

## 目录

引言.....	1
一、宏观基本面模块.....	2
1. 数据准备和处理.....	2
2. 模型原理.....	4
3. 策略构建及回测.....	5
4. 模型可解释性探究.....	7
二、动量模块.....	8
三、基于宏观基本面&动量的大类资产轮动策略构造.....	10
附录-分年参数平原.....	12
参考文献.....	20
风险分析.....	21

## 图目录

图 1:宏观变量处理流程.....	3
图 2:PMI 原值 vsPMI 季调.....	4
图 3:PMI 季调 vsPMI 季调后滤波.....	4
图 4:宏观样例策略净值.....	6
图 5:动量样例策略净值.....	9
图 6:宏观基本面&动量复合策略回测净值.....	10
图 7:宏观基本面参数平原-2017 年.....	12
图 8:宏观基本面参数平原-2018 年.....	12
图 9:宏观基本面参数平原-2019 年.....	13
图 10:宏观基本面参数平原-2020 年.....	13
图 11:宏观基本面参数平原-2021 年.....	14
图 12:宏观基本面参数平原-2022 年.....	14
图 13:宏观基本面参数平原-2023 年.....	15
图 14:宏观基本面参数平原-2024 年.....	15
图 15:动量参数平原-2017 年.....	16
图 16:动量参数平原-2018 年.....	16
图 17:动量参数平原-2019 年.....	17
图 18:动量参数平原-2020 年.....	17
图 19:动量参数平原-2021 年.....	18
图 20:动量参数平原-2022 年.....	18
图 21:动量参数平原-2023 年.....	19
图 22:动量参数平原-2024 年.....	19

## 表目录

表 1:初始宏观变量列表.....	3
表 2:宏观样例策略回测结果.....	6
表 3:宏观样例策略分年收益.....	6
表 4:宏观样例策略 2024 年决策依据 .....	7
表 5:动量样例策略回测结果.....	9
表 6:动量样例策略分年收益.....	9
表 7:宏观基本面&动量复合策略回测结果 .....	10
表 8:复合策略分年收益.....	11
表 9:2024 年以来复合策略持仓 .....	11

## 引言

大类资产轮动策略是一种自上而下的资产配置策略，通过在不同的市场周期中轮换投资于表现较强的资产类别，投资者可以实现更高的风险调整收益。目前市场上构造大类资产轮动策略的主流方法论是周期划分，通过对经济环境主观划分周期来决定配置策略，但是这种方法不可回测且完全依赖于每个人对经济的主观认知预测，不确定性较强，本文着重解决这一痛点，将宏观基本面维度的信息量化并加入资产价格动量效应构造完全量化可回溯的大类资产轮动策略。

通过经济周期划分来构造大类资产轮动策略的思路是事前将经济状态划分为几个状态，每次决策时对当下经济状态作一个状态判定，并依据同样状态的历史表现来做资产配置决策。最经典的经济周期划分是美林时钟，它将经济周期划分为复苏、过热、滞涨、衰退四种状态，复苏配置股票，过热配置大宗商品、滞涨和衰退配置债券，普林格周期在美林时钟的基础上增加了两个政府逆周期调节周期，分别是经济失速时政府逆周期调节周期、经济过热政府采取紧缩的政策限制过热。从以上流程可以看出，周期划分本质上是对纷繁复杂的宏观经济进行降维并赋予每个维度经济学含义，资产配置决策则是根据当下经济状态主观寻找历史上较为相似的情形并赋予当下与历史一致的状态，并配置相应状态的历史统计最优资产。因此通过经济周期划分进行资产配置决策的成功取决于以下几个方面：1.历史状态划分的合理性；2. 对目标资产配置周期的宏观状态预测；3.目标资产配置周期的宏观状态与历史的相似性判定，通常三方面均由主观判定，这为决策带来很大不确定性。

