.103231。Jiang, F., Tong, G., Song, G., 2019年。不存在数据窥探偏差的技术分析盈利能力：来自中国股票市场的证据。《国际金融评论》19, 191–206。doi:10.1111/irfi.12161。Jiang, J., Kelly, B., Xiu, D., 2023年。（重新）想象价格趋势。《金融学杂志》78, 3193–3249。doi:10.1111/jofi.13268。Lehmann, B.N., 1990年。时尚、鞅与市场效率。《经济学季刊》105, 1–28。doi:10.2307/2937816。Leippold, M., Wang, Q., Zhou, W., 2022年。中国股票市场中的机器学习。《金融经济学杂志》145, 64–82。doi:10.1016/j.jfineco.2021.08.017。Liu, P., 2025年。中国A股之间的反相关网络。《EPL》149, 11002。doi:10.1209/0295-5075/ada181。Liu, P., 2026年。中国股票市场收益尾部之间的局部高斯相关网络。《现代物理学国际期刊C》37, 2542007。doi:10.1142/S0129183125420070。Liu, P., Zheng, Y., 2023年。中国股票市场指数收益分布特征的精确测量。《Entropy》25, 36。doi:10.3390/e25010036。Lo, A.W., 2002年。夏普比率的统计学。《金融分析师杂志》58, 36–52。doi:10.2469/faj.v58.n4.2453。Lo, A.W., 2004年。适应性市场假说。《投资组合管理杂志》30, 15–29。doi:10.3905/jpm.2004.442611。Lo, A.W., Mamaysky, H., Wang, J., 2000年。技术分析基础：计算算法、统计推断与实证实施。《金融学杂志》55, 1705–1765。doi:10.1111/0022-1082.00265。Lonkani, R., Changchit, C., Cutshall, R., Treerotchananon, A., Prasertsoontorn, T., 2025年。投资者的情绪和抑郁状态对感知收益与风险的影响。《亚洲商业与经济研究杂志》32, 134–146。doi:10.1108/JABES-10-2024-0473。Loshchilov, I., Hutter, F., 2017年。SGDR：带热重启的随机梯度下降。arXiv: 1608.03983。doi:10.48550/arXiv.1608.03983。Loshchilov, I., Hutter, F., 2019年。解耦权重衰减正则化。arXiv: 1711.05101。doi:10.48550/arXiv.1711.05101。Mandelbrot, B., 1963年。某些投机价格的变动。《商业杂志》36, 394–419。doi:10.1086/294632。Mantegna, R.N., 1999年。金融市场中的层级结构。《欧洲物理学杂志B》11, 193–197。doi:10.1007/s100510050929。Mantegna, R.N., Stanley, H.E., 1995年。经济指数动态中的标度行为。《自然》376, 46–49。doi:10.1038/376046a0。Menkhoff, L., 2010年。基金经理对技术分析的使用：国际证据。《银行与金融杂志》34, 2573–2586。doi:10.1016/j.jbankfin.2010.04.014。财政部和国家税务总局，2023年。关于减半征收证券交易印花税的公告。中华人民共和国财政部、中华人民共和国国家税务总局。网址：https://m.mof.gov.cn/czxw/202308/t20230827 3904226.htm。2023年第39号公告，自2023年8月28日起生效。Neely, C.J., Rapach, D.E., Tu, J., Zhou, G., 2014年。股票风险溢价预测：技术指标的作用。《管理科学》60, 1772–1791。doi:10.1287/mnsc.2013.1838。Newey, W.K., West, K.D., 1987年。一种简单的、正半定的异方差和自相关一致协方差矩阵。《计量经济学》55, 703–708。doi:10.2307/1913610。Radfar, E., 2025年。通过图表分析使用深度神经网络预测股票市场趋势：实用方法还是神话？《人文与社会科学传播》12, 662。doi:10.1057/s41599-025-04761-8。Scholl, M.P., Calinescu, A., Farmer, J.D., 2021年。市场生态如何解释市场失灵。《美国国家科学院院刊》118, e2015574118。doi:10.1073/pnas.2015574118。Sullivan, R., Timmermann, A., White, H., 1999年。数据窥探、技术交易规则表现与自助法。《金融学杂志》54, 1647–1691。doi:10.1111/0022-1082.00163。Thakkar, A., Chaudhari, K., 2021年。股票市场深度神经网络综合综述：需求、挑战与未来方向。《应用专家系统》177, 114800。doi:10.1016/j.eswa.2021.114800。Tran, P., Pham, T.K.A., Phan, H.T., Nguyen, C.V., 2024年。应用机器学习算法预测股票市场中的股票价格趋势——以越南为例。《人文与社会科学传播》11, 393。doi:10.1057/s41599-024-02807-x。Welch, I., Goyal, A., 2008年。股票溢价预测实证表现的全面考察。《金融研究评论》21, 1455–1508。doi:10.1093/rfs/hhm014。

Xu, Y., Peng, L., Song, A., 2026年. 综合不确定性指标与股票市场收益：基于有监督降维技术。《国际金融》29, 240–255. doi:10.1111/infi.70023.

Zhao, D., Li, K., 2022年. 有限理性、适应性行为与资产价格。《国际金融分析评论》80, 102037. doi:10.1016/j.irfa.2022.102037.