

A 股的估值、趋势与交易方法论

一、A 股的估值

（一）券商对于市场或个股估值的研究

从近年国内券商研报看，对于 A 股估值的研究主要围绕估值因子展开。估值因子是一类非重要的风格因子，投资者能够根据上市公司估值的高低判断股票当前价格是否合理，并对该公司的发展前景产生合理预期。在一个完全有效的市场中，股票价格能够反映所有关于该公司的有效信息，但是实际中市场总是存在局部无效性，价值投资理论的支持者们会试图找出价格被低估的股票来获得超额收益。

华泰证券在《华泰单因子测试之估值类因子》中，将净利润(TTM)/总市值、扣非后净利润(TTM)/总市值、净资产/总市值、营业收入(TTM)/总市值等十个因子定义为估值因子，并将估值因子在不同规模上市公司和不同行业中的历史表现进行了详细比较，分析发现，不同一级行业间估值因子差异较大，并且随时间推移同一行业的估值水平也在不断变化。估值因子在不同规模的上市公司间差异也比较大，近两年 EP、EPcut、BP、SP、NCFP、OCFP、DP 明显与市值因子呈现正相关性，FCFP、EV2EBITDA 与市值因子略微负相关，PEG 与市值因子相关性不明显。国泰君安在《寻找牛、熊股基本特征：基于财务、估值角度》中，将每年涨（跌）幅前 15%的股票定义为牛（熊）股，观察维度从 2003 到 2013 年，观察指标包括盈利能力（ROE），成长性（扣非净利增长率），估值（PE）和总市值。结果表明财务指标的主要作用在于提供安全边际，而非选择牛股，如果投资标的是个股而非指数，那么不用过于关注市场风格，牛（熊）股的市值特征远没有指数表现的那么显著。兴业证券在《兴业证券猎金系列之十二：挖掘错误估值背后蕴藏的 Alpha》中，受价值投资中安全边际概念的启发构建了估值偏离度指标，研究发现，估值偏离度因子与市净率、市盈率、流通市值和过去一个月的收益率等因子之间具有一定相关性，估值偏离度因子与过去一个月的累计收益之间的相关性来源于投资者的过度反应。申万宏源在《从估值和业绩分解的角度析成长股投资策略》中，将股价增长分解为公司业绩和票估值两部，以此考察成投资策略的收益来源，研究发现，涨幅最高的股票，收益率主要来自业绩增长，而业绩增

长最高的股票，收益率也非常高，但此收益是超高的业绩增长和下滑的估值共同作用的结果。

以上研究都是在多因子方法体系之下，通过分析因子与市场/股票不同期限走势的相关性来对因子进行评价，从而指导投资决策。在实操过程中，多因子方法体系最大的局限在于其完备性的缺乏，基金经理需要制定精细的操作流程来配合多因子体系，而这些操作流程在市场的不断变化中是否有效也难以确认(回测)，这整体上提高了构建策略的难度、并降低了策略的有效性。若从周期的视角来看，基于多因子交易体系的鲁棒周期要大于市场风格切换周期，随着市场多因子系机构参与者的增多，多因子鲁棒周期将越来越长，基于多因子方法体系将越来越难以从市场中获取稳定回报。目前看来，基于深度强化学习方法体系有望取代多因子方法体系，成为新的市场分析范式。本章以下部分将对市场估值进行探讨，这些探讨将成为深度强化学习范式的基础数据来源。

(二) 基于市值的 A 股估值分布

为分析 A 股估值分布，我们对 A 股全市场 3443 只个股截止 2017 年 11 月 29 日的 PE 和市值进行了统计。我们根据分位数将 PE 分为四类：亏损 ($PE < 0$)、低 PE ($0 < PE < 40$)、中 PE ($40 < PE < 70$)、高 PE ($PE > 70$)、根据分位数将市值也分为四类：小市值 (市值 < 40 亿元)、中市值 ($40 \text{ 亿元} < \text{市值} < 100$ 亿元)、中大市值 ($100 \text{ 亿元} < \text{市值} < 500$ 亿元) 和大市值 (市值 > 500 亿元)。

图 1 将全市场个股的 PE 和市值进行了交叉分析，在亏损个股中，小市值 (市值 < 40 亿元) 个股占比 57%，中市值 ($40 \text{ 亿元} < \text{市值} < 100$ 亿元) 个股占比 29%，中大市值 ($100 \text{ 亿元} < \text{市值} < 500$ 亿元) 个股占比 14%，大市值 (市值 > 500 亿元) 个股占比 0.7%。在高 PE 个股中，小市值 (市值 < 40 亿元) 个股占比 46%，中市值 ($40 \text{ 亿元} < \text{市值} < 100$ 亿元) 个股占比 32%，中大市值 ($100 \text{ 亿元} < \text{市值} < 500$ 亿元) 个股占比 21%，大市值 (市值 > 500 亿元) 个股占比 1.6%。在中 PE 个股中，小市值 (市值 < 40 亿元) 个股占比 45%，中市值 ($40 \text{ 亿元} < \text{市值} < 100$ 亿元) 个股占比 31%，中大市值 ($100 \text{ 亿元} < \text{市值} < 500$ 亿元) 个股占比 22%，大市值 (市值 > 500 亿元) 个股占比 2.5%。在低 PE 个股中，小市值 (市值 < 40 亿元) 个股占比 21%，中市值 ($40 \text{ 亿元} < \text{市值} < 100$ 亿元) 个股占比 31%，中大市值 ($100 \text{ 亿元} < \text{市值} < 500$ 亿元) 个股占比 39%，大市值 (市值 > 500 亿元) 个股占比 8.7%。




