

doi: 10.19920/j.cnki.jmssc.2025.10.007

如何运用经济和金融周期改进大类资产配置?^①

周颖刚^{1,2}, 潘 骏^{3,4}, 贝泽赞^{5*}, 刘 航⁶

(1. 厦门大学经济学院, 厦门 361005; 2. 厦门大学王亚南经济研究院, 厦门 361005;
3. 厦门大学邹至庄经济研究院, 厦门 361005; 4. 香港城市大学经济及金融系, 中国香港 999077;
5. 清华大学五道口金融学院, 北京 100080; 6. 招商银行股份有限公司重庆分行, 重庆 401121)

摘要: 探究经济与金融周期在资产配置中的作用对于提升大类资产配置效率具有重要意义。本研究首先借助小波分解方法, 构建了具有代表性的经济与金融周期变量, 能够有效体现经济运行的周期性规律。其次, 本研究提出了经济周期和金融周期双驱动的投资时钟策略(WISE 时钟), 改进了仅基于经济周期的美林时钟。最后, 本研究将变量中蕴含的周期性经济金融信息和机器学习方法相结合, 对大类资产收益率进行预测, 并以预测值作为投资者观点构造 Black-Litterman 投资组合。回测结果显示, 融合了周期性经济金融信息和机器学习的预测方法显著优于传统的机器学习模型, 并显著提高了投资组合的收益和风险表现。

关键词: 经济周期; 金融周期; 小波分析; 机器学习; 资产配置

中图分类号: F832 **文献标识码:** A **文章编号:** 1007-9807(2025)10-0110-16

0 引言

2023 年中央金融工作会议强调, 要加快建设金融强国, 提升国家金融核心竞争力, 以满足经济社会发展和居民金融需求。随着我国金融开放进程加快及私人财富增长, 投资者对跨国资产配置与风险管理的需求显著上升, 全球资产配置趋势日益明显。在此背景下, 如何统筹金融开放和安全、平衡全球资产配置的风险和收益是一个重要的问题。

大类资产配置旨在通过分散投资于股票、债券、商品及不动产等资产类别, 优化风险收益结构。以往学界和业界多聚焦于经济周期及宏观政策对资产收益的影响, 其中运用最为广泛的策略是基于经济周期的美林投资时钟, 其理论基础隐含的假设是货币的长期中性, 将金融周期视为经济周期的附属。然而, 2008 年金融危机后, 金融周期对宏观经济的影响日益凸显^[1-3], 金融冲击成

为经济波动的关键因素, 仅依赖经济周期难以充分解释资产价格的中长期波动。因此, 构建融合经济与金融周期的资产配置框架, 对提升组合绩效具有重要现实意义。如何利用周期性经济、金融信息进行大类资产投资? 金融周期和经济周期在大类资产收益率的预测中扮演着什么角色? 投资者能够获得超出市场组合的回报吗? 这些问题具有重要的学术意义和投资价值。

本研究的主要贡献体现在以下三个方面:

第一, 本研究基于先分解后集成的思想, 利用小波分解方法提出了识别经济周期和金融周期的新算法。本研究将经济金融变量视为由周期性经济和金融信号相互叠加而形成的波动过程, 根据经济和金融周期具有不同周期长度的内在特征^[4], 将对应周期长度的经济和金融周期分量从特定经济金融变量中分解并提取出来, 最后利用主成分分析方法集成得到具有广泛代表性的经济和金融周期变量。基于此, 本研究首次提出了经济

① 收稿日期: 2020-07-21; 修订日期: 2025-04-01。

基金项目: 国家社会科学基金资助项目(19ZDA060); 国家自然科学基金资助项目(71988101)。

通讯作者: 贝泽赞(1994—), 男, 广西贺州人, 博士。Email: zeyun.bei@my.cityu.edu.hk

和金融周期双驱动的投资时钟策略(WISE 时钟^②),有效改进了仅基于经济周期的美林时钟^③。本研究根据经济和金融周期将经济运行划分为四个阶段,归纳统计了5种大类资产在各个经济运行阶段的收益规律,为研究多种金融资产收益波动特征提供了全新的双周期视角。

第二,本研究创新性地将周期性经济金融信息与机器学习预测模型有机结合,有助于理清不同频率下各个预测变量与预测对象之间的结构关系。相比于运用原始序列,对众多具有混杂频率的信息直接进行建模,本研究通过频谱分解对具有相似频率特征的信息进行建模。因此,在不增加更多变量和使用更复杂模型的基础上,有效提升了大类资产收益的预测效果。

最后,本研究运用 Black-Litterman 模型,将基于周期性经济金融信息与机器学习模型得到的大类资产预测分布与历史收益均衡分布进行有机结合,提高资产配置的风险收益表现,改进了仅基于历史均衡分布的马科维兹的资产配置模型。

1 文献综述

1.1 经济和金融周期及其测度

经济周期的测度方法在现有文献中主要分为三类:单一变量法:基于真实商业周期理论,采用 GDP 或工业产出等单一指标表征经济周期^[2,4-6];双变量框架:如 Greetham 和 Hartnett^[7]通过 GDP 产出缺口与 CPI 两个维度对经济周期进行刻画;多指标综合法:美国国家经济研究局(NBER)公布的商业周期广泛被美国商务部和学界认可和引用,其月度指标涵盖就业、工业生产、收入及消费等指标,季度指标则侧重 GDP 与就业。

2008 年金融危机后,随着经济金融化程度加深,金融周期的测度与影响成为研究热点^[8,9]。Borio^[10]将金融周期界定为风险偏好、信贷约束与资产价格的交互作用,并指出信贷与房地产价格

是其核心指标。国内研究则强调中国金融周期的特殊性,认为固定资产投资是主要驱动因素,而货币供应量是关键代理变量^[11]。总体而言,现有文献主要基于货币供给、信贷/GDP 及资产价格构建金融周期指标^[2,4,11,12]。

关于经济与金融周期的周期长度,经文献测算,主要发达国家的经济周期长度范围大致为5个季度~32个季度(约1年~8年),金融周期长度范围为32季度~120季度(8年~30年)^[4,13,14]。国内研究表明,中国经济周期的长度介于1年~6年之间,中国金融周期的长度则介于6年~20年之间^[5,15,16]。

在周期测度方法方面,现有研究主要采用时域和频域两类方法测度经济金融周期。时域方法以 BP 滤波^[2,4,5](Band Pass Filter)和 HP 滤波^[17](Hodrick Prescott Filter)为代表,而频域方法则包括傅里叶变换^[12],经验模态分解^[18](EMD)和小波分解^[19]等。其中,小波分解方法因其有限长衰减基函数的特性,能够有效避免端点效应并保持分频可逆性,在样本外预测方面展现出独特优势^[20-22]。实证研究表明,相比其他分频方法(如 EMD),小波分解不仅能更准确地捕捉中国经济周期波动特征^[20],在 GDP 与通胀预测^[21]以及股票收益率预测^[22]中也具有更好的样本外预测表现。

1.2 资产配置与机器学习的相关研究

现代资产配置理论经历了重要演进。Markowitz 的均值-方差模型奠定了投资组合理论基础,但其依赖历史数据的特性在市场结构变化时可能导致显著偏差^[23]。为克服这一局限,Black-Litterman 模型创新性地采用贝叶斯方法,将基于历史信息的市场均衡收益分布与投资者主观观点分布有机结合,大幅提升了配置稳健性^[24,25]。值得注意的是,该模型效果依赖于投资者观点的准确性。近年来,机器学习方法在金融预测领域展现出显著优势,其凭借对非线性特征的捕捉能力在股票、债券等资产收益预测中表现优

② 因作者来自厦门大学王亚南经济研究院(简称 WISE),本研究将改进的投资时钟命名为 WISE 时钟。

③ 美林投资时钟是一种将资产轮换和行业战略与经济周期联系起来的直观的投资策略。运用 HP 滤波,美林时钟将产出缺口和消费者物价指数(CPI)的周期成分作为经济阶段的划分标准,将1973年以来美国经济走势划分为四个阶段,然后统计每个周期运行阶段的大类资产(股票、债券、商品和现金)收益并归纳出大类资产投资的周期性规律。

异^[26-31]. 最新研究趋势是将机器学习预测结果作为 BL 模型的投资者观点输入, 形成智能化的资产配置框架^[32].

