

中低频 量化交易策略研发

(上)

杨博理 著

中低频量化交易策略研发（上）

作者：杨博理

E-mail: yangboli_qt@126.com

版权号：17-2015-A-20152385

版权所有，转载需注明出处

纸张大小：16开 184mm × 260mm

序 言

相对于全球的发达金融市场而言，在中国市场上，量化交易即便不能算作一个新兴的事物，也仍然是相对小众的。直至目前为止，国内量化交易的资金管理额度、业界影响能力都远逊于美国的同类产品。而由于量化交易策略在中国市场上的运行时间较短，因此也尚未出现一个真正意义上处于业界领先地位的量化基金。同时，中国的金融市场自身也处在高速发展和完善的曲折道路之上，就在前段时间，市场的剧烈变动使得大量的量化交易策略表现出不适应甚至直接停摆。但是也正因为如此，量化交易在中国的未来发展是值得期待的，参照发达市场的情况来看，留给后来者的竞技空间应该足够宽广。在这种背景下，希望进入金融市场的朋友有理由对量化交易给予足够的关注。实际上，本书的写作目的也正在于此，我愿尽绵薄之力，为有志于学习的读者提供一个可以参考的量化交易策略研发框架，希望大家在初入门径时少走弯路。如果这本书真的是有帮助的，我自己也能体会到随之而来的成就感。

但是需要说明的是，由于量化交易策略是一个复制较为容易、不宜公开的交易策略种类，因此作者对于策略核心等内容，也只能如其他的量化交易从业者一样，保持讳莫如深的态度。如果寄希望于通过本书直接找到一个可以盈利的量化交易策略，可能会在阅读完毕之后感到失望，因为全书的目的仅仅是为量化交易策略的研发提供一个可供参考的流程框架。而具体的策略与真实数据上的案例，虽然占据了书中的大量篇幅，但是其目的在于帮助读者更好的理解这个流程框架，因此策略本身也都是由最为简单的模型所构成的。希望读者不要陷入对具体策略交易结果的关注，而把注意力置于更宽泛的范围上，更多的去研究如何通过基础的想法来构造量化交易策略、如何对这些量化交易策略进行研判等问题上来。

由于写作这样一本书的想法只是一时的心血来潮，而在随后的写作过程中又忽略了一些琐事的麻烦程度，因此直到目前为止全书的进度也只完成了一半。好在这一半的内容似乎也能独立成篇，这里先将后面的目录一起展示出来，在之后有空闲的时候再尝试将具体内容补完。当然，实际上所有的数据实验已经全部完成，这也是我能够

将目录提早公布的原因。在这里特别感谢我的妻子贾芳，是她的理解和支持，才使得本书的上半部分得以顺利的完成。

我写作这本书，只是单纯的想要分享我关于量化交易策略的一些经验和知识，以此盈利的想法可以说是一点也没有。因此我制作了免费的电子版本，放在网络上以供下载，后半部分在完成后也会及时的更新电子文档。欢迎对书中内容有意见或疑问的读者、或者是对量化交易感兴趣的朋友与我交流，我的 E-mail 是：

yangboli_qt@126.com

杨博理

目 录

(上)

第 1 章 引言

| | |
|----------------------|---|
| 1.1 量化交易策略简述 | 1 |
| 1.2 量化交易策略的优缺点 | 7 |

第 2 章 量化交易策略的研发流程

| | |
|----------------------------|----|
| 2.1 量化交易策略的基本研发流程 | 13 |
| 2.2 量化交易策略研发流程的进一步论述 | 16 |

第 3 章 注意事项与应对

| | |
|------------------------|----|
| 3.1 未来信息的规避 | 22 |
| 3.2 过度拟合与欠拟合 | 25 |
| 3.3 回溯测试与真实环境的差异 | 29 |

第 4 章 简单的择时策略

| | |
|-----------------------|----|
| 4.1 择时策略的基本框架 | 34 |
| 4.2 均线趋势策略的简单优化 | 37 |
| 4.3 均线反转策略的简单优化 | 41 |
| 4.4 自回归策略的简单优化 | 45 |

第 5 章 简单的选股策略

| | |
|------------------------|----|
| 5.1 因子选股的基本框架 | 50 |
| 5.2 市值因子 | 54 |
| 5.3 反转因子 | 62 |
| 5.4 多因子选股策略的简单优化 | 69 |

第 6 章 推进分析

| | |
|--------------------|----|
| 6.1 推进分析框架 | 77 |
| 6.2 多层推进分析 | 82 |
| 6.3 推进分析下的验证 | 86 |

第 7 章 推进的择时策略

| | |
|------------------------|-----|
| 7.1 均线趋势策略的推进分析 | 89 |
| 7.2 均线反转策略的推进分析 | 93 |
| 7.3 均线混合策略的推进分析 | 95 |
| 7.4 自回归策略的推进分析 | 98 |
| 7.5 自回归策略的多层推进分析 | 101 |

第 8 章 推进的选股策略

| | |
|--------------------------|-----|
| 8.1 多因子选股策略的推进分析 | 106 |
| 8.2 多因子选股策略的多层推进分析 | 113 |

(下)

第 9 章 风险

- 9.1 常用的风险度量
- 9.2 其他风险度量
- 9.3 风险和收益的结合
- 9.4 止损

第 10 章 仓位决策

- 10.1 凯利公式
- 10.2 实用的仓位决策方法

第 11 章 仓位优化的择时策略

- 11.1 仓位优化的均线趋势策略
- 11.2 仓位优化的自回归策略

第 12 章 投资组合决策

- 12.1 最优投资组合理论
- 12.2 实用的投资组合优化方法

第 13 章 投资组合优化的选股策略

- 13.1 多因子风险模型
- 13.2 多因子选股策略下的最优投资组合

第 14 章 交易成本

14.1 交易成本估计

14.2 考虑交易成本的择时策略

14.3 考虑交易成本的选股策略

第 15 章 分解与组合

15.1 分解

15.2 组合

15.3 择时与选股的结合

第 16 章 策略评价

16.1 策略评价指标

16.2 策略评价报告

第 17 章 结束语

17.1 内容总结

17.2 策略深化的路径

17.3 主观控制的作用

第1章 引言

1.1 量化交易策略简述

本书的主要目的，在于为量化交易策略的研发提供一个可供参考的流程框架。但是直到目前为止，对于量化交易的界定，仍然存在着比较大的分歧。因此，为量化交易策略给出定义，虽然是全书开头一个不得不做的工作，却也是一件会导致争议的事情。为了尽量减小一个明确定义受到质疑的可能性，本书采用了相对而言较为稳妥的处理办法，即贴近字面意思进行解释。不过，出于一个研究人员的偏执，作者同时对策略的研发过程进行了着重强调，因此有了如下的定义：

量化交易策略，就是采用数量化手段构建而成并进行决策的交易策略。

具体解释起来，该定义包括两层含义。首先，在构建交易策略的过程中，数量化的手段应该占主要成分。这里的数量化手段，包括对整个交易流程和交易目标的数量刻画、对量化目标的最优化、对策略结果的数量化评价等方式方法。但是在这一部分中仍然允许有定性的、或者人为主观的成分存在，毕竟策略的研发是一个人为操作的过程。其次，交易策略在构造完毕、用来进行交易决策时，必须具有明确的数量化规则，完全不存在主观判断的成分。这一特性也保证了整个策略能够在完全量化的设置下进行回溯测试，是前一个特征的必要条件。同时满足这两个方面的限定，则能够被称之为量化交易策略。

在这样的界定下，量化交易策略既可以借助程序化的方式完成下单，也可以通过人工来执行。实际上出于成本和可控性等方面的考虑，一些交易频率较低的量化交易策略有可能更倾向于采用人工下单的方式来完成。在作者看来，策略的执行手段并不是量化交易策略的核心特征。

这种关注于数量化、而非程序化的定义，也使得整个量化交易策略的历史比许多人认知中的要更长一些。因为就实际情况而言，技术分析中的技术指标，在适当的情

况下是可以形成量化交易策略的。虽然技术分析中的图表分析手段，例如“双头”、“头肩”等图形形态的分类，相对而言太过主观而且很难量化^①，但是技术指标注重于价格和成交量的定量分析，通过公式化的计算可以得到一些用来参考的量化指标，用以指导交易，具有数量化的特征。只不过在这些量化指标的使用上，交易者往往又归于主观，进一步造成了对技术指标是否是量化交易策略的争论。

例如当某个交易员的交易策略是“移动平均线看起来很好时买入，看起来不好时卖出”，那么就完全有悖于上文给出的量化交易策略的定义。首先，该交易策略在表述上较为模糊，不是一个具有明确数量化规则的决策手段，因此交易员需要在交易过程中通过主观的判断来完成买卖行为。其次，正是由于缺乏明确的数量化决策规则，交易员在形成这样的交易规则时很难量化的描述整个交易策略和交易过程，也就难以使用最优化之类的数量方法。在多数情况下，交易员可能更倚重于复盘等人工形式来完成这一类交易策略的构建。

但是当交易员基于一些定量的规则来使用技术指标进行交易时，这些交易策略就可能会符合量化交易策略的特征。例如把上面的策略改换为“价格线从下向上穿过移动平均线时买入，从上向下穿过移动平均线时卖出”，那么策略就既可以通过量化手段完成构建，又具有明确的数量化交易规则了。其他典型代表还包括大部分的技术指标，如唐奇安所开发的通道规则，其以过去特定天数内的最高价和最低价为边界形成一个通道，当目前价格超出通道范围时，形成买卖决策。

丹尼斯的“海龟交易法则”是一个非常著名的例子，因为丹尼斯招收交易员并传授该法则而为外界所熟知。这一交易策略正是在唐奇安通道指标的基础上构建而成的，除了通道突破的买卖规则外，“海龟交易法则”还包括仓位大小的选择、随时间的调整、止损等多个组成部分，更接近于一个构架完整的交易策略。当然，就本书的定义而言，“海龟交易法则”是否算作标准的量化交易策略仍然有待商榷。首先，被披露的规则只是交易决策部分，具体的构建过程我们无从得知，因此也难以判断。更重要的是，其执行过程中存在人为主观的成分，这也直接导致了交易学员在使用同样规则

^① 有学者通过对价格序列进行平滑的方式，完全量化的给出了这些价格形态的判别方法。再基于对当前价格的形态判断，可以形成相应的量化交易策略。

的情况下获得了不同的交易结果。但是这并不妨碍大量的从业者将“海龟交易法则”作为一个量化交易策略的范本来进行研究和使用的，作者本人也非常认同其在量化研究中的指导地位。

业内较为认同的量化交易策略的开端，可能是马科维茨的最优投资组合理论这一学术性的创新^①。在1952的论文当中，马科维茨开创性的引入了均值和方差这两个统计学上的概念，用来定量的描述投资者在投资组合上获得的收益和承担的风险。基于投资组合中资产的收益情况和相互之间的协方差矩阵，采用最优化的方法，就可以得到投资组合的最优配比方式，从而帮助投资者在风险一定的情况下获取最大收益，或者在收益固定的情况下使得风险最小。整个过程通过明晰的数量模型进行了表述，优化结果也能定量的指导投资组合的构建行为，是比较契合本书关于量化交易策略的定义的。

在此之后，经济学家和金融学家开始越来越多的通过定量的数学模型来研究金融市场和投资交易。夏普等人于1964年前后在马科维茨的工作基础上，发展出了资本资产定价模型^②。该模型将股票在无风险收益之上的超额收益分解为两个部分，即市场部分和残余部分，股票的风险也相应的分为两个部分，对应起来分别是系统风险和非系统风险。模型证明了在资本市场完全有效等前提假设下，残余部分的期望值为零，也就是说，非系统性风险是没有风险补偿的，股票的超额预期收益仅与其承担的系统风险大小有关。

之后，罗斯从另外一些假设条件出发，得出了与资本资产定价模型在一定程度上具有相似性的套利定价理论。该理论同样认为股票的超额预期收益仅与其所承担的风险有关，只不过除了最主要的市场系统风险，理论模型还能够包含其他一些存在风险补偿的风险因子。在资产收益来源于对风险的承担等思想的推动下，法玛提出了著名的“有效市场假说”^③，即在一个有效的证券市场中，价格完全反映了所有可以获得

① 马科维茨因此而获得了1990年的诺贝尔经济学奖。

② 夏普因此而获得了1990年的诺贝尔经济学奖。

③ 法玛获得了2013年的诺贝尔经济学奖。“有效市场假说”是其研究工作中最为核心的成果，而三因子模型也是其获得诺贝尔经济学奖的一个重要原因。

的信息。再结合资本资产定价模型的主要结论，认为实际上消极型管理，即仅持有市场组合和无风险资产，才是明智的选择。随着这种思想在学术界的逐渐主流化，学术研究中主动型交易的关注开始减少。

然而有趣的是，罗斯的套利定价理论和法玛的另一项著名研究却间接的发展出了一些行之有效的量化交易策略。在 1992 年的一篇论文当中，法玛基于套利定价理论的形式，发现股票的两个当前特征，市值和账面市值比，可以有效的预测未来的股票收益。简单来说，就是市值越小的股票、或者账面市值比越大的股票，在统计意义上会产生更高的未来收益。在次年的论文中，法玛将这两个特征构造为两个风险因子，再结合市场因子，从风险补偿的角度对实际数据进行了研究和解释，这项工作一般被称为“三因子模型”。

暂且不论市值和账面市值比这两个股票特征的风险化解释，1992 年的论文中它们所表现出的显著预测能力，已经让逐利行为关注于此了。阿斯内斯是法玛在芝加哥大学指导的金融博士，其博士毕业论文在三因子模型的基础上加入了动量因子，以四因子模型的形式完成了一系列的实证分析。博士毕业后阿斯内斯进入高盛，成为了一名量化交易分析员，随后在高盛组建了全球阿尔法基金，主要从事以量化为导向的交易工作，业绩不俗。1997 年他离开高盛创办了自己的 AQR 资本管理公司，目前该公司是全球顶尖的对冲基金之一。虽然没有直接的证据证明阿斯内斯在工作中采用的是多因子模型基础上的股价预测技术，但是可以想见的是，市值、账面市值比、动量因子和因子模型应该与其量化交易策略存在一定的关联。阿斯内斯在一些访谈和学术论文中也时常谈到价值、动量/趋势、低风险、套息等相关概念，是为佐证。

由学术研究进入量化交易实业领域的一个更为极端的例子，应该是文艺复兴科技公司的西蒙斯，这也是中国读者较为熟悉的一个量化交易从业者。西蒙斯于 1961 年在加州大学伯克利分校取得数学博士学位，年仅 23 岁，并在 30 岁时就任纽约州立大学石溪分校数学学院院长。他在 1978 年离开学校创立了文艺复兴科技公司，该公司因为旗下的量化旗舰基金——大奖章基金傲人的业绩而闻名。关于西蒙斯所使用的量化交易策略，坊间一直有诸多猜测。许多人认为其所使用的应该是基于隐马尔科夫模型的量化交易策略，原因在于西蒙斯的早期合伙人鲍姆是隐马尔科夫模型估计算法的

创始人之一，同时文艺复兴科技公司招聘了大量的语音识别专家，隐马尔科夫模型正是语音识别领域的一个重要技术工具。作者对这一说法持怀疑态度，不过不管怎样，从文艺复兴科技公司比较另类的人员构成来看，这应该是一个比较纯正的使用量化交易策略进行运作的对冲基金公司。

虽然大部分的量化对冲基金正在使用的交易策略都或多或少的进行保密，但是仍然有一些量化交易策略在多年的使用后开始慢慢为外界所熟知，统计套利就是其中之一。这个策略的概念最早产生于摩根斯坦利，当时的做法也被称为配对交易，实际上就是使用统计的方法选取一对历史价格走势相似的股票，当两支股票之间的价格差距变大、超出一定阈值之后，就分别做多和做空这两支股票，依靠该价格差在随后的时间里回归到正常水平来获取收益。由于这种量化交易策略既源自于统计分析、又存在等待价差回归的套利特性，因此被称之为统计套利。而随着对这类交易策略的进一步深入研究，统计套利策略目前已经远远超出了配对交易的范畴，变得更加的复杂和多样化。

肖曾经是摩根斯坦利这个统计套利交易组的成员之一，他于1980年在斯坦福大学获得计算机博士学位，随后留校进行学术研究。肖在1986年加入摩根斯坦利后负责该组的技术部门，但是在两年之后、如同统计套利的首创者班伯格^①一样、由于政治斗争等原因从公司离职，并创立了自己的德劭基金公司。结合了肖的大规模并行计算研究背景和在摩根斯坦利接触到的统计量化策略，德劭基金公司利用计算机量化模型作为主要的策略进行交易并取得了巨大的成功。值得一提的时，肖在对冲基金领域扎根之后，仍然不忘科学研究，其成立的德劭研究公司致力于通过强大的计算机硬、软件能力在分子动力学模拟等生化科研领域取得前沿性进展。这与阿斯内斯一直在金融杂志上发表学术论文的行为，相映成趣，当然肖的学术研究相对而言可能更为极客一些。

相比起统计套利，传统意义上的套利策略是一个更为人熟知、更经典的量化交易策略。实际上现代金融框架的一部分都是基于“无套利”这样一个假设原则建立起来

^① 关于谁首创了统计套利，存在若干种说法。综合来看，班伯格作为首创者的说法应该是较为可信的。

的，可见套利策略的深入人心与重要性。如果说统计套利的重点在于刻画和预测多个资产间的统计关系，那么传统套利可能就更重注于各个资产的价值计算，以及策略执行时的交易成本估计和优化。只不过量化交易策略进化到现在，统计套利和传统的套利策略已经是互相渗透、互相融合的了。以计算机能力见长的德劭基金公司，对这两种套利策略应该都是有所涉及的。

说起套利，不得不提到长期资本管理公司。这家公司的阵容十分豪华，包括债券套利的先驱梅里韦瑟、两位诺贝尔奖获得者莫顿和斯科尔斯、美联储副主席穆林斯等诸多顶级从业者，主要从事的正是债券的量化套利交易，当然其中也会包含一些其他形式策略的成分。公司成立的前三年间表现非常出色，但是在1998年俄罗斯国债违约之后，相关的连锁反应使得公司产生巨大亏损，在美联储的干预下被华尔街几家公司出资接管，形同倒闭。实际上，长期资本管理公司在俄罗斯债券上的损失本身并不大，但是许多大金融机构在亏损环境下必须保证足够的资本量，因此通过出售流动性较好的七大工业国债券等资产来减低风险、增加资本，全球主要债券价格在卖出压力下大幅下跌，波动巨大，这才导致了杠杆极大的长期资本管理公司在债券套利上产生巨额亏损。

这里谈及长期资本管理公司，决然不是为了说明套利策略的缺陷，或是用一个失败的量化交易特例，来衬托其他量化交易公司的成功。实际上，套利策略是一个具有内在金融逻辑的优秀交易策略，只不过任何量化策略都难以完整的考虑到所有可能出现的情况，长期资本管理公司也正是被一个极端事件的连锁效应所击倒。一个量化交易的研究者和从业者，首先应该具有概率、统计的思维方式，应该理解任何有概率的事情都是可能发生的。对于交易这个行当而言，不到退出市场的一刻，永远都存在着失败的可能，拥有再光鲜的历史业绩也无法摆脱这一事实，而且光鲜业绩本身可能也只是大样本下的一个幸运个体而已。希望读者能在阅读本书时始终保持这样的思维，不要盲目的被看似美好的回溯测试结果甚至实盘业绩所迷惑。

套利策略中一个非常重要的部分就是对交易成本进行判断，同时尽可能的减小交易成本，从而保证足够的套利空间。随着交易电子化的不断发展，以及美国证监会“另类交易系统规定”等法案的推出，交易策略的自动执行也在持续的发展和演化。在这

样急速更新的市场环境下，开始出现一些相应的量化技术，例如通过订单拆分来减小市场冲击成本的算法交易等等。更为人们熟知的是高频交易这个概念，交易的执行者通过计算机下单、将策略执行部件放置于距离交易所主机更近的地理位置上、交易订单直通交易所等手段，从时间延迟等层面减小了价格变动带来的交易成本，从而增加套利空间。当然，在作者写作本书时高频交易技术已经进入到了微秒级别的领域，其在套利当中的应用也只占全部应用的一部分而已，高频交易实际上被更多的使用在了做市商策略等其他策略之上。

在开头处已经提到，本书的主要目的是为量化交易策略研发提供一个可供参考的流程框架。而高频交易等策略方法在很大程度上注重于执行层面的技术手段，对比传统意义的量化交易策略研发具有一定的独立性，因此本书将不涉及高频交易、算法交易等量化交易策略的内容，对套利和统计套利的讨论也局限于非常浅显的层面。不过作者仍然认为中低频的量化交易策略研发框架对于高频交易同样存在一定的借鉴意义，原因在于，开发交易策略始终是离不开对收益和风险的认知的。由于高频交易的内容不会出现，因此从此处开始，书中但凡提到量化交易策略，如没有具体说明，均特指中低频量化交易策略，敬请注意。

1.2 量化交易策略的优缺点

达尔文在 1859 年出版的《物种起源》一书中系统性地阐述了他的进化论思想，认为生物是进化的，而自然选择是生物进化的动力。如果一个有利的变异更能适应当前的环境，那么变异的个体就更容易生存下来并繁衍后代，保存自身的性状，从而不断的进化。我一直都很倾向于将这种理论类比到某种技术发展或者社会实践上，一样事物的产生并兴起，往往是因为它更好的适应了环境。好像量化交易策略一样，因为学术理论的不断产生、交易环境的不断更新、计算机技术的不断进步而持续发展。而由于量化交易策略在这种大环境下表现出了种种优点，以及对比其他交易策略的一些优势，从而呈现出了欣欣向荣之势。

由于量化交易策略自身的特质，其首先存在着比较强的可度量性。作为采用数量

化手段构建而成并进行决策的交易策略，其在构建过程以及决策过程中，都是可以被精确度量的。对比而言，主观化、定性化的交易策略虽然在复盘等过程中可以得到数量化的交易结果，但是由于缺乏整体性的精确度量，因此局部的定量化结果往往波动较大、在很大程度上不具备稳定的刻画能力。

这一特性带来了量化交易策略的另一个优点，即可验证性。由于未来数据的不可得，实际上交易员在判断一个交易策略时，很大程度上都依赖于策略在历史数据上的测试结果。然而主观的交易策略在复盘或者其他测试过程中含有人为判断的成分，因此历史验证就成为了一个不可精确重复、缺乏稳定性和说服力的部分，这对于此类交易策略而言是一个比较严重的缺陷。量化交易策略就不存在这个问题，在策略构建和策略表述数量化的基础上，多次重复历史回溯测试均能够得到一致的结果。如果测试结果是正向的，至少可以说明该量化交易策略在历史检验上具有盈利能力。

上述两个特性使得量化交易策略具有较强的客观性。由于构建交易策略的过程中数量化手段占主导地位，交易决策更是具有明确的数量化规则，因此量化交易策略可以在很大程度上规避策略开发者的主观臆断，在构建的过程中始终获得客观的对待。这里举一个反例，作者曾经在构造一个量化交易策略的时候，由于急于获得最终的结论，因此对策略粗略运行得出的待加工结果进行了人工观察。在没有进一步编写程序进行验证的情况下，得到了该策略可以获利的结论。但是在测试完整策略的时候，发现预期情况和实际不符，重新检查后才发现偏差来自于这一点点的人工行为。量化交易策略的研发已然如此，作者有理由相信在主观策略的研究过程中，这种情况更为常见。实际上，在开发人员对策略有效性有期待的情况下，即使面对一个非常简单的问题，人的主观判断也是有可能产生偏误的。

同时，明确的数量化交易决策规则这一特点，也使得交易员在执行量化交易策略时，有希望完全排除情绪对于整个交易过程的干扰和影响。基于数量化规则，量化交易策略本身具备相当的独立性，不需要交易员的主观判断也可以完整的指导整个交易流程。而主观的交易策略由于在交易操作中需要持续的人为控制和判断，因此不可避免的存在一定的偏向。行为经济学里研究了很多相关的问题，包括损失厌恶偏向、过度自信偏向、参考点偏向等等，都是一些人类固有的行为偏向。当这些客观存在的偏

向影响到交易策略的实际执行时，交易结果的预期从最优点处发生偏移就无法避免了。虽然量化交易策略不可能帮助我们完全的规避这些问题，但是数量化的框架和规则确实可以尽量减小这些不安定因素所带来的损害。

上面所说的排除情绪化操作，实际上也包含了交易员常常谈到的一致性，也就是保证交易策略在执行过程中，使用相同的交易规则，其中包括买入点、卖出点、交易仓位大小的确定等等。如果交易员在执行量化交易策略时不主动加入人为判断，量化的交易规则可以帮助其很轻松的完成这个任务。更为重要的是，量化交易策略可以做到历史验证过程和实际交易行为的一致性，因为不论是真实交易决策，还是历史回溯测试，所参照的交易规则都是由数量化表达精确定义了的。这种整体上的一致性，是绝大部分主观交易策略都无法保证的。

量化交易策略的数量化特点，及其带来的一致性，使得这种策略具备了比较好的可移植性。除非使用特定的量化因素，一般而言量化交易策略是比较容易在一个市场或者资产上证实有效后，移植到其他的市场或资产上使用的。例如，当策略使用的量化数据仅限于价格时，所有存在报价的市场都能够使用历史数据来验证这种量化交易策略。而当使用的量化数据包括价格和成交量时，除了外汇市场等少数情况外，量化交易策略也是能够移植到其他大部分的场内交易市场上的。量化交易策略所使用的数据的可得性越强，其移植能力也就越强。

同时，由于量化交易策略可以很方便的得到数量化的验证结果，收益、风险等策略特征都能够通过数据形式得以呈现。因此，在量化交易策略被应用到多个市场或者资产上时，策略开发人员可以通过数量化结果这样的直观形式来进行横向对比，从而针对性的选取适合某一特定量化交易策略的市场，或者在多个市场之间进行配比。而由于量化交易策略的执行过程中不需要交易员的主观判断，因此相比于主观化的交易策略，其有能力同时覆盖大量的市场和资产，这对于投资组合的分散化来说具有很好的辅助作用。在现实中，大部分的量化基金都持有数量较多的资产和资产种类来组成投资组合，这正是利用了量化交易策略的特性从而更方便的分散风险。

另一方面，对于量化交易策略而言，这种多个市场间的策略移植所需要的成本很小，在一些情况下甚至不需要变动原先的基础工具，因此降低了研发成本，同时节省

了宝贵的研发时间。而量化交易策略不仅仅可以在策略研发的过程中帮助节省时间、降低成本，由于其具有非常明确的数量化规则用以指导交易，因此策略在实际使用的过程中可以脱离人为判断，执行速度更快，运作效率得到了提高。不论是否采用程序化的执行手段，量化交易策略都能够在实际交易中减少人的负担，也就减少了许多重复性的劳动。对于一个交易策略的控制者而言，就能够把更多的精力放在最为核心的策略创新上。