本文将经济周期划分指导资产配置决策的过程进行量化建模处理，进而构造可回溯可回测的大类资产轮动策略。首先我们取消主观划分经济状态，即将宏观经济降维这一过程从主观修正为量化，其次取消对目标资产配置周期的宏观状态预测，仅仅基于可得的宏观数据进行决策，最后将宏观状态与历史的相似性判定问题抽象为信息检索问题，类比搜索引擎，输入关键字（宏观状态）输出最“相关”的查询结果（大类资产配置优先顺序）。我们创新性地引入信息检索领域常用的排序学习（LTR）算法来对宏观与大类资产的映射关系进行建模。

排序学习主要应用于信息检索领域，即给定一个查询，返回每个文档的得分排序，得分代表每个文档的相对重要程度，训练的过程即给定一系列的（查询，完美排序的文档列表）样本，拟合模型使得模型在给定样本集上可以精确预测文档列表排名。主流的排序学习算法主要有三种类别（Cao, 2007）：元素级模型（pointwise）、配对模型（pairwise）、列表模型（listwise），元素级模型的目标是预测每个文档的得分，是一个回归问题，配对模型则是将文档进行两两配对，预测两两间的相对强弱，是若干二分类问题，列表模型则是将整个文档列表作为整体来考量，通过定义预测列表和目标列表之间的损失函数来完成训练。元素级模型没有考虑到文档之间的相关性，有大量文献证明这种建模方式在信息检索领域表现不佳（H. Li, 2011），配对模型一方面容易有样本失衡问题，许多配对的二分类模型很可能正样本远多于负样本，这样训练出的模型将会丧失辨别能力，另一方面模型复杂度较高，将会有 $O(n^2)$ 个模型，参数较多，容易过拟合，列表模型可以很好的解决以上问题，列表模型与以上两种方法最主要的区别在于损失函数的定义，比较经典的损失函数有 ListNet（Cao, 2007），ListMLE（Xia, 2008），RankCosine（Qin, 2010），其中 ListMLE 是公认的有较好理论性质以及实证表现的损失函数。

本文我们采用以 ListMLE 为损失函数的列表模型建模方式构造宏观与大类资产之间的桥梁。将信息检索类比至资产配置上，整个模型使用流程为输入关键字（宏观变量向量），输出大类资产的配置优先级，模型训练过程为将历史上每个月的宏观变量向量（关键字）做一个线性变换，转化为大类资产的得分，通过优化其与真实得分（当月大类资产收益率向量）的距离（损失函数为 ListMLE）得到线性变换，以此作为宏观-大类资产“信息检索系统”，对目标配置月输入可得的宏观状态向量即可产生轮动配置信号。为了防止过拟合，我们还在

ListMLE 损失函数的基础上添加了惩罚项。

最后考虑到宏观基本面潜在的失效问题，我们引入了大类资产价格动量效应与其互补，构造复合轮动策略。

本文约定大类资产使用标的为股（881001.WI）、债（CBA00601.CS）、商（NH0100.NHF）。

整个报告主要分为三个部分，首先介绍宏观基本面模块，然后介绍动量模块，最后介绍复合轮动策略。

## 一、宏观基本面模块

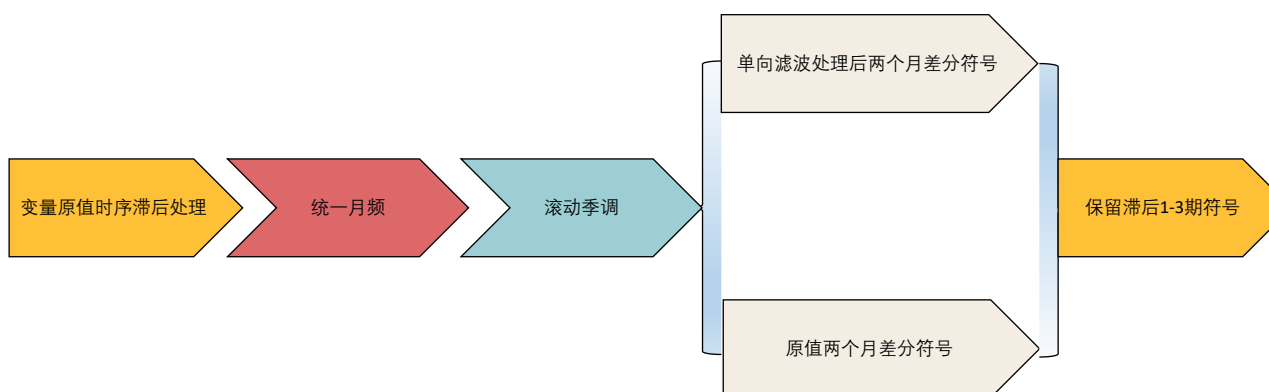
本节主要介绍大类资产轮动策略的宏观模块，本节主要是三个部分，第一部分是数据准备和处理，第二部分是模型原理，第三部分是策略构建及回测，最后一部分则是模型可解释性探究。