2 实证设计

2.1 小波分解原理

本研究采用小波分析方法进行经济金融周期测度, 该方法在样本内分析和样本外预测方面均表现出色. 具体而言, 本研究运用最大重叠离散小波变换 (MODWT) 结合 Haar 小波滤波器进行多分辨率分析, 该方法相比传统离散小波变换 (DWT) 具有显著优势^[22]. MODWT 不仅不受样本量限制且具有平移不变性, 对时间序列起点选择不敏感, 这一特性对分频预测尤为重要; 同时该方法不引入小波系数相移, 确保分解后各周期成分与原始序列的波峰波谷正确对应. 原始时间序列 (y_t) 可以分解为有限个小波函数 (即小波分量) 的和

$$y_t = y_t^{S_J} + y_t^{D_J} + y_t^{D_{J-1}} + \cdots + y_t^{D_1} \quad (1)$$

其中 J 既代表分量的个数, 也代表各个分量对应的频率, 小波分量既和频率变量 j 有关, 同时也是 t 的函数, 即获得了时变的频谱信息. 若 y_t 为月度时间序列, $y_t^{D_j}$ 刻画了周期长度为 2^{j-1} 个到 2^j 个月的小波分量, $y_t^{S_J}$ 刻画了周期长度大于 2^J 个月的小波分量. 本研究参考已有研究关于中国与美国市场经济、金融周期的特征, 设置小波分量的总个数 J 为 8, 按照周期长度将具有特定频率的分量重组为高频分量 ($j = 1, 2, 3, 4$)、中频分量 ($j = 5, 6$)、低频分量 ($j = 7, 8$) 和残差 (趋势) 分量 ($y_t^{S_8}$). 本研究将经济金融变量视为由经济和金融因素相互叠加和共振而形成的波动过程, 由于中频分量和经济周期范围基本重合, 主要蕴含了经济周期的周期性信息, 故称之为经济周期信息; 低频分量则与金融周期的周期范围基本重合, 更多受金融周期共振的影响, 称之为金融周期信息.

2.2 经济、金融周期和投资时钟

参考 NBER 商业周期的范式和以往文献的经验, 本研究构造月度美国经济周期指标时, 以工业

指数、失业率和 CPI 同比增速作为基础变量, 将变量标准化后通过小波分析提取变量中蕴含中频分量, 并使用主成分分析法提取共同波动成分^[11]. 在构造月度中国经济周期指标时, 由于我国失业率数据缺失较多, 本研究运用国家统计局公布的月度宏观经济景气一致指数^[33], 其主要以产出和就业为基础变量, 此外本研究也加入了 CPI 同比增速构造中国经济周期指标. 相比于以往文献只运用产出缺口, 本研究更加接近 NBER 经济周期的构造方法.

构造中美两个市场的金融周期指标时, 本研究以 M2 同比增速、信贷/GDP 和房价指数同比增速作为基准变量, 将变量标准化后通过小波分析提取变量中蕴含的低频分量, 并使用主成分分析法提取共同波动成分, 以此作为金融周期变量.

利用经济周期和金融周期波动的不同走向, 本研究将经济运行分成四个阶段: 扩张期 (经济周期上行、金融周期上行); 复苏期 (经济周期上行、金融周期下行); 泡沫期 (经济周期下行、金融周期上行); 衰退期 (经济周期下行、金融周期下行). 在此基础上, 本研究对各个阶段大类资产的收益率进行统计, 并总结提炼规律, 形成 WISE 时钟投资策略. 周期波峰波谷等拐点的识别则参考 Harding 和 Pagan^[34] 提出的算法^④.

2.3 Black-Litterman 资产配置策略

Black-Litterman 资产配置模型通过引入投资者观点得到后验资产收益率, 提供了一个更加稳健与贴合实际的投资组合优化框架. 在均衡状态下, 市场均衡收益的先验分布 π 如式 (2) 所示

$$\pi = \Pi + \varepsilon \quad (2)$$

$$\Pi = \delta \Sigma w \quad (3)$$

其中 Π 为先验分布的预期收益; w 为市场均衡权重, 本研究使用各大类资产市值比重作为市场组合权重; δ 表示风险厌恶系数; Σ 为资产历史收益率的协方差矩阵; ε 是均值为 0 和协方差矩阵为 $\tau \Sigma$ 的正态分布随机向量, 其中 τ 衡量了先验分布的不确定性.

通过贝叶斯方法将对资产未来收益的预测与市场均衡收益的先验分布进行结合, 可以得到组

④ 由于篇幅限制, 具体算法可联系作者备案获取.

合收益的 BL 后验分布,如式(4)和式(5)所示

$$\mu_{BL} = [(\tau \Sigma)^{-1} + P' \Omega^{-1} P]^{-1} [(\tau \Sigma)^{-1} \Pi + P' \Omega^{-1} Q] \quad (4)$$

$$\Sigma_{BL} = \Sigma + [(\tau \Sigma)^{-1} + P' \Omega^{-1} P]^{-1} \quad (5)$$

其中 μ_{BL} 为调整后的资产预期收益的后验分布, Σ_{BL} 为后验分布的方差, P 为观点矩阵,由于本研究利用大类资产收益率的预测值作为观点,故 P 为 5×5 的单位矩阵; Q 为观点的预期收益向量; Ω 为衡量观点不确定性的协方差矩阵,此处使用大类资产收益预测值的方差衡量观点的不确定性。

最后利用调整后的 BL 后验收益分布,得到优化后的 BL 投资组合权重 (w_{BL}^*)

$$w_{BL}^* = (\delta \Sigma_{BL})^{-1} \mu_{BL} \quad (6)$$

2.4 结合小波分析和机器学习的预测流程

本研究的主要目标是采取“先分解,后集成”的思路,结合周期性经济金融信息和机器学习方法改进大类资产收益率的预测,进而改进大类资产配置。具体而言,先通过小波分解获取每个变量蕴含的周期性经济金融信息,并将其输入三类常见的机器学习模型^⑤: 随机森林(RF),支持向量回归(SVR)和神经网络(NN),用于大类资产收益率的对应的周期分量的预测,最后将各分量预测值合成得到大类资产回报率的预测值(分别记为 RF-Cycle,SVR-Cycle 和 NN-Cycle)。通过这种方式,本研究可以充分利用经济金融变量中蕴含的周期性信息去预测各大类资产收益率中对应的各周期成分,改进了仅依赖原始序列的预测效果。需要强调的是,本研究在分解与集成的过程中,避免使用预测对象的未来信息,严格保证了分频预测的样本外性质。

2.4.1 预测模型构建流程

本研究广泛地收集了用于大类资产收益率预测的预测变量集(记为 $X_t, t = 1, 2, \dots, T-1$, 记 T 为样本长度),被预测变量为大类资产收益率(记为 Y_{t+1}),预测步长为 1 个月。具体地,本研究对中美两个市场的 5 种大类资产收益率共计 10 个时间序列分别进行样本外预测。Tashman^[35]发现对于单个时间序列,采用滚动窗口预测的方式可以兼顾预测的可靠性与计算效率。因此,本研究采取滚动窗口方法来划分训练集、验证集和测试集。

按照机器学习预测的典型范式以及本研究的 数据特点,本研究首先以 4:6 的比例将样本划分成初始的训练验证集 ($T_{train+vali}$) 和测试集 (Test Set, T_{test}),进一步地,将训练验证集的最后 12 个月的样本作为验证集 (Validation Set, T_{vali}),其余样本为训练集 (Train Set, T_{train})。测试集前 12 个月的样本作为样本外预测区间 (Out-of-sample set, T_{oos})。每次向前滚动预测时,将训练集、验证集向前滚动 1 年并维持固定窗口宽度,并对未来 12 个月的样本进行样本外预测(每年重新训练模型以节省计算成本),通过不断向前滚动预测直到将测试集所有样本进行预测为止。如图 1 所示,预测的具体流程如下:




图1 固定窗口滚动预测数据集划分示意图

Fig. 1 The division of dataset for rolling window forecast

第一步 对训练样本进行小波分解。在训练验证集 ($T_{train+vali}$) 内通过小波分解,将大类资产收益率和宏观经济金融变量分解为 8 个具有不同周期的小波分量,并按照周期长度将特定周期分量合成为高频分量 ($j = 1, 2, 3, 4$)、中频分量 ($j = 5, 6$)、低频分量 ($j = 7, 8$) 以及残差(趋势)项。被预测变量为 5 种大类资产收益率的高频、中频、低频和残差分量,预测变量为宏观经济金融指标对应的各周期分量。

具体地,对于每一次预测模型估计,首先在训练验证集内,将预测和被预测变量进行小波分解,分别得到该区间预测和被预测变量的高 (High, H)、中 (Medium, M)、低 (Low, L) 频分量与残差项分量 (Residual, r)。其中训练集样本的预测变量和被预测变量的高、中、低频分量以及残差项分别表示为 $X_{train}^H, X_{train}^M, X_{train}^L, X_{train}^r$ 与 $Y_{train}^H, Y_{train}^M, Y_{train}^L, Y_{train}^r$ 。同理,验证集的预测和被预测变量的各频

⑤ 由于篇幅限制,相关机器学习方法的介绍可联系作者备案获取。

率分量分别表示为 $X_{vali}^H, X_{vali}^M, X_{vali}^L, X_{vali}^r$ 与 $Y_{vali}^H, Y_{vali}^M, Y_{vali}^L, Y_{vali}^r$. 需要说明的是, 本研究将滚动迭代的训练集和验证集连接起来进行小波分解, 出于两方面的考虑: 其一是时间序列需具备一定样本长度才可对其进行分频处理, 其二是为了最大程度的保留原始序列与各周期分量的波动连贯性.

第二步 训练模型. 通过 RF, SVR, NN 这三种机器学习模型在训练集和验证集中训练模型和选择最优超参数. 具体地, 本研究在训练集中利用预测变量的各周期信息 ($X_{train}^H, X_{train}^M, X_{train}^L, X_{train}^r$) 对被预测变量的对应周期信息 ($Y_{train}^H, Y_{train}^M, Y_{train}^L, Y_{train}^r$) 分别进行建模和预测, 并通过验证集 X_{vali} 与 Y_{vali} 的各周期分量获取各机器学习模型的最优调节参数.

第三步 对样本外预测变量进行小波分解. 对于每次滚动预测, 本研究将训练集 T_{train} 、验证集 T_{vali} 和样本外预测区间 T_{oos} 的预测变量进行连

接(记为 $X_{train+vali+oos}$) 并对 $X_{train+vali+oos}$ 重新进行小波分解, 得到 X_{oos} 的各周期分量为 $X_{oos}^H, X_{oos}^M, X_{oos}^L, X_{oos}^r$. 特别地, 本研究没有将样本外预测区间的被预测变量进行小波分解, 以保证样本外预测的性质不被破坏.

第四步 样本外预测. 最后, 将样本外预测区间的预测变量的各周期分量, 即将 $X_{oos}^H, X_{oos}^M, X_{oos}^L, X_{oos}^r$ 作为新的预测变量集输入第二步中训练好的预测模型, 分别对样本外预测区间的被预测变量(记为 Y_{oos}) 对应的高、中、低频和残差项进行预测, 预测结果记为 $\hat{Y}_{oos}^H, \hat{Y}_{oos}^M, \hat{Y}_{oos}^L, \hat{Y}_{oos}^r$, 进而根据式(7)得到 Y_{oos} 的最终预测值 \hat{Y}_{oos} .

$$\hat{Y}_{oos} = \hat{Y}_{oos}^H + \hat{Y}_{oos}^M + \hat{Y}_{oos}^L + \hat{Y}_{oos}^r \quad (7)$$

经过以上步骤, 可实现小波分解提取经济金融变量中的周期性信息, 并结合机器学习进行大类资产收益率预测. 以上步骤严格避免了使用测试集信息来训练预测模型, 因而保证了预测的样本外性质. 图2描述了结合小波分析和机器学习的预测流程.

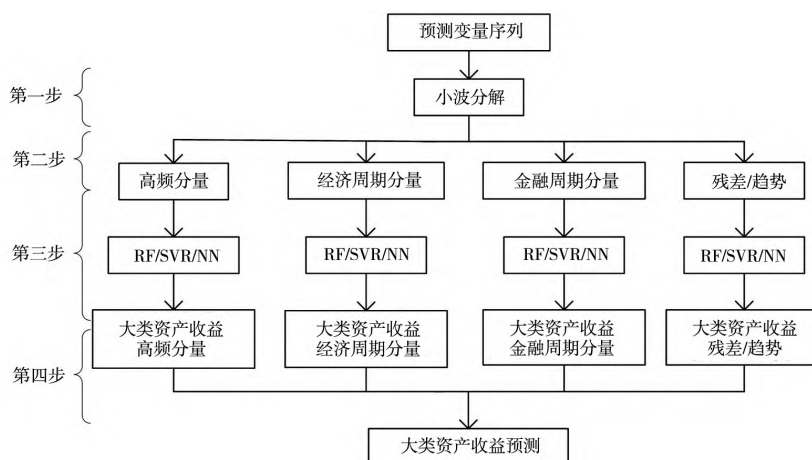


图2 结合小波分析和机器学习的预测方法流程图

Fig. 2 The forecasting method combining wavelet analysis and machine learning

2.4.2 预测效果评估

为了比较不同模型样本外的预测效果, 本研究参考 Gu 等^[26] 以及李斌和龙真^[30] 统一选择零作为比较基准, 计算了各方法的 R_{oos}^2 指标

$$R_{oos}^2 = 1 - \frac{\sum_{t=T_0+1}^T (r_t - \hat{r}_t)^2}{\sum_{t=T_0+1}^T r_t^2} \quad (8)$$

其中 T_0 为样本内预测区间, T 为全部样本区间长度, r_t 为大类资产月度收益率真实值, \hat{r}_t 表示预测

值. R_{oos}^2 越大则说明模型预测能力越强, 反之说明模型预测能力较弱.

本研究进一步检验了预测回归模型的均方预测误差 (MSPE) 是否显著低于零基准预测, 这相当于检验了 $R_{oos}^2 \leq 0$ 的原假设和 $R_{oos}^2 > 0$ 的备择假设. 参考 Clark 和 West^[36], 本研究进行了 Clark-West 检验. 此外, 为了对不同模型的预测效果进行两两比较, 本研究参考 Gu 等^[26], 采用 Diebold 和 Mariano^[37] 检验来比较两个模型之间的样本外预测性能的差异.