而在策略创新上，量化交易策略本身也具有一定的优势。在科学不断进步的今天，越来越多的先进技术被创造出来并应用到各种情境之下。通过结合多个不同学科的知识 and 相应的数学模型，量化交易策略更有可能发现一些隐藏较深的复杂数据规律，而这些规律往往不太容易被主观交易者察觉得到。时至今日，神经网络、支持向量机、隐马尔科夫模型等机器学习模型已经开始被量化交易从业人员频繁提起，虽然作者并不能确定这些技术手段在量化交易策略方面有多大程度的应用，但是可以肯定的是，交叉学科知识进入量化交易策略研发已经形成了一种趋势。而量化交易策略本身也在融合这些科学技术的同时保持极快的发展速度，以至于有些从业人员开始用“第几代量化交易策略”之类的说法来划分各种策略方法。虽然作者并不太赞同这种过分注重技术手段的行业观点，但是量化交易策略当前的迅速发展是不可否认的。当然，主观的定性交易策略也是在不断进步当中的，只不过在目前这种科技发展、学科交叉的环境下，量化交易策略发展和进步的速度应该是更快的。

实际上就整个行业的状况而言，量化交易策略还有一个不太被人提及的优点或者说特点，那就是能够在一定程度上帮助公司减小对所谓的明星交易员的依赖。由于在交易流程当中，做决策的不再是具体的交易员，而是已经具有明确规则的量化交易策略，因此在量化交易策略研发完毕、甚至只是核心理念构建完成之后，公司对于量化交易策略的研发者的依赖程度就会迅速下降，这一方面可以帮助公司在人员配置上减少支出，更重要的是提高了公司对于交易整体的控制程度。整个公司系统的核心优势在于量化交易策略本身，因此不会由于人员变动等问题而非常迅速的消失，有利于公司在量化交易方面保持长期稳定。

不过这个特质在稳定公司的同时，实际上也损害了量化交易策略研发者的利益。

量化交易策略的研究人员在策略研发完成之后丧失了一定的价值，因此在薪资等方面也不如主观交易的明星交易员一般具有讨价还价的底气。这也导致一部分的量化交易从业者较为消极的对待工作，甚至选择保留核心交易策略，进而隐性的损害了公司的利益。好在很多情况下，量化交易策略即使在研发完成之后，仍然需要不断的改进，从而适应市场环境的不断变化，因此对量化交易策略研发人员的持续需求仍然是存在的。当然，这个问题要妥善解决，仍然在于公司对此的激励政策。

量化交易策略由于其明确而数量化的交易规则，不仅仅会造成上面提到的这一缺点，更重要的是，这些明确的量化规则是非常容易复制的。量化交易策略和许多科技创新一样，具有研发困难、复制简单的特点。即使在最终交易规则保密程度良好的情况下，仅仅只是泄露出一些策略理念出来，相比于主观交易策略，量化交易策略也有更大的可能会被逆向工程破解从而外泄。这种特性一方面增加了量化交易策略使用的成本，另外一方面也加大了量化交易策略在交易之外的风险。一些量化交易的从业者在交流过程中非常的小心谨慎、公司在管理量化交易时执行诸多规章条例、对员工加以合同上的严格限制甚至最后走到对簿公堂的境地，都是由量化交易策略这样的特性引起的。

量化交易策略还有一个非常重大的缺点，就在于量化这个特性本身。诚然这一特征为量化交易策略带来了多种优势，但是由于这一特点，使得量化交易策略在对待无法量化的因素时，只能采取舍弃这样较为无奈的处理办法。因此，量化交易策略损失掉了很多其实有可能带来盈利的信息，也使得策略在处理信息时所覆盖到的范围变得狭窄。当然，随着科学技术的发展，一些之前无法被量化的因素开始进入量化交易策略的研究范围之内，例如针对网络信息刻画出的投资者情绪等等。但是，即使科技手段会让量化交易策略能够处理的信息范围更广更深，对比起主观交易策略而言，这样的缺陷始终是量化交易策略无法彻底摆脱的。这种来源于自身特性的缺点，只能改善而无法根治。

同时，由于量化交易策略在构建过程中采用的是数量化的方法，需要一定数量的数据样本进行研究，而相应的数据都是随着时间逐渐产生的，因此当量化交易策略的构造形式没有本质上的改变时，从数据中抽取的数量化特征也只会随着时间逐渐变化，

策略所形成的交易也只能缓慢的变化。当市场情形发生重大转变时，这种缓慢变化的特性会导致量化交易策略无法适应转折期的市场，在短时间内造成较大的损失。相比较而言，一部分定性的交易策略由于主要基于逻辑上的思路来进行交易，因此当市场情形发生改变时，能够基于主观逻辑迅速进行本质上的策略调整。转向缓慢这一特点也是量化交易策略一个较难改善的缺陷。

第2章 量化交易策略的研发流程

2.1 量化交易策略的基本研发流程

本书将在后面的章节中，通过流程化的说明和一些中国市场上的实际例子来介绍量化交易策略的具体研发框架。通过整本书的内容，读者将遵循一定的逻辑来具体了解量化交易策略是怎样构成的、以及如何被研发出来的。在这一章中，作者在精炼量化交易策略基本研发结构的基础上，通过介绍有限的几个组成部分，对一个较为完整的量化交易策略进行了初步说明。希望读者通过阅读体量不大的文字内容之后，对量化交易策略的研发形成一个大致的概念和逻辑上的了解。图 2.1 给出了一个最为基本的量化交易策略研发流程，该流程是一个较为松散的、但是同时相对典型的研发流程，对于本节中的基础性介绍而言较为合适。

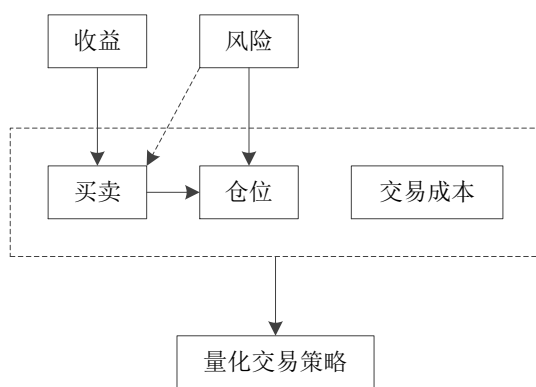


图 2.1 量化交易策略的基本研发流程

在整个量化交易策略的研发流程当中，买和卖是最为基本的量化交易策略组成部分，而这个部分的设定主要与收益情况相关。这里所说的相关，具体分为两种不同的情形，一种是总体的关联性，即基于买点、卖点的选择，买卖策略应该得到一个正的

整体收益。另一种则来自于对交易资产未来收益的判断、或者说预测，即判断交易资产的未来收益为正时，就买入资产；判断交易资产的未来收益为负时，则卖出或卖空资产。实际操作中，这两种关联关系的情况可能更为复杂一些，读者可以通过第4章的内容进行具体的理解。有的时候，买和卖的具体操作也可能受到风险方面设置的影响，例如为了限制单次交易的最大损失而采取止损之类的操作时，用于清仓的买卖设置就会相应的变动，这也是作者将风险和买卖用虚线相连的原因。不过在大部分情况下，买卖这一最为基本的组成部分还是与收益的关系最大，研究者也应该在研发这一个组成部分时，着重考虑收益情况的具体影响。

对量化交易策略风险的控制可能会影响到量化交易策略中的买卖设置，但是在更普遍的情况下，风险这一因素主要影响的是交易仓位的设置。当然，前提条件还是需要买卖策略的总体收益为正，在这样的条件下再结合仓位的设置，才能够在合适的风险水平下取得达到要求的收益。通过对交易资产具体仓位的调整，交易者可以比较直接的控制单次交易以及整个交易策略的风险水平。例如在满仓交易的情况下，定量的判断了当前交易的风险之后，觉得风险过大无法承受，那么最为直接的处理方法就是在满仓的基础上相应的降低仓位的大小。在仓位降低之后，对于整体资金而言风险也就随之降低了。由于仓位本身具有量化、直观的特性，因此当交易者希望将风险处理到一个特定的水平时，调整仓位是一个比较方便的手段。

需要说明的是，前面已经提到了买和卖是量化交易策略最为基本的组成部分，实际上仓位的设定是根据买卖决策和风险两个因素共同形成的，不建立在买卖之上的仓位选择是空洞没有意义的。此外还有一个更为极端的情况，仓位的正确设定有助于进一步优化策略的整体收益，第10章第1节所要介绍的凯利公式的意义正在于此。在图2.1中由买卖到仓位的箭头，实际上可以看作是收益、买卖这一个整体部分指向仓位的箭头。不过在实际使用中，凯利公式所导出的仓位设定往往过于偏激，超过正常风险控制下的最高仓位值，因此仓位仍然与风险的关系更为紧密。

在图2.1这个较为松散的量化交易策略研发流程中，交易成本是和买卖以及仓位具有同等地位的组成部分。在实际操作中，就是首先基于对收益和风险的判断得出合适的买卖和仓位选择，然后在买卖和仓位共同组成的量化交易策略当中考虑交易成本，

也就是在建立仓位和退出仓位等操作中扣除所需要承担的交易成本。随后再次判断该量化交易策略所代表的收益和风险情况，只有这两个因素仍然在接受范围之内，才能确认这是一个可行的量化交易策略。虽然最后用来执行的组成部分只有买卖和仓位，但是交易成本作为对量化交易策略的一个实际化修正，也是策略研发流程中一个不可或缺的重要组成部分。

上面提到的对量化交易策略收益和风险情况的判断，实际上是一个综合性的评价问题。一个最为重要的参考依据应该是策略在整个交易过程中的净值走势，通过对策略净值走势的分析，就可以建立起该量化交易策略运行情况的全面判断。但是净值走势本身由于细节过多，因此无法简单的用来进行策略之间的横向对比。这时就需要精炼净值走势中所包含的信息，选取合适的部分形成量化的评价指标，从而进行量化交易策略的进一步判定。就作者看来，评判一个策略的标准中最重要的仍然是策略在整个交易过程下的收益情况，一个负收益的量化交易策略根本无需考虑其风险即可排除。而当收益为正时，再结合风险的度量进行具体的取舍，就可以直观的给出量化交易策略是否合格的评判标准了。作者心目中最重要风险指标是策略净值的回撤水平，在后面的案例分析中也会重点查看回撤的结果。更多的内容则请参考第 16 章关于策略评价的具体讲解。

于此同时，一些量化交易策略在进行收益和风险情况的判断时，仅仅针对策略自身的净值走势进行研究是不够的，给出一个合理的基准来进行对比往往是更为有效的判别方法。例如后面的案例中会涉及到的量化选股策略，当交易选择仅限为对具体的股票进行持仓，而不考虑空仓或者卖空时，选取一个特定的基准进行对比就会是一个更为有效的判别方法。这主要是由于量化选股策略的仓位始终为多头，因此不论如何配置，策略所持仓位都含有资本资产定价模型中所提到的市场成分。而选股策略本身的意义在于选择更好的股票、不在于获取市场收益，因此将市场走势作为对比、或者在策略收益中剔除掉市场成分就是一个更合理的做法。第 5 章和第 8 章中的因子选股策略就使用了沪深 300 指数作为基准进行了比较，同时简单的用策略收益率减去指数收益率形成新的收益率序列，进而研究该收益率之上的净值走势情况。当然，由于做空也需要保证金的投入，因此这样简单的减法处理是欠缺现实基础的，更贴合实际的

做法是以市场中性组合的方式来进行策略构建，进而研究中性策略的净值走势，在第 15 章的第 1 节和第 2 节中会对此进行详细论述。

上述所有的操作，都需要建立在对历史数据的分析之上，在量化交易领域当中一般称之为回溯测试，或者简称回测。所谓回溯，也就是将交易的过程在历史数据上复现一遍，这里面包含了一个假设，即历史数据在量化交易策略中展现出的样本特征在未来的交易中依然存在，否则回溯测试就失去了意义。关于这一假设的分析其实在诸多技术分析著作中均有涉及，一般被称为“历史会重演”，这里不再继续展开。不同于传统技术分析的是，量化交易策略的研发过程更加深入具体，在涉及到策略的参数设定、模型设置等具体问题时，需要采用数量化的方法、也就是最优化等技术手段进行解决。例如如何设置买点和卖点可以使得相应的总体收益最大等等，都是很典型的最优化数学问题，那么找到合适的最优化技术和算法并加以应用，就能够确定量化交易策略的最终形式，用以进行实际交易。

2.2 量化交易策略研发流程的进一步论述

图 2.1 中所展示的是一个较为松散的一般性框架，用来总领性的说明量化交易策略的基本研发流程。在具体的策略研发过程中，这个框架经常会因为具体研发设置和策略设置的不同而产生变化。例如当量化交易策略的主要作用不是在时间轴上选择具体的买卖时点，而是在同一个时间点上对多个资产进行选择 and 配置时，图 2.1 中的一些说明就显得有些含混不清。在本书中，作者将在后面介绍的选股策略就是这一类策略中最为常见的形式，因此这里在整体框架不变动的情况下，针对图 2.1 进行了文字上的调整，用以说明量化选股策略的运行框架与研发流程。当然，使用选股策略的框架体系来处理多个资产甚至多个策略的挑选、配置也是可以的，在不复杂的情况下读者只需要稍作联想即可。

买卖和仓位虽然是更为通用的说法，但是更适合于描述择时策略，放在选股策略的研发框架中会显得比较突兀，因此图 2.2 将买卖换成了选股，仓位则换成了配比，这样更容易让读者领会该研发流程的含义。实际上，对于每一期的选股而言，如果选

择了原先没有仓位的股票，那么对应的操作就是买入该股票，如果已经建仓的股票没有被选入这一期的股票池，那么对应的操作就是卖出该股票。而配比则是在买卖的基础上，通过仓位大小的变化来实现具体配置。因此，选股和配比实际上可以算是买卖和仓位选择的特殊情况，只是这种说法更为贴合量化选股策略本身。

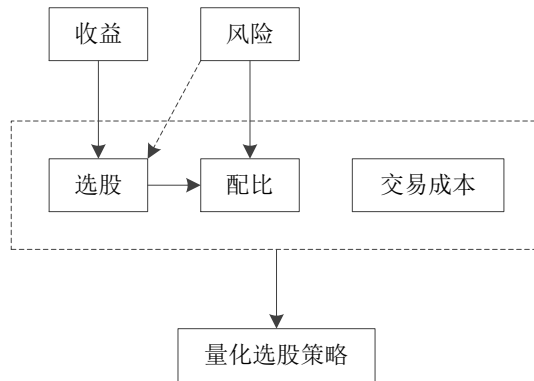


图 2.2 量化选股策略的研发流程

略有不同的，是风险在量化选股策略研发流程中的具体含义。由于选股策略的仓位操作涉及到多个股票之间的配比问题，因此这里的风险不仅包括单支股票的风险，也涉及到多支股票之间的风险程度，后一种风险一般采用股票收益之间的相关性来进行描述。例如在一般性的最优投资组合理论当中，经常使用协方差矩阵来刻画整个资产组合的风险水平。虽然从实际情况来看，相关性这一度量方式与风险的直观感受之间有一定的差距，但是在多资产环境下，一般都将资产间的相关性视为风险的来源之一，这是一个偏学术的、约定俗成的做法。由于这种风险刻画的方式主要针对多个资产的投资组合，因此在第 9 章论述风险时并不涉及，而在第 12 章讨论投资组合决策时进行针对性的说明，并在第 13 章介绍实际的量化选股策略时给出具体的协方差矩阵估计方法。

上面的例子是针对选股策略进行的文字上的变动，实际上量化交易策略研发流程的变化更多来自于各个研发组成部分不同的结合方式。而不同的结合方式，对应的是策略研发过程中不同的目标 and 需求。例如图 2.1 所介绍的松散的研发流程，是在确定

好买卖行为和仓位设定之后，再针对实际交易所产生的交易成本进行二次测试。这样的做法虽然简便易行，但是忽视了交易成本本身对于收益的影响，以及更进一步对于买点和卖点的影响。因此，在确定买卖设置的步骤中就考虑交易成本的影响，应该是一个更贴近于实际的研究框架。图 2.3 给出了相应的流程刻画，如图所示，在判断收益因素时，同时考虑交易成本对于收益的影响，从而优化出更为实际的买卖设置。再根据相应的风险控制，结合买卖点的选择，得出最后的仓位设置。在确定了买卖和仓位这两个部分之后，就获得了一个完整的量化交易策略。

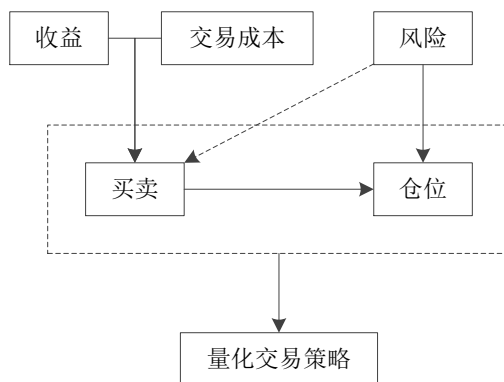


图 2.3 收益和成本共同决定买卖的研发流程

图 2.4 给出了一个更紧凑、更贴合实际操作的量化交易策略研发流程。在该流程中，买卖和仓位的设置是同时作为参数进行优化的，优化的目标函数也进行了唯一化，即量化交易策略的风险调整后收益。而在确定需要优化的目标函数时，交易成本也如同上一个研发流程一样同时被考虑进去，从而保证买卖和仓位优化结果的准确性。毫无疑问，相较于上面所涉及到的研发流程、特别是图 2.1 中较为松散的研发流程，该量化交易策略研发流程的各个组成部分更为紧密，因此在优化过程中所产生的与实际操作的偏离也就越小，买卖和仓位设置的准确度也就更高。但是在实际工作中，如果想参照这一流程进行研发，那么就需要比较强的计算能力，数据量的大小也要达到一定要求，同时优化方法和目标函数的设定要能够同时覆盖买卖和仓位的所有参数，因此往往也只有极为简单的策略思路可以采用这样的流程框架进行研发。例如后面会详

细介绍的双均线策略，实际上是可以通过这样的研发流程来完成的，有兴趣的读者可以自行考察。

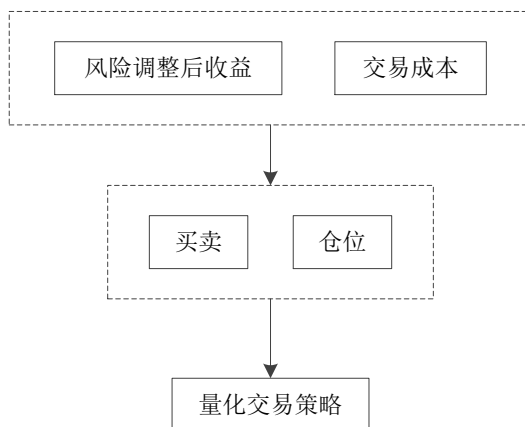


图 2.4 买卖和仓位同时优化的研发流程

在实际的量化交易策略相关工作中，研发只是整个工作流程的一部分，还有两个组成部分需要着重强调。基于此，图 2.5 在图 2.1 所示的研发流程的基础上给出了一个更为完整的工作流程。如图所示，需要增加的部分包括处于研发过程之前的数据准备工作以及处于研发过程之后的策略执行工作。这两项工作与前面所论述的研发流程具有很强的逻辑关联性与内在依赖性，三者结合起来形成的一个整体，基本上可以涵盖量化交易策略具体工作的绝大部分内容。

首先论述数据准备的工作，循着图 2.5 中的箭头可以看到，在量化交易策略的整体工作中，既要为研发过程准备相应的研究数据，也要为策略执行准备相应的实时数据。在研究数据方面，由于寻找合适的量化交易策略需要不断重复研发流程，因此对于数据的要求更偏重于准确性和覆盖能力。同时，对数据的清洗和转换也是一项重点工作，在大部分的数据科学研究、包括量化交易策略的研发当中，数据特征的合理抽取对于整体效果提升的重要性有时甚至要高于精巧的模型，当然很多时候数据的转换和模型的构造是相互融合的，针对具体情况应当采取具体的分析和处理。而在策略执行数据方面，则更应该关注于数据获取的及时性。至于数据的清洗和变换，只需要完

全复制研发得到的量化交易策略下的数据准备工作即可。另外，为了保证数据的及时性，最终进行的数据清洗工作对时间消耗存在一定的要求。

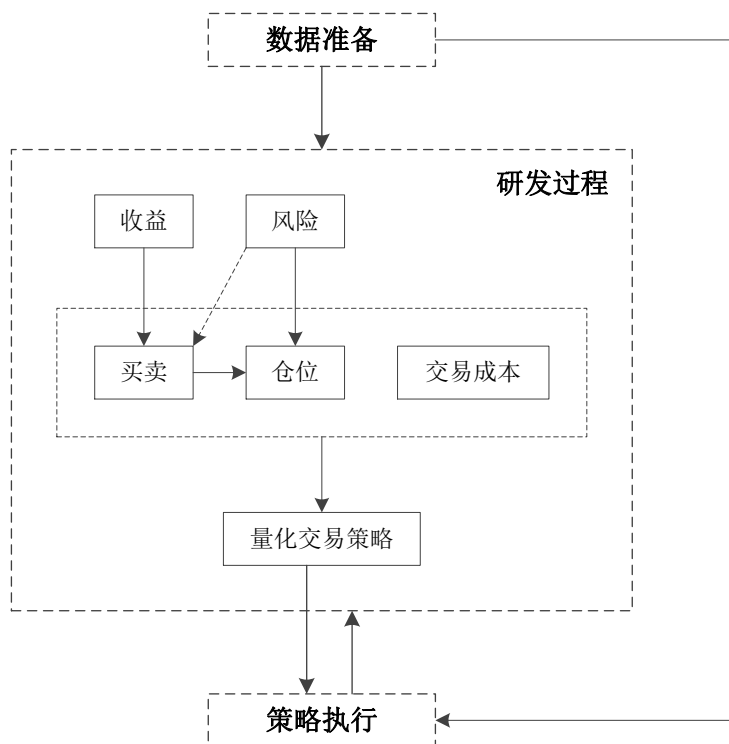


图 2.5 量化交易策略的整体流程

然后讨论策略执行的工作。策略执行，是在量化交易策略研发完成之后，最终产出实际效能的组成部分。执行时应该遵循尽量贴近研发完成的量化交易策略的原则，与量化交易策略所确定的买卖、仓位等设置尽可能的保持一致，这样才能最真实的反映出前面量化交易策略的研发结果。同时，策略执行的结果也可以用来反向支持具体的研发流程，通过对策略执行所得到的收益、风险情况的判断，实时的重新进行研发，对量化交易策略进行修改，从而使得策略能够及时的得到现实的反馈，增强自身的稳健程度。值得一提的是，第6章将要介绍的推进分析是一种模拟策略执行的回溯测试技术，读者可以在运行推进分析时有限度的了解到量化交易策略实际执行时的种种状态。

由于数据准备和策略执行两个部分都重在实际操作，比较难以呈现在纸上，因此后面的内容不会对这两部分给出单独的介绍，整本书主要集中于讨论量化交易策略的研发流程。而在量化交易策略研发流程的诸多框架类型当中，则选取作者认为的最为基本的流程进行研究和阐述，即量化择时策略采用图 2.1 的研发流程，量化选股策略采用图 2.2 的研发流程。希望读者能够根据最为基本的框架举一反三，并在实践中慢慢掌握如何根据具体的研发环境选择最为合适的流程框架。

第3章 注意事项与应对

3.1 未来信息的规避

在量化交易策略的研发过程当中，存在着许多需要注意的事项。如果忽视了这些问题，轻则造成量化交易策略的优化结果与实际要求存在偏差，重则直接导致最后的量化交易策略没有任何实际用处，甚至造成真实的损失。在这些事项之中，首先需要注意的是量化交易策略研发中是否存在未来信息的问题，如果对历史数据进行建模和优化的过程中包含了未来信息，那么应该重新构建研发模型，规避掉所有的未来信息，保证量化交易策略与实际相符。




图 3.1 未来信息示意图

所谓未来信息问题，就是指基于历史数据进行回溯测试的过程中，使用交易完成之后的信息来决定交易本身。为了更为直观的说明何为未来信息，这里给出了一个用来解释的示意图，如图 3.1 所示。在图中，回溯测试能够使用的样本数据包括 A 阶段的数据和 B 阶段的数据，假设模型判断出一个买卖点在 A 和 B 之间，那么 B 阶段所有的信息对于这一个买卖点而言都是发生在未来的信息，因此在判断交易的时刻，B 阶段的所有信息都是无法得知的。在量化交易策略正常执行的过程中，买卖、仓位等策略组成部分的判断都是基于之前所有可以获取的数据得到的，也就不存在未来信息的问题。但是在进行回溯测试的时候，由于我们已经得到了超越买卖点的数据信息，也就是图 3.1 中 B 阶段的信息，因此就可能发生将 B 阶段的未来信息用以判断买卖点这样一种不符合实际交易逻辑的情况。

在国内的一些资料当中，这样一种问题更常见的名称是未来函数，作者猜测这样的习惯可能源自于国内交易者对于技术指标的深入研究。在编写技术指标函数的时候，往往会由于疏忽等问题出现这种使用不应该出现的未来信息的情况。而在国外的一些文献和资料当中，比较常见的叫法还包括前视偏差。相较于未来函数而言，作者认为这种叫法的覆盖面更加广泛一些，因为在一个较为完整的量化交易策略研发过程当中，函数只是其中的一部分。而前视偏差则比较形象的说明了这个问题，站在图 3.1 中的买卖点上，B 阶段的信息都是时间前进后才能得到的，这样所造成的偏差就会让未来的信息进入交易决策本身。

使用 K 线图当前柱的最高、最低价判断买卖点是一个比较常见的使用未来信息的情况。举例而言，当一个建仓策略为“若今日的最低价高于上日的收盘价，则在今日的最低价买入”时，就是一个很典型的含有未来信息的交易策略。在该策略中，买卖决策依赖于两个重要的价格信息，一个是上日的收盘价，一个是今日的最低价。上日的收盘价显然是没有问题的，是一个从当日开始交易时就已经获得的信息。但是今日的最低价就是一个比较明显的未来信息或者说未来函数，因为不到今日收盘，是不可能确定今日的最低价的，要求在最低价买入是一个在现实中不可能完成的任务。不过在回溯测试过程当中，由于已经在做决策时得到了关于当日最低价的信息，因此就有可能错误的将今日最低价当作可用信息并用来确定买卖决策。

还有其他一些关于未来信息错误使用的例子，比较知名的如“在牛市当中持有股票”。实际上，除非具有预判牛市来临时间点的技术手段，否则这种说法往往只是牛市确认之后的事后诸葛亮。当一波牛市已经形成甚至走完的时候，再说出初期建仓之类的意见已经没有任何实际操作意义，而在牛市刚刚开始的时候，交易员常常无法准确的判定这到底是牛市的开始、持续的盘整、还是前一波下跌途中的波动，也就无从谈起牛市持有股票了。

另外一个例子则更偏技术一些，当研究人员使用整个样本的数据进行优化并得到一个量化交易策略之后，使用该量化交易策略在全样本的整体回溯测试中判断买点、卖点、仓位大小等设置就属于引入了未来信息。这时的未来信息问题不在于量化交易策略本身，而在于量化交易策略的研究过程。用上面的示意图 3.1 来进行说明，就是

优化量化交易策略时，无差别的使用了 A 阶段和 B 阶段的数据，但是最终优化得到的量化交易策略，又放到整个样本中进行回溯测试并得到了 A 和 B 之间的买卖点。因此在回溯测试的过程中，该买卖点的确认就使用了 B 阶段的信息，也就是未来的信息。