### 1. 数据准备和处理

本节数据处理主要是针对宏观变量进行处理，将宏观变量处理成为完全可得的 1，-1 以此来表示每个指标的上行下行趋势，本节考虑使用增长、通胀、货币、汇率、利差、全球利率几个维度共计 17 个宏观变量作为基础变量。

第一步针对所有宏观变量做滞后处理，保证所有宏观数据均为可得数据，比如 PPI 同比这一指标，当月披露上月 PPI，因此实际可得的每月 PPI 同比为上月数据，第二步将所有数据统一为月频，日频数据将月内均值作为当月值，第三步则是对环比型数据做滚动季调（保证季调过程不引入未来数据），本文所用的数据仅 PMI 为环比型指标，需要做季调，我们采用 X-13 ARIMA SEATS 对其进行季调，第四步针对所有可得宏观数据做滚动单向小参数 HP 滤波（单向保证滤波不引入未来数据）获得去噪版本，这一步是为了提取宏观变量的中长期趋势，第五步将每个宏观变量的原始版本和去噪版本均进行两个月差分仅保留符号作为其上行下行趋势的代理变量，最后一步则是对所有上行下行趋势做滞后处理，对于及时公布的变量同时计算其滞后 0-3 期趋势变量（滞后 0 期表示当期变量），对于不及时公布的变量则计算其滞后 1-3 期变量。经过以上处理，最终可以得到  $5（及时披露）\times 2（原始趋势+滤波趋势）\times 4（滞后 0-3 期）+12（滞后披露变量）\times 2（原始趋势+滤波趋势）\times 3（滞后 1-3 期）=112$  个宏观变量。

以 PMI 为例，滚动季节调整后的 PMI 时间序列相比原序列趋势更加稳定，异常值得到了修复（比如 2020 年 2 月的疫情异常冲击），扩展窗口单向 HP 滤波调整后的序列则是忽略了更多的短期波动，是中长期趋势很好的代理变量。


**图 1:宏观变量处理流程**


数据来源：中信建投证券

**表 1:初始宏观变量列表**

维度	指标名称	公布时滞	变频处理	季调
增长	工业增加值同比	1		
	制造业 PMI	0		需要
	OECD 中国领先指数	1		
	商品房销售面积同比	1		
	社会消费品零售总额同比	1		
	房地产开发投资完成额同比	1		
通胀	PPI 同比	1		
	CPI 同比	1		
	CPI 非食品同比	1		
利差	信用利差	0	日频变为月频	
	期限利差	0	日频变为月频	
货币信贷	社融规模存量同比	1		
	M1 同比	1		
	M2 同比	1		
	金融机构:各项贷款余额同比	1		
汇率	美元指数	0	日频变为月频	
美债利率	10 年期美国国债收益率	0	日频变为月频	

资料来源：中信建投证券

**图 2:PMI 原值 vsPMI 季调**


数据来源: Wind, 中信建投证券

**图 3:PMI 季调 vsPMI 季调后滤波**


数据来源: Wind, 中信建投证券

## 2. 模型原理

本文采用排序学习中 Listwise 流派中的经典模型 ListMLE，在机器学习的语境下其仅仅是一个特殊的具有良好性质的损失函数，本节我们在宏观-大类资产框架下从模型构建开始对整个建模原理进行说明。