3 数 据

3.1 变量及描述性统计

表 1 呈现了中美市场五大类资产的收益率特征^⑥。美国市场数据显示(如 Panel A 所示)股票、房产、债券、商品和现金的月均收益率分别为 0.645%、0.42%、0.577%、0.213% 和

0.345%；中国市场(见表 1 的 Panel B)相应资产的收益率则分别为 0.927%、0.373%、0.378%、0.489% 和 0.207%。值得注意的是，两国市场均呈现一个共同特征：虽然房产收益率并非最高，但其波动率显著低于其他风险资产，展现出了较好的风险收益比。相比之下，股票和商品虽具有较高收益，但其波动幅度可达房产的数倍。

表 1 主要变量的描述性统计

Table 1 Summary statistics

Panel A 美国市场					
变量名	均值	标准差	Q25	Q75	样本区间
股票收益率/%	0.645	4.391	-1.769	3.510	1976 年 04 月—2022 年 12 月
房产收益率/%	0.420	0.559	0.191	0.690	1976 年 04 月—2022 年 12 月
债券收益率/%	0.577	1.947	-0.339	1.584	1976 年 04 月—2022 年 12 月
商品收益率/%	0.213	5.822	-2.870	3.889	1976 年 04 月—2022 年 12 月
现金收益率/%	0.345	0.293	0.080	0.500	1976 年 03 月—2022 年 12 月
工业生产指数同比增长/%	2.072	4.416	0.292	4.610	1975 年 12 月—2022 年 12 月
失业率同比增长/%	1.991	28.169	-9.710	5.116	1975 年 12 月—2022 年 12 月
CPI 同比增长/%	3.711	2.807	1.970	4.493	1975 年 12 月—2022 年 12 月
货币供应 M2 同比增长/%	6.915	3.818	4.878	8.403	1975 年 12 月—2022 年 12 月
房地美房价指数	116.537	64.016	67.330	164.574	1975 年 12 月—2022 年 12 月
私人信贷/GDP/%	132.467	22.604	118.200	151.600	1975 年 12 月—2022 年 12 月
Panel B 中国市场					
股票收益率/%	0.927	6.700	-4.497	5.016	2002 年 2 月—2022 年 12 月
房产收益率/%	0.373	0.463	0.080	0.620	2010 年 6 月—2022 年 12 月
债券收益率/%	0.378	0.758	-0.084	0.865	2003 年 7 月—2022 年 12 月
商品收益率/%	0.489	3.308	-1.878	2.736	2009 年 3 月—2022 年 12 月
现金收益率/%	0.207	0.051	0.168	0.246	2006 年 3 月—2022 年 12 月
宏观经济景气一致指数	108.425	8.050	102.354	114.896	1991 年 1 月—2022 年 12 月
CPI 同比增长/%	0.042	3.863	-1.656	1.959	1991 年 1 月—2022 年 12 月
货币供应 M2 同比增长/%	14.763	4.432	11.385	17.594	1998 年 1 月—2022 年 12 月
国房景气指数	101.023	3.663	98.550	103.630	1997 年 1 月—2022 年 12 月
私人信贷/GDP/%	147.196	45.894	112.625	200.900	1996 年 3 月—2022 年 12 月


4 实证结果

4.1 中国与美国市场的金融与经济周期

图 3 展示了本研究构建的美国经济周期与金融周期指标。上半图显示，经济周期(实线)的波谷(垂直线)以及波谷前的快速下行的时期与 NBER 衰退区间(阴影)高度吻合，表明

该指标能准确捕捉经济运行的周期性特征。下半图显示，本研究构造的金融周期指标与 Drehmann 等^[4]研究结果一致。具体而言，金融周期准确刻画了 1987 年和 2007 年两次美国资本市场的重大下跌，以及 2021 年信贷见顶、QE 退出和 2022 年加息周期引发的金融状况转向。这些结果验证了本研究周期测度方法的有效性。

⑥ 由于篇幅限制，详细的数据来源及介绍可联系作者备案获取。



注: 上(下)半图展示了美国的经济(金融)周期, 虚线和实线垂直线分别表示波峰和波谷; 阴影代表 NBER 认定的衰退区间; 实线代表周期序列。

图 3 美国经济周期(上)与金融周期(下)指标

Fig. 3 The economic cycle (upper) and financial cycle (lower) in the U. S.

图 4 描绘了中国的经济和金融周期指标。首先, 本研究构造的经济周期指标走势与中国经济的几大转折点基本对应: 20 世纪 90 年代初期的繁荣对应了经济周期上行阶段, 1990 年—1992 年 GDP 增速从 4.1% 上升到 13.6%, 升幅近三倍; 1993 年中国爆发三大赤字危机: 财政赤字、金融赤字和外贸赤字, 经济增长开始收窄, 进入经济下行期; 2008 年—2009 年国际金融危机期间, 我国经济周期再次大幅下行调整; 2020 年 3 月重大公共卫生安全事件期间, 我国经济周期陷入短暂的低谷, 受益于高效的疫情管控, 经济周期迅速提升, 但随着后续需求不足, 经济周期继续下探。截至 2022 年 12 月, 中国经济周期下探至 -0.2 左右, 低于重大公共卫生安全事件期间的波谷, 创 2015 年 3 月以来的新低。


图 4 的下半图描绘了中国金融周期指标, 该指标有效捕捉了关键政策时点的金融环境转变。2000 年国企去杠杆改革引发金融周期下行, 而 2008 年危机期间的大规模政策刺激则维持了金融周期稳定, 使其在 2012 年短暂调整后持续攀升

至 2016 年峰值。2017 年全国金融工作会议后, 进入去杠杆时期, 对信贷和房地产市场实施了较为严格的调控, 促使周期进入下行通道, 这一演变趋势与既有研究具有一致性^[5], 验证了指标构建的有效性。

4.2 基于金融与经济周期的 WISE 时钟

表 2 展示了根据金融周期和经济周期划分的各阶段中大类资产平均回报率。表 2 的 Panel A 展示了 WISE 时钟在美国市场的表现。在经济和金融周期上行的扩张期, 股票和商品呈现顺周期特征, 经济基本面良好、公司盈利能力强、金融流动性充足, 股票平均月度收益率为 0.914%, 商品收益率为 0.753%。在经济上行和金融下行的复苏期, 实体经济率先复苏, 商品需求上升, 成为最佳投资标的, 平均月度收益率为 1.083%; 股票因公司盈利改善, 平均月度回报率为 0.849%, 仅次于商品。在经济和金融双下行的衰退期, 现金表现出逆周期特点, 平均收益率为 0.528%, 债券作为安全资产提供 0.326% 的平均收益。在经济下行和金融上行的泡沫期, 尽管经济基本

面下行 金融状况宽松 美国债券成为优质资产 ,平均月收益率为 0.914%.



注：上(下)半图展示了中国的经济(金融)周期,其余同图 3.

图 4 中国经济周期(上)和金融周期(下)指标

Fig.4 The economic cycle (upper) and financial cycle (lower) in China

表 2 的 Panel B 呈现了中国市场 WISE 时钟的资产配置规律. 研究表明,中美市场在扩张期(股票最优)、复苏期(商品最优)和泡沫期(债券最优)的资产表现具有一致性,在衰退期中国债券表现最优、现金次之,而美国市场现金更具优势. 总体来看,WISE 时钟在中美市场的表现大体

一致,但也存在细微差异. 特别地,中国房地产在扩张期(0.674%)和复苏期(0.655%)的收益率显著高于美国,展现其顺周期特性. 中国股票市场展现出更强的顺周期性,扩张期收益率达 2.656%,但衰退期则为 -1.110%,其波动幅度大于美国市场.

表 2 WISE 时钟资产收益率统计

Table 2 Return statistics of WISE Clock

Panel A 美国市场						
月收益率/%		股票	债券	商品	房产	现金
扩张期	金融上行	0.914	0.557	0.753	0.599	0.301
	经济上行					
复苏期	金融下行	0.849	0.634	1.083	0.372	0.364
	经济上行					
衰退期	金融下行	0.192	0.326	0.252	0.162	0.528
	经济下行					
泡沫期	金融上行	0.595	0.914	-1.053	0.342	0.309
	经济下行					

续表 2

Table 2 Continues

Panel B 中国市场						
月收益率/%		股票	债券	商品	房产	现金
扩张期	金融上行	2.656	0.233	-0.037	0.674	0.191
	经济上行					
复苏期	金融下行	0.917	0.197	2.560	0.655	0.213
	经济上行					
衰退期	金融下行	-1.110	0.531	-0.402	0.170	0.217
	经济下行					
泡沫期	金融上行	-0.883	0.687	-0.121	-0.088	0.242
	经济下行					

注: Panel A(B) 统计了美(中)国市场的大类资产在各经济运行阶段的平均收益率。

在 WISE 时钟的基础上,本研究根据当期经济和金融周期的阶段构造资产组合,对组合下一期的收益表现进行回测。实证结果表明该策略显著优于传统美林时钟及单资产投资策略。特别地,在 2008 年金融危机后的市场环境中,WISE 时钟通过精准捕捉金融周期对资产收益的影响,展现出更优异的稳健性^⑦。