由于未来函数对于回溯测试的可靠性有负面的影响，因此在实际的策略研发过程当中是需要极力规避的。最直接的办法莫过于将研发完成的量化交易策略放入实际环境中进行模拟交易或者实盘交易，原因在于实际交易中判断策略执行的时间点总是现在，因此必然是无法得到未来的信息的。如果在回溯测试过程中不慎加入了未来信息用来判断，具有相同结构的量化交易策略在实际的交易中也必将暴露出来。但是在实际的策略研发过程当中，由于量化交易策略会经历频繁的变更，因此全部采取实际检验的方法有时是难以达到的。在有些回溯测试的情形下可以人为的将数据样本分成两个部分并分开存储，使用其中一个部分进行量化交易策略的优化工作，然后再将优化完成的策略放入另外一个部分的样本数据进行模拟运行。这种强制分开储存数据的做法，其实也是在效仿实际运行中未来数据的绝对不可得。如果在实际的研发工作中数据分开存储也因为工作量过大而不易完成，那么似乎也只能依靠量化交易策略研究人员自身的逻辑思考和判别能力来规避未来信息了。

虽然这里给出了一些办法用来规避未来信息，但是仍然存在一些未来信息的种类是难以发觉甚至是难以避免的，例如在其他资料中讨论较多的存活者偏差。存活者偏差是指在某一个数据集当中，由于时间的推移，集合中之前包含的一部分成员由于无法存活而离开数据集，而在回溯测试时参照的是最后的存活成员，因此提前剔除了表现不好的非存活成员，造成了未来信息的问题。依然使用图 3.1 来进行说明，研究人员在回溯测试时得到的数据是 B 阶段末尾所有存活成员的数据，但是在箭头所指向的买卖点时，所能见到的成员中还包括一些在 B 阶段离开的成员。回溯测试中由于数据集的问题直接把这些在 B 阶段表现不佳的成员进行了排除，就是滥用了 B 阶段才能得到的信息，从而虚假的提升了量化交易策略的回溯测试成绩。

这种问题常常发生在选股策略当中，一些较为常见的股票数据库实际上已经根据当前的信息剔除了之前由于退市等问题而消失的股票的数据，使用这些数据库的数据

进行回溯测试就会产生幸存者偏差的问题。例如“买入价格极低的股票”这一策略，在获得的数据具有幸存者偏差的情况下，能够在测试中建仓的都是之后会存活下来的股票，在价格很难更低的前提下上涨的可能性很高，因此回溯测试的结果往往不切实际的优秀。由于完全排除幸存者偏差问题的数据库通常价格更高甚至无法得到，依靠研究人员在时间轴上自行搜集数据组建数据库的做法又耗时耗力，因此在这类情况下完全规避幸存者偏差是非常困难的。

3.2 过度拟合与欠拟合

在最简单的情况下，拟合是指对于一组已知的离散点，给定一个带未知系数的函数，通过调整该函数中系数的取值，使得已知的离散点与函数之间的差别最小化的过程。量化交易策略研发中的最优化部分可以在一定程度上看作是一个拟合的过程，通过优化量化交易策略的模型设置和参数设置来让策略尽量适应交易资产的内在特征，从而获得更高的收益和更低的风险。在这个最优化的过程当中，可能会产生出一些偏离实际目标的结果，依照一般量化交易研究的习惯，作者称之为过度拟合和欠拟合。实际上，在大的数据科学框架下，过度拟合和欠拟合具有更丰富的表现形式，下面的内容仅针对量化交易策略研究可能出现的情况进行说明，从而保证对整本书内容的针对性。




图 3.2 原始数据与来源

这里用一个简单的例子来实际说明一下过度拟合和欠拟合。假设一个数据集源自于一个带有误差项的二次方程，如下：

$$y = -x^2 + 15x + 200 + \varepsilon$$

其中 ε 是一个在 $[-50, 50]$ 之间均匀分布的误差项。数据集一共包括二十个点，其中 x 分别选取从 1 到 20 的 20 个整数。如图 3.2 所示，星号为二十个观测数据点，曲线为不带误差项的原始二次方程。




图 3.3 三次方程下的过度拟合

在实际的工作中，研究人员并不知道数据来源的具体逻辑，因此可能会设置出各种各样的方法来拟合数据集。当研究者采用三次方程来拟合这 20 个数据点时，得到的方程曲线如图 3.3 所示。曲线与数据点的差距有一定缩小，但是曲线形状与图 3.2 中原始方程的曲线存在走势上的差别，在图形最左侧有一个原始图形没有的下降趋势，右侧的下降则比原图更甚。使用复杂度比二次方程更高的三次方程来研究该数据集，造成的就是过度拟合的问题。

当研究人员使用一次方程来拟合这 20 个点的数据集时，得到的方程曲线如图 3.4 所示。很明显，用复杂度较低的线性方程拟合出的结果损失掉了原始曲线中先上升后下降的走势特性，而呈现出一个线性下降的趋势，这就是由欠拟合造成的。

上面这个例子简单化的展现了过度拟合和欠拟合在数据研究中的形式。对于量化交易策略而言，过度拟合指的是由于选取的策略或模型过于复杂，不仅适应了交易资产本身的内在属性，而且在优化过程中还刻画了噪音在样本数据中表现出的一些特性，




图 3.4 一次方程下的欠拟合

过度的拟合了样本数据，从而造成偏差，影响到策略的盈利能力。在一些专业书籍当中，过度拟合问题有时候也被称之为曲线拟合。欠拟合则恰好相反，往往是由于选取的策略或者模型过于简单，适应交易资产内在特征的能力不强，拟合水平较低，因此盈利能力也就较弱。

就过度拟合和欠拟合的具体表现而言，两者有相似之处也由于不同之处。正如上面所述，两种问题都会导致策略的实际盈利能力下降，这是它们的相同之处。但是欠拟合的量化交易策略由于对数据的描述和挖掘能力不足，往往在历史数据优化下和实际交易中表现不好，因此在回溯测试时就可以比较直观的分辨出来。过度拟合的量化交易策略则不同，由于在拟合样本数据时过度的优化，进而拟合了样本中噪音的特性，因此常常是历史数据优化下的结果很好，只有在实际交易中才会显著变差，也就是俗称的泛化能力低下。在实际的量化交易策略研发过程当中，这样的性质增加了过度拟合判别的难度。

在大部分情况下，一个量化交易策略往往既具有过度拟合的问题，也具有欠拟合的问题，原因在于金融资产的内在属性并不像物理学等学科所研究的对象一样，存在一个较为明确的运行逻辑，同时也比语音识别等数据科学问题的情况更加复杂和模糊，人们现在对于资产价格运行模式等问题的了解还处在非常皮毛的状态。在实际工作中，研究选取的策略或模型可能只有一部分设置适应了交易资产的内在属性，相符的内在属性也只占交易资产整体属性的一部分，因此策略模型是欠拟合的。好在量化交易策略研发并不是一个需要绝对精确的学科，即使策略模型与数据内在特性相符的程度不

大，只要存在这种适应性，就有可能为研发者带来可观的利润。于此同时，研究得到的策略模型的另外一部分设定可能就与交易资产的内在属性完全没有相关性，经过最优化等工作之后只是拟合了资产交易中的噪声，从而造成过度拟合的问题。

实际工作中研究人员既需要减少量化交易策略过度拟合的程度，也要同时减少策略欠拟合的程度。解决欠拟合的途径较为清晰，就是不断的尝试各种各样的策略，基于更多、更好的策略模型来挖掘交易资产的内在特征，获得相应的盈利能力。当然，尝试新策略是量化交易策略研究工作的基本要求，因此欠拟合这一问题也较少的被研究人员所提及，大部分文献资料都更侧重于过度拟合的问题，也存在许多相关论述。从本质上说，简化策略当然是一个行之有效的较少过度拟合的方法，冯诺伊曼曾通过费曼和戴森之口说出了“我能用四个参数拟合一头大象，用五个参数让它摆动鼻子”的经典名言，参数过多、模型过于复杂可能会导致过度拟合这一看法已经成为了一个公论。



图 3.5 策略复杂化的示例

但是与此同时，简化策略又与研究者要解决欠拟合、尝试找到更合适的策略的目标背道而驰。图 3.5 给出了一个策略在简单和复杂之间变动时，欠拟合与过拟合情况的粗略示例。由于交易资产的内在运行逻辑尚不清楚，因此任何一个交易策略都只能挖掘并利用数据内在特征的一部分，也就是两个圆重合的浅灰色区域，而剩下的白色区域则是交易策略没有实际效用但是客观存在的部分。当策略复杂度增加时，策略就有可能更多的利用数据的特征，表现为浅灰色的重合区域增加，欠拟合问题得到缓解。但是与此同时，策略无效的白色区域也可能相应的增加，这一部分经过最优化就是过度拟合的成因。因此在量化交易策略的研发工作中，策略的复杂程度、参数数量的设

置等问题常常需要研究人员根据实际情况、过往经验来进行主观判断，没有一个固定的最优标准。好在针对回溯测试过程而言，存在着一些可以用来判别过度拟合问题的技巧，因此研究者可以在适当增加量化交易策略复杂程度的基础上，通过这些技巧来尽量规避策略的过度拟合，本书将在第6章中介绍的推进分析正是一种处理过度拟合问题时行之有效的分析技巧。

除此之外，增加回溯测试时使用的样本量也是一个可能会产生作用的做法。如果量化交易策略所针对的交易资产内在特性没有随着时间产生变化，那么增加样本量可以扩展回溯测试的覆盖范围，从而在更大的区间内研究策略的稳定程度，而样本量的增加也可以让研究人员更自由的使用一些判断过度拟合的研究技巧，这样就能够保证不造成欠拟合问题的条件下，更好的规避过度拟合的产生。在实践中增加样本量进行研究的做法也确实能够取得一定的效果，因此作者建议在可获得的数据量充足的前提下，还是应该尽可能的让回溯测试覆盖更广的范围。不过究其根源，内在特性不随时间变化的假设本身是值得怀疑的，前面已经说过，人们现在对于资产价格运行等内在特性的了解还处于非常皮毛的状态，即使研究者们发现了某些规律并基于这些规律形成了可以盈利的策略，也不能保证这些规律会保持下去。在这种情况下，不经判断而盲目的增加数据量，就可能对量化交易策略的盈利能力造成误判。而且在中国市场这种运作时间较短、环境变化较快的市场上，该问题就更加严重。完全消除这个矛盾需要研究人员对本质问题充分理解和把握，这并不是仅靠一个合理的量化交易策略研发框架就可以解决的问题。

3.3 回溯测试与真实环境的差异

回溯测试中的交易环境与真实的交易环境是有一定差异的，这种差异越大，回溯测试的结果用于判断策略效用的能力就越低下。因此，理解回溯测试与真实环境之间的差异问题，学习如何处理两者之间存在的差异，也是本书在讨论具体的量化交易策略之前需要讲解的内容。

回溯测试与真实环境之间差异的情况，大致可以分为两类。其中一类差异是可以

通过人为设置回溯测试、或者人为限定真实交易的手段而基本消除的。在这一类差异当中，实际交易时的买卖点与回溯测试下的买卖点不一致的问题是一个比较常见的例子。具体来说，就是在中低频的量化交易策略研发中，回溯测试使用的数据往往不是价格进行一次变化就记录一次的分笔数据，而是记录一段时间内的开始价格、最高价格、最低价格、结束价格之类的二次处理后的数据。因此，如果真实交易中的买卖点发生在开始价格和结束价格之间的某一个时间时，是不能反映在二次处理数据所构造的回溯测试中的，也就会造成这两者买卖不一致的问题。




图 3.6 日内买卖与回溯测试不符的案例

图 3.6 给出了一个日内买卖与回溯测试不符的实际案例。假设在这个例子当中，研究人员在回溯测试中使用的数据是日度收盘价所组成的时间序列，测试的量化交易策略为“当价格超过 10 日均价时买入，当价格低于 10 日均价时卖出”。图中给出的是某一日全天的价格走势，假设这一天的价格达到 53.5 以上时，则触发“价格超过 10 日均价”的条件需要买入。可以看到，在回溯测试的流程中，由于当日价格报收于 53，没有达到 53.5，因此回溯测试时是判断该日没有交易行为的。但是查看实际的全天价格走势，可以发现价格突破了 53.5 一共三次，并又三次下跌到 53.5 以下，如果采用回溯测试得到量化交易策略并全天候的应用于资产交易当中，这一天其实已经买入并

卖出了该资产三次了。如果这里的资产是 A 股中交易的股票，那么情况可能更糟，在日内第一次超过 53.5 时进行了买入操作之后，由于 T+1 的规定因此不能再在该日卖出，最后的结果是回溯测试中该日没有交易，但是实际上该日收盘后持有了股票仓位，这种差异将完全破坏掉回溯测试结果的可信程度。

对于如何处理这一类的差异，作者给出三种可供参考的解决方案：

1. 在回溯测试时，使得回溯测试的环境尽量与真实的交易环境保持一致。在上面的例子当中，就是将回溯测试使用的二手数据换成更为精确的分笔数据，从而模拟整个交易过程中都可以买卖的现实环境。

2. 在实际的交易过程当中，尽量贴近回溯测试中的交易情况。以上面的例子而言，就是在实际交易中忽略每一日盘中的走势，只在收盘时判断交易与否。但是值得注意的是，由于得到收盘价的同时也就代表着当日交易的结束，完全按照收盘价进行交易决策会导致不能执行的问题，因此这种解决方案需要在实际收盘点提前一小段时间进行交易决策并执行。

3. 合理估计实际环境下的交易与回溯测试之间的差异，并在回溯测试过程中通过计算上的调整反映出这些差异。在上面的例子里，实际上就是估计出相对于回溯测试中的收盘交易而言，盘中交易会带来的收益和损失，并在回溯测试里加入对估计收益和损失的刻画。但是如果实际差异涉及到 A 股市场 T+1 造成的建仓不符之类的问题，那么这种解决方案可能就不是一个很好的选择了。

此外，改变量化交易策略，使之能够适应这种回溯测试与真实环境之间差异，也是一种在实际策略研发过程中可能会用到的处理手段。比如上面的例子中，可以在原始的量化交易策略判断买卖点时，加入合适的限定条件或者缓冲条件，从而解决频繁的来回买卖的问题。但是这种方法只能治标、不能治本，即使来回买卖的问题得到了缓解，但是回溯测试与真实环境间的差异仍然会存在，如果希望将这种差异消除掉，可能仍然要结合上面所述的三种方案或者其他方案来完成。

对于这三种方案而言，作者建议在有能力的情况下，优先考虑第一种解决方案，即使很难获得相同样本期下的分笔数据，也尽量采用频率更高的数据来代替之前的数据，从而更好的逼近真实的交易环境。随后的选择才是第二种和第三种解决方案，这

两者之间没有一个固定的更优选择，需要结合具体的量化交易策略、研究环境和交易环境进行人为判断。当然，也存在着其他一些具有实际意义的操作方案，例如将第一种和第二种解决方案结合起来，同时更新回溯测试和实际环境中的交易行为。再以图 3.5 中所展示的例子来说明，完全在收盘时进行判断和买卖在现实环境中是不可能的。而由于在收盘之前的短暂时间进行交易的判断和执行稳定性较差，而且用来判断交易的数据点也不是收盘价，因此会存在较大的差异。在频率更高的样本数据无法获取的情况下，其实可以在回溯测试中改用开盘价进行研究，如果测试结果也可以得到合适的收益和风险情况，那么执行时就可以在开盘之后立即执行，这种情况下所使用的判别点就是当日的开盘价，差异仅存在于开盘和执行之间的时间差，而且这种差异较之前一种情况来说，一般会更小一些。

需要说明的是，在本书后面介绍的所有量化择时策略与量化选股策略案例中，使用的都是收盘价等收盘时获取的数据。也就是说，回溯测试的模拟交易过程，都默认的将收盘时刻作为进行交易决策的时间点。因此，对实际环境下的交易与回溯测试之间的差异进行估计、从而判断出策略的实际效用，就成为了一个本书没有具体分析、但是极其重要的研究组成部分。在现实研究中，将本书所介绍的几个简单的交易策略全部更改为开盘时刻进行交易决策并不困难，相关的数据也比较容易得到，对此感兴趣的读者可以自行尝试。但是由于本书实际上的目的是介绍量化交易策略研发的流程框架，实际案例仅作为辅助介绍的工具使用，因此也就依照一般的研究传统，将数据确定为收盘数据。这里再次申明，作者希望读者在阅读本书时，不要将关注的重点放在具体策略之上，本末倒置。

另外一类回溯测试与真实环境之间的差异则是很难通过人为的修改和设置来消除的，其中最常见的是实际环境中会产生交易成本。估计交易成本是量化交易策略从研发进入实际执行前一个必要的步骤，本书在第 2 章的研发流程中曾经谈到了交易成本问题，在后面的第 14 章中则会用一章的内容对其进行分析，因此这里不做过多阐述。流动性也是一个时常会导致回溯测试产生重大缺陷的问题，这个问题在 A 股市场上同样格外明显，到目前为止国内的 A 股市场仍然设置涨跌停板，如果某交易策略判断买入一支将会涨停的股票，在回溯测试中可以正常建仓，但是真实交易中可能

由于当日的开盘时刻就涨停，因此实际上是没有机会买入这支股票的。将回溯测试使用的二次处理数据更换为更精确的数据，例如分笔数据或者分钟数据、小时数据等来进行研究，可以在一定程度上减小这种情况下回溯测试与真实环境之间的差异。当然这只是流动性缺失的一个比较极端的例子，在大部分存在流动性问题的情况下，可能会出现的结果是实际交易价格与回溯测试的虚拟交易价格不一致，研究者们通常将这种差异也归为交易成本的一种，并通过预估来尝试解决。总的来说，处理这一大类的差异主要还是采用前面提到的第三种方法，即合理估计实际环境下的交易与回溯测试之间的差异，并在回溯测试过程中通过计算上的调整反映出来。

此外，很难通过人为的修改和设置来消除的差异还包括量化交易从业者对于量化交易系统的整体判断和情感因素。诚然量化交易策略的优点之一就是可以规避策略研发者的主观臆断、排除情绪化对于整个交易过程的干扰和影响，但是研究和控制量化交易策略的毕竟还是人，因此总体上的行为偏误依然会存在。例如量化交易员对于量化交易策略整体风险的承受能力，虽然在研发过程中，研究者可能会设定一个30%的警戒线，如果亏损达到30%则判定策略失效并放弃策略，但是实际的运行过程中，5%的亏损已经让人惴惴不安，10%的亏损则让人开始怀疑策略的正确性并重新检验，20%的亏损可能就让人放弃坚持并修改策略了。有主观判断存在，就有偏误和差异存在，这是交易策略都固有的问题，作者将在最后一章中对此进行一定的论述。

第4章 简单的择时策略

4.1 择时策略的基本框架

在这一章中，作者将向读者介绍最基本的择时策略是如何构成的，以及相应的一些实际案例。首先需要说明，这里所谓的最基本的择时策略，指的是只判断买卖、不涉及到仓位优化的择时策略，图 4.1 通过灰色区域说明了基本的择时策略在研发流程中所处的位置。由于不考虑风险的问题，因此择时策略完全是通过优化收益情况来形成相应的买卖决策的。另外需要注意的是，这一章的主要目的是为读者提供较为清晰易懂的量化择时策略案例以供入门，因此会在策略的优化过程中使用全样本数据进行设置的优化，并直接使用最优化下的买卖决策作为模拟交易的结果加以分析，这也是章节名称取为“简单”的意思。这种做法会产生出未来信息的问题，希望读者暂时忽略，后面的章节中会有相关内容来处理这一问题。

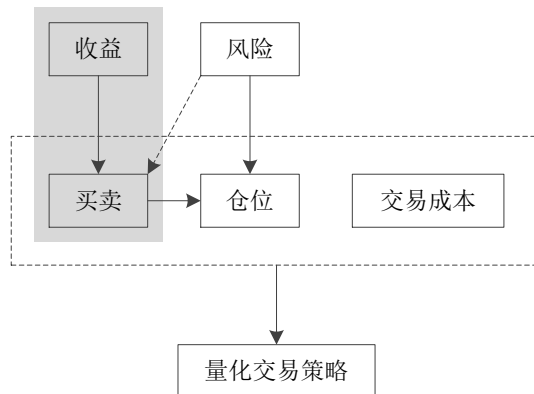


图 4.1 基本的择时策略在研发流程中的位置

一个基本的量化择时策略框架如图 4.2 所示，不论是回溯测试还是实际交易，每一次做出交易决策时，都根据决策时刻的已知数据，通过策略构建的分类器或分类函




图 4.2 基本的择时策略框架

数将当前的状态分为两类。在分类为多的情况下，如果当前仓位为多头则保持不变，如果不是则通过买入操作将仓位变为多头；在分类为空的情况下，如果仓位为空头则保持不变，如果不是则通过卖出和卖空操作将仓位变为空头。另外，假如市场禁止做空，那么在分类为空的情况下，如果仓位为空仓则保持不变，如果不是则通过卖出操作将仓位变为空仓。这是一个相对而言比较简单的过程，期间不涉及到对于交易决策点之后收益情况的预测，交易决策仅仅和当前状态的分类有关，因此很多基于这种模式构造量化交易系统的从业者声称自己只跟随系统、不做预测。不过在作者看来，分类的做法本身暗含着对于未来状态的分类，这种情况类似于一个条件预期的计算和判断，预测隐藏其中。当然，怎么理解一个框架是见仁见智的问题，并无优劣之分，量化交易策略的研究人员只需要明确自己的理念和判断即可。




图 4.3 多分类的基本择时策略框架

有时候一个量化交易策略的使用者在整个交易的过程中并非只有买和卖这两种选择，例如在市场允许卖空的情况下，既不买也不卖、持币观望也是一种很重要的做法。好在分类函数也并不是只能处理二分类的问题，通过组合多个二分类器或者直接引入多分类器，就可以将分类结果扩展为多种。图 4.3 的框架就加入了中立的类别，

如果分类为多就保证仓位为多头，分类为空就保证仓位为空头，分类为中立则将仓位平掉保持观望。这实际上是图 4.2 中框架的一个顺理成章的演化，在大的思路不变的条件下，这个框架还能够进一步的复杂化，从而适应具体的交易问题。

在图 4.2 和图 4.3 的量化交易策略框架当中，分类器/分类函数的含义是比较广的。例如一个技术指标的使用，当该技术指标符合某一种判别形式时则看多，符合另一种判别形式时则看空，就是一种很典型的分类。对外部环境的判断也可以归于这样的框架之下，当交易资产的外部环境向好时则看多，当外部环境变差时则看空。对新闻事件的影响进行押注的交易策略也可以看作是一种分类，当某个特质的事件发生时就看多或看空，事件影响消失或者过去一段时间之后则分类回中立状态。当然，只有使用量化的方法来对环境加以判断或者对事件加以处理，才能将其置于量化交易策略的框架之中。实际上，大部分的择时策略都可以纳入到这样一个框架当中，更复杂一些的择时策略组成成分，例如过滤器之类的辅助判别工具，可以看作是分类技术的进一步细化。而仓位建立之后的进一步加仓、减仓、止损、止盈等手法，则可以看作是分类类别更多的分类器所导出的结果。当然，在现实的量化交易策略研究当中，有时候把加仓、减仓当作另外一次开仓、平仓的过程来对待，然后再将多次交易行为合并起来，可能会是一种更为高效的处理方法，逻辑上也更为清晰一些，不过这并不妨碍我们使用上面所述的框架来理解整个策略。




图 4.4 基于收益预期的基本择时策略框架

基本的量化择时策略还有一种比较特殊的形式，即基于对交易资产未来收益的预测来形成具体的交易策略，一个简单的框架如图 4.4 所示。图 4.2 和图 4.3 中的基本择时策略在表面上均不涉及到对于交易决策点之后收益情况的预测，交易决策仅仅和当前状态的分类有关。图 4.4 中的择时策略框架则不同，主要的工作往往就是在预期

收益的计算和处理上。由于这里讲解的基本择时策略不涉及到风险的估计和仓位的位置，因此最后要做出的交易决策只包括买和卖。图 4.4 中就采用了一个简单的正负分类来判断多空，如果预期收益为正则看多，如果预期收益为负则看空，买卖决策方面与图 4.2 中的情况相似。当然，也可以通过设定 0 上下的阈值来形成多分类，如同图 4.3 一样判断出多、空、中立等类别，从而做出相应的交易决策。需要注意的是，对于这一类的策略框架而言，由于存在着预测未来收益这样一个中间步骤，因此在参数优化时既可以选择以收益预测模型拟合的最好为优化目标，也可以选择以整个策略最后得到的交易结果最优为优化目标。在实际的研究中一般都采用前面一种优化方式，当然具体的选择仍需要针对具体的研究问题来加以判断。

从上述几种框架的特性出发，其实就很容易理解目前机器学习的一些算法在量化交易策略中不断应用的趋势了。机器学习和人工智能领域中一些在应用上较为成熟的算法，很多都是以分类为目标的，同时一些算法也可以用来进行非线性回归之类的拟合和预测，因此本质上就和量化交易策略的框架具有相容性。但是即便如此，作者仍然不太认同行业中存在的拿来主义，一些量化交易策略的研究人员在没有搞清楚机器学习算法内在逻辑的情况下，简单的将现成的工具包直接套用到交易数据之上，其实是不可取的。例如使用支持向量机做分类，至少也应该先弄清楚使用支持向量来判断类别所具有的优点和缺点，是否适用于自己的策略和实际情况。况且一部分机器学习算法在工业界的应用是有大规模的样本数据作为训练基础的，直接用来构造量化交易策略时，会有多大的可能性造成过度拟合，都是应该提前考虑的问题。

4.2 均线趋势策略的简单优化

使用资产价格的均线来判断趋势是一种非常常见的做法，而且量化起来简单直接，这一节就将均线趋势策略运用于现实数据当中，给出一个相对来说比较容易上手的量化择时策略案例。图 4.5 在图 4.2 所示的框架基础上，说明了一个双均线趋势策略是如何运行的。在交易决策的时点需要根据已知数据计算短期均线和长期均线两个值，当短期均线高于长期均线时，判断交易决策时刻的趋势为上涨趋势，按照趋势会延续

的思想，认为后市会继续上涨，因此看多。而当短期均线低于长期均线时，判断交易决策时刻的趋势为下跌趋势，认为后市继续下跌，因此看空。图中的两个分类标准一个是大于，一个是小于等于，主要是因为最后分出的类别仅为两类，因此要保证两个分类标准合起来涵盖所有的可能性，等于号出现在上一个或下一个标准当中对实际交易情况会有一些影响，但不会太大。




图 4.5 均线趋势策略的基本框架

前面已经提到过，这一章的目的主要是为读者提供较为清晰易懂的量化择时策略以供入门，因此会在策略的优化过程中使用全样本数据进行一次性的优化，从而使整个研究过程简单化。以这一节的均线趋势策略为例，也就是在固定了均线趋势策略的基本框架之后，对于短期均线长度和长期均线长度两个参数，在全部模拟交易样本上考虑不同参数组合所带来的收益情况，选取收益最好的一个参数组合为优化后的参数组合。随后考察这一个参数组合的均线趋势策略在相同样本上的模拟交易表现，进而判断均线趋势策略的优劣。这里就通过整体优化引入了未来信息，作者将在后面的章节中解决这一问题，本节则直接考察相关结果。由于策略构建过程中，在全部样本数据上只优化了一次，也就是说模拟交易样本下都将使用同一对参数组合，具有较好的一致性，因此优化确定了参数组合的均线趋势策略实际上等同于“短期均线从下向上穿过长期均线则做多，短期均线从上向下穿过长期均线则做空”。