假设第 $t$ 个月可得的宏观变量向量为 $X_t = (x_{1,t}, x_{2,t}, \dots, x_{j,t})^T$ ，大类资产收益率向量为 $Y_t = (y_{1,t}, y_{2,t}, \dots, y_{K,t})^T$ 。我们为每种资产定义一个宏观线性打分 $a_i^T X_t (i = 1, 2, \dots, K)$ ，大类资产的打分向量为 $S_t = (s_1, s_2, \dots, s_K)^T = A^T X_t = (a_1, a_2, \dots, a_K)^T X_t$ ，那么理论上 $K$ 种大类资产每月打分的排列有 $K!$ 种可能，比如排列 $\pi = (s_{\pi_1}, s_{\pi_2}, \dots, s_{\pi_K})$ ， $\pi' = (s_{\pi_2}, s_{\pi_1}, \dots, s_{\pi_K})$ ， $\pi'' = (s_K, s_{K-1}, \dots, s_2, s_1)$ ，在这 $K!$ 种排列上定义如下概率分布

$$P(\pi) = \prod_{j=1}^K \frac{\exp(s_{\pi(j)})}{\sum_{v=j}^K \exp(s_{\pi(v)})}$$

其中 $s_{\pi(j)}$ 表示在排列 $\pi$ 中第 $j$ 个位置上的资产得分。可以证明（Cao, 2007）以上所定义的概率分布有如下三个性质：

a.  $\sum_{\pi} P(\pi) = 1$ 即所有的排列概率之和为 1。

b. 在一个排列 $\pi$ 中，将得分位于前面的大类资产和得分位于后面的大类资产交换位置，所得到的新排列 $\pi^*$ 的概率值要小于 $\pi$ 的概率值。

c. 假如得分排序为 $s_1 > s_2 > \dots > s_K$ ，那么排列 $\pi$ 的概率 $P(\pi)$ 在所有排列中是最大的，排列 $\pi''$ 的概率 $P(\pi'')$ 在所有排列中是最小的。

以上三条性质说明这种概率分布定义的合理性，即按照得分降序排列的概率最大，升序排列的概率最小，并且排列和排列之间的概率还具备单调性：任意交换两个资产，交换前后更接近正确排序结果（降序）的排列概率更大。

以上定义的概率分布是经典的 Plackett-Luce 模型，这一模型的统计含义为在所有候选标的中选择得分

$(\exp(s_i))$ 最高的标的作为第一名，在剩下的标的中选择得分最高的作为第二名，以此类推得到的排列发生的概率，以上概率模型与投资中做决策的过程非常契合。

ListMLE 基于以上概率定义借用了极大似然的思想，在排列的概率空间上计算历史所有样本的联合似然函数，将其作为目标函数进行优化进而得到打分函数的样本估计 $\hat{A}$ 。单一样本 $(X_t, Y_t)$ 的似然定义为

$$P(Y_t|X_t) = \prod_{j=1}^K \frac{\exp(s_{y(j),t})}{\sum_{v=j}^K \exp(s_{y(v),t})}$$

其中 $s_{y(j),t}$ 表示收益率向量 $Y_t$ 中排名第 $j$ 位的资产的得分，以上概率的含义为按照事实上大类资产当月收益率降序排列得到的排列概率。由此可以得到样本 $(X_1, Y_1), (X_2, Y_2) \dots (X_T, Y_T)$ 的联合似然函数

$$L(A) = \prod_{t=1}^T P(Y_t|X_t)$$

可以证明 $L(A)$ 有一系列优秀性质，既有大样本收敛的一致性（Xia, 2008），又有小样本的经济学含义：历史上每月的真实大类资产排列联合出现的概率最大，同时对数似然函数 $-\log(L(A))$ 是一个严格凸函数（需要一些等价变形，本文不再赘述），模型拟合可以得到全局最优解。