4.3 大类资产收益率预测

本文对中国与美国市场的五个大类资产收益率进行预测,设定预测步长为一个月^[26,30]。采用随机森林(RF)、支持向量回归(SVR)和神经网络(NN)以及结合周期性经济金融信息和机器学习的预测模型(分别记为 RF-Cycle、SVR-Cycle 和 NN-Cycle)并将 ARMA 模型与弹性网(ENET)模型

作为线性类预测模型进行对比。

表 3 呈现了美国市场五大类资产在不同预测模型下的样本外预测效果 R^2_{OOS} 。研究发现,股票作为高波动性资产,其预测难度较大,除神经网络外,多数线性和非分频的机器学习模型的 R^2_{OOS} 均为负值。然而,基于小波分解和机器学习的组合预测方法展现出显著优势,其 R^2_{OOS} 显著为正,且优于线性基准模型和非分频机器学习模型。这一结果验证了周期性经济金融信息与机器学习方法相结合的有效性。类似地,债券预测中所有模型均取得显著正 R^2_{OOS} ,但融合周期信息的机器学习模型表现最优。此外,大宗商品的线性预测效果不佳,而机器学习方法则展现出明显优势;房产和现金因波动率较低,其预测效果普遍优于其他资产。

表 3 美国大类资产样本外预测表现

Table 3 Out-of-sample forecasting performance of U. S. assets

R^2_{OOS}	股票	债券	商品	房产	现金
ARMA	-2.02	5.09 ***	-3.41	7.78 ***	63.4 ***
ENET	-1.82	7.32 ***	-1.68	12.76 ***	42.49 ***
RF	-1.57	8.91 ***	2.66 ***	15.25 ***	73.86 ***
RF-Cycle	5.77 ***	11.78 ***	3.12 ***	30.21 ***	84.31 ***
SVR	-2.46	8.59 ***	0.74 **	20.24 ***	79.09 ***
SVR-Cycle	3.23 ***	13.69 ***	1.0 ***	27.72 ***	84.31 ***
NN	1.48 ***	11.46 ***	3.74 ***	22.73 ***	73.86 ***
NN-Cycle	3.63 ***	13.05 ***	4.02 ***	37.69 ***	79.09 ***

注: 表格展示了美国市场的 5 个大类资产在不同预测模型下的 R^2_{OOS} 及显著性水平(Clark-West 检验)。预测模型包括 ARMA、弹性网络(ENET)、随机森林(RF)、支持向量回归(SVR)、神经网络(NN),以及机器学习结合周期性经济金融信息的预测模型(RF-Cycle、SVR-Cycle、NN-Cycle)。“*”,“**”,“***”分别表示在 10%、5% 和 1% 的显著性水平下显著。

⑦ 由于篇幅限制,相关具体结果联系作者备案获取。

表 4 Diebold-Mariano 比较检验(美国)
Table 4 Diebold-Mariano comparison test (U. S.)

大类资产	DM 统计量	RF	SVR	NN	ARMA	ENET
股票	RF-Cycle	2.12 **	2.29 **	1.89 **	2.16 **	2.23 **
	SVR-Cycle	1.96 **	2.13 **	1.72 **	2.0 **	2.07 **
	NN-Cycle	1.89 **	2.05 **	1.66 **	1.93 **	1.99 **
债券	RF-Cycle	2.07 **	2.63 ***	1.94 **	2.2 **	2.09 **
	SVR-Cycle	2.35 ***	2.92 ***	2.22 **	2.48 ***	2.37 ***
	NN-Cycle	2.14 **	2.7 ***	2.01 **	2.27 **	2.16 **
商品	RF-Cycle	1.31 *	1.44 *	1.19	1.73 **	1.56 *
	SVR-Cycle	1.1	1.24	1.0	1.53 *	1.37 *
	NN-Cycle	1.35 *	1.48 *	1.24	1.76 **	1.6 *
房产	RF-Cycle	2.16 **	1.75 **	1.61 *	2.88 ***	2.43 ***
	SVR-Cycle	1.86 **	1.48 *	1.31 *	2.56 ***	2.1 **
	NN-Cycle	2.91 ***	2.49 ***	2.43 ***	3.55 ***	3.19 ***
现金	RF-Cycle	3.34 ***	2.3 **	4.2 ***	9.91 ***	1.42 *
	SVR-Cycle	3.21 ***	2.19 **	4.06 ***	9.86 ***	1.41 *
	NN-Cycle	1.9 **	0.99	2.76 ***	9.37 ***	1.34 *

注：该表展示了美国大类资产样本外预测的 Diebold-Mariano 比较检验。对于每个资产，将结合周期性经济金融信息的模型预测结果与未结合周期性信息的预测结果进行比较检验，正的统计量表明行模型优于列模型。“*”，“**”，“***”分别表示在 10%、5% 和 1% 的显著性水平下显著。

表 4 报告了美国市场大类资产预测模型比较的 DM 检验。若 DM 统计量显著为正，则表明行对应的模型预测效果显著优于列对应的模型。由于本研究的重点在于探究利用周期性经济金融信息结合机器学习方法是否能够改进大类资产预测效果，故将结合分频和机器学习的预测模型与其他模型进行对比。结果显示，所有的 DM 统计量为正，除了大宗商品外绝大多数统计量均显著，说明结合周期性经济金融信息和机器学习的预测方法显著优于非分频机器学习模型和线性基准模型。

表 5 展示了中国市场大类资产收益率的预测

结果。从股票的预测效果来看，除了弹性网络 (ENET) 预测的 R^2_{oos} 为负，其他预测模型的 R^2_{oos} 均显著为正，整体上比美国的预测效果更好。同样地，基于小波分解和机器学习的 R^2_{oos} 显著为正且高于其他模型，预测效果明显优于线性基准模型和非分频的机器学习模型，说明利用经济金融周期信息并结合机器学习方法同样可以提高中国大类资产收益率的预测精度。中国市场的其它大类资产预测结果也呈现类似效果，不再赘述。但也有个别例外，比如基于神经网络 (NN) 的分频预测模型对中国现金资产的预测效果不如其他模型。

表 5 中国大类资产样本外预测结果

Table 5 Out-of-sample forecasting performance of Chinese assets

R^2_{oos}	股票	债券	商品	房产	现金
ARMA	2.05 ***	2.64 ***	2.79 ***	19.24 ***	87.53 ***
ENET	-1.5	4.12 ***	2.53 ***	16.86 ***	90.66 ***
RF	9.07 ***	5.59 ***	6.93 ***	26.36 ***	91.88 ***
RF-Cycle	15.36 ***	10.02 ***	10.98 ***	50.12 ***	94.72 ***
SVR	7.28 ***	5.59 ***	2.9 **	26.36 ***	93.3 ***
SVR-Cycle	13.62 ***	8.54 ***	4.05 ***	28.74 ***	93.5 ***
NN	9.8 ***	7.07 ***	14.87 ***	31.11 ***	90.79 ***
NN-Cycle	10.39 ***	18.87 ***	17.2 ***	38.24 ***	71.68 ***

注：指标同表 3。

表 6 展示了中国市场相应的 DM 检验统计量及显著性水平. 与美国市场预测结果类似, 整体上来看, 融合了周期性经济金融信息和机器学习的预测方法比传统线性回归、非分频机器学习模型具有显著的改进. 也有一些例外, 比如对于中国大宗商品的预测, 只有神经网络结合小波分解的预测效果具有相对显著的改进; 但对于中国的现金类资产预测, NN 结合小波分析的预测效果反而不如传统预测模型. 这与 R_{oos}^2 的结果保持一致. 这可能与我国现金资产收益低、波动小有关, 复杂的

神经网络建模并不一定优于较为简单的预测模型. 但从整体上看, 特别是对于风险资产, 结合周期性经济和金融信息的机器学习预测模型显著优于仅基于传统机器学习的预测方法.