这个案例中选取的交易资产为沪深 300 股指期货主力合约，其标的指数为中证指数公司编制的沪深 300 指数，由上海和深圳证券市场中规模大、流动性好的 300 只股票组成。沪深 300 指数期货是中国国内最早上市也是最有影响力的股票指数期货，由中国金融期货交易所于 2010 年 4 月 16 日推出。本着尽可能多的利用数据的原则，这里获取了从 2010 年 4 月 19 日到 2015 年 6 月 30 日的日收盘价数据，判断买卖则从

2010年12月31日收盘开始，也就是说在回溯测试样本中将一共模拟交易四年半的时间。2010年4月19日到2010年12月30日的日收盘价数据作为交易前计算短期均线和长期均线的备用数据，数据长度为172个交易日，也就是说只要长期均线在173日均线以下，备用数据都可以支持均线趋势策略的计算顺利完成。虽然股指期货可以在最低交易保证金为8%的情况下进行杠杆交易，但是在本节的基本择时策略环境下，统一将杠杆率设定为100%进行研究。

这里进行的优化，其实就是很简单的将所有参数的可能组合都测试一遍，然后选取整体收益最高的参数组合，这种方法也被称之为网格搜索。但是对于一个均线策略而言，考察从1开始直到某一个长度结束所有可能的均线情况其实是一种存在冗余和偏向的做法。长度越大的两根相邻均线之间的差异越小，例如2日均线和3日均线之间的差异，远远大于100日均线和101日均线之间的差异，后两者由于一个交易日的差距被百分之一化，因此相差其实很小。这样，如果从1开始直到某一个长度结束所有可能的均线均参与搜索，那么长度小的均线的变化较快，搜索会偏向于变化不大的长期均线，进而造成计算上的冗余。

前人采用过的改进方法包括将所有的短期均线加入搜索范围，长期均线则每5个步长加入搜索等，本书则使用斐波那契数列来处理均线的搜索范围。对于这个例子而言，斐波那契数列并不是一个具有神奇效果的技术工具，仅仅是作者觉得该数列在数学上可以比较好的将均线之间的差异平均化而已，换成其他的抽取形式其实也是可以的，请读者不要过分联想。斐波那契数列的形式为[1,2,3,5,8,13,21,34,55,89,144,...]，也就是说，均线趋势策略的简单优化将使用1日均线^①、2日均线、3日均线、5日均线、等等直到144日均线一共11种均线的长短组合进行搜索，寻找盈利能力最好的组合，从而确定最优的均线趋势策略形式。这里限定短期均线最大搜索到34日均线，长期均线则从短期均线的后一根开始搜索一直到144日均线结束。

表4.1给出了所有的短期、长期均线组合下均线趋势策略的年化收益率情况。整个表中年化收益率为正的均线趋势策略一共有47个，年化收益率为负的仅仅5个，因此纯粹从优化的角度来看，均线趋势策略是一个相对而言比较稳健的策略。收益率

① 实际上就是日收盘价序列

表现最差的一个策略是短期均线为3日均线、长期均线为5日均线的趋势组合，年化收益率为-12.77%。收益率表现最好的一个策略是短期均线为3日均线、长期均线为21日均线的趋势组合，年化收益率达到25.51%。值得注意的是，这两个均线组合中的短期均线都是3日均线，也就是说在使用3日均线形成的短期均线时，均线趋势策略的收益表现具有比较大的变化幅度，这在网格搜索当中是一个不太好的现象。但是同时，长期均线是21日均线的6个均线趋势策略的收益都比较高而且相对稳定，年化收益率最低的一个也达到了18.13%。综合来看，通过收益最优原则选择出来的短期均线为3日均线、长期均线为21日均线的均线趋势策略，所处的区域应该算是比较稳健的。

表4.1 所有组合下均线趋势策略的年化收益率

| | 1 | 2 | 3 | 5 | 8 | 13 | 21 | 34 |
|-----|--------|--------|---------|--------|--------|--------|--------|--------|
| 2 | 3.05% | | | | | | | |
| 3 | 2.59% | 11.39% | | | | | | |
| 5 | 2.33% | 11.10% | -12.77% | | | | | |
| 8 | 8.31% | -0.60% | -3.80% | 5.41% | | | | |
| 13 | 8.03% | 12.49% | 10.23% | 12.52% | 9.64% | | | |
| 21 | 21.54% | 20.85% | 25.51% | 18.13% | 20.13% | 19.86% | | |
| 34 | 17.64% | 18.33% | 19.75% | 19.59% | 19.66% | 7.41% | -1.95% | |
| 55 | 8.53% | 14.65% | 15.58% | 15.04% | 8.15% | 8.37% | 0.24% | 1.82% |
| 89 | 13.74% | 15.28% | 12.74% | 16.64% | 12.97% | 14.12% | 13.93% | 12.09% |
| 144 | 9.40% | 14.86% | 16.31% | 11.87% | 9.56% | 4.47% | -2.89% | 3.23% |

在优化完成之后，再将短期均线为3日均线、长期均线为21日均线的均线趋势策略应用到选取的模拟交易样本之上进行回溯测试，从而得到回溯条件下相应的交易情况。图4.6展示了使用这一均线组合的均线趋势策略进行交易的情况下，以1为初始值的净值走势情况。在2011年底、2012年底、2013年底和2014年底，交易策略下的净值分别变为1.3583、1.4800、1.4721、2.2542。可以发现，该均线趋势策略在2011

年的收益情况较好，随后进入了一个为期将近三年的平缓上升。从2014年11月开始直到2015年6月样本期结束一共7个月的时间里，净值水平有了一个明显的提升，从1.55左右上涨到结束交易时的2.7803，涨幅大约为78%，当然其间的波动也较为明显。基于整个交易过程来看，四年半的策略收益率为178.03%，折算下来的年化收益率达到25.51%。




图 4.6 简单优化的均线趋势策略净值走势

在整个四年半的均线趋势策略交易当中，净值的最大回撤率为 19.83%，而且从 2011 年 1 月 10 日收盘开始，就再也没有下降到 1 以下的水平。最大回撤的发生时间在 2013 年中，最高点为 2013 年 6 月 25 日收盘的 1.7427，最低点则为 2013 年 8 月 1 日收盘的 1.3971，整个回撤过程一共经历 27 个交易日，是一个相对而言不算太长的回撤时间。经过计算，整个交易过程中平均的年度最大回撤为 14.33%，对比 25.51% 的年化收益率，该回撤水平是可以接受的。

4.3 均线反转策略的简单优化

均线反转策略与均线趋势策略是一对具有相反内涵的量化择时策略，同均线趋势

策略一样，均线反转策略同样具有量化起来简单直接的特点。在这一节中，作者将均线反转策略基于同样的研究方法，运用到相同的数据样本之中，一是用来进一步介绍简单的择时策略，同时也能够与上一节的内容进行参照和对比，促使读者形成灵活运用量化工具的思维。图 4.7 在图 4.2 所示的框架基础上，说明了一个双均线反转策略是如何运行的，与图 4.5 对比起来看，其实就是将分类步骤中的大于号和小于号进行了调换。在交易决策的时点需要根据已知数据计算短期均线和长期均线两个值，当短期均线高于长期均线时，判断交易决策时刻的趋势为上涨趋势，按照走势会反转的思想，认为后市会下跌，因此看空。而当短期均线低于长期均线时，判断交易决策时刻的趋势为下跌趋势，认为后市会转为上涨，因此看多。




图 4.7 均线反转策略的基本框架

优化方式方面，同样选择在整个过程中使用全部模拟交易样本进行一次性的优化，进而让整个研究过程简单化。这一节中均线反转策略的研究过程基本上就是上一节均线趋势策略的翻版，因此不多做赘述。由于策略构建过程中，在全部样本数据上只优化了一次，也就是说模拟交易样本下都将使用同一对参数组合，因此优化确定了参数组合的均线反转策略实际上等同于“短期均线从上向下穿过长期均线则做多，短期均线从下向上穿过长期均线则做空”。

选用的交易资产依然为沪深 300 股指期货主力合约，具体的样本数据是从 2010 年 4 月 19 日到 2015 年 6 月 30 日的日收盘价。判断买卖从 2010 年 12 月 31 日收盘开始，也就是说在回溯测试样本中均线反转策略一共模拟交易四年半的时间。2010 年 4 月 19 日到 2010 年 12 月 30 日的日收盘价数据作为交易前期计算短期均线和长期均线的备用数据，数据长度为 172 个交易日，也就是说只要长期均线在 173 日均线以下，备用数据都可以支持均线反转策略的计算顺利完成。股指期货交易的杠杆率也同样被

设置为 100%，从而使策略的研究过程相对简单。

在进行网格搜索的优化过程中，也依然使用斐波那契数列来处理均线的搜索范围，用以缓解搜索全部均线时可能会出现的计算冗余和搜索偏向的问题。斐波那契数列的形式为[1,2,3,5,8,13,21,34,55,89,144,...]，也就是说，均线趋势策略的简单优化将使用 1 日均线、2 日均线、3 日均线、5 日均线、等等到 144 日均线一共 11 种均线的长短组合进行搜索，寻找盈利能力最好的组合，从而确定最优的均线趋势策略形式。这里限定短期均线最大搜索到 34 日均线，长期均线从短期均线的后一根开始一直到 144 日均线结束。整个设置都和上一节保持一致。

表 4.2 所有组合下均线反转策略的年化收益率

| | 1 | 2 | 3 | 5 | 8 | 13 | 21 | 34 |
|-----|---------|---------|---------|---------|---------|---------|---------|---------|
| 2 | -2.30% | | | | | | | |
| 3 | -2.98% | -11.06% | | | | | | |
| 5 | -2.28% | -9.99% | 14.64% | | | | | |
| 8 | -7.61% | 0.60% | 3.95% | -4.94% | | | | |
| 13 | -7.44% | -11.10% | -9.28% | -11.12% | -8.79% | | | |
| 21 | -17.72% | -17.25% | -20.33% | -15.35% | -16.75% | -16.57% | | |
| 34 | -15.00% | -15.49% | -16.49% | -16.38% | -16.43% | -6.90% | 1.99% | |
| 55 | -7.86% | -12.77% | -13.48% | -13.08% | -7.53% | -7.72% | -0.24% | -1.79% |
| 89 | -12.08% | -13.26% | -11.30% | -14.26% | -11.48% | -12.37% | -12.23% | -10.78% |
| 144 | -8.60% | -12.94% | -14.02% | -10.61% | -8.73% | -4.28% | 2.98% | -3.13% |

表 4.2 给出了所有的短期、长期均线组合下均线反转策略的年化收益率情况。整个表中年化收益率为正的均线趋势策略一共只有 5 个，年化收益率为负的达到了 47 个之多，与表 4.1 中的情况正好相反。当然，由于均线反转策略和均线趋势策略两种策略的分类标准刚好相反，因此在没有交易成本等其他影响因素的环境下，表 4.2 中的年化收益率结果和表 4.1 中的年化收益率结果应该有如下的一一对应关系：

$$r_{\text{反转}} = \frac{1}{1 + r_{\text{趋势}}} - 1$$

在仅有的5个正的年化收益率中，除了最高的一个为14.64%，超过了5%，剩下的4个分别为0.60%、3.95%、1.99%、2.98%，都是不太突出的收益水平。因此从表4.2中的结果来看，网格搜索下的均线趋势策略相对而言并不是一个稳健的策略，大部分的搜索都落入到了收益率不佳的区间之内，最优选择处呈现出一个陡峭的峰值。不过在这一节的简单框架之下，最后通过收益最优原则选择出来的短期均线为3日均线、长期均线为5日均线的均线反转策略，至少在样本上具有一定的收益表现。



图 4.8 简单优化的均线反转策略净值走势

在优化完成之后，再将短期均线为3日均线、长期均线为5日均线的均线反转策略应用到相同的样本数据之上进行回溯测试，从而得到回溯条件下相应的交易情况。图4.8展示了使用这一均线组合的均线反转策略进行交易的情况下，以1为初始值的净值走势情况。在2011年底、2012年底、2013年底和2014年底，交易策略下的净值分别变为1.1340、1.5702、2.0279、1.7522，2015年6月结束时净值达到1.8493。从图中也可以看到，自模拟交易开始起一直到2013年底，该均线反转策略的净值水平都保持着上升的趋势，特别是在2012年前两个月和2013年下半年，净值增加的比较明显。2014年后净值在一定水平上维持了接近一年的时间，然后经过一个较大的波动下降到最后的1.8493。基于整个交易过程来看，四年半的策略收益率为84.93%，折

算下来的年化收益率达到 14.64%。此外需要说明的是，图 4.8 和图 4.6 的纵轴比例尺不一样，而且后面的所有图形均是如此，使用图形进行对比的读者应注意纵轴坐标的具体刻度。

在整个四年半的均线反转策略交易当中，净值的最大回撤率为 28.11%，而且与上一节的均线趋势策略一样，从 2011 年 1 月 10 日收盘开始，净值就再也没有下降到 1 以下的水平。最大回撤发生的起始点为 2014 年 4 月 1 日收盘的 2.2555，最低点则是 2015 年 4 月 27 日收盘的 1.6214，整个回撤的走势维持了一年以上。经过计算，整个交易过程中平均的年度最大回撤为 15.19%，与 14.64% 的年化收益率接近一致。仅仅和上一节中的结果进行对比而言，均线反转策略在收益和风险两个方面都逊于均线趋势策略。

4.4 自回归策略的简单优化

自回归模型是计量经济学中最简单最基本的模型之一，常常用来刻画时间序列的性质以及做出相应的预测。这一节作者就通过自回归模型构建量化择时策略，并将其运用于现实数据当中，为基于收益预期的择时策略提供一个简单的案例。图 4.9 在图 4.4 所示的框架基础上，说明了一个自回归策略是如何运行的。首先假设自回归模型的形式如下：

$$r_t = \sum_{i=1}^N b_i r_{t-i}$$

其中 r_t 是交易资产在 t 时刻的收益率， b_i 是各阶的回归系数。交易决策的时间点为 t 时刻头、 $t-1$ 时刻末，此时 r_{t-1} 到 r_{t-N} 一共 N 日的日度收益率都是已知数据，通过计算上面的回归式就可以得到对 t 时刻收益率的预测值。当 t 时刻的预期收益率为正时，则看多 t 时刻的交易资产；当 t 时刻的预期收益率为负时，则看空 t 时刻的交易资产。分类过程中同样需要保证两个分类标准合起来涵盖所有的可能性，因此当预测值为 0 时，固定将其分类为多或者固定将其分类为空即可。预测值精确为 0 的情况在实际研究中十分罕见，即使出现也影响不大。




图 4.9 自回归策略的基本框架

为了给读者提供较为清晰易懂的量化择时策略以供入门，这一节同样在优化过程中使用全部模拟交易样本进行一次性的优化。不过与前两节中均线策略的优化相比，这里优化的目标是不一样的。均线策略的优化目标是整个交易期间内的收益率最大，而这里的优化目标则是样本数据上自回归模型的拟合度最高，从实践的角度来看就是模型拟合后对未来收益率的预测最好。前面已经提到过，对于这样的策略框架而言，由于存在着预测未来收益这样一个中间步骤，因此参数的最优化既可以通过自回归模型在样本中的拟合来完成，也可以通过使得自回归策略在样本中交易的收益最大化来完成。对于自回归模型这样一个相对而言比较简单的策略模型来说，其实两种优化方法都是可以使用的，相对而言后一种方法可能还更加贴近实际交易的意图一些。但是这一节中使用的优化方法确定为前面一种，即通过拟合自回归模型来获取系数值，这样做一是为了给读者呈现出不同优化方法的实际案例，二是因为在实际研究中如果使用更复杂一些的预测模型或手段，特别是拟合技术相对固定的一些模型如神经网络等，后一种优化方法的计算过于复杂，因此在实践中被应用的情况其实并不多见。

选用的交易资产也同样是沪深 300 股指期货主力合约，具体的样本数据包括从 2010 年 4 月 19 日到 2015 年 6 月 30 日的日收盘价。判断买卖从 2010 年 12 月 31 日收盘开始，也就是说在回溯测试样本中自回归策略一共模拟交易四年半的时间。2010 年 4 月 19 日到 2010 年 12 月 30 日的日收盘价数据作为交易前期计算 N 日日度收益率的备用数据，数据长度为 172 日，也就是说最高能支持 N 为 172 的自回归模型进行计算。在这一节的研究中，模型形式应该是在优化之前就确定好的，这里作者直接将自回归的阶数固定为 9，也就是将 N 取为 9。股指期货交易的杠杆率依然被设置为 100%，从而使策略的研究过程相对简单。

表 4.3 自回归模型拟合结果

| 滞后阶数 | 回归系数 |
|------|----------|
| 1 | 0.01356 |
| 2 | -0.05809 |
| 3 | -0.01531 |
| 4 | 0.04056 |
| 5 | 0.03179 |
| 6 | -0.03602 |
| 7 | 0.06777 |
| 8 | 0.05457 |
| 9 | 0.07993 |

表 4.3 给出了 9 阶自回归模型在样本数据上的拟合估计结果，9 个回归系数实际上就是组成自回归策略的 9 个参数。9 个系数中为正的有 6 个，分别是 1 阶、4 阶、5 阶、7 阶、8 阶、9 阶，为负的有 3 个，分别是 2 阶、3 阶、6 阶。由于每一个滞后阶的日度收益率均值基本一致，因此可以直接用回归系数的大小来初步判断滞后收益率对未来收益率的影响程度。9 个系数的绝对值均在 0.01 以上，也就是说均具有一定的影响，但是滞后 1 阶的影响其实相对较小，系数估计值仅为 0.01356。滞后 2 阶的回归系数是 3 个负值中绝对值最大的，为 -0.05809，而正向影响最大的则是滞后 9 日的收益率，回归系数的估计值为 0.07993。不过，由于滞后的收益率之间也存在着相互关联关系，因此纯粹从系数大小来判断影响程度也是不可取的。如果要深究该问题，则需要进一步引入其他计量经济学的模型和检验方法，这里不做阐述。

在表 4.3 中，作者没有给出模型拟合下各个自回归系数的 T 统计量、P 值等数据来判断系数的显著性水平，也没有给出整体模型的 R 方等数据用来判断模型的拟合程度等性质，原因在于量化交易策略的研究中虽然使用了计量经济学的模型，但是量化交易策略研发和计量经济学的研究目标以及研究思路都是有差别的。量化交易策略研发的根本目的是发现具有盈利能力的策略，而不是探究数据下的经济关系、以及相应的解释和预测。当然，数据的检验与预测对于发现具备盈利能力的策略有着重要的

推动作用，统计学和计量经济学的一些检验方法也能够在量化交易策略研发中起到指导性的作用。但是在本书的例子当中，作者选择性的把一些计量经济学中重要的研究内容都忽略掉了，一是为了在大框架清晰的前提下尽量简化内容，二是希望读者能够通过作者这种舍弃的行为理解量化交易策略研发的一些本质特征。




图 4.10 简单优化的自回归策略净值走势

在自回归模型拟合完成之后，便可通过确定了回归系数的模型在相同的样本下逐日预测下一日的收益率，进而判断交易方向，得到回溯条件下相应的交易情况。图 4.10 展示了使用这一系数确定的自回归策略进行模拟交易的情况下，以 1 为初始值的净值走势情况。在 2011 年底、2012 年底、2013 年底和 2014 年底，交易策略下的净值分别变为 1.2469、1.2487、1.3446、1.3501，但是到了 2015 年 6 月交易结束，净值已经上升到了 2.7145。从图中也可以看到，在 2014 年 12 月中旬之前，该自回归策略的净值其实上升幅度较小，但是在 2014 年 12 月中旬之后，净值水平有了一个非常大的提升，从这个时间点开始到交易结束的 6 个半月间，净值的上升幅度达到了 135% 左右。基于整个的交易过程来看，四年半的策略收益率为 171.45%，折算下来的年化收益率达到 24.85%。虽然收益情况不错，但是四年半的上升幅度其实主要贡献都来自于最后半年多，这反映出该策略在样本期内缺乏一定的稳定性。

在整个四年半的自回归策略交易当中，净值的最大回撤率为 27.49%，这一次回撤的起始点是 2012 年 3 月 2 日收盘的 1.3434，最低点到 2013 年 6 月 18 日收盘的 0.9741，整个回撤的时间一共 310 个交易日。在这一次最大回撤之前，净值也曾在 2011 年 5 月 19 日收盘时下探到 0.8529 过。经过计算，整个交易过程中平均的年度最大回撤为 17.86%。当然整个策略的净值走势存在细节上的不稳定，前面已有提到，因此仅靠年化收益和平均年度回撤来判断策略是不够的。

第 5 章 简单的选股策略

5.1 因子选股的基本框架

在上一章中，作者介绍了最基本的择时策略以及简单的一次性优化过程。作为与择时策略同样重要的选股策略，其在横截面上的作用与择时策略在时间轴上的作用是量化交易策略的两个重要方向。在这一章中，作者就向读者介绍最基本的量化选股策略是如何构建起来的，同时引入一些相应的实际案例用以说明。与上一章一样，这里所谓的最基本的选股策略，指的也是只判断买卖、不涉及到仓位优化的选股策略，或者更贴切的说，是在挑选了合适的股票之后，只简单分配资金、不做具体配比优化的选股策略。图 5.1 通过灰色区域说明了基本的选股策略在研发流程中所处的位置。由于不考虑风险的问题，因此选股策略完全是通过判断收益情况来挑选股票的。同样的，为了给读者提供较为清晰易懂的量化选股策略以供入门，因此会在策略的优化过程中使用全样本数据进行简单的优化，进而产生出未来信息的问题。不过对于单因子选股策略和多因子选股策略而言，未来信息问题的表现情况不尽相同，在后面的内容中会具体说明。

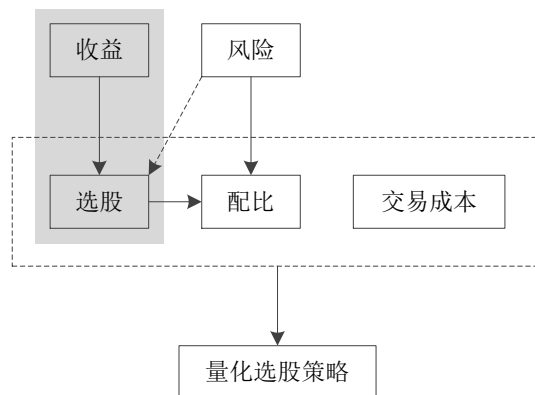


图 5.1 基本的选股策略在研发流程中的位置

单因子选股是整个因子选股策略框架的基础。一方面，单因子选股可以直接反映该因子的获利能力，如果单因子选股策略的收益情况达到要求，是可以直接用来进行策略交易的；另一方面，单因子选股的过程实际上与因子挑选密切相关，在大多数情况下，只有在单因子选股过程中能获得一定收益的因子，才有理由被纳入到多因子选股策略的考量之中。其实相较于多因子选股策略的模型，单因子选股策略非常的简单直接，图 5.2 给出了一个最为粗略的单因子选股策略框架，在决定选股的时间点上，通过分类器来判断因子的取值是否符合一定条件，如果符合则将股票选入，在下一期持有。在这样的框架下，选股策略在表面上并没有涉及到对后一期股票收益的预测，也没有使用一般意义下的最优化手段。不过就作者的看法，预测在分类时已经暗含其中，测试不同因子的过程也可以被看作广义上的最优化。




图 5.2 单因子选股策略的粗略框架

在实践中，因子选股已经是一个相对成熟而且大致框架较为固定的策略，同时存在一个业界从业人员都较为认同的策略体系，本书作为一个以介绍策略框架为主要目标的作品，也无意去变动或复杂化这样一个体系框架，因此在内容上基本就是介绍最简单、最受认可的策略构建方法。而操作单因子选股策略时，需要考虑到将单个因子融合进多因子策略的问题，因此在分类、判别的部分不易过于复杂，甚至可以说存在一个较为固定的判别模式。简单而言，就是在交易决策时按照当前的因子大小进行排序，然后选入排序前列的股票，排序选择顺序还是逆序则由下一期收益率与因子的具体关系决定，最后保证选取股票的收益率相对更高即可。图 5.3 给出了这样一个基本的单因子选股策略框架。

多因子选股策略方面，本书也选用一个较为成熟的策略框架来进行介绍。首先假定已经选出了 N 个有效因子，分别用 f_1 到 f_N 标记，然后针对每一支股票，用这 N 个




图 5.3 基本的单因子选股策略框架

因子的值来预测下一期或者下一段时间的收益率。这里选用简单的线性回归来完成预测工作，如下式所示：

$$r_t = a + \sum_{n=1}^N b_n f_{n,t-1}$$

其中 r_t 是时刻 t 的股票收益率， $f_{n,t-1}$ 即为 $t-1$ 时刻下第 n 个因子的大小， a 和 b_n 是回归式中的系数。进行交易决策的时间点为 t 时刻初、 $t-1$ 时刻末，因此回归式左边为预测值，回归式右边的所有成分则都是决策点下的已知信息。在预测出每一支股票在时刻 t 的收益率之后，按照收益预期值从大到小进行排序，然后选取排在前列的股票作为当前可以建仓的股票。

需要特别说明的是，在某些量化交易策略的相关资料当中，会把对于不同股票而言取值一致的回归系数 b_n 称之为风险因子，而将具体的股票特征值 $f_{n,t-1}$ 称之为各支股票在因子上的溢价。这主要是因为学术界在套利定价理论等研究的基础上，形成了一种约定俗成的叫法，其中风险因子对于所有资产应该保持一致，而因子溢价则各有不同。不过在量化选股策略中，对比本节所使用的称谓，这种叫法以及其他一些叫法并不是非常直观，因此不予以使用。如果读者在阅读其他资料时碰到不一样的名称，只需对号入座弄清准确含义即可。

a 和 b_n 等参数的优化和拟合，书中使用的是法玛与麦克贝斯给出的一种线性回归估计方法。如果可以获得 T 个时间段的因子数据以及相应的下一期股票收益率数据，那么对于上面的线性回归式而言，一共可以进行 T 次估计，表示如下：

$$r_t = a_t + \sum_{n=1}^N b_{n,t} f_{n,t-1}, \quad t=1, \dots, T$$

相比起上一个回归时， a 和 b_n 的形式略有变动。 a_t 和 $b_{n,t}$ 代表一共可以得到 T 组 a 和

b_n 的参数估计值。然后将 T 个 a_t 求平均值，就是参数 a 的拟合结果；分别将 T 个 $b_{n,t}$ 求平均，则得到 N 个 b_n 各自的拟合结果。




图 5.4 基本的多因子选股策略框架

图 5.4 展示了这样的多因子选股策略的基本框架，和单因子选股策略不同的地方在于，单因子选股直接针对因子进行排序来选择股票，而多因子选股需要先基于因子预测股票的未来收益，然后再对预期收益进行排序进而选择下一期持有的股票。因此，多因子选股策略中很明确的包含了预测的成分，以及通过估计回归模型来完成的最优化手段。如果像第 4 章一样仅介绍简单的选股策略，那么从表面上来看，多因子选股策略的研究过程中由于存在回归模型的一次性估计，因此包含有未来信息的成分，而单因子选股策略的研究过程中则不存在未来信息的问题。但是正如前面所言，不断的尝试不同的因子、最后挑选出合适因子的过程，实际上也是在进行最优化的筛选，这其中暗含的未来信息问题，需要研究人员加以注意。