最后我们在以上损失函数的基础上添加 L1 范数作为本文模型训练的损失函数。这主要是因为在大类资产配置框架下数据样本量较少，而我们的宏观自变量较多，可能会有奇异解，另一方面可以获得相对稀疏的解，进一步增强模型可解释性。

$$\text{ListMLE}_{\text{Loss}} = -\log(L(A)) + \lambda \|A\|_1$$

### 3. 策略构建及回测

考虑到宏观模型的“信息检索”系统属性，本文我们使用扩展的时间窗口进行模型训练，每隔一段时间使用所有可得样本进行训练，回测具体细则如下。

- 策略回测时间：2016 年 12 月 31 日-2024 年 6 月 30 日。
- 策略调仓频率：月频。
- 模型训练规则：每六个月使用全部可得历史数据进行模型训练，数据对应规则为 112 个宏观变脸 T-1 月趋势值做自变量，3 个大类资产 T 月收益率排名做因变量。
- 策略持仓生成：将 112 个宏观变量 T-1 月趋势值输入最新模型得到 3 个大类资产的下月打分，选择打分最高的资产进行持仓。
- 超参数选择：滚动训练过程中保持超参数 $\lambda$ 保持不变。


我们以参数 $\lambda = 13$ 为例，展示回测结果如下。从回测结果可以看出轮动效果非常优秀，相比单一大类资产有最高的年化收益 14.52%、收益回撤比 1.23、月度胜率 72.5%，夏普也仅低于低波动资产债券，远高于权益和商品，同时最大回撤仅为 11.8%，远优于权益和商品。分年来看，除了 2022 年以外均能获得正收益。



**表 2:宏观样例策略回测结果**

	股	债	商	宏观样例策略
年化收益率	-0.35%	4.27%	9.90%	14.52%
年化波动	17.3%	2.4%	15.0%	10.81%
夏普	-0.02	1.78	0.66	1.34
最大回撤	-32.6%	-3.7%	-16.5%	-11.8%
卡玛比	-0.01	1.16	0.60	1.23
胜率	47.8%	72.2%	61.1%	72.5%

资料来源: Wind, 中信建投证券

**图 4:宏观样例策略净值**


数据来源: Wind, 中信建投证券

**表 3:宏观样例策略分年收益**

2017/12/31	13.02%
2018/12/31	11.00%
2019/12/31	21.01%
2020/12/31	32.06%
2021/12/31	13.00%
2022/12/31	-1.40%
2023/12/31	2.22%
2024/12/31	22.43%

资料来源: Wind, 中信建投证券



为了避免样本内参数寻优的问题，我们在附录中展示了策略的分年参数平原，即 $\lambda$ 取不同的值生成的策略在每一年的收益率，其中 2024 年为截止到 2024 年 6 月 30 日的参数平原。从参数平原可以看出宏观变量指导大类资产轮动的优秀能力，策略对参数 $\lambda$ 敏感度较低， $\lambda$ 可以在一个很宽广的区间内取值，策略当年的表现都差距不大，优秀的年份大多数参数表现都非常优秀，失效的年份大多数参数都表现不佳。其中 2017，2018，2020，2024 年大部分参数对应策略的表现优于任何一种单一资产，轮动效果极其出色，2019，2021 年仅跑输当年最优资产（2019 年股，2021 年商品），2022 和 2023 年策略表现不佳，主要是因为这两年有较多异常的宏观波动和市场之外的因素扰动。

## 4. 模型可解释性探究

本文所提出的宏观基本面模块的另一个优势在于，模型可解释性较强，一方面本文所用模型均为线性模型，模型复杂度较低，资产与宏观之间的映射关系一目了然，另一方面，本文模型有“信息检索”系统的特点，即可以知晓决策依据具体是什么，比如某个月模型根据当月可得宏观状态配置商品，我们可以通过回溯模型拟合样本自动输出，当月资产的排序分布（6 种可能的排序结果的离散概率分布）与历史上哪些时段较为接近，进而可以得出配置商品的具体历史经验依据。

本节使用 KL 散度刻画分布间距离，

$$D(P||Q) = \sum_{i=1}^{n!} p_i * \log\left(\frac{p_i}{q_i}\right)$$

接下来以样例策略 2024 年上半年决策过程为例，来说明如何根据 2023 年 12 月 31 日训练所得模型寻找每月决策历史依据。对于每个目标月份（2024 年上半年每一月）使用模型计算每一种排列（共 6 种排列）对应概率

$$P(\pi) = \frac{\prod_{j=1}^K \exp(s_{\pi(j)})}{\sum_{v=1}^K \exp(s_{\pi(v)})}$$