此外, 表 3 与表 5 的结果发现, 在结合小波分解预测股票中, 随机森林 (RF) 优于神经网络 (NN). 这可能因为: 1) 小波分解后的信号更平稳, 适合 RF 善于捕捉局部特征的特点; 2) RF 参数少易调优, 而 NN 对不同频段数据需要更复杂的参数结构调整.

表 6 Diebold-Marian 比较检验 (中国)

Table 6 Diebold-Mariano comparison test (China)

大类资产	DM 统计量	RF	SVR	NN	ARMA	ENET
股票	RF-Cycle	2.6 ***	3.08 ***	2.51 ***	2.7 ***	2.43 ***
	SVR-Cycle	2.51 ***	2.99 ***	2.43 ***	2.62 ***	2.34 ***
	NN-Cycle	2.01 **	2.5 ***	1.95 **	2.16 **	1.85 **
债券	RF-Cycle	2.51 ***	2.41 ***	1.64 *	1.86 **	1.65 **
	SVR-Cycle	2.75 ***	2.65 ***	1.9 **	2.13 **	1.9 **
	NN-Cycle	2.63 ***	2.53 ***	1.77 **	2.0 **	1.78 **
商品	RF-Cycle	1.51 *	1.09	1.25	1.36 *	1.22
	SVR-Cycle	1.81 **	1.41 *	1.57 *	1.68 **	1.53 *
	NN-Cycle	2.08 **	1.66 **	1.84 **	1.95 **	1.8 **
房产	RF-Cycle	3.15 ***	3.26 ***	2.54 ***	2.48 ***	2.28 **
	SVR-Cycle	1.99 **	2.04 **	1.3 *	1.04	1.03
	NN-Cycle	2.84 ***	2.94 ***	2.2 **	2.06 **	1.92 **
现金	RF-Cycle	5.01 ***	4.4 ***	5.23 ***	6.33 ***	5.84 ***
	SVR-Cycle	4.73 ***	4.12 ***	4.67 ***	6.06 ***	5.34 ***
	NN-Cycle	-2.58	-2.88	-4.14	-1.63	-3.71

注: 指标同表 4.

此外, 为进一步明确论文的预测机制, 并探讨不同宏观变量对各类资产收益的预测能力差异, 本研究针对每个大类资产与预测模型, 对各个预测变量进行重要性分析^⑧.

4.4 Black-Litterman 资产配置策略

本节将预测的大类资产收益率作为投资者观点, 运用 Black-Litterman 模型构建投资组合, 核心在于检验结合周期性经济金融信息与机器学习构建的投资组合是否显著优于市场组合及其他未考虑周期性信息的 BL 投资组合.

BL 模型最为重要的调节参数为风险厌恶系数 δ 和先验分布的不确定性 τ . 风险厌恶系数一般为市场组合的历史均衡收益率与市场组合的历史方差的比率. 本研究选用的市场组合权重为中美两国各大类资产市值比重. 此外, 先验分布的不确定性 τ 越高, BL 后验分布更多地由投资者观点分布所决定. 对于中国市场, 本研究将 2015 年 1 月—2018 年 12 月的大类资产收益率预测值作为调节参数 τ 的验证集^⑨, 选取验证集中收益—

⑧ 篇幅所限, 详细结果可联系作者备案获取.

⑨ 中国大类资产收益率数据的样本区间自 2010 年至 2022 年, 使用前 40% 的样本 (约为前 5 年) 用于初始模型训练, 所以大类资产收益率的预测值从 2015 年 1 月至 2022 年 12 月. 其次, 又将大类资产预测收益率样本的 40% (即 2015 年 1 月—2018 年 12 月的样本) 作为调节 BL 模型参数 τ 的验证集.

风险表现最均衡的 BL 组合的参数 τ ,最后基于 2019 年 1 月—2022 年 12 月大类资产的预测收益率构建 BL 投资组合.在美国市场中,为了保持中美两国投资组合回测区间的一致性,本研究将 1995 年 1 月—2018 年 12 月的大类资产收益预测值作为调节参数 τ 的验证集^⑩,以 2019 年 1 月—2022 年 12 月的大类资产收益率预测值作为回测样本.根据选择的参数 τ 构建 BL 投资组合,并回测其风险和收益表现.投资组合的构建方法具体为:在 t 月的时间节点,以 $t+1$ 月的大类资产收益率的预测值引入 BL 模型构建组合,并持有至 $t+1$ 月,投资组合将继续根据下一月的资产收益率的预测值进行每月调仓.

表 7 展示了美国市场 BL 投资组合的实证结果.研究发现,所有非线性机器学习模型(NN、

RF、SVR) 构建的 BL 组合在收益率、CAPM-Alpha 和风险调整后收益(夏普比率、卡玛比率和索提诺比率) 方面均显著优于线性模型(ENET、ARMA)、马科维茨组合及市场基准组合,凸显了机器学习在资产配置中的优势.更重要的是,融入周期性经济金融信息后,基于 NN-Cycle、RF-Cycle 和 SVR-Cycle 的 BL 组合进一步提升了对应非分频的机器学习组合的表现:其平均收益率和 CAPM-Alpha 全面优于未分频的对应机器学习模型,同时风险收益比也获得显著改善.具体而言,组合主要配置于股票和房产,辅以债券投资,这一资产配置模式在考虑周期因素后展现出更强的稳健性.实证结果充分证实,周期性经济金融信息的引入能够有效提升结合机器学习和 BL 模型在美国市场的资产配置绩效.

表 7 投资组合权重及其投资回报(美国)

Table 7 Portfolio weights and performance (U. S.)

Panel A 组合权重										
大类资产	BL 组合权重								Markowitz	Market
	NN-Cycle	NN	RF-Cycle	RF	SVR-Cycle	SVR	ENET	ARMA		
股票	0.291	0.345	0.047	0.049	0.145	0.250	0.232	0.051	0.051	0.235
债券	0.063	0.083	0.470	0.494	0.226	0.197	0.150	0.670	0.735	0.260
商品	0.043	0.046	0.055	0.051	0.052	0.053	0.051	0.047	0.109	0.233
房产	0.555	0.476	0.384	0.354	0.529	0.450	0.524	0.179	0.053	0.242
现金	0.048	0.050	0.044	0.053	0.048	0.050	0.044	0.052	0.052	0.031
Panel B 投资组合表现										
收益率 / %	0.823 ** (2.231)	0.726 (1.545)	0.715 *** (2.897)	0.700 *** (2.546)	0.721 *** (3.536)	0.597 (1.407)	0.482 (1.227)	0.384 (1.338)	0.257 (0.798)	0.567 (1.207)
Alpha / %	0.461 (1.587)	0.235 (0.855)	0.433 *** (2.516)	0.390 ** (2.104)	0.501 *** (3.522)	0.155 (0.559)	0.074 (0.283)	0.079 (0.377)	-0.104 (-0.539)	
夏普比率	0.319	0.221	0.414	0.363	0.504	0.201	0.175	0.191	0.114	0.172
卡玛比率	0.977	0.422	1.178	0.890	3.486	0.336	0.369	0.376	0.210	0.359
索提诺比率	0.469	0.297	0.652	0.534	1.490	0.263	0.219	0.252	0.144	0.232

注:表 7 的 Panel A 和 Panel B 分别展示了各组合的资产配置权重及其风险收益特征.其中,“收益率(%)”和“Alpha(%)”分别表示组合的平均收益率及基于 CAPM 模型的超额收益(括号内为 T 统计量).风险调整后收益:夏普比率(收益率/标准差)、卡玛比率(收益率/最大回撤)和索提诺比率(收益率/下行标准差).“*”,“**”,“***”分别表示在 10%,5% 和 1% 的显著性水平下显著.