在本节开始处作者提到过，单因子选股模型一方面可以直接反映该因子的获利能力，另一方面可以过渡到多因子选股策略的准备工作——因子挑选之上。不过单因子选股模型在这两个方面发挥作用的时候，策略研发人员的关注点和需要处理的细节问题都有细微的差别，图 5.5 给出了一个简单的例子用来说明。当研究人员使用单因子模型直接构建交易策略进行交易时，主要关注的是被选入股票的收益情况，如图中曲线的加粗部分所示。只要这一部分的未来收益能够达到标准即可，至于因子大小排序在后面的股票，不管是展现出如图中的非线性趋势、还是有明确的线性趋势、甚至是没有一个显著的走势，在重要性上要远逊于选入股票的收益情况，至多影响到策略的进一步改进。但是当研究人员使用单因子模型来挑选有效因子、从而构建多因子模型时，由于涉及到具体的收益预测问题，单个因子在多因子预测中需要合并起来使用，




图 5.5 单个因子与预期收益关系的简单示例

因此整个曲线的性状都是要加以考虑的问题。而本书中所述的多因子策略方法基于线性回归模型，因此预期收益和因子大小之间符合线性关系是最优状态，当两者的关系呈现出如图 5.5 中所示的非线性关系时，在线性回归步骤之前对因子或收益数据做合适的预处理，例如法玛所使用过的对数化，就是一个很有必要的过程。

5.2 市值因子

市值因子一直是业界和学术界都比较认同的一个选股因子，法玛标志性的三因子模型当中，市值因子就是其中之一。法玛在他的实证研究中发现，就美国市场上的股票而言，随着股票市值的变大，其未来收益率存在一个显著的逐渐下降的趋势。简单来说，就是市值越小的股票，未来收益情况往往越好。当然，对于中国的股票市场，市值因子的定义可能更为复杂一些，因为国内的股票更多的牵涉到了流通与非流通的问题，市值应该采用流通市值、总市值还是其他形式来进行计算是一个存在选择性的部分，好在实际的策略研究发现市值因子定义上的细微变化并不显著影响到其盈利能力的存在与否。而且实际上，市值因子对于目前的中国股票市场而言，可以说是接近公认的最为有效的选股因子。虽然就在本书所涉及到的样本期的末尾，市值因子在一段时间内完全失效，但是从后续的市场运行情况来看，市值依然是中国股票市场上一

个不能被忽略的重要因子。

为了研究这个选股因子，作者获取了自1991年1月开始直到2015年6月底结束的国内股票月度数据。所选股票的范围涵盖在深圳证券交易所进行交易的所有A股，包括主板、中小企业板和创业板三个板块，以及在上海证券交易所进行交易的所有A股。月度数据则包括月末收盘时股票的复权后月度收益率，以及股票的月度流通市值。开始挑选股票进行买卖的时间从2010年12月的收盘开始，也就是说在回溯测试样本中将一共交易四年半的时间，和上一章中的简单择时策略的交易时间保持一致。1991年1月到2010年12月的所有月度流通市值数据则作为开始买卖股票前的备用数据，不过对于单因子的简单判断来说，只需要用到2010年12月这一个月数据。研究内容上将同时兼顾因子有效性测试和单因子选股策略两个方面，先将股票按照因子从小到大排序分成若干个等份，从而研究因子大小和未来收益的相关关系，然后再选取排列中的第一等份建立仓位，进而研究市值因子选股策略的盈利情况。

鉴于股票在整个生命周期内的不稳定性，也就是可能出现的停牌、涨跌停、无法交易等现实情况，在进入策略研究阶段之前，需要对相应的数据进行处理，尽量贴近真实环境下的交易情况。对某一些在研究过程中无法完全处理的差异，也应该做到心中有数，如有可能尽量在结果中进行估计和描述。而在整个回溯过程中，模拟交易也设定为只进行买入和卖出操作，不进行卖空的操作。这样设定的原因在于中国的股票市场本身处在一个高速发展的阶段，相关的交易手段并不完善而且变化较快，直到本书写作的时间也只有少部分股票可供做空，因此回溯测试中完全体现出现实的交易环境相对而言比较麻烦，做出不卖空的交易限制则可以有效的简化整个量化选股策略，方便读者更好的掌握相关内容。同时在本章的基本选股策略框架下，全部资金都用来持有股票，至于无风险资产参与配比的内容请参见第12章和第13章。

回溯测试的过程其实比较简单，在第一个选股和交易的时间点，即2010年12月收盘时，将样本中所有数据完备且可以交易的股票当前的流通市值从低到高进行排序，然后按顺序等分为若干个部分，每一等份中的股票又按照等权重进行组合。也就是说，把每一个等份看作一个股票组合，则该组合中按照收盘价买入的每一支股票的资金量都相同。然后在2011年1月收盘时进行相同的排序和等分过程，形成新的股票组合

分组。之后每个月收盘时都进行相同的操作，直到交易样本结束即 2015 年 6 月底为止。

在 54 个月份之间，排序第一的等份就对应着一个长度为 54 的收益率序列，假设在 2010 年 12 月收盘的时候资金量为 1，那么对于“在下个月持有当月排序第一的等份中对应的股票”这样一个策略，就可以通过该收益率序列计算出一个净值走势，这也就是单因子选股策略的净值走势。需要说明的是，除了交易成本在这一章的简单研究过程中暂时不考虑以外，这里的策略回溯过程还将引入另一个与实际交易环境不符的刻画：如果在一个收盘交易点判定了新的选入股票之后，原来某个正在持仓的股票不在新的选入股票之列，但是此时由于该股票因为停牌等情况无法卖出，那么在回溯环境下假设该股票同样退出持仓，且该月的收益率为 0。这样的假设虽然脱离现实，但是会使得回溯过程更加清晰，在实际交易中这种情况会牵涉到仓位的分配调整，是一个需要研究人员自行做出处置的疑难问题。

对于排序不同的等份而言，均可以像处理排序第一的等份一样，将其看作一个逐月变化的股票组合并计算出净值变化的情况，再折算成月度的收益率，代表的就是这一排序的平均月度收益，如下式所示：

$$\bar{r}_n = \sqrt[54]{\prod_{t=1}^{54} (1 + r_{n,t})} - 1$$

其中 $r_{n,t}$ 是排序第 n 的等份组合在第 t 个月的收益率， \bar{r}_n 就是排序第 n 的等份在样本区间内的平均月度收益率。如果因子大小和未来收益有显著的关系，那么 \bar{r}_n 应该随着 n 的变化具有显著的趋势。当然，这种趋势也会随着 n 的具体取值而变化，如果 n 太小，不同等份间变动的表现能力会因为太多的股票参与平均而减弱，如果 n 太大，趋势又可能会受到股票收益中噪声的影响而不明晰。

在本书中，作者将所有股票按照因子大小排序划分为 3 等份、10 等份、30 等份共三种情况来加以研究。首先来看 3 等分的情况，图 5.6 展示了将所有股票按照流通市值大小划分为 3 等份，每一等份中的股票又按照等权重进行组合时，3 个等份各自的平均月度收益，分别为 2.62%、1.46% 和 0.94%，由于同期的股市从整体上来说是在上涨的，因此三个值均为正值是一个合理的结果。第 1 等份和第 2 等份之间的月度收益




图 5.6 市值因子 3 等分的收益情况

率相差 1.16%，第 2 等份和第 3 等份之间则相差 0.52%，表现出了非常明显的下降趋势。当然，由于等份数量较少，只以此来判定因子大小和未来收益间的逆向关系是不够的。




图 5.7 市值因子前 1/3 的股票组合净值走势

在确定了逐月的排序和 3 等分之后，就可以顺理成章的得到第 1 等份股票组合的逐月变动情况，也就是市值因子选股策略的交易详情。图 5.7 中的实线展示了使用市值因子选股策略进行交易的情况下，以 1 为初始值的策略净值走势，虚线则是同期沪深 300 指数的走势，用以比较。可以发现，该选股策略的净值在 2014 年之前没有明显的走势，只是稍向下探然后又回复到初始值左右，2014 年后显示出了一个比较明显

的上升趋势，到2015年6月底净值达到4.0429。从整个交易过程来看，四年半的策略收益率为304.29%，折算下来的年化收益率为36.40%。对比而言，同期四年半的沪深300指数的收益率则仅为42.99%，经过折算，指数的年化收益率为8.27%。通过比较收益率情况可以发现，基于市值因子的选股策略在盈利能力上是优于市场指数的。此外，为简便起见，后面的研究内容中将不再说明沪深300指数的具体收益率，仅在图中以虚线标出作为对比，请读者注意。




图 5.8 市值因子前 1/3 的股票组合与沪深 300 收益之差的净值走势

图 5.8 则是逐月的将市值因子排序前 1/3 的股票组合收益率减去沪深 300 指数的收益率后，所得到的收益率序列形成的净值走势。净值从 2010 年 12 月收盘的 1 开始，在 2015 年 6 月底达到 2.5842，四年半的收益率为 158.42%，折算下来的年化收益率为 23.49%。四年半之间的最大回撤率为 40.38%，回撤的开始点为 2014 年 10 月收盘的 2.2646，结束点则是 2015 年 1 月收盘的 1.3503，实际上四年半中的主要回撤就是最大回撤下的这三个月。由于最大回撤的特殊性，整个交易过程中平均的年度最大回撤这一指标在一定程度上失去了评判的意义，因此不再具体给出。

然后是划分为 10 等份的情况。图 5.9 展示了将所有股票按照流通市值大小划分为 10 等份，每一等份中的股票又按照等权重进行组合时，10 个等份各自的平均月度收益率情况。第 1 等份的月度收益率为 3.62%、第 10 等份的月度收益率为 0.71%，而




图 5.9 市值因子 10 等分的收益情况

且值得注意的是，10 个等份的月度收益率按照排序存在着非常规律的下降顺序。这表明在 10 等分的情况下，市值因子的有效性得到了比较好的体现。




图 5.10 市值因子前 1/10 的股票组合净值走势

在确定了逐月的排序和 10 等分之后，也就得到了通过市值因子选出的第 1 等份股票组合的逐月变动详情。图 5.10 中的实线展示了使用市值因子选股策略进行交易时，以 1 为初始值的净值走势情况，虚线则是用来对比的沪深 300 指数。相较于图 5.7 而言，净值走势在 2015 年的半年之间上升的幅度更加明显，这也使得 2015 年之前的走势显得越发平缓。策略净值在 2015 年 6 月收盘达到 6.8180，四年半之间策略的收

益率一共为 581.80%，折算下来的年化收益率为 53.20%。




图 5.11 市值因子前 1/10 的股票组合与沪深 300 收益之差的净值走势

图 5.11 则是逐月的将市值因子排序前 1/10 的股票组合收益率减去沪深 300 指数的收益率后，所得到的收益率序列形成的净值走势。净值从 2010 年 12 月收盘的 1 开始，在 2015 年 6 月收盘达到 4.3541，四年半的收益率为 335.41%，折算下来的年化收益率为 38.67%。四年半之间的最大回撤率为 39.91%，回撤的开始点为 2014 年 11 月收盘的 2.5743，结束点则是 2015 年 1 月收盘的 1.5469，回撤期长度为两个月，较之 3 等分的情况少了一个月，即 2014 年 11 月。

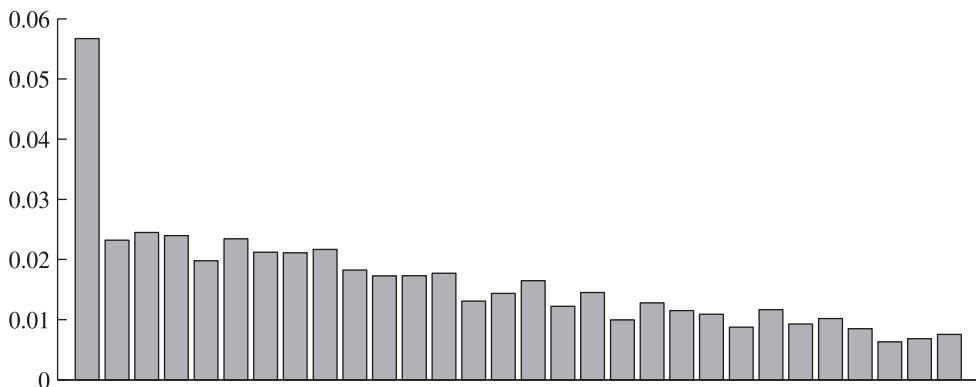


图 5.12 市值因子 30 等分的收益情况

最后来看 30 等分的情况。图 5.12 展示了将所有股票按照流通市值大小划分为 30 等份，每一等份中的股票又按照等权重进行组合时，30 个等份各自的平均月度收益率。最高收益率是第 1 等份的 5.67%，第 2 等份的收益率就下降至 2.32%，降幅在图中表现的非常明显，而后面的 29 个等份则基本表现出一定的下降趋势，第 30 等份的收益率情况为 0.75%。




图 5.13 市值因子前 1/30 的股票组合净值走势

在确定了逐月的排序和 30 等分之后，也就得到了通过市值因子选出的第 1 等份股票组合的逐月变动详情。图 5.13 中的实线展示了 30 等分的情况下，以 1 为初始值的市值因子选股策略净值走势，虚线则是用来进行比较的沪深 300 指数。该图的走势情况与图 5.10 非常相似，但是整个交易过程的净值增幅更加突出，2015 年 6 月收盘时的策略净值为 19.6552，而且末尾没有如图 5.7 和图 5.9 一般略有下降，而是在交易结束时达到了净值的最大值。整个四年半期间的策略收益率为 1865.52%，折算下来的年化收益率达到 93.84%。

图 5.14 则是将逐月的将市值因子排序前 1/30 的股票组合收益率减去沪深 300 指数的收益率后，所得到的收益率序列形成的净值走势。净值从 2010 年 12 月收盘的 1 开始，在 2015 年 6 月收盘时达到 12.5894，四年半的收益率为 1158.94%，折算下来的年化收益率为 75.57%。四年半之间的最大回撤率为 39.89%，回撤的开始点为 2014




图 5.14 市值因子前 1/30 的股票组合与沪深 300 收益之差的净值走势

年 12 月收盘的 3.2663，结束点则是 2015 年 1 月收盘的 1.9633，回撤期只有一个月，较之 10 等分的情况又减少了一个月，即 2014 年 12 月。另外通过对比可知，三种等分方法的回撤水平其实相差都不大。

5.3 反转因子

反转因子是另外一个比较重要的选股因子，在实际的金融市场上，股票往往对当前的信息存在过度反应的现象，因此在短期内具有回复到正常状态的动力，从股价上看就是一种反转的行为。一般情况下，如果研究使用的是月度的股票数据，那么常常将上一个月的收益率作为反转因子使用，从而描述短期内资产价格对信息的过分反应。在阿斯内斯等人的四因子模型当中，普通的动量因子一般定义为一年前到上上个月的收益率，略过上个月的收益情况，也正是因为这种反转现象的存在。这种过度反应导致的反转，会使得股票的未來收益率随着上月收益率的增加而呈现出逐渐下降的趋势，简单来说，就是上个月收益率越低的股票，下个月的收益情况往往越好。从后面的实际数据分析中可以发现，对于中国的股票市场，上月收益反转因子同样是一个存在盈利能力的选股因子。但是值得注意的是，其在样本期的末尾也经历了一段失效时间，并且与市值因子的失效时间几乎重合。因此在那几个月中，使用因子选股策略的基金

普遍产生亏损并不简单是市值因子失效的问题，市场特征发生变化导致若干个有效因子同时出现问题才是深层次的原因。

为了研究这个选股因子，作者获取的同样是自1991年1月开始直到2015年6月结束的国内股票月度数据。所选股票的范围涵盖在深圳证券交易所和上海证券交易所进行交易的所有A股，月度数据则是所有这些股票在月末收盘时的复权后月度收益率。开始挑选股票进行买卖的时间也从2010年12月收盘开始，也就是说在回溯测试样本中将一共交易四年半的时间。1991年1月收盘到2010年12月收盘的所有复权后月度收益率数据作为开始买卖股票前的备用数据，不过对于单因子的简单判断只需要用到2010年12月这一个月数据。研究内容也跟上一节一样，同时兼顾因子有效性测试和单因子选股策略两个方面，先将股票按照上月收益反转因子排序分成若干个等份，从而研究因子大小和未来收益的相关关系，然后再选取排序中的第一等份建立仓位，进而研究反转因子选股策略的收益情况。整个交易过程也设定为只进行买入和卖出操作，不进行卖空操作，资金全部持有股票。

需要特别指出的是，上月收益反转因子和市值因子都有一个比较好的特性，那就是数据在金融资产进行交易时可以实时获取，该特性源自于这两个因子同属于市场数据。当量化交易策略研发人员研究的不是市场数据而是某些财务数据时，这些数据可能会由于财务报表披露的延时而无法实时得到，交易时间点下数据库所显示的数据往往在实际交易中是无法获得的，也就产生在第3章中提到过的未来信息的问题。上月收益反转因子和市值因子都不存在这样的问题，回溯测试中按照数据库所显示的数据直接进行研究即可。这也是作者选择这两个因子作为案例的原因之一。

与上一节相同，作者将所有股票按照因子大小排序划分为3等份、10等份、30等份共三种情况来加以研究。图5.15展示了将所有股票按照上月收益率大小划分为3等份，每一等份中的股票又按照等权重进行组合时，3个等份各自的平均月度收益率情况。具体的收益率大小分别为1.95%、1.71%和0.84%。第1等份和第2等份之间的月度收益率相差较小为0.24%，而第2等份和第3等份之间的差距则更大一些，为0.87%，约等于第3等份本身的收益率。划分为3个等份的情况下，下降趋势是比较明显的。




图 5.15 反转因子 3 等分的收益情况

确定了逐月的排序和 3 等分之后，就可以得到第 1 等份股票组合的逐月变动情况，也就是反转因子选股策略的交易详情。图 5.16 中的实线展示了使用反转因子选股策略进行交易的情况下，以 1 为初始值的策略净值走势，虚线则是用来对比的同期沪深 300 指数走势。策略净值在 2015 年 6 月底达到 2.8431，四年半的策略收益率为 184.31%，折算下来的年化收益率为 26.14%。




图 5.16 反转因子前 1/3 的股票组合净值走势

图 5.17 是逐月的将反转因子排序前 1/3 的股票组合收益率减去沪深 300 指数的收益率后，所得到的收益率序列形成的净值走势情况。净值从 2010 年 12 月收盘的 1 开始，在 2015 年 6 月底达到 1.8439，四年半的收益率为 84.39%，折算下来的年化收




图 5.17 反转因子前 1/3 的股票组合与沪深 300 收益之差的净值走势

益率为 14.57%。四年半之间的最大回撤率为 38.43%，回撤的开始点为 2014 年 10 月收盘的 1.9495，结束点则是 2015 年 1 月收盘的 1.2003，一共三个月的回撤期与市值因子 3 等分的情况完全一致。




图 5.18 反转因子 10 等分的收益情况

然后是划分为 10 等份的情况。图 5.18 展示了将所有股票按照上月收益率大小划分为 10 等份，每一等份中的股票又按照等权重进行组合时，10 个等份各自的平均月度收益情况。第 1 等份的月均收益率为 2.00%，而第 2 等份的月均收益率略高，为 2.01%，也是 10 个等份中最高的，第 10 等份的月均收益率最低，为 0.12%。整体上

来看，除了第 2 等份略高于第 1 等份以外，其他部分均表现出了下降的趋势。相对而言，最后两个等份，特别是第 10 等份的月均收益率下降幅度是比较大的。




图 5.19 反转因子前 1/10 的股票组合净值走势

在确定了逐月的排序和 10 等分之后，也就得到了通过上月收益反转因子选出的第 1 等份股票组合的逐月变动详情。图 5.19 中的实线展示了使用反转因子选股策略进行交易时，以 1 为初始值的净值走势情况，虚线则是用来对比的沪深 300 指数走势。策略净值在 2015 年 6 月底达到 2.9113，四年半的策略收益率为 191.13%，折算




图 5.20 反转因子前 1/10 的股票组合与沪深 300 收益之差的净值走势

下来的年化收益率为 26.80%。

图 5.20 则是逐月的将反转因子排序前 1/10 的股票组合收益率减去沪深 300 指数的收益率后，所得到的收益率序列形成的净值走势。净值从 2010 年 12 月收盘的 1 开始，在 2015 年 6 月底达到 1.8792，四年半的收益率为 87.92%，折算下来的年化收益率为 15.05%。四年半之间的最大回撤率为 40.46%，回撤的开始点为 2014 年 10 月收盘的 1.9684，结束点则是 2015 年 1 月收盘的 1.1720。

最后来看划分为 30 等份的情况。图 5.21 展示了将所有股票按照上月收益率大小划分为 30 等份，每一等份中的股票又按照等权重进行组合时，30 个等份各自的平均月度收益情况。第 1 等份的月均收益率最高，为 2.19%，第 30 等份最低，为 -0.75%。第 29 等份和第 30 等份之间的月均收益率相差 1.32%，相对较大，在图中也能看到一个非常明显的收益率由正转负的变化。与此同时，最后几个等份展现了比前面等份更为明显的下降趋势。




图 5.21 反转因子 30 等分的收益情况

在确定了逐月的排序和 30 等分之后，也就得到了通过反转因子选出的第 1 等份股票组合的逐月变动详情。图 5.22 中的实线展示了 30 等分的情况下，以 1 为初始值的反转因子选股策略净值走势，虚线则是用来进行比较的沪深 300 指数走势。到 2015 年 6 月底策略净值达到 3.2234，四年半的策略收益率为 222.34%，折算下来的年化收益率为 29.71%。




图 5.22 反转因子前 1/30 的股票组合净值走势

图 5.23 则是逐月的将上月收益反转因子排序前 1/30 的股票组合收益率减去沪深 300 指数的收益率后，所得到的收益率序列形成的净值走势情况。净值从 2010 年 12 月收盘的 1 开始，在 2015 年 6 月底达到 2.1051，四年半的收益率为 110.51%，折算下来的年化收益率为 17.99%。四年半之间的最大回撤率为 40.19%，回撤的开始点为 2014 年 10 月收盘的 2.1441，结束点则是 2015 年 1 月收盘的 1.2824。可以发现，不同于市值因子的情况，反转因子不论是 3 等分、10 等分还是 30 等分，最大回撤都发生在相同的三个月当中。




图 5.23 反转因子前 1/30 的股票组合与沪深 300 收益之差的净值走势

5.4 多因子选股策略的简单优化

在本章开头的部分，作者简单介绍了多因子选股策略是如何在若干个有效因子基础之上进行构建的。随后作者展示了两个因子的实际案例，可以看到，流通市值因子和上月收益反转因子在所研究的样本数据之上是两个具有预测效力和盈利能力的选股因子。在这一节中，作者就将这两个因子组合成多因子模型并用来选择股票，这样的做法一来遵循循序渐进的过程，二来也简化了多因子策略的复杂度，用最基本的两个选股因子来做直观的案例展示，从来方便读者更好的了解多因子选股策略的整体框架。需要注意的是，本书中使用的两个选股因子都在2014年年底、2015年年初出现了比较极端的失效情况，因此多因子选股策略会相应的经历一个短暂但程度较重的回撤也是必然的结果，这在本节和第8章中的实际案例里都会有具体的体现。不过就多因子选股策略的本质而言，有效因子越多、因子配置越均衡，多因子选股策略受到单因子失效影响的程度也就会越小，这其实和投资组合配置的情况是类似的，实际交易中研究人员还是应该尽可能的多发掘出一些相关性较小的选股因子，从而增强多因子选股策略的稳健性。

为了研究多因子选股策略，作者获取的同样是自1991年1月开始直到2015年6月底结束的国内股票月度数据。所选股票的范围涵盖在深圳证券交易所进行交易的所有A股，包括主板、中小企业板和创业板三个板块，以及在上海证券交易所进行交易的所有A股。月度数据则包括月末收盘时股票的复权后月度收益率，以及股票的月度流通市值，这其实与单个市值因子研究中的样本数据完全一致。但是在进行线性回归之前，需要对流通市值进行对数化处理，其目的是为了更好的反映出月度收益率和流通市值之间的线性关系。当然，还应该存在着更为适合的数据预处理手段，使得因子和收益率之间的线性关系更加明晰。不过这属于第2章第2节中提到的过的数据准备工作，不在本书讨论范围之内，因此不再做深入研究，读者可以在研究过程中自行摸索合理的处理方法。

开始挑选股票进行买卖的时间同样从2011年12月收盘开始，也就是说在回溯测试样本中将一共交易四年半的时间。1991年1月到2010年12月的所有月度流通市

值数据和月度收益率则作为开始买卖股票前的备用数据，不过对于本节中简单的多因子选股策略而言也只需要用到2010年12月这一个月数据。而在整个交易过程中，回溯动作也设定为只进行买入和卖出操作，不进行卖空的操作，资金全部用于持有股票，与单因子的研究环境一致。

回溯测试的过程如下，在第一个选股和交易的时间点，即2010年12月收盘时，将此时所有股票的月收益率、流通市值与2011年1月的收益率进行匹配，并进行回归估计，如下所示：

$$r_{2011-1} = a + b_1 S_{2010-12} + b_2 r_{2010-12}$$

其中 r_t 是2011年1月的月收益率， S_{t-1} 是2010年12月收盘时股票的流通市值， r_{t-1} 是2010年12月的月收益率，通过估计该回归式可以得到针对2011年1月的 a 、 b_1 、 b_2 三个参数估计值。然后将时间按月份向后推进，每个月都可以得到一组参数估计值，直到2015年6月收盘时结束，一共54组估计参数。然后将54个 a 进行平均得到 \bar{a} 、将54个 b_1 平均得到 \bar{b}_1 、将54个 b_2 平均得到 \bar{b}_2 ，那么基于整个样本所得到的最终回归结果就是

$$r_t = \bar{a} + \bar{b}_1 S_{t-1} + \bar{b}_2 r_{t-1}$$

同第4章中所介绍的简单择时策略一样，作者在估计完回归式之后，又会将该回归式用到相同的样本数据上进行交易的模拟。虽然这样会产生未来信息的问题，但是相对简单的流程处理可以方便读者进行理解。具体来说，就是在2010年12月收盘的选股时间点上，基于2010年12月所有股票的月度流通市值和月度收益率数据，使用最终得到的回归式计算得到所有股票在2011年1月的收益率的预测值。然后将股票按照收益率预测值从高到低进行排序，再按顺序等分为若干个部分，每一等份中的股票又按照等权重进行组合，也就是买入占用的资金量相等的组合。然后在2011年2月底进行相同的排序和等分过程，各个等份中的股票组成基于预测收益率排序的变化而发生改变。之后每个月收盘时都进行相同的操作，直到交易样本结束即2015年6月收盘为止。

排序完成之后的处理，与单因子的研究内容完全一致。首先根据每一个等份下长

度为 54 的收益率序列，计算出各个等份的平均月度收益情况，进而判断多因子模型预测下一期收益率的整体趋势性。不过由于多因子模型本身的作用不在于挑选合适的因子，因此这一部分的结果仅作参考，实际意义小于其在单因子研究中的作用。交易策略方面，则根据排序中的第一个等份选择股票，这也就是每个月多因子选股策略所选择的股票组合。根据这个长度为 54 的收益率序列，就可以计算出多因子选股策略的净值走势。需要指出的是，多因子选股模型预测的是下一个月各支股票的收益率水平，因此按预期收益从大到小排序，排序第一的股票就应该是建仓的选择，这是符合交易逻辑的。而本书中挑选出来的两个单因子恰好都是收益预期与因子大小具有反向关系，因此按照因子从小到大进行排序，建仓选择才是排序第一的股票组合。希望读者能够区分这之间的差别。