再使用同一模型计算训练样本的每个时间点排列的概率分布，通过比较目标月份与历史上每月概率分布的 KL 散度即可得到目标月决策的依据。下表为 2024 年每月决策时历史上与决策目标月最相似的月份，其中配置标的列既是目标决策月配置标的又是历史上最相似月份根据样本内得分配置标的。

**表 4:宏观样例策略 2024 年决策依据**

决策目标月	配置标的	历史上与决策目标月最相似的月份	资产历史当月表现		
			股	债	商
2024/1/31	债	2016/8/31	4.7%	0.6%	-0.5%
2024/2/29	股	2017/6/30	4.8%	0.6%	5.8%
2024/3/31	商	2021/5/31	5.1%	0.7%	0.9%
2024/4/30	商	2016/11/30	3.9%	-1.2%	8.9%
2024/5/31	商	2018/5/31	-0.1%	0.3%	2.2%
2024/6/30	债	2015/6/30	-10.5%	0.4%	-5.2%

资料来源: Wind, 中信建投证券

从上表中可以看出模型即便在样本内也并没有每月均配置最优标的，这主要是因为我们拟合的目标函数综合考虑了全部历史并设置了惩罚项，有些月份不配置最优标的对“检索系统”整体更有利。

## 二、动量模块

本节我们针对动量指导大类资产轮动进行初步探索。考虑到宏观基本面有时会失效的问题，本节主要研究动量这一直觉上与基本面互补的大类因子。

首先考虑简单的 Bias 因子，因子定义为

$$MA_t(n) = \frac{1}{n} \sum_{i=t-n+1}^t P_i,$$

$$BIAS_t(n) = \frac{P_t}{MA_t} - 1$$

即每个资产当前偏离其过去  $n$  天价格均线的幅度。在此基础上我们叠加价格波动信息，一种经典波动因子 BBW 定义为

$$BBW_t = \frac{4\sigma_{t, 250}}{MA_{t, 250}}$$

表示每个资产过去一年的价格波动率与价格均线的比值，可以很好的刻画资产波动，我们将二者叠加在一起得到 BBW\_BIAS 因子，

$$BBW\_BIAS_t(n) = BIAS_t(n) * BBW_t$$

这种因子构造方式可以放大高波动资产的因子值，使得趋势开始阶段可以更早地入场或离场。

动量因子频率较高，可以日频计算因子，但为了与宏观模块可比，我们统一使用月底因子进行回测，具体回测规则如下。

- 策略回测时间：2016 年 12 月 31 日-2024 年 6 月 30 日。
- 策略调仓频率：月频。
- 持仓规则：每次选取因子值最大的资产作为下月持仓。

参数  $n=30$  的因子回测结果如下。

**表 5:动量样例策略回测结果**

	股	债	商	动量样例轮动策略
年化收益率	-0.35%	4.27%	9.90%	7.9%
年化波动	17.3%	2.4%	15.0%	11.9%
夏普	-0.02	1.78	0.66	0.66
最大回撤	-32.6%	-3.7%	-16.5%	-17.8%
卡玛比	-0.01	1.16	0.60	0.44
胜率	47.8%	72.2%	61.1%	61.5%

资料来源: Wind, 中信建投证券

**图 5:动量样例策略净值**


数据来源: Wind, 中信建投证券

**表 6:动量样例策略分年收益**

2017/12/31	-1.8%
2018/12/31	-6.7%
2019/12/31	12.6%
2020/12/31	22.8%
2021/12/31	-2.6%
2022/12/31	27.2%
2023/12/31	9.4%
2024/12/31	3.4%

资料来源: Wind, 中信建投证券

以上内容仅为本文档的试下载部分，为可阅读页数的一半内容。如要下载或阅读全文，请访问：<https://d.book118.com/838142056005006125>