表 8 呈现了中国市场 BL 投资组合的实证结果.研究发现,非线性机器学习模型(NN、RF、SVR) 在收益率、Alpha 和风险调整后收益(夏普比率、卡玛比率和索提诺比率) 方面均优于线性

ARMA 模型,其中类线性 ENET 模型也展现出良好的表现.值得注意的是,虽然 SVR 模型的平均收益率略低于市场组合,但其各项风险收益比指标均显著占优.在引入周期性经济金融信息后,

^⑩ 美国大类资产收益率数据的样本区间自 1976 年至 2022 年底,其中前 40% 的样本(约为前 19 年) 用于初始模型训练,故大类资产收益率的预测值从 1995 年 1 月—2022 年 12 月.

NN-Cycle、RF-Cycle 和 SVR-Cycle 组合虽然未在绝对收益上取得显著提升,但其稳定性明显增强,各项风险调整后收益指标均获得改善.与美国市场相比,中国 BL 组合呈现出明显的风险规避特征:两国均重视房地产配置(与 Jordà 等^[38]的研究结论一致),但中国组合更偏好债券资产,而美国组合则更侧重股票投资.中国市场的 BL 组合收益较低但风险也更低,收益风险性价比更高.

综上所述,基于经济金融周期信息和机器学习的 BL 组合显著优于仅依赖机器学习或线性模型的 BL 组合、马科维茨组合及市场组合,验证了经济金融周期信息在跨资产定价和配置中的重要作用.

最后,本研究进一步探讨了在经济金融周期的历史波动下, BL 组合配置权重的变化,有望为投资者提供更具实操性的资产配置参考^①.

表 8 投资组合权重及其投资回报(中国)

Table 8 Portfolio weights and performance (China)

Panel A 组合权重										
大类资产	BL 组合权重								Markowitz	Market
	NN-Cycle	NN	RF-Cycle	RF	SVR-Cycle	SVR	ENET	ARMA		
股票	0.06	0.051	0.055	0.06	0.064	0.067	0.088	0.163	0.049	0.113
债券	0.336	0.498	0.495	0.496	0.586	0.487	0.177	0.214	0.105	0.198
商品	0.05	0.069	0.053	0.063	0.054	0.056	0.099	0.098	0.275	0.181
房产	0.499	0.335	0.35	0.331	0.245	0.344	0.58	0.475	0.522	0.493
现金	0.055	0.047	0.048	0.051	0.052	0.046	0.056	0.05	0.049	0.015
Panel B 投资组合表现										
收益率/ %	0.373 *** (7.92)	0.408 *** (7.16)	0.354 *** (5.98)	0.366 *** (4.32)	0.358 *** (5.51)	0.264 *** (3.43)	0.416 *** (3.67)	0.244 (1.37)	0.393 (1.59)	0.360 *** (2.860)
Alpha/ %	0.100 *** (3.84)	0.120 *** (3.41)	0.087 *** (2.94)	0.089 (1.61)	0.091 ** (2.29)	-0.005 (-0.098)	0.113 (1.55)	-0.079 (-0.464)	-0.04 (-0.213)	
夏普比率	0.957	0.85	0.770	0.555	0.716	0.439	0.473	0.177	0.205	0.371
卡玛比率	5.387	3.87	5.455	3.972	3.116	1.709	2.588	0.274	0.513	1.288
索提诺比率	2.844	2.241	2.217	1.481	1.744	0.872	1.225	0.224	0.266	0.634

注: 指标同表 7.

5 结束语

本研究利用小波分析提取多个宏观变量中蕴含的周期性经济、金融信息,并利用主成分分析来构造经济金融周期指标.基于中美两个市场的实证结果显示,本研究构造的经济周期与美国 NBER 的衰退区间具有较高的一致性,而金融周期指标也能准确刻画历次美国金融状况的转向.在此基础上,本研究首次提出了经济和金融周期双轮驱动的投资时钟策略(WISE 时钟),归纳统计了不同大类资产在各个经济运行阶段的收益规律,为研究多种金融资产收益波动特征提供了全新的双周期视角.

其次,本研究将周期性经济金融信息与机器

学习预测模型进行有机结合,提出了将周期信息用于大类资产收益预测的新范式.预测结果表明,结合周期性经济金融信息和机器学习的预测方法显著优于传统线性回归以及非分频的机器学习模型,且该方法在中美两国市场的多个大类资产收益率的预测中表现了较强的稳定性和一致性.

最后,本研究将大类资产收益率的预测值作为投资者观点引入 Black-Litterman 模型,结合大类资产收益的预测分布与历史收益均衡分布,改进了仅基于历史均衡分布的马科维兹的资产配置模型,提高资产配置的收益和风险表现.在美国和中国市场的实证检验表明,基于结合周期性经济、金融信息和机器学习方法的预测模型所构建的 BL 投资组合优于市场组合和其他基准模型.

① 由于篇幅限制,详细内容可联系作者备案获取.

参考文献:

- [1]周炎,陈昆亭. 金融经济周期模型拟合中国经济的效果检验[J]. 管理世界, 2012, (6): 17-29.
Zhou Yan, Chen Kunting. A test on the effect of modeling China's economy by a financial business cycle model[J]. Journal of Management World, 2012, (6): 17-29. (in Chinese)
- [2]Claessens S, Kose M A, Terrones M E. How do business and financial cycles interact? [J]. Journal of International Economics, 2012, 87(1): 178-90.
- [3]Terrones M, Kose M A, Claessens S. Financial cycles: What? How? When? [J]. IMF Working Papers, 2011, 7(1): 303-344. <https://www.imf.org/external/pubs/ft/wp/2011/wp1176.pdf>.
- [4]Drehmann M, Borio C, Tsatsaronis K. Characterising the financial cycle: Don't lose sight of the medium term! [J]. BIS Working Papers, 2012, 68(3): 1-18.
- [5]范小云,袁梦怡,肖立晟. 理解中国的金融周期: 理论、测算与分析[J]. 国际金融研究, 2017, (1): 28-38.
Fan Xiaoyun, Yuan Mengyi, Xiao Lisheng. Understanding Chinese financial cycle: Theory, measurement and analysis[J]. Studies of International Finance, 2017, (1): 28-38. (in Chinese)
- [6]马勇,冯心悦,田拓. 金融周期与经济周期——基于中国的实证研究[J]. 国际金融研究, 2016, (10): 3-14.
Ma Yong, Feng Xinyue, Tian Tuo. Financial cycle and economic cycle: An empirical study based on China[J]. Studies of International Finance, 2016, (10): 3-14. (in Chinese)
- [7]Greetham T, Hartnett H. The investment clock special report: Making money from macro[J]. Merrill Lynch, 2004, (10): 1-28.
- [8]Miranda-Agrippino S, Rey H. US monetary policy and the global financial cycle[J]. Review of Economic Studies, 2020, 87(6): 2754-2776.
- [9]周泽将,雷玲,李鼎. 经济周期与企业金融化[J]. 管理科学学报, 2023, 26(7): 17-31.
Zhou Zejiang, Lei Ling, Li Ding. Business cycle and corporate financialization[J]. Journal of Management Sciences in China, 2023, 26(7): 17-31. (in Chinese)
- [10]Borio C. The financial cycle and macroeconomics: What have we learnt? [J]. Journal of Banking & Finance, 2014, 45: 182-198.
- [11]钱宗鑫,王芳,孙挺. 金融周期对房地产价格的影响——基于SV-TVP-VAR模型的实证研究[J]. 金融研究, 2021, (3): 58-76.
Qian Zongxin, Wang Fang, Sun Ting. The impact of financial cycle on real estate prices: An empirical study based on a SV-TVP-VAR model[J]. Journal of Financial Research, 2021, (3): 58-76. (in Chinese)
- [12]方意,邵稚权. 中国金融周期与横向关联: 时空双维度相结合视角[J]. 金融研究, 2022, (1): 38-56.
Fang Yi, Shao Zhiquan. China's financial cycle and horizontal correlation: A perspective combining time and space[J]. Journal of Financial Research, 2022, (1): 38-56. (in Chinese)
- [13]Christiano L J, Fitzgerald T J. The band pass filter[J]. International Economic Review, 2003, 44(2): 435-465.
- [14]Bandi F M, Tamoni A. Business-cycle consumption risk and asset prices [J]. Journal of Econometrics, 2023, 237(2): 105447.
- [15]朱太辉,黄海晶. 中国金融周期: 指标、方法和实证[J]. 金融研究, 2018, (12): 55-71.
Zhu Taihui, Huang Haijing. China's financial cycle: Indicators, methods and empirical research[J]. Journal of Financial Research, 2018, (12): 55-71. (in Chinese)
- [16]王博,李昊然. 中国金融周期测度及国际比较研究[J]. 经济学动态, 2018, (6): 61-76.
Wang Bo, Li Haoran. Measurement of China's financial cycle and international comparative study[J]. Economic Perspectives, 2018, (6): 61-76. (in Chinese)
- [17]单强,吕进中,王伟斌,等. 中国化泰勒规则的构建与规则利率的估算——基于考虑金融周期信息的潜在产出与自然利率的再估算[J]. 金融研究, 2020, (9): 20-39.
Shan Qiang, Lü Jinzhong, Wang Weibin, et al. Taylor rule construction and rule interest rate estimation in China[J].