图 5.24 多因子选股 3 等分的收益情况

和单因子的研究设置相仿，作者将所有股票按照预期收益大小排序划分为 3 等份、10 等份、30 等份共三种情况来加以研究。首先来看 3 等份的情况，图 5.24 展示了将所有股票按照多因子模型的预期收益大小划分为 3 等份，每一等份中的股票又按照等权重进行组合时，3 个等份各自的平均月度收益情况。具体的收益率大小分别为 2.43%、1.53%、0.53%。等份之间的差额分别为 0.9% 和 1%，呈现出一个比较稳定的下降趋势。

确定了逐月的排序和 3 等份之后，就可以得到第 1 等份股票组合的逐月变动情况，也就是多因子选股策略的交易详情。图 5.25 中的实线展示了使用多因子选股策略




图 5.25 多因子选股前 1/3 的股票组合净值走势

进行交易的情况下，以 1 为初始值的策略净值走势，虚线则是用来进行对比的同期沪深 300 指数走势。策略净值在 2015 年 6 月收盘时达到 3.6539，四年半的策略收益率为 265.39%，折算下来的年化收益率为 33.37%。




图 5.26 多因子选股前 1/3 的股票组合与沪深 300 收益之差的净值走势

图 5.26 则是逐月的将多因子选股排序前 1/3 的股票组合收益率减去沪深 300 指数的收益率后，所得到的收益率序列形成的净值走势。净值从 2010 年 12 月收盘的 1 开始，在 2015 年 6 月底达到 2.3364，四年半的收益率为 133.64%，折算下来的年化

收益率为 20.75%。四年半之间的最大回撤率为 40.50%，回撤的开始点为 2014 年 10 月收盘的 2.3757，结束点则是 2015 年 1 月收盘的 1.4136，一共三个月的回撤期与两个单因子的研究一致。




图 5.27 多因子选股 10 等分的收益情况

然后是划分为 10 等份的情况。图 5.27 展示了将所有股票按照多因子模型的预期收益大小划分为 10 等份，每一等份中的股票又按照等权重进行组合时，10 个等份各自的平均月度收益情况。第 1 等份的月均收益率是 10 个等份中的最高值，为 2.78%，第 10 等份的月均收益率则是 10 个等份中的最低值，为 0.14%。其他等份也按照排序




图 5.28 多因子选股前 1/10 的股票组合净值走势

关系存在严格的下降趋势，而且下降的幅度也比较稳定。与前两节中的单因子研究对比起来，可以发现多因子模型使得等分下的未来收益率具有更平稳的趋势。

在确定了逐月的排序和 10 等分之后，也就得到了通过多因子模型选出的第 1 等份股票组合的逐月变动详情。图 5.28 中的实线展示了使用多因子选股策略进行交易时，以 1 为初始值的净值走势情况，虚线则是用来对比的沪深 300 指数走势。策略净值在 2015 年 6 月底达到 4.3883，四年半的策略收益率为 338.83%，折算下来的年化收益率为 38.91%。

图 5.29 则是逐月的将多因子选股排序前 1/10 的股票组合收益率减去沪深 300 指数的收益率后，所得到的收益率序列形成的净值走势。净值从 2010 年 12 月收盘的 1 开始，在 2015 年 6 月底达到 2.7747，四年半的收益率为 177.47%，折算下来的年化收益率为 25.46%。四年半之间的最大回撤率为 41.79%，回撤的开始点为 2014 年 10 月收盘的 2.6863，结束点则是 2015 年 1 月收盘的 1.5638。




图 5.29 多因子选股前 1/10 的股票组合与沪深 300 收益之差的净值走势

最后来看划分为 30 等份的情况。图 5.30 展示了将所有股票按照多因子模型的预期收益大小划分为 30 等份，每一等份中的股票又按照等权重进行组合时，30 个等份各自的平均月度收益情况。第 1 等份的月均收益率同样也是 30 个等份中的最高值，为 2.89%，第 30 等份的月均收益率也是 30 个等份中的最低值，为 -0.25%。其他等份

的收益情况也基本显示出一个比较平稳的下降趋势，同样对比前两节中的单因子研究可以发现，多因子模型使得等分下的未来收益率具有更平稳的趋势。




图 5.30 多因子选股 30 等分的收益情况

在确定了逐月的排序和 30 等分之后，也就得到了通过多因子模型选出的第 1 等份股票组合的逐月变动详情。图 5.31 中的实线展示了 30 等分的情况下，以 1 为初始值的多因子选股策略净值走势，虚线则是用来进行比较的沪深 300 指数走势。策略净值在 2015 年 6 月底达到 4.6520，四年半的策略收益率为 365.20%，折算下来的年化收益率为 40.72%。




图 5.31 多因子选股前 1/30 的股票组合净值走势




图 5.32 多因子选股前 1/30 的股票组合与沪深 300 收益之差的净值走势

图 5.32 则是逐月的将多因子选股排序前 1/30 的股票组合收益率减去沪深 300 指数的收益率后，所得到的收益率序列形成的净值走势。净值从 2010 年 12 月收盘的 1 开始，在 2015 年 6 月底达到 2.9179，四年半的收益率为 191.79%，折算下来的年化收益率为 26.87%。四年半之间的最大回撤率为 43.08%，回撤的开始点为 2014 年 11 月收盘的 2.9003，结束点则是 2015 年 1 月收盘的 1.6508，回撤期的长度为两个月。

第 6 章 推进分析

6.1 推进分析框架

在第 4 章和第 5 章的策略研究当中，由于回溯测试过程简单化的处理，因此不可避免的会受到未来信息问题的影响。与此同时，最优化的处理只在整个样本数据上进行了一次，因此如果只分析回溯测试的结果，研究人员无法判断研发得到的具体策略是否具有过度拟合的问题。在这一章中，作者就将介绍一种具有实践意义的分析方法来处理这些问题，也就是章节名称所提到的推进分析。在具体说明推进分析的框架和使用方法之前，本节首先介绍一下与推进分析有着极高关联性、但是适用范围更加广泛的样本外检验，方便读者循序渐进的了解推进分析的框架结构，更好的掌握这种研究方法。




图 6.1 样本外检验示例

样本外检验是一种被广泛应用于数据科学研究当中的检验方法。在数据科学的一般研究情况下，样本外检验的功能主要是用来判断对数据的处理方法是否存在明显的过度拟合。图 6.1 给出了一个样本外检验的示例用以说明，先忽略下面的时间轴，实际上样本外检验就是将整个样本分为两个相互不重叠的部分，也就是白色的样本内和灰色的样本外。首先针对样本内的数据进行模型的研究和优化，得到一个在样本内数据上最优的模型方法，再将已经优化完成的模型方法直接放入样本外的数据进行检验，如果样本外的数据检验结果依然说明该模型方法具有显著的效果，那么就可以在一定程度上判断出该模型方法对实际问题处理的有效性。对于在样本内优化得到的具体模型方法，比较其在样本内和样本外数据上各自的效果，两者越接近，那么该模型方法

在样本内进行优化时的过度拟合问题就越小。在样本内、样本外的示例下面加上一个时间轴，是为了指出在处理资产价格等具有时间特征的数据时，往往将样本内的部分取在时间段前期，而将样本外的部分取在时间段后期。当然，将样本外的部分放在时间轴的前面，甚至将样本外分为两部分置于样本内的前后两端，都是可以接受的处理方法，符合样本外检验的基本定义。但是相比较而言，图 6.1 的样本处理方式更加合乎逻辑，更为贴合时间流逝下的数据特征。因此一般而言，这是一种更被接受的处理方法。

量化交易策略的研发作为数据科学的一个专业化分支，实际上是可以直接使用样本外检验来进行过度拟合的判断的。但是正是由于量化交易策略研发作为一个分支，具有自身的特殊性和专业性，因此存在一些更为合适的研究方法来判断过度拟合的问题。推进分析正是其中比较具有代表性的一种方法，其不仅可以判别量化交易策略的过度拟合程度，同时具有其他一些比较好的性质特点，是量化交易策略的研究中比较常见且值得使用的检验方法。




图 6.2 推进分析示例

图 6.2 给出了一个推进分析的示例。最下面的数字代表随时间前进的交易周期，例如在第 4 章量化择时策略的数据下，每个数字都代表 1 日，在第 5 章量化选股策略的数据下，每个数字都代表 1 个月，而如果使用的样本数据为分笔数据的话，那么每一个数字都代表两次分笔数据到达的间隔。也就是说，推进分析的计算周期、或者说推进周期应该以交易判断的间隔为准，而不是以某一个固定的时间长度为准，日度数

据和月度数据的例子只是因为判断交易的时间间隔恰好是日和月而已。

首先来看图中离计数条最近的一行白色框加灰色框，这里的操作类似于图 6.1 中的样本外检验过程。其中白色框包括从周期 1 到周期 5 的数据，灰色框则是周期 6 的数据。假设研究人员要检验的是一个参数待估计的量化交易策略，现在先基于白色框的数据对其进行最优化，得出相应的参数，然后将参数确定好的策略放入灰色框的数据中进行检验，得到相应的结果。优化的具体目标既可以是量化交易策略的整体收益情况，也可以是一个具体模型的预测能力，这在前面的说明和案例讲解中均有涉及，这里就不再多做赘述了。可以发现，针对这一行数据的研究操作实际上就是一个样本外检验的过程，但是该检验具有一个明显的特点，就是样本外的数据长度仅为一个交易周期。

随后的操作基本上就是推进分析这个名称的由来。将样本内和样本外两个部分分别按照时间前进的方向向后推进一个周期，白色框的样本内数据变为了周期 2 到周期 6 的数据，灰色框的样本外数据则变成了周期 7 的数据。同样的，先基于白色框的数据对其进行最优化，得出相应的参数，然后将参数确定好的策略放入灰色框的数据中进行检验，得到对应的结果，这也就是第二行数据得到的样本外检验结果。之后则每次推进一个周期，进行相同的检验操作，如图 6.2 中的上面 6 排，每一行数据都有一个周期下的样本外检验结果。最后将所有灰色框的检验结果汇总，就可以得到从第 6 个周期直到结束的推进分析检验结果，作者也称其为全部样本下的推进分析检验结果。值得注意的是，如果具体的量化交易策略本身需要备用数据来参与计算，那么整个研究实际需要的数据量将超过计数框的限制，提前到周期 1 之前。灰色框的检验计算也需要用到白色框中的数据，从而完成策略的计算。这些内容在图中都没有显示出来，希望读者自行理解。

从上面对推进分析的介绍中其实不难发现，推进分析的整个操作流程非常贴合实际交易的情况。在实际环境中如果使用量化交易策略进行交易，使用者常常会先根据最近的数据优化好策略设置和策略参数之后，再用其来指导当前的交易，而在下一次需要判断是否交易时，再重新优化一遍策略设置和策略参数，从而使得策略更好的反映最近的市场情况。从宏观来看，市场是在一直变化的，因此针对距离交易时刻更近

一些的数据进行特征的挖掘和策略的开发,就能够更好的保证特征的存留以及策略的及时有效,是一个符合基本直觉的做法。而在交易资产或者金融市场出现转折点时,转折点前后的优化结果会根据转折本身的特性进行变化,这样的做法就可以更好的应对这种性质或环境的突然转变。同时,市场虽然不停的变化,但是这种变化本身在大多数情况下又是趋于稳定的,因此从过往一段时间内提取出的数据特征和相应的策略在一次交易周期内仍然有很大可能是值得信赖的。从操作的选择上来看,就是用来优化的时间段越长,则提取出的特征和策略就会由于数据量的增加而更加可信,而时间段越短,则提取出的特征和策略就越具有时效性,策略越灵活,也越容易快速的度过转折点前后的失效期。

本书主要讨论的是中低频的量化交易策略,由于交易频率较低,交易的及时性要求不是特别高,因此在使用量化交易策略进行每一次的交易判断之前,用来进行策略优化的时间和计算空间往往是比较充足的,最近数据的延迟也基本可以忽略,因此量化交易策略的实际使用者会更倾向于做这样的优化处理。相较于较为简单的样本外检验,推进分析可以在回溯测试的过程中更为精准的反映出这种实际的处理方式。每一次优化都推进一个周期的形式,实际上就是在回溯的环境下复制实际交易中每次判断前都优化策略的做法,这也是作者在第3章第3节中曾经提到过的,让回溯测试环境尽量与真实交易环境保持一致的最优解决方案。正是由于这种贴近真实交易的特性,在判断策略盈利能力时,推进分析下的模拟交易情况具有更高的参考价值。

当然,同样本外检验的初衷一样,推进分析的首要目的实际上也是判断量化交易策略具有多大程度的过度拟合问题。仍然用图6.2来做演示,对于推进过程中的每一行而言,具体的操作都相当于一次样本外检验。如果回溯测试中所使用的量化交易策略的刻画超过了数据本身的内在特征,那么在所有样本内部分都会具有过度拟合的问题,实际的反映就是针对每一行的数据集,灰色框的样本外检验结果都将大概率的劣于白色框的优化结果。当一个特征在每一行数据的检验过程中发生的概率都较大时,将多行结果合并到一起就可能会出现统计上的明显表现。因此,假如量化交易策略并不具备挖掘数据内在特性的能力,也就是不具备真实的盈利能力或预测能力,那么综合所有灰色框一起考虑时,整体结果就很可能缺乏显著的盈利性或预测准确性。从

上面的叙述中可以发现，推进分析的检验过度拟合和判断策略实际盈利能力这两个功能，在一定程度上是相互融合的。

同时，推进分析可以在回溯测试当中较为有效的排除未来信息的存在。依然采用图 6.2 的例子进行说明，在每一行的数据集中，都是首先针对白色框的样本内数据进行优化，然后将优化后的具体交易策略代入与样本内数据无交集的样本外数据进行检验。这种回溯测试的方法完全不同于第 4 章和第 5 章中作者介绍择时、选股策略时所采用的简单框架，数据的优化和检验在时间轴上是分开而且具有严格先后顺序的，因此也就在很大程度上规避了回溯测试中存在的未来信息问题。总体来看，推进分析这一回溯测试工具比较全面的照顾到了第 3 章中作者介绍的几个需要注意的事项，是一个在研究量化交易策略时相对而言较为稳妥的解决方案。




图 6.3 计算紧张时改动的推进分析示例

在实际的量化交易策略研发中，有时候会由于使用的策略方法计算量过大而导致完全按照推进分析的流程进行检验出现困难。一般而言，样本内优化需要的计算量远远大于样本外检验的计算量，因此当出现计算量过大、计算机处理水平不足的问题时，可以通过降低最优化处理的频率来有效减小总体的计算量。图 6.3 基于图 6.2 中的示例，给出了一个经过改动的推进分析的例子用以说明。在这个例子当中，仍然先基于周期 1 到周期 5 的数据进行优化，但在得到参数确定的量化交易策略之后，将其放置于周期 6 和周期 7 的数据上进行检验。也就是说，在周期 7 上运行的策略同样也是经过周期 1 到周期 5 数据优化得到交易策略，那么图 6.2 中前两行的计算过程就简化为图 6.3 中的第一行的计算，计算量几乎减小了一半。在图 6.3 中，第一行的数据处理完成之后，第二行中用来优化策略的是周期 3 到周期 7 的数据，样本外检验则包括周期 8 和周期 9 的数据，以此类推，每一次都推进两个周期。因此整体而言，计算量也

就几乎减小到图 6.2 中推进分析的一半。

当然，这样的改动在节省计算量的同时，也会随之生成一些其他的问题。首先，这样的回溯测试过程不能够再精细的体现出实际交易下不断优化更新策略的操作过程。当然，对于在实际交易中每隔一段时间优化一次策略的使用者而言，这样的改动反而能够更好的刻画现实情况，如何选择需要根据实际情况进行判定。最重要的是，在假设市场稳定变化的前提下，这样合并检验数据的做法会使得策略的有效性受到损害。以图 6.3 为例而言，相较于图 6.2 中的标准推进分析过程，使用周期 1 到周期 5 的数据优化得到的量化交易策略，会由于交易资产和市场数据的变化而对周期 7 的数据适应能力变差，周期 9、11、13 下的检验情况也类似。因此，这样的改动虽然会降低量化交易策略回溯测试的计算量，但是也会同时增加判断策略真实能力的难度，在计算能力可以支撑的情况下作者并不推荐这种做法。另一方面，如果实际交易也是间隔一段时间优化一次策略，那么对于相隔较远的交易决策而言，策略的适应能力同样会降低，进而弱化盈利能力。鉴于在真实交易环境下优化操作只需要进行一次，因此硬件的计算能力往往并不是策略运行的制约因素之一，在这种情况下，作者其实更不推荐在实际操作中降低中低频量化交易策略优化的频率。对于作者的这一观点，读者可以自行进行判断。

6.2 多层推进分析

推进分析通过先优化策略参数，然后将量化交易策略置于其后的数据进行检验的方法，可以较为有效的对策略所具有的过度拟合问题进行判断。但是值得注意的是，在进行推进分析的过程中，研究人员有时仍然会将一些参数固定从而方便研究。用第 4 章提到的自回归策略举例而言，当研究人员使用自回归模型预测下一个周期的收益率时，虽然自回归的具体回归系数会在逐次优化中不断的被估计出来，但是自回归的阶数设置往往会被研究人员在整个推进分析中固定为一个常数。这种固定阶数的做法对于推进分析的某次操作本身是没有任何影响的，但是问题在于，如果一个研究人员在试验了阶数为 5 的自回归择时策略、发现其推进分析的结果没有显著盈利能力之

后，又试验了阶数为 6、7、8、9、10 的自回归择时策略，最后发现 9 阶自回归模型构建的择时策略具有一定的盈利能力，并将其确定为实盘使用的交易策略，就会产生过度拟合检验不完全的情况。在这个例子下，阶数实际上可以被看作是策略的一个具体参数，对不同阶数的自回归策略都进行测试并选择结果最优的一种，也就可以被视为一次最优化的过程。但是直到决定使用 9 阶自回归策略进行实盘操作为止，研究者都没有针对这一参数分析其过度拟合的情况。

在大多数模型优化方式比较固定的情况下，这种模型设置类的参数都是难以和模型系数一起进行优化的，因而常常会被研究人员在推进分析中设置为某一固定值。例如上面所举的例子中，自回归模型的回归系数估计一般都会使用普通最小二乘法等计量经济学中常用的估计方法来完成，这些方法本身是不能用来同时优化自回归模型的阶数设置的。更为明显一些的例子，是采用诸如人工神经网络这样的机器学习算法进行构建的量化交易策略，这些算法的拟合技巧往往都较为复杂，而且在长时间的科学研究过程中会固化出一些公认的有效处理方法，甚至包括诸如模型预训练这样的复杂操作，不易变动。因此在绝大多数情况下，试图更改这些拟合方法进而同时优化人工神经网络隐层节点数之类的参数都是不切实际的。其他一些情况包括支持向量机中的核函数选择等，虽然不再是一个直接的参数，但是仍然能够通过人为控制来改变整个策略的实际效能，因此尝试多种核函数的做法同样等同于最优化的过程。或者更为隐蔽的训练样本大小，也应该被看作为一种参数，只不过这种参数来自于对推进分析本身的设置。以图 6.2 所展示的推进分析为例，如果研究者分别在白色框长度为 3、4、5、6、7 等设定的推进分析框架下测试了同一种量化交易策略，最后发现长度为 5 时策略收益最高，并在实际运行中也将优化期固定为 5 个周期，那么就同样缺乏对于白色框长度这一设置的过度拟合程度判断。

这一节中将要介绍的多层推进分析，正是为了缓解这一问题而针对推进分析流程进行的改进。多层推进分析的原理叙述起来较为简单，就是在推进分析的基础之上，针对进行交易的灰色框序列再做新的推进分析，从而研究上一层推进分析中无法优化的参数的过度拟合情况。但是实际上，在量化交易策略研究当中，多层推进分析的逻辑其实较为复杂，如果不小心处理就有可能会出现细节上的错误。在研究人员较难驾

驳这种复杂逻辑的情况下，作者建议最好避免使用这种方法，为了测试一些参数的过度拟合程度而导致整个回溯测试结果的不可信，其实是得不偿失的。当然，接下来依然要介绍这种方法的具体操作流程，读者可以在量化交易策略的研发过程中基于现实情况来判断使用与否。




图 6.4 多层推进分析示例

图 6.4 在图 6.2 所展示的推进分析的基础上，给出了一个两层推进分析的示例用以说明。在图 6.2 中，每一个灰色框都是所在行的样本外数据，而在图 6.4 中，一部分的灰色框除了作为第一层推进分析的样本外数据以外，同时还是第二层推进分析的样本内数据，用以优化在第一层推进分析中无法同时优化的参数。以第二层推进分析中的第一行为例，在第二层参数固定为某定值的情况下，如同图 6.2 中所做的一样，基于周期 1 到周期 5 的数据进行优化得出一个最优策略，应用在周期 6 的数据上就可以得到该交易策略在周期 6 的收益率，同理，周期 7 可以根据周期 2 到周期 6 的数据优化出一个最优策略并得到相应的收益率，依此类推直到周期 10 为止。综合周期 6 到周期 10 的收益率结果，就可以得到第二层参数设为该定值时这 5 个周期上的策略

收益情况，之后更换第二层参数的设置，重复上述过程，得到其他参数情况下的策略收益率。在获得第二层参数所有可能取值下的策略收益率后，就可以选出收益情况最好的一个或一组参数，这一轮操作可以看作是第二层推进分析中的样本内优化过程，如图中的浅灰色部分所示。

在得到第二层参数的优化值之后，将策略中相应的设置固定为该优化值，然后回到第一层推进分析当中，基于周期 6 到周期 10 的数据，对第一层推进分析的参数进行优化并得到优化结果。这样，针对周期 11 而言，使用前期数据同时得到了最优的第一层参数值和第二层参数值，将基于这些参数设置的策略应用到周期 11 的数据之上，就可以得到一个两层推进分析的样本外交易结果，如图 6.4 中的深灰色框所示。至此，针对第二层推进分析中第一行的操作全部完成。

然后将所有的时间窗向后推进一个周期，进行同样的工作，可以完成第二行的操作。通过不断的向后推进一个周期直到整个数据样本结束，就可以得到多行的第二层推进分析结果，当然图 6.4 受空间所限只展示了三行。将深灰色框下最优策略的模拟交易结果进行综合，就可以得到该量化交易策略在两层推进分析下的策略净值走势和收益情况，从而判断出第二层参数的过度拟合程度，并更好的对整个策略的真实盈利能力加以判断。

上面介绍的是双层推进分析的具体流程，在第二层推进分析的基础之上，可以采用相似的方法进一步划分数据，进而形成第三层的推进分析。只要数据量足以应对复杂化的推进分析过程，这样的分层就可以持续的进行下去。但是需要注意的是，多层推进分析虽然可以解决一层推进分析无法完全解决的参数优化与过度拟合判断的问题，但是同时会引入新的参数设置，增加整个研发流程的复杂程度。举例而言，当一层的推进分析已经可以在样本内优化所有的策略参数和设置时，这个时候需要固定的参数只有推进分析本身的训练样本大小，即图 6.2 中的白色框长度。此时如果使用双层推进分析来判断训练样本量的设置是否存在过度拟合问题，那么检验的也只是第一层推进分析中的训练样本量参数，而第二层推进分析又会引入一个新的训练样本量设置，即图 6.4 中的浅灰色框长度，同时优化白色框长度时的取值范围也是一个新引入的设置，这些参数、设置依然是人为设定的，并有可能存在未来信息和过度拟合的双

重问题。这样看来，不管多加多少层的推进分析，人为设置的参数总是存在的，多层推进分析不能从根本上解决这个问题。

不过即使是在这种情况下，多层推进分析的引入依然是有一定作用的。在交易资产特性、市场环境缓慢变化的前提假设下，多层推进分析中更高层的设定参数应该比低层的参数变化更加稳定，因此增加推进分析层数而对上一层推进分析的设置进行过度拟合判断是一个相对而言更为稳定、可信性更高的回溯测试流程。但是与此同时，由于多层推进分析提高了整个回溯测试的复杂程度，因此也同时提高了对样本数据量的需求，层数越多需要的样本数据就越多。而遗憾的是，中国的金融市场与资本市场由于历史较短，因此历史数据量相对而言是较少的，同时市场环境、政策法规的频繁变化使得可用的样本数据更为有限，在本书主要讨论的中低频量化交易策略的背景下，多层推进分析往往缺乏实际的使用基础。因此，本节所介绍的方法虽然有其意义所在，但是实际使用需要结合具体情况认真分析，作者在目前的研发环境下即使只应用双层推进分析，也会在处理时相当的谨慎。

6.3 推进分析下的验证

上两节介绍了推进分析和多层推进分析的操作流程，不管是简单的推进分析，还是逻辑更为复杂一些的多层推进分析，其主要目的都在于判断策略参数的过度拟合程度，以及在一个贴近真实交易的环境下模拟出策略的盈利情况。在实际的量化交易策略的使用过程中，通过研究推进分析或多层推进分析得到策略的净值走势和收益情况，就可以基于一定的收益和风险标准决定是否使用该量化交易策略。但是由于推进分析这种方法的主要目的还包括参数过度拟合程度的判断，因此在流程设计上会有所限制，基于推进分析结果直接判断实盘与否的做法在逻辑上也显得不是那么完整。本节就在推进分析的基础上，另外介绍一种用来判断量化交易策略是否进入实际使用的方法，作为前面内容的补充。

实际上，这种方法也是根据样本外检验的原理发展而成的，而综合基本的推及分析来看，方法本身也具有一些数据科学中交叉验证的性质，因此作者称其为推进分析

下的验证。简单来说，就是将推进分析的数据分为两个部分，一个部分进行推进分析的研究，如果结果具有合格的盈利能力，则针对同样的策略在另一部分数据上进行推进分析研究。在实际研究中，后一步的推进分析只进行一次，如果结果显示盈利能力依然存在，则认定该量化交易策略可以实际使用，如果策略不再具有盈利能力，则直接判断策略无用，需要更换策略思路、重新寻找其他策略。需要注意的是，这里作者说的是“更换策略思路”、而不是“更换策略设置”，因此后一次的推进分析实际上是一锤定音的决定性流程。




图 6.5 推进分析下的验证示例

图 6.5 基于图 6.2 给出的推进分析示例，展示了一个推进分析下的验证的具体流程，方便读者更直观的理解推进分析下的验证这一方法。图中的横线将原本的推进分析进行了划分，针对处在横线下方的前 5 行数据，挑选多种不同的策略，各自进行普通的推进分析研究，直到找到一个在这部分样本内具有盈利能力的量化交易策略。然后将该策略置于横线上方的后 3 行数据上，进行一次普通的推进分析，查看深灰色框内的收益情况和策略净值表现，如果仍然具有盈利能力则使用该策略进行实际交易，如果策略失效则否定该策略，重新寻找其他策略。通过如上的示例解释，读者应该可以发现，推进分析下的验证实际上就是一个样本外检验的过程，只不过前面提到的样本外检验都是针对策略模型的具体参数，而这一种样本外检验针对的则是量化交易策略本身。

从对图 6.5 中示例的具体讲解中也可以发现，该方法下样本内外的划分其实可以

看作是对灰色框的划分,也就是划分推进分析中模拟交易的样本外数据部分,在图 6.5 中分别用浅灰色框和深灰色框进行了标示。因此,多层推进分析也同样可以使用这种验证方法来判定策略是否进入实际应用,只需在理解多层推进分析逻辑的基础上,针对最后一层的数据样本进行样本内外的划分即可。