图1 A股的市值与估值分布（基于PE）

在图2基于市值的交叉分析中,对于小市值个股,亏损(PE<0)个股占比14%,高PE (PE>70)个股占比28%,中PE (40<PE<70)个股占比34%,低PE (0<PE<40)个股占比25%。在中市值个股中,亏损(PE<0)个股占比8.15%,高PE (PE>70)个股占比25%,中PE (40<PE<70)个股占比27%,低PE (0<PE<40)个股占比43%。在中大市值个股中,亏损(PE<0)个股占比4%,高PE (PE>70)个股占比16%,中PE (40<PE<70)个股占比21%,低PE (0<PE<40)个股占比59%。在大市值个股中,亏损(PE<0)个股占比1.2%,高PE(PE>70)个股占比7.3%,中PE(40<PE<70)个股占比14%,低PE (0<PE<40)个股占比77%。




图2 A股的市值与估值分布（基于市值）

以上数据一定程度上揭示了当前A股市场中市值与估值的基本关系：首先，

亏损个股比重与个股市值呈现出显著的负相关，市值低于 40 亿的个股亏损比例甚至占到 14%，因此若是从降低组合风险的目标出发，中高频交易者应降低小市值个股的投资比重。其次，当 PE 大于 40（高 PE 和中 PE）时，PE 的提升与个股的市值分布相关性较小，此时个股市值分布较为稳定，在此条件下，组合的高流动性并不会因为投资偏好变得进取（高 PE 的成长性投资偏好）而降低，当前 A 股市场中进取类型产品的规模化空间尚存。最后，小市值与其它三类市值股票的 PE 分布结构存在显著区别，小市值股票的 PE 呈现出“中 PE>高 PE>低 PE>亏损 PE”，但其它三类市值股票均呈现出“低 PE>中 PE>高 PE>亏损 PE”，随着市场机构化和“注册制”实质化，小市值低 PE 个股比例有望提升，而这一过程也将伴随着小市值个股价值回归（小市值“股灾”）。

（三）基于行业的 A 股估值分布

为分析 A 股的行业估值分布，我们比较了申万一级行业（共 28 个）在当前（2017 年 11 月 29 日）、3 月前（2017 年 8 月 29 日）、6 月前（2017 年 5 月 29 日）、1 年前（2016 年 11 月 29 日）和 2 年前（2015 年 11 月 29 日）等五个时间节点的 PE 值。另外，我们也对这些行业的 PE 和成分股平均市值进行了交叉分析。

通过图 3 比较发现，行业之间 PE 差异显著，当前国防军工 PE（为 80 倍 PE）最高，其次为通信（62 倍 PE）、计算机（60 倍 PE）、综合（50 倍 PE）、机械设备（49 倍 PE）、有色（46 倍 PE）和电子（40 倍 PE），以上这些行业的 PE 均大于 40 倍 PE，属于中高 PE 类别。从 PE 变化趋势看，多数行业 PE 从 2 年前至今存在较大幅度下降，但仍有一些行业 PE 出现上升，如家用电器、公用事业和非银金融，这些行业 PE 普遍较低（平均 PE 仅为 23），PE 的持续上升也可视作行业间估值修复过程。




图 3 A 股的行业估值分布（基于不同期限）

图 4 对行业估值和成分股平均市值进行了综合分析，发现银行（平均市值 2717 亿）和非银金融（平均市值 760 亿）属于大市值行业（成分股平均市值 > 500 亿元）；多数行业如农林牧渔（平均市值 101 亿）、化工（平均市值 102 亿）、商业贸易（平均市值 105 亿）、通信（平均市值 119 亿）、汽车（平均市值 131 亿）、医药生物（平均市值 133 亿）、传媒（平均市值 142 亿）、电子（平均市值 147 亿）、公用事业（平均市值 153 亿）、有色金属（平均市值 158 亿）、建筑装饰（平均市值 163 亿）、国防军工（平均市值 166 亿）、房地产（平均市值 177 亿）、家用电器（平均市值 193 亿）、交通运输（平均市值 190 亿）、食品饮料（平均市值 250 亿）、钢铁（平均市值 266 亿）等属于中大市值行业（100 亿元 < 成分股平均市值 < 500 亿元）；另一些行业如纺织服装（平均市值 67 亿）、综合（平均市值 74 亿）、轻工制造（平均市值 77 亿）、机械设备（平均市值 77 亿）、休闲服务（平均市值 84 亿）、建筑材料（平均市值 90 亿）、计算机（平均市值 92 亿）、电气设备（平均市值 96 亿）等属于中市值行业（40 亿元 < 成分股平均市值 < 100 亿元）。鉴于行业内个股市值分化显著，在中市值行业中多数个股属于小市值个股，未来这些行业中的中高 PE（大于 40 倍 PE）个