- Journal of Financial Research, 2020, (9): 20–39. (in Chinese)
- [18] 孙少龙, 魏云捷, 汪寿阳. 基于分解-聚类-集成学习的汇率预测方法[J]. 系统工程理论与实践, 2022, 42(3): 664–677.
Sun Shaolong, Wei Yunjie, Wang Shouyang. Exchange rate forecasting with decomposition-clustering-ensemble learning approach[J]. Systems Engineering-Theory & Practice, 2022, 42(3): 664–677. (in Chinese)
- [19] 林建浩, 赵文庆, 李仲达. 央行沟通与实际干预的频域政策效果研究[J]. 管理科学学报, 2017, 20(8): 27–38.
Lin Jianhao, Zhao Wenqing, Li Zhongda. Monetary policy effects of central bank communication and actual intervention in frequency domains[J]. Journal of Management Sciences in China, 2017, 20(8): 27–38. (in Chinese)
- [20] 杨天宇, 黄淑芬. 基于小波降噪方法和季度数据的中国产出缺口估计[J]. 经济研究, 2010, 45(1): 115–126.
Yang Tianyu, Huang Shufen. Estimating China's output gap using wavelet denoising method and quarterly data[J]. Economic Research Journal, 2010, 45(1): 115–126. (in Chinese)
- [21] Rua A. A wavelet-based multivariate multiscale approach for forecasting[J]. International Journal of Forecasting, 2017, 33(3): 581–590.
- [22] Faria G, Verona F. Forecasting stock market returns by summing the frequency-decomposed parts[J]. Journal of Empirical Finance, 2018, 45: 228–242.
- [23] 宋正阳, 周忠宝, 余乐安, 等. 基于混合集成预测算法和 Black-Litterman 模型的投资组合优化策略研究[J]. 中国管理科学, 2024, 30(5): 1–12.
Song Zhengyang, Zhou Zhongbao, Yu Lean, et al. Portfolio optimization strategy with a hybrid ensemble forecasting algorithm and Black-Litterman model[J]. Chinese Journal of Management Science, 2024, 30(5): 1–12. (in Chinese)
- [24] Black F, Litterman R. Asset allocation: Combining investor views with market equilibrium[J]. Goldman Sachs Fixed Income Research, 1991, 2(15–28): 218.
- [25] Kolm P, Ritter G. On the bayesian interpretation of black-litterman[J]. European Journal of Operational Research, 2017, 258(2): 564–572.
- [26] Gu S, Kelly B, Xiu D. Empirical asset pricing via machine learning[J]. The Review of Financial Studies, 2020, 33(5): 2223–2273.
- [27] Bianchi D, Büchner M, Tamoni A. Bond risk premiums with machine learning[J]. The Review of Financial Studies, 2021, 34(2): 1046–1089.
- [28] Bali T G, Beckmeyer H, Moerke M, et al. Option return predictability with machine learning and big data[J]. The Review of Financial Studies, 2023, 36(9): 3548–3602.
- [29] Leipold M, Wang Q, Zhou W. Machine learning in the Chinese stock market[J]. Journal of Financial Economics, 2022, 145(2): 64–82.
- [30] 李 斌, 龙 真. 中国股票市场可预测性研究: 基于机器学习的视角[J]. 管理科学学报, 2023, 26(10): 138–158.
Li Bin, Long Zhen. Retrun predictability of Chinese stock market: A machine learning perspective[J]. Journal of Management Sciences in China, 2023, 26(10): 138–158. (in Chinese)
- [31] 靳馥境, 姜富伟, 唐国豪. 优胜劣汰还是逆向选择——基于上市公司质量与股价表现关联的研究[J]. 管理科学学报, 2025, 28(2): 154–70.
Jin Fuming, Jiang Fuwei, Tang Guohao. Survival of the fittest or fattest? The relationship between quality of listed firms and performance of stock price[J]. Journal of Management Sciences in China, 2025, 28(2): 154–170. (in Chinese)
- [32] 李仲飞, 周 骐. 一个基于 BL 模型和复杂网络的行业配置模型[J]. 中国管理科学, 2024, 32(4): 1–13.
Li Zhongfei, Zhou Qi. An industry allocation model based on BL model and complex network[J]. Chinese Journal of Management Science, 2024, 32(4): 1–13. (in Chinese)
- [33] 邓 创, 谢敬轩. 中国的金融稳定及其与经济、金融周期波动的关联动态[J]. 国际金融研究, 2021, (7): 13–23.
Deng Chuang, Xie Jingxuan. The financial stability and its dynamic correlation with business cycle and financial cycle in China[J]. Studies of International Finance, 2021, (7): 13–23. (in Chinese)

- [34] Harding D, Pagan A. Dissecting the cycle: A methodological investigation [J]. *Journal of Monetary Economics*, 2002, 49 (2): 365–381.
- [35] Tashman L J. Out-of-sample tests of forecasting accuracy: An analysis and review [J]. *International Journal of Forecasting*, 2000, 16(4): 437–450.
- [36] Clark T E, West K D. Approximately normal tests for equal predictive accuracy in nested models [J]. *Journal of Econometrics*, 2007, 138(1): 291–311.
- [37] Diebold F X, Mariano R S. Comparing predictive accuracy [J]. *Journal of Business & Economic Statistics*, 2002, 20(1): 134–144.
- [38] Jordà Ò, Knoll K, Kuvshinov D, et al. The rate of return on everything, 1870–2015 [J]. *The Quarterly Journal of Economics*, 2019, 134(3): 1225–1298.

How to use the economic and financial cycles to improve asset allocation?

ZHOU Ying-gang^{1,2}, PAN Jun^{3,4}, BEI Ze-yun^{5}, LIU Hang⁶*

1. School of Economics, Xiamen University, Xiamen 361005, China;
2. The Wang Yanan Institute for Studies in Economics, Xiamen University, Xiamen 361005, China;
3. The Paula and Gregory Chow Institute for Studies in Economics, Xiamen University, Xiamen 361005, China;
4. Department of Economics and Finance, City University of Hong Kong, Hong Kong 999077, China;
5. PBC School of Finance, Tsinghua University, Beijing 100080, China;
6. China Merchants Bank Co., Ltd. Chongqing Branch, Chongqing 401121, China

Abstract: This study incorporates economic and financial cycles into asset allocation to enhance portfolio efficiency. Utilizing wavelet decomposition and principal component analysis, the paper constructs variables that broadly represent economic and financial cycles. Then, this study proposes the WISE Clock, a new data-driven investment strategy that extend the traditional Merrill Lynch Investment Clock by incorporating financial cycle. Employing machine learning techniques and cyclical information, this study forecasts asset returns for the U. S. and Chinese markets and integrates these predictions into a Black-Litterman framework. Backtesting results confirm that the approach significantly surpasses traditional models, enhancing portfolio risk-return performance.

Key words: economic cycle; financial cycle; wavelet decomposition; machine learning; asset allocation