但是正如多层推进分析所存在问题的一样,使用推进分析下的验证同样需要足够数据量的支持。由于中国市场上能够获取的有效数据较为有限,因此研究人员在使用推进分析下的验证前应该首先确认样本量是否充足。更重要的问题在于,作为验证环节的后一次推进分析对策略去留具有决定性的影响,一个实际上有盈利能力的量化交易策略由于在样本数据上无法通过验证从而被淘汰的情况是有可能发生的。在推进分析下的验证中,样本内和样本外的长度设定、样本数据的具体选择等都可能影响验证的结果,偏差较大时就会导致有效策略被错误的排除。而推进分析的验证要起到实际的决定效果,后一次的推进分析就必须严格的只进行一次,否则又会流于一种优化过程而得不到真正的检验。在这种情况下,如果由于人为设置和实际数据特性的影响导致错误的排除了有效策略,是无法通过其他办法进行补救的,研究人员必须承受这种错误发生的可能。当然,是有效策略丢失的问题更严重,还是无效策略被应用到实际交易中的问题更严重,就需要研究者自行判断了。由于推进分析的验证中后一次推进分析只进行一次这样的操作,在纸面上是无法反映出来的,因此本书对这种方法只做介绍,不具体进行案例的说明。

第7章 推进的择时策略

7.1 均线趋势策略的推进分析

第4章第2节介绍了均线趋势策略的基本运行模式，并提供了一个简单的回溯测试案例。在这一节中，作者采用大体上相同的设置进行了均线趋势策略的推进分析，用来模拟实际交易中策略的运转流程，从而得到一个贴合实际环境的策略盈利能力结果，同时判断均线趋势策略两个均线参数的过度拟合程度。双均线趋势策略的具体定义和第4章第2节中保持一致，仍然是在交易决策的时点需要根据已知数据计算短期均线和长期均线两个值，当短期均线高于长期均线时，判断交易决策时刻的趋势为上涨趋势，按照趋势会延续的思想，认为后市会继续上涨，因此看多，而当短期均线低于长期均线时，判断交易决策时刻的趋势为下跌趋势，后市继续下跌，因此看空。具体请参见图4.5和相关叙述。




图 7.1 均线趋势策略的推进分析流程

数据方面也 and 前面所选取的数据一致，交易资产是以中证指数公司编制的沪深300指数为标的物的沪深300股指期货主力合约，收集得到从2010年4月19日到2015年6月30日的日收盘价数据。虽然股指期货可以在最低交易保证金为8%的情况下进行杠杆交易，但是在本节的回溯测试环境下，依然将杠杆率设定为100%进行研究。图7.1展示了均线趋势策略的推进分析在这段时间的样本下是如何进行的。2010

年4月19日到2010年12月30日的日收盘价数据作为计算短期均线和长期均线的备用数据，数据长度为172日，也就是说只要长期均线的长度在173日以下，备用数据都可以支持整个推进分析的计算顺利完成。但是这部分数据的使用在图7.1中没有具体显示，希望读者注意。

在推进分析的第一行操作中，白色框为优化期，从2010年12月31日的收盘开始，直到2011年12月30日的收盘结束，一共244个交易日。在这一部分样本数据下，可以通过测试不同均线组合的交易情况来寻找最优的均线趋势策略参数，具体的操作其实完全等同于第4章第2节中所做的优化过程。由于将所有参数的可能组合都测试一遍的做法存在冗余且具有偏向性，因此优化过程在进行网格搜索时，依然使用斐波那契数列来处理均线的搜索范围，也就是使用1日均线、2日均线、3日均线、5日均线、等等到144日均线一共11种均线的长短组合进行搜索，寻找盈利能力最好的组合，从而确定最优的均线趋势策略形式。同样限定短期均线最大搜索到34日均线，长期均线从短期均线的后一根开始一直到144日均线结束。在这一部分当中，具有一致性的均线趋势策略实际上也等同于“短期均线从下向上穿过长期均线则做多，短期均线从上向下穿过长期均线则做空”。

第一行的优化操作结束之后，则按照最优结果固定短期和长期均线的长度，并用来计算2011年12月30日收盘时刻下的短期均线值和长期均线值。当短期均线值大于长期均线值时，就对2011年12月30日收盘到2012年1月4日收盘的走势看多，如果2011年12月30日收盘时仓位为多头则保持不变，如果不是则通过买入操作将仓位变为多头；当短期均线值小于等于长期均线值时，就对2011年12月30日收盘到2012年1月4日收盘的走势看空，如果2011年12月30日收盘时仓位为空头则保持不变，如果不是则通过卖出和卖空操作将仓位变为空头。

在进行完一行的操作之后，将白色框和灰色框都分别向后推进一日，重复这种样本外检验的过程，直到最后一行为止。前面介绍推进分析时已经说明过，这个时间周期应该以判断交易的间隔为准，在本案例中使用的是日度收盘价数据，因此交易判断的最短间隔也就是一日。最后一行中，用来优化参数的白色框从2014年6月30日收盘开始到2015年6月29日收盘结束，一共244个交易日，与第一行中白色框的长度

一致。虽然在样本期间某些年份的总交易日数可能不是 244 日，但是按照逐日推进一日的操作流程，所有白色框的长度都应该保持为 244。最后一行中被检验的灰色框为 2015 年 6 月 29 日收盘到 2015 年 6 月 30 日收盘，也就是触及到样本数据的最后一个数据。

总的来看，在推进分析的过程中，模拟买卖的行为从 2011 年 12 月 30 日收盘时开始，到 2015 年 6 月 30 日收盘时结束，一共交易三年半的时间，也就是所有灰色框所覆盖的区间。需要单独说明的是，在第 4 章第 2 节均线趋势策略的简单优化中，策略的参数设置在四年半的模拟交易时间内始终保持不变，因此这段时间内的均线趋势策略也等同于“短期均线从下向上穿过长期均线则做多，短期均线从上向下穿过长期均线则做空”。但是这里灰色框所代表的模拟交易期则不同，三年半的时间由相对独立的 845 个交易日组成，对每一个灰色框中运行的均线趋势策略而言，参数设置都由前面 244 个交易日下的优化结果决定，因此会在这三年半期间产生变化。由于灰色框中策略设置的不一致，再用引号内所述的交易思维来看待整个交易过程就会产生逻辑上的错误，出现诸如策略参数变化时买卖点不一致之类的问题。因此，研究人员需要始终采用分类思维来处理仓位变换，即在分类为多的情况下，如果仓位为多头则保持不变，如果不是则通过买入操作将仓位变为多头；在分类为空的情况下，如果仓位为空头则保持不变，如果不是则通过卖出和卖空操作将仓位变为空头。当然，还有其他一些处理方法可以保证推进分析下模拟交易的正常运行，本书之所以选用这种方法，原因在于其最贴合前面给出的量化交易策略框架。但是使用分类变换的方法来处理仓位时，可能会由于策略参数的切换导致多空在短时间内来回变动，进而带来操作上的反复，这是该方法本身存在的不足之处。

在整个推进分析 845 行的过程中，均线趋势策略的参数组合一共变动了 52 次。实际上，变动次数与用来优化的白色框的长度有内在关系，优化样本的长度越短则变动越频繁。将整体综合起来进行计算得知，用来优化的白色框内策略平均的年化收益率为 43%，而用来检验策略的灰色框的年化收益率则为 5.34%，两相比较，均线趋势策略的长短两个参数具有一定的过度拟合现象。逐行的样本外检验结果则可以来说明具体时间内参数的过度拟合情况，但是由于逐行下的结果波动很大、不易分辨，因

此一般而言可以将总样本划分为若干个时间段并进行平均化研究。这里将灰色框三年半的时间按半年为单位划分为7个部分，每半年中的优化期年化收益和检验期年化收益情况如表7.1所示。当然，这里只是用一个例子来说明具体的做法，由于检验期整体的年化收益率过低，与优化期整体的年化收益率相差也较大，因此再分段进行过度拟合的判断其实意义已经不大。

表7.1 优化期年化收益率与检验期年化收益率对比

| 时间段 | 优化期年化收益率 | 检验期年化收益率 |
|----------|----------|----------|
| 2012 上半年 | 35.47% | -41.78% |
| 2012 下半年 | 26.44% | 22.57% |
| 2013 上半年 | 42.61% | 35.24% |
| 2013 下半年 | 38.84% | -47.77% |
| 2014 上半年 | 41.23% | 1.02% |
| 2014 下半年 | 32.81% | 143.39% |
| 2015 上半年 | 92.22% | 16.10% |

图7.2展示了均线趋势策略在推进分析的框架下，模拟交易过程以1为初始值的净值走势情况。在2012年底、2013年底和2014年底，策略的净值分别变为0.8448、0.7100、1.1133。2012年策略净值有所下跌，在2013年中期回归初始值附近，随后下跌至最低点。在样本期最后的一年多时间内，净值保持了一个上升态势，直到最后一段时间有一个较为明显的下跌，到2015年6月30日收盘时的策略净值为1.1996。基于整个交易过程来看，三年半的策略收益率为19.96%，可以说缺乏较为明显的盈利能力。同期对比来看，均线趋势策略的简单优化下，2011年12月30日收盘到2015年6月30日收盘时的收益率为104.69%，是这里的19.96%的5倍多。

在整个三年半的均线趋势策略模拟交易当中，净值的最大回撤率为37.95%，回撤的发生从2012年1月5日收盘的1.0288开始，一直到2014年4月9日收盘时的0.6384结束，整个回撤过程一共经历543个交易日，是一个相对而言较长的回撤时间。经过计算，均线趋势策略在整个交易过程中平均的年度最大回撤为21.65%，回撤水

平也是比较大的。




图 7.2 推进分析下均线趋势策略的净值走势

7.2 均线反转策略的推进分析

第 4 章第 3 节介绍了均线反转策略的基本运行模式，并提供了一个简单的回溯测试案例。在这一节中，作者同样采用与前面大体相同的设置对均线反转策略进行推进分析，模拟实际交易中策略的运转流程，进而得到一个贴合实际环境的策略盈利能力结果，同时判断反转趋势策略两个均线参数的过度拟合程度。双均线反转策略的具体定义和第 4 章第 3 节中保持一致，在交易决策的时点需要根据已知数据计算短期均线和长期均线两个值，当短期均线高于长期均线时看空，而当短期均线低于长期均线时看多。具体可以参见图 4.7 和相关叙述。

数据方面同样保持一致，收集得到沪深 300 股指期货主力合约从 2010 年 4 月 19 日到 2015 年 6 月 30 日的日收盘价数据，且依然将股指期货的杠杆率设定为 100% 进行研究。均线反转策略的推进分析运行情况与上一节中的均线趋势策略如出一辙，推进分析时间段划分、优化样本长度、检验样本长度等都保持同一设置，区别仅仅在于策略逻辑的不同，因此这里不再多做赘述，请读者根据图 7.1 和相关的描述进行类推。

同样的，均线反转策略在白色框的优化期中，可以等同于“短期均线从上向下穿过长期均线则做多，短期均线从下向上穿过长期均线则做空”。而在灰色框的模拟交易运行过程当中，则应该保持使用分类思维来处理仓位变换，根据长短均线的大小对比来逐日判别多空并形成交易。




图 7.3 推进分析下均线反转策略的净值走势

在整个推进分析 845 行的过程中，均线趋势策略的参数组合一共变动了 71 次。综合计算可知，用来优化的白色框内策略平均的年化收益率为 36.27%，而用来检验策略的灰色框的年化收益率则为-11.10%，差距比较大，甚至盈亏方向都不一致。图 7.3 展示了均线反转策略在推进分析的框架下，模拟交易过程以 1 为初始值的净值走势情况。在 2012 年底、2013 年底和 2014 年底，策略的净值分别变为 1.0902、1.2381、0.9799。在交易样本期的前半段内，策略的净值水平大部分时间都处在 1 以上，2014 年 2 月 19 日收盘时达到最高点 1.3345。但是在 2014 年 9 月之后，策略净值经历了一个非常直接的下跌，2015 年 6 月 30 日收盘时达到 0.6625。基于整个交易过程来看，三年半的策略收益率为-33.75%，是一个比较差的策略净值情况。同期对比来看，均线反转策略的简单优化下，2011 年 12 月 30 日收盘到 2015 年 6 月 30 日收盘时的收益率为 63.08%。

在整个三年半的均线反转策略模拟交易当中，净值的最大回撤率为 54.52%，回撤的发生从净值最高点的 2014 年 2 月 19 日收盘起，一直到 2015 年 6 月 29 日收盘时的 0.6070 结束，整个回撤过程一共经历 333 个交易日，其实也就是样本期的后半段时间。经过计算，均线趋势策略在整个交易过程中平均的年度最大回撤为 20.75%，回撤水平也是比较大的。实际上，推进分析下的均线反转策略表现较差，将其反向操作倒是能够取得一定的收益。但是在推进分析框架下，研究人员是采用前期最优的策略进行交易，具有基本的交易逻辑和经济直觉，反向操作后将丧失这种基础的逻辑性，作者不推荐这样的处理行为。

7.3 均线混合策略的推进分析

在第 4 章中，作者基于均线工具分别介绍了均线趋势策略和均线反转策略这两种量化择时策略。由于在简单的优化和回溯测试框架之下，量化交易策略在整个策略样本中具有一致性，因此一旦确定策略思想是趋势或者反转，就不能在交易过程中变化了。但是在这一章中，由于推进分析中的每一行操作都相对独立，每一步推进都需要重新判断一次分类，并基于分类思维来处理仓位变换和交易操作，因此可以引入更加灵活的策略调整手段，作者称之为均线混合策略。实际上，就是将均线趋势策略和均线反转策略在优化过程中同时进行考虑，选择盈利能力最强的策略方式和具体参数设置，并将其应用到检验数据之上。

仍然选取同样的数据进行研究，即从 2010 年 4 月 19 日到 2015 年 6 月 30 日的沪深 300 股指期货日收盘价数据。交易环境和推进分析设置也保持一致，在股指期货可以进行保证金为 8% 的杠杆交易的情况下，依然将杠杆率设定为 100% 进行研究，推进分析的时间段划分、优化样本长度、检验样本长度等均依照图 7.1 中所示进行设定。但是由于均线混合策略的策略思路有异于单纯的均线趋势策略或均线反转策略，因此推进分析下具体的策略执行会稍微复杂一些，下面对此进行描述，方便读者更好的理解均线混合策略的推进分析。

在推进分析的第一行操作中，白色框为优化期，从 2010 年 12 月 31 日的收盘开

始，直到 2011 年 12 月 30 日的收盘结束，一共 244 个交易日。在这一部分样本数据下，首先通过测试不同均线组合的交易情况来寻找最优的均线趋势策略参数，然后再通过测试不同均线组合的交易情况来寻找最优的均线反转策略参数。这两个优化过程在进行网格搜索时，都依然使用斐波那契数列来处理均线的搜索范围，且限定短期均线最大搜索到 34 日均线，长期均线从短期均线的后一根开始一直到 144 日均线结束。在这 244 日的优化样本期上，如果最优均线趋势策略的收益高于最优均线反转策略的收益，那么选取最优参数下的均线趋势策略作为最终的优化结果，反之则选取最优参数下的均线反转策略作为最终的优化结果。

在得到白色框的优化结果之后，就按照最优结果固定短期和长期均线的长度，并用来计算 2011 年 12 月 30 日收盘时刻下的短期均线值和长期均线值。基于最终选取的均线趋势策略或均线反转策略，通过比较短期均线值和长期均线值的大小，就可以得到对 2011 年 12 月 30 日收盘到 2012 年 1 月 4 日收盘走势的多空看法。在看多的情况下，如果 2011 年 12 月 30 日收盘时仓位为多头则保持不变，如果不是则通过买入操作将仓位变为多头；在看空的情况下，如果 2011 年 12 月 30 日收盘时仓位为空头则保持不变，如果不是则通过卖出和卖空操作将仓位变为空头。

在完成第一行的操作之后，将白色框和灰色框都分别向后推进一日，重复同样的样本外检验过程，然后持续推进直到最后一行为止。总的来看，在推进分析的过程中，模拟买卖的行为从 2011 年 12 月 30 日收盘时开始，到 2015 年 6 月 30 日收盘时结束，一共交易三年半的时间，也就是所有灰色框所覆盖的区间。由于逐行进行优化，灰色框中的策略设置同样也是不一致的，而且趋势和反转会交替出现。因此研究人员依然需要采用分类思维来处理仓位变换。当然，也正是因为推进分析的框架和这种分类思维的使用，使得推进分析中可以更加灵活的组合策略，回溯研究均线混合策略这种在第 4 章中无法研究的策略。这也是推进分析更贴近于实际交易环境的一种具体体现，在实际交易中，交易人员是可以根据历史数据上的研究自由选择合适的策略的。

在整个推进分析 845 行的过程中，均线混合策略的参数组合一共变动了 58 次，介于均线趋势策略和均线反转策略的变动次数之间。综合计算可知，用来优化的白色框内策略平均的年化收益率为 54.03%，而用来检验策略的灰色框的年化收益率则为

7.83%，这两个结果都比前两节的相关结果要高。就这两者而言，优化样本下的收益率更高是一个非常容易理解的结果，原因在于优化过程综合选择了均线趋势策略和均线反转策略这两个策略中更优异的一个，因此必然会比两个策略分开讨论的情况都要好。而检验期下的收益率水平有所提升，就是一个对于量化交易策略而言具有实际意义的结果了，其说明至少在回溯测试的样本下，策略的混合改进确实带来了一定的盈利能力。




图 7.4 推进分析下均线混合策略的净值走势

图 7.4 展示了均线混合策略在推进分析的框架下，模拟交易过程以 1 为初始值的净值走势情况。在 2012 年底、2013 年底和 2014 年底，策略的净值分别变为 0.7473、0.8964、1.2082。在 2012 年初，净值就迅速下降到 0.8 左右，并一直较为稳定的运行直到 2014 年 11 月，随后的策略净值水平有了一个比较大的提升。在最后时期策略净值又有一定的下降，2015 年 6 月 30 日收盘时的净值为 1.3019。基于整个模拟交易过程来看，三年半期间当中均线混合策略的总收益率为 30.19%，而净值的最大回撤率为 27.63%，回撤的发生从 2012 年 1 月 5 日收盘的 1.0288 开始，一直到 2013 年 1 月 10 日收盘时的 0.7445 结束，整个回撤过程一共经历 246 个交易日。经过计算，均线混合策略在整个交易过程中平均的年度最大回撤为 11.15%。

虽然均线混合策略在收益率和回撤水平上都比单独的均线趋势策略和均线反转策略表现更好，但是年化收益率仍然只有 7.83%，而模拟交易中的平均年度最大回撤为 11.15%。同时，在三年半的交易检验期中，净值在相当长的一段时间内低于初始净值且没有明显变动。实际上，综合来看，三种均线策略的推进分析结果均没有很好的表现。通过这些研究结果来判断，这三种均线策略均不适合应用于实际交易当中。当然，作为趋势类交易策略和反趋势类交易策略的典型代表，均线构成的量化择时策略是否存在实际的盈利能力显然不是一个简单的推进分析结果可以决定的，样本数据的更换、推进分析具体设置的变化等都可能改变最终的结果和结论，对趋势、反转的交易逻辑抱有信心的研究者有必要通过更多的研究来验证自己的理念。

7.4 自回归策略的推进分析

第4章第4节介绍了自回归策略的基本运行模式，并提供了一个简单的回溯测试案例。在这一节中，作者将采用大体上相同的设置对自回归策略进行推进分析，用来模拟实际交易中策略的运转流程，从而得到一个贴合实际环境的策略盈利能力结果，同时判断自回归模型参数估计的过度拟合程度。自回归策略的具体设置与第4章第4节中保持一致，仍然是通过前9日的日度收益率回归得到交易时刻的日度收益率，基于收益率预测值的情况给出多空的想法，即交易时刻的日度收益率预测值为正时则看多，为负时则看空。具体的模型解释和策略详情请参见图4.9和相关叙述。

数据方面和前几节推进分析中所选取的数据一致，收集得到沪深300股指期货主力合约从2010年4月19日到2015年6月30日的日收盘价数据。在本节的回溯测试环境下，依然忽略股指期货可以进行保证金为8%的杠杆交易，将杠杆率设定为100%进行研究。数据在推进分析框架下的划分也可以沿用图7.1中的演示，但是需要注意的是，使用均线策略时，2010年4月19日到2010年12月30日的日收盘价数据作为计算短期均线和长期均线的备用数据，数据长度为172日，也就是说只要长期均线的长度在173日以下，备用数据都可以支持整个推进分析的计算顺利完成。同样的，这段时间的收盘价数据在本节中就是估计自回归模型的备用数据，因此备用数据最高

能支持 172 阶的自回归模型进行参数估计。而均线策略最多测试到 144 日均线，这里的自回归仅为 9 阶，因此本节实际使用的备用数据是要远远少于前面三节的。由于图 7.1 没有具体体现备用数据这一部分，所以特别做出说明，以免读者误解。

在推进分析的第一行操作中，白色框为优化期，从 2010 年 12 月 31 日的收盘开始，直到 2011 年 12 月 30 日的收盘结束，一共 244 个交易日。这 244 日的日度收益率与各自之前的 9 个日度收益率组成了 244 组数据，针对这 244 组数据进行自回归模型的估计，得到相应的参数估计结果。然后使用估计好的自回归模型，以及 2011 年 12 月 19 日收盘到 2011 年 12 月 30 日收盘之间的 9 个日度收益率数据，来预测 2011 年 12 月 30 日收盘到 2012 年 1 月 4 日收盘的收益率。该收益预期为正时，就对 2011 年 12 月 30 日收盘到 2012 年 1 月 4 日收盘的走势看多，如果 2011 年 12 月 30 日收盘时仓位为多头则保持不变，如果不是则通过买入操作将仓位变为多头；该收益预期为负时，就对 2011 年 12 月 30 日收盘到 2012 年 1 月 4 日收盘的走势看空，如果 2011 年 12 月 30 日收盘时仓位为空头则保持不变，如果不是则通过卖出和卖空操作将仓位变为空头。之后逐行推进并进行相似的操作，直到样本期结束，可以得到三年半的灰色框检验期下具体的模拟交易结果。

通过上面的叙述可以发现，在逐行的操作当中，三种均线策略下的推进分析都是先在优化期对策略的参数进行优化，选取盈利能力最强的策略作为优化结果，然后将优化好的策略置入检验期进行多空判断。而在自回归策略下，优化期主要用来估计具体的模型，得到拟合程度最佳的模型参数，然后将拟合好的模型置入检验期，再根据模型形成策略判断多空。简单来说，均线策略由优化期进入检验期的是具体的策略，而自回归策略由优化期进入检验期的则是策略中的模型。这是图 4.2 和图 4.4 所代表的两类量化交易策略在进行推进分析时非常大的一个区别，同时也是用来进行实际交易时非常大的一个区别，应该加以注意。

首先来看自回归模型在逐行样本外检验中的过度拟合程度。在前面均线策略中，由于样本内和样本外具有策略上的直接联系，因此过度拟合的判断只需要直接比较策略收益情况即可。但是在自回归策略当中，直接关联样本内外的是具体的自回归模型，因此过度拟合程度的判断来自于收益率预测值和真实收益率之间的差距。在计量经济

学研究中，往往更倾向将这类做法称之为模型预测能力的检验。当然，过度拟合是策略的偏误，而预测能力则是模型的效能，一个负面一个正面，在逻辑上是有区别的，希望读者更多的去体会。将整体结果综合起来进行计算得知，灰色框中收益率预测值的年化值为 6.75%，真实收益率的年化值为 19.38%。需要说明的而是，这两个值越接近则说明模型预测能力越强，真实收益率超过收益预测值过多反而是模型能力不强的表现，但是这种情况下的结果却是策略盈利能力增加，是一个模型逻辑和实际效用相悖的表现，需要具体情况具体分析。将灰色框三年半的时间按半年为单位划分为 7 个部分，每半年中的预期收益年化值和真实收益率年化值的情况如表 7.2 所示。当然，由于模型预测的特殊性，两者的差距其实是比较大的，研究人员可以通过其他手段来进一步判断模型的预测能力。

表 7.2 交易期的收益率预测值与真实收益率对比

| 时间段 | 收益率预测值 | 真实收益率 |
|----------|--------|---------|
| 2012 上半年 | 1.67% | 9.73% |
| 2012 下半年 | -4.10% | 5.67% |
| 2013 上半年 | -3.26% | -26.99% |
| 2013 下半年 | 1.72% | 16.93% |
| 2014 上半年 | -1.49% | -15.61% |
| 2014 下半年 | 26.71% | 178.22% |
| 2015 上半年 | 31.91% | 48.68% |

图 7.5 展示了自回归策略在推进分析的框架下，模拟交易过程以 1 为初始值的净值走势情况。在 2012 年底、2013 年底和 2014 年底，策略的净值分别变为 1.3830、1.7447、2.3044。整个模拟交易期内，策略净值存在一个较为稳定的上升趋势，只在 2014 年末 2015 年初出现了一个比较大的震荡，到 2015 年 6 月 30 日收盘时的策略净值为 2.1722。基于整个交易过程来看，三年半的策略收益率为 117.22%，折算下来的年化收益率达到 24.81%。同期对比来看，自回归策略的简单优化下，2011 年 12 月 30 日收盘到 2015 年 6 月 30 日收盘时的收益率为 117.70%。推进分析下的自回归策略与

存在未来信息问题的简单优化收益表现基本一致，而且净值走势具有更高的平稳性，这表明自回归策略不仅通过了推进分析的初步筛查，而且在一定程度上展现出了逐行优化更贴近实际交易的优势。




图 7.5 推进分析下自回归策略的净值走势

在整个三年半的均线趋势策略模拟交易当中，净值的最大回撤率为 25.39%，回撤的发生从 2014 年 12 月 22 日收盘的 2.4171 开始，一直到 2015 年 2 月 25 日收盘时的 1.8033 结束，整个回撤过程一共经历 40 个交易日，是一个相对而言较为急促的回撤过程。而且值得注意的是，这一段回撤期与因子选股策略的回撤期有非常大的重合程度，中国的股票市场和股指期货市场在这几个月中到底出现了什么样的特性变化，使得择时和选股的多种策略同时失效，是一个非常值得思索的问题。此外经过计算，自回归策略在整个交易过程中平均的年度最大回撤为 14.11%，和年化收益率比较来看，这一回撤水平是完全可以接受的。

7.5 自回归策略的多层推进分析

上一节以沪深 300 股指期货为样本介绍了自回归策略的推进分析流程，并发现在

特定的样本期以及策略设置下得到了一个相对积极的盈利结果。不过由于自回归模型阶数这一模型设置参数没有和回归系数一起进行优化，而是固定为9阶并进行模型的估计，因此该参数就存在过度拟合验证不完全的问题。而且，作者可以直截了当的告诉读者，9阶这一设置实际上是作者在全样本上试验了若干个阶数后选取的一个表现较为优秀的情况，这里面很明显的存在未来信息使用的问题。因此在这一节中，作者将主要针对阶数这一参数设置进行自回归策略的双层推进分析，一是进一步判断自回归策略的实际盈利能力，更重要的是为读者提供一个可以参考的多层推进分析示例。自回归策略沿用上面的构造方式，这里不多做赘述，具体请参考上一节以及第4章第4节的相关内容。

获取的数据仍然和前面一致，交易资产为沪深300股指期货的主力合约，具体包括从2010年4月19日到2015年6月30日的日收盘价数据。并且在本节的回溯测试环境下，依然将股指期货交易的杠杆率设定为100%进行研究。图7.6描述了自回归策略双层推进分析中第二层的数据划分和运行情况，而推进分析第一层的设置与上一节的做法完全保持一致，为了简化示意图而没有加入，希望读者自己联想全过程。在图中，第二层计算最早的时间点为2011年12月30日收盘，因此第一层推进分析的首次优化时间为2010年12月31日收盘到2011年12月30日收盘，再之前的数据都作为备用数据加以使用，这和上一节的情况是一致的。




图 7.6 自回归策略的多层推进分析流程

在第二层推进分析的第一行操作中，浅灰色框为阶数设置的优化期，从2011年12月30日的收盘开始，直到2012年12月31日的收盘结束，一共243个交易日。

需要说明的是，在这个例子当中，第二层推进分析选择优化期长度时仍然基于一整年的考虑进行确定，但是由于2011年全年和2012年全年的交易日数量不一致，因此推进分析第一层和第二层的具体设置也就相应的存在区别，也就是第一层中白色框的长度为244，第二层中浅灰色框的长度为243。而且由于推进分析逐行推进一日的操作特性，这两个设置将一直保持到推进分析流程结束，不再改变。

再回到第二层推进分析第一行的操作中来，浅灰色框中的优化主要针对自回归模型的阶数这一参数，实际上就是依次选取从1到20的阶数设置，然后分别在固定阶数的情况下，进行完全等同于上一节中自回归策略推进分析的操作，最后根据不同阶数情况下所得到模拟交易盈利结果，选取一个盈利能力最优的阶数。在确定了第一行的最优阶数之后，就可以将该阶数设置固定到深灰色框的自回归模型之上，然后进行相似的第一层推进分析操作，也就是估计出自回归模型系数之后，预测2012年12月31日收盘到2013年1月4日收盘的日度收益率，根据正负值判断多空，进而得到模拟的交易情况。

在进行完第一行的操作之后，将浅灰色框和深灰色框都分别向后推进一日，重复同样的流程，直到最后一行为止。总的来看，在双层推进分析的过程中，模拟买卖的行为从2012年12月31日收盘时开始，到2015年6月30日收盘时结束，一共交易两年半的时间，也就是所有深灰色框所覆盖的区间。与推进分析的情况一样，多层推进分析中深灰色框所应用的交易策略仍然具有设置上的不一致性，而且这种不一致性程度更高，因此研究人员同样需要采用分类思维来处理仓位变换。也就是说，对于逐个深灰色框而言，在分类为多的情况下，如果仓位为多头则保持不变，如果不是则通过买入操作将仓位变为多头；在分类为空的情况下，如果仓位为空头则保持不变，如果不是则通过卖出和卖空操作将仓位变为空头。由于多层推进分析中交易策略变化的更为复杂和深化，因此多空在短时间内来回变动的情况有可能更加严重一些，需要研究者在研发过程中加以注意。

在第二层推进分析602行的过程中，自回归模型的阶数设置一共变动了22次。在研究自回归模型在推进分析中的过度拟合程度时，由于多层推进分析当中，除了最后一层推进分析以外，其他层的处理次数过多，因此一般不具体分析。这里仅针

对第二层推进分析来研究自回归模型阶数设置的过度拟合程度。在上一节中，由于检验期内需要根据收益预期来判断买卖，因此自回归策略过度拟合程度的判断来自于收益率预测值和真实收益率之间的差距。而在这一节中，第二层推进分析的样本内和样本外已经具有策略上的直接联系，所以过度拟合的判断只需要直接比较策略收益情况即可，这和本章前三节处理均线策略时的做法反而更为接近。将整体综合起来进行计算得知，用来优化的浅灰色框内策略平均的年化收益率为 35.61%，而用来检验策略的深灰色框的年化收益率则为 20.84%，相对而言两者是较为接近的。此外，将深灰色框两年半的时间按半年为单位划分为 5 个部分，每半年中的优化期年化收益和检验期年化收益情况如表 7.3 所示。

表 7.3 第二层的优化期年化收益率与检验期年化收益率对比

| 时间段 | 优化期年化收益率 | 检验期年化收益率 |
|----------|----------|----------|
| 2013 上半年 | 38.05% | 5.14% |
| 2013 下半年 | 51.82% | -2.24% |
| 2014 上半年 | 32.46% | 15.73% |
| 2014 下半年 | 26.23% | 90.38% |
| 2015 上半年 | 30.88% | 13.77% |

图 7.7 展示了自回归策略在双层推进分析的框架下，模拟交易过程以 1 为初始值的净值走势情况。在 2013 年底和 2014 年底，策略的净值分别变为 1.0138、1.5049。在整个模拟交易期内，策略净值依然存在一个较为明显的上升趋势，但在 2014 年末 2015 年初也出现了一个比较大的震荡，到 2015 年 6 月 30 日收盘时的策略净值为 1.6051。基于整个交易过程来看，两年半的策略收益率为 60.51%，折算下来的年化收益率达到 20.84%。同期进行对比，上一节中自回归策略的推进分析下，2012 年 12 月 31 日收盘到 2015 年 6 月 30 日收盘时的收益率为 57.06%。双层推进分析下的自回归策略的盈利能力还要略优一些，考虑到上一节中的阶数 9 是作者多次试验下的结果，本身带有未来信息的问题，双层推进分析的研究结果进一步说明了自回归策略的有效性，验证了逐行优化更贴近实际交易的优势。



图 7.7 双层推进分析下自回归策略的净值走势

在整个两年半的自回归策略模拟交易当中，净值的最大回撤率为 29.03%，回撤的发生从 2014 年 12 月 26 日收盘的 1.5528 开始，一直到 2015 年 2 月 13 日收盘时的 1.1020 结束，整个回撤过程一共经历 33 个交易日，较之上一节中的回撤期更短而且正处于上一节回撤期的中间。经过计算，自回归策略在整个交易过程中平均的年度最大回撤为 16.11%，和年化收益率比较来看，这一回撤水平依然是可以接受的。

第 8 章 推进的选股策略

8.1 多因子选股策略的推进分析

第 5 章第 4 节介绍了多因子选股策略的基本运行模式，并提供了一个简单的回溯测试案例。在这一节中，作者采用大体上相同的设置进行了多因子选股策略的推进分析，用来模拟实际交易中策略的运转流程，从而得到一个贴合实际环境的策略盈利能力结果，同时考察策略的过度拟合程度。多因子选股策略的具体定义和第 4 章第 4 节中保持一致，仍然是使用估计完成的回归式计算得到所有股票收益率的预测值，然后将股票按照收益率预测值从高到低进行排序，再按顺序等分为若干个部分，每一等份中的股票又按照等权重进行组合，也就是买入各支股票占用的资金量相等的组合。交易中，选取排序中的第一个等份进行持仓操作。具体请参见第 5 章第 4 节前半部分的相关叙述。




图 8.1 多因子选股策略的推进分析流程

数据方面也和前面所获取的数据一致，同样是自 1991 年 1 月开始直到 2015 年 6 月底结束的国内股票月度数据。所选股票的范围涵盖在深圳证券交易所进行交易的所有 A 股，包括主板、中小企业版和创业板三个板块，以及在上海证券交易所进行交易的所有 A 股。月度数据则包括月末收盘时股票的复权后月度收益率，以及股票的月度流通市值。在进行具体的推进分析之前，为了更好的反映出月度收益率和流通市值之

间的线性关系，需要对流通市值进行对数化处理。图 8.1 展示了多因子选股策略的推进分析在这段时间的样本下是如何进行的。1991 年 1 月到 2005 年 12 月的月度数据作为多因子回归模型估计的备用数据，但是实际需要使用的也只有 2005 年 12 月这一个月的数据。这一部分在图中没有具体显示，特此说明。

在推进分析的第一行操作中，白色框为优化期，从 2006 年 1 月到 2010 年 12 月一共 60 个月。根据这 60 个月的月度数据，结合 2005 年 12 月的备用数据，就可以得到 60 组用来回归的数据，从而进行多因子回归模型的估计，具体的估计过程可以参考第 5 章第 4 节中的说明，这里不再赘述。使用白色框的数据完成回归式的估计之后，则将回归式用到灰色框的样本数据上进行交易的模拟。具体来说，就是在 2010 年 12 月收盘的选股时间点上，基于 2010 年 12 月所有股票的月度流通市值和月度收益率数据，使用白色框中得到的回归式计算得到所有股票在 2011 年 1 月的收益率的预测值。然后将股票按照收益率预测值从高到低进行排序，再按顺序等分为若干个部分，每一等份中的股票均按照等权重进行组合，也就是买入占用的资金量相等的组合。在进行完一行的操作之后，将白色框和灰色框都分别向后推进一个月，重复相同的排序和等分过程，直到最后一行为止。

在得到了所有灰色框中的排序结果之后，需要进行的处理实际上与简单优化下的多因子选股完全一致。首先根据每一个等份下长度为 54 的收益率序列，计算出各个等份的平均月度收益情况，进而判断多因子模型预测下一期收益率的整体趋势性。交易策略方面，则根据排序中的第一个等份选择股票，这个序列的股票组合即是每个月多因子选股策略所选择的股票组合，而该等份的收益率序列也就是策略在每个月下的交易收益。根据这一长度为 54 的收益率序列，可以计算出多因子选股策略在灰色框模拟交易下的净值走势。

灰色框下的研究设置沿用前面简单优化时所采用的设置，即将所有股票按照收益预期大小排序划分为 3 等份、10 等份、30 等份共三种情况来加以研究。首先来看 3 等分的情况，图 8.2 展示了将所有股票按照多因子模型的预期收益大小划分为 3 等份，每一等份中的股票又按照等权重进行组合时，3 个等份各自的平均月度收益率情况，具体大小分别为 2.38%、1.51%、0.60%。第 1 等份与第 2 等份之间相差 0.87%，第 2

等份与第 3 等份之间相差 0.91%，呈现出一个比较稳定的下降趋势。




图 8.2 多因子选股 3 等分的收益情况

确定了逐月的排序和 3 等分之后，就可以得到第 1 等份股票组合的逐月变动情况，也就是多因子选股策略的交易详情。图 8.3 中的实线展示了使用多因子选股策略进行交易的情况下，以 1 为初始值的策略净值走势，虚线则是用来进行对比的同期沪深 300 指数走势。策略净值在 2015 年 6 月收盘时达到 3.5613，四年半的策略收益率为 256.13%，折算下来的年化收益率为 32.61%。




图 8.3 多因子选股前 1/3 的股票组合净值走势

图 8.4 则是逐月的将多因子选股排序前 1/3 的股票组合收益率减去沪深 300 指数




图 8.4 多因子选股前 1/3 的股票组合与沪深 300 收益之差的净值走势

的收益率后，所得到的收益率序列形成的净值走势。净值从 2010 年 12 月收盘的 1 开始，在 2015 年 6 月底达到 2.2777，四年半的收益率为 127.77%，折算下来的年化收益率为 20.07%。四年半之间的最大回撤率为 40.54%，回撤的开始点为 2014 年 10 月收盘的 2.3527，结束点则是 2015 年 1 月收盘的 1.3990。同期对比来看，多因子选股简单优化的 3 等分策略下，四年半的收益率为 133.64%，最大回撤则为 40.50%，且回撤期的时间一致。




图 8.5 多因子选股 10 等分的收益情况

然后是划分为 10 等份的情况。图 8.5 展示了将所有股票按照多因子模型的预期

收益大小划分为 10 等份，每一等份中的股票又按照等权重进行组合时，10 个等份各自的平均月度收益情况。第 1 等份的月均收益率是 10 个等份中的最高值，为 2.71%，第 10 等份的月均收益率则是 10 个等份中的最低值，为 0.29%。其他等份也按照排序关系存在严格的下降趋势，而且下降的幅度比较稳定。这与第 5 章第 4 节中相关结果的表现是一致的，说明与两个单因子相比，多因子模型可以使等分下的未来收益率具有更平稳的趋势。而由于推进分析本身的优点，这里的结果无疑更加具有说服力。




图 8.6 多因子选股前 1/10 的股票组合净值走势

在确定了逐月的排序和 10 等分之后，也就得到了通过多因子模型选出的第 1 等份股票组合的逐月变动详情。图 8.6 中的实线展示了使用多因子选股策略进行交易时，以 1 为初始值的净值走势情况，虚线则是用来进行对比的沪深 300 指数走势。策略净值在 2015 年 6 月底达到 4.2323，四年半的策略收益率为 323.23%，折算下来的年化收益率为 37.80%。

图 8.7 则是逐月的将多因子选股排序前 1/10 的股票组合收益率减去沪深 300 指数的收益率后，所得到的收益率序列形成的净值走势。净值从 2010 年 12 月收盘的 1 开始，在 2015 年 6 月底达到 2.6757，四年半的收益率为 167.57%，折算下来的年化收益率为 24.45%。四年半之间的最大回撤率为 41.80%，回撤的开始点为 2014 年 10 月收盘的 2.7217，结束点则是 2015 年 1 月收盘的 1.5841。同期对比来看，多因子选

股简单优化的 10 等分策略下，四年半的收益率为 177.47%，最大回撤则为 41.79%，回撤期的时间相同。




图 8.7 多因子选股前 1/10 的股票组合与沪深 300 收益之差的净值走势

最后来看划分为 30 等份的情况。图 8.8 展示了将所有股票按照多因子模型的预期收益大小划分为 30 等份，每一等份中的股票又按照等权重进行组合时，30 个等份各自的平均月度收益情况。第 1 等份的月均收益率同样也是 30 个等份中的最高值，为 2.76%，第 30 等份的月均收益率也是 30 个等份中的最低值，为 -0.083%。其他等份的收益情况也基本显示出一个比较平稳的下降趋势。




图 8.8 多因子选股 30 等分的收益情况




图 8.9 多因子选股前 1/30 的股票组合净值走势

在确定了逐月的排序和 30 等分之后，也就得到了通过多因子模型选出的第 1 等份股票组合的逐月变动详情。图 8.9 中的实线展示了 30 等分的情况下，以 1 为初始值的多因子选股策略净值走势，虚线则是用来进行比较的沪深 300 指数走势。策略净值在 2015 年 6 月底达到 4.3460，四年半的策略收益率为 334.60%，折算下来的年化收益率为 38.61%。




图 8.10 多因子选股前 1/30 的股票组合与沪深 300 收益之差的净值走势

图 8.10 则是逐月的将多因子选股排序前 1/30 的股票组合收益率减去沪深 300 指

数的收益率后，所得到的收益率序列形成的净值走势。净值从2010年12月收盘的1开始，在2015年6月底达到2.7434，四年半的收益率为174.34%，折算下来的年化收益率为25.14%。四年半的最大回撤率为43.02%，回撤的开始点为2014年11月收盘的2.7749，结束点则是2015年1月收盘的1.5812。同期对比来看，多因子选股简单优化的30等分策略下，四年半的收益率为191.79%，最大回撤则为43.08%，回撤期的时间也是相同的。

由于本节中多因子选股策略推进分析的模拟交易时间与第5章第4节简单优化下的模拟交易时间完全重合，因此可以直接进行相应的对比。综合3等分、10等分、30等分这三种情况来看，推进分析下的多因子选股策略的盈利表现较之简单优化略差，但是差距很小，最大回撤的程度则几乎没有区别。鉴于简单优化中存在的未来信息偏误，推进分析的结果已经在一定程度上说明了多因子选股策略的有效性，同时也体现出了逐行优化更贴近交易点的优势。

此外，通过对比两个单因子策略的结果可以发现，虽然多因子选股策略中包含市值因子，但是市值因子作为单因子的表现实际上是要好于多因子选股的。这主要是由于在2014年底、2015年初的特殊时间段内，多因子选股策略中的两个因子同时遭遇了因子失效的问题，所以多因子选股策略在没有降低最大回撤风险的情况下，收益情况却被两个因子平均化了，进而形成了这种退化的结果。但是在真实的策略研发过程中，即使在样本中出现了这样的问题，作者同样建议在多因子选股策略中尽可能多的吸收有效因子。只要研究人员通过逻辑判断出多个因子之间没有非常强的内在相关性，例如本书例子中的市值因子和上月收益反转因子，就应当把多个有效因子的结合视为一个可能更优的选择来看待。这样的做法来源于多因子选股策略本身的内在经济直觉，而不是数据实证的结果。虽然本书整个篇幅都在讲解数据的实证研究，但是在作者的观念里，经济直觉的重要性其实是要高于纯粹的数据研究结果的。

8.2 多因子选股策略的多层推进分析

上一节中作者以国内所有A股为样本介绍了多因子选股策略的推进分析流程，

并发现在特定的样本期以及策略设置下可以得到一个正面的盈利结果。在这部分的研究中，由于回归模型来自于选股因子的交易逻辑，因此并没有具体的设置参数需要提前确定。但是正如第 6 章中提到过的，训练样本的大小、也就是图 8.1 中白色框的长度，作为推进分析本身的设置参数是需要分析之前人为给定的。在这一节中，作者就主要针对训练样本大小这一参数设置进行多因子选股策略的双层推进分析，从而进一步判断多因子选股策略的实际盈利能力。当然，这也同时为读者提供了一个可以参考的多层推进分析示例，特别是针对推进分析自身设置所进行的多层推进分析示例。至于多因子选股策略的构造形式，读者可以参考上一节以及第 5 章第 4 节的相关内容，这里不再赘述。




图 8.11 多因子选股策略的双层推进分析流程

数据方面也 and 前面所获取的数据一致，样本涵盖在深圳证券交易所和上海证券交易所进行交易的所有 A 股，具体包括月末收盘时股票的复权后月度收益率，以及股票的月度流通市值。在进行策略研究之前，为了更好的反映出月度收益率和流通市值之间的线性关系，需要对流通市值进行对数化处理。图 8.11 描述了多因子选股策略双层推进分析中第二层的数据划分和运行情况，而为了简化示意图，推进分析第一层的设置没有在图中进行展示。但是值得注意的是，这一节研究中第一层推进分析的具体情况与第 7 章第 5 节中的情况又有所不同。在自回归择时策略的双层推进分析中，第二层推进分析主要针对的是自回归模型的阶数，因此第一层白色框的长度依然保持为 1 年没有改变，第一层推进分析的具体形式也相对比较固定。但是在这里，第一层白色框的长度正是第二层推进分析所针对的检验对象，因此图 8.11 中没有展示的第一层

推进分析的结构其实是随着第二层的检验过程而不断变动的。

下面进行具体的说明。在第二层推进分析的第一行操作中，浅灰色框为第一层白色框长度设置的优化期，同时也是第一层推进分析的模拟交易期，从2008年1月开始，直到2010年12月结束，共计36个月。对白色框长度的优化采用完全的网格搜索，也就是将长度分别设置为1到120，使用与上一节中雷同的推进分析流程逐个测试不同长度下的模拟交易情况，进而选取盈利能力最强的白色框长度设置作为最优结果。因此，第一行操作中没有具体显示的白色框最远回溯到120个月之前，也就是1997年1月。再加上估计多因子回归模型所需要用到的前一个月的备用数据，全部的双层推进分析所使用的数据实际从1996年12月开始。需要说明的是，由于中国股票市场的迅速发展，较早的样本数据与当前的股票数据在内特征上是否具有较大差异，显然是一个值得考虑的问题。因此在本节这种样本期较长的情况下，有必要对研究结果持有更高的怀疑态度。

在确定了第一行的最优白色框长度之后，就可以将该长度设置固定到深灰色框的多因子回归模型之上，进行相似的第一层推进分析操作。也就是根据前期数据估计出回归模型系数之后，在2010年12月收盘的选股时间点上，基于2010年12月所有股票的月度流通市值和月度收益率数据，使用得到的回归式计算出所有股票在2011年1月的收益率的预测值。然后将股票按照收益率预测值从高到低进行排序，再按顺序等分为若干个部分，每一等份中的股票又按照等权重进行组合，也就是买入占用的资金量相等的组合。在进行完一行的操作之后，将所有的数据框都分别向后推进一个月，重复相同的研究过程，直到最后一行为止。

在得到了所有深灰色框中的排序结果之后，需要进行的处理实际上也就与其他因子选股研究流程完全一致了。首先根据每一个等份下长度为54的收益率序列，计算出各个等份的平均月度收益情况，进而判断多因子模型预测下一期收益率的整体趋势性。交易策略方面，则根据排序中的第一个等份选择股票，这个序列的股票组合即是每个月多因子选股策略所选择的股票组合，而该等份的收益率序列也就是策略在每个月下的交易收益。根据这一长度为54的收益率序列，可以计算出多因子选股策略在深灰色框模拟交易下的净值走势。

深灰色框下的研究设置依然沿用前面研究选股策略时所采用的设置，即将所有股票按照收益预期大小排序划分为 3 等份、10 等份、30 等份共三种情况来加以研究。首先来看 3 等分的情况，图 8.12 展示了将所有股票按照多因子模型的预期收益大小划分为 3 等份，每一等份中的股票又按照等权重进行组合时，3 个等份各自的平均月度收益率情况。具体的收益率大小分别为 2.25%、1.49%、0.75%。第 1 等份与第 2 等份之间相差 0.76%，第 2 等份与第 3 等份之间相差 0.74%，呈现出了一个比较稳定的下降趋势。




图 8.12 多因子选股 3 等分的收益情况

确定了逐月的排序和 3 等分之后，就可以得到第 1 等份股票组合的逐月变动情况




图 8.13 多因子选股前 1/3 的股票组合净值走势

况，也就是多因子选股策略的交易详情。图 8.13 中的实线展示了使用多因子选股策略进行交易的情况下，以 1 为初始值的策略净值走势，虚线则是用来进行对比的同期沪深 300 指数走势。策略净值在 2015 年 6 月收盘时达到 3.3271，四年半的策略收益率为 232.71%，折算下来的年化收益率为 30.62%。




图 8.14 多因子选股前 1/3 的股票组合与沪深 300 收益之差的净值走势

图 8.14 则是逐月的将多因子选股排序前 1/3 的股票组合收益率减去沪深 300 指数的收益率后，所得到的收益率序列形成的净值走势。净值从 2010 年 12 月收盘的 1 开始，在 2015 年 6 月底达到 2.1358，四年半的收益率为 113.58%，折算下来的年化收益率为 18.37%。四年半之间的最大回撤率为 40.62%，回撤的开始点为 2014 年 10 月收盘的 2.1933，结束点则是 2015 年 1 月收盘的 1.3024。同期对比来看，上一节推进分析的 3 等分策略下，四年半的收益率为 127.77%，最大回撤则为 40.54%，回撤期的时间是一样的。

然后是划分为 10 等份的情况。图 8.15 展示了将所有股票按照多因子模型的预期收益大小划分为 10 等份，每一等份中的股票又按照等权重进行组合时，10 个等份各自的平均月度收益情况。第 1 等份的月均收益率是 10 个等份中的最高值，为 2.42%，第 10 等份的月均收益率则是 10 个等份中的最低值，为 0.54%。其他等份也按照排序关系存在严格的下降趋势，而且下降的幅度比较稳定。




图 8.15 多因子选股 10 等分的收益情况

在确定了逐月的排序和 10 等分之后，也就得到了通过多因子模型选出的第 1 等份股票组合的逐月变动详情。图 8.16 中的实线展示了使用多因子选股策略进行交易时，以 1 为初始值的净值走势情况，虚线则是用来对比的沪深 300 指数走势。策略净值在 2015 年 6 月底达到 3.6319，四年半的策略收益率为 263.19%，折算下来的年化收益率为 33.19%。




图 8.16 多因子选股前 1/10 的股票组合净值走势

图 8.17 则是逐月的将多因子选股排序前 1/10 的股票组合收益率减去沪深 300 指数的收益率后，所得到的收益率序列形成的净值走势。净值从 2010 年 12 月收盘的 1 开始，在 2015 年 6 月底达到 2.3012，四年半的收益率为 130.12%，折算下来的年化




图 8.17 多因子选股前 1/10 的股票组合与沪深 300 收益之差的净值走势

收益率为 20.35%。四年半之间的最大回撤率为 42.29%，回撤的开始点为 2014 年 10 月收盘的 2.4052，结束点则是 2015 年 1 月收盘的 1.3881。同期对比来看，上一节推进分析的 10 等分策略下，四年半的收益率为 167.57%，最大回撤则为 41.80%，回撤期的时间也是相同的。




图 8.18 多因子选股 30 等分的收益情况

最后来看划分为 30 等份的情况。图 8.18 展示了将所有股票按照多因子模型的预期收益大小划分为 30 等份，每一等份中的股票又按照等权重进行组合时，30 个等份各自的平均月度收益情况。第 1 等份的月均收益率同样是 30 个等份中的最高值，为 2.59%，第 30 等份的月均收益率也是 30 个等份中的最低值，为 0.25%。其他等份的

收益情况也基本显示出一个比较稳定的下降趋势。




图 8.19 多因子选股前 1/30 的股票组合净值走势

在确定了逐月的排序和 30 等分之后，也就得到了通过多因子模型选出的第 1 等份股票组合的逐月变动详情。图 8.19 中的实线展示了 30 等分的情况下，以 1 为初始值的多因子选股策略净值走势，虚线则是用来进行比较的沪深 300 指数走势。策略净值在 2015 年 6 月底达到 3.9847，四年半的策略收益率为 298.47%，折算下来的年化收益率为 35.96%。




图 8.20 多因子选股前 1/30 的股票组合与沪深 300 收益之差的净值走势

图 8.20 则是逐月的将多因子选股排序前 1/30 的股票组合收益率减去沪深 300 指数的收益率后, 所得到的收益率序列形成的净值走势。净值从 2010 年 12 月收盘的 1 开始, 在 2015 年 6 月底达到 2.5080, 四年半的收益率为 150.80%, 折算下来的年化收益率为 22.67%。四年半之间的最大回撤率为 42.51%, 回撤的开始点为 2014 年 11 月收盘的 2.8613, 结束点则是 2015 年 1 月收盘的 1.6450。同期对比来看, 上一节推进分析的 30 等分策略下, 四年半的收益率为 174.34%, 最大回撤则为 43.02%, 回撤期的具体时间也是相同的。

由于本节中多因子选股策略多层推进分析的模拟交易时间与上一节推进分析的模拟交易时间完全重合, 因此可以直接进行相应的对比。综合 3 等分、10 等分、30 等分这三种情况来看, 多层推进分析下多因子选股策略的交易表现比单纯的推进分析下略差, 但是差距同样很小。由于多层推进分析较之上一节的推进分析进一步考虑到了策略优化样本长度的过度拟合问题, 因此这一差距是可以接受的, 而且可以认为多因子选股策略实际上具有比较稳健的有效性。在实际交易过程中, 用来优化执行策略的样本期长度设定, 也可以通过相同的方法实时得到。

不过与此同时, 本节所进行的多因子选股策略的多层推进分析存在两个需要注意的问题。其一是前面已经提到过的, 使用数据的时间过长的问题, 从 1996 年 12 月收盘开始的前面几年内, 中国股市实际上还在不断的成熟与改进当中, 这一部分数据的应用会在多大程度上影响整个回溯测试过程的内在一致性, 是需要研发人员进行主观判断的问题。第二个问题在第 6 章介绍多层推进分析时也曾进行过阐述, 就是这种方法会在检验一些参数设置的过度拟合的同时, 引入新的参数设置。在这一节的具体案例中, 第二层推进分析可以用来研判白色框长度这一设定的过度拟合程度, 但是同时增加了两个新的设置, 一个是浅灰色框的长度, 另一个是优化白色框长度时的搜索范围。因此增加这一层推进分析的意义到底有多大, 与各个不同设置的稳定性有直接关系, 这也需要研发人员进行合理的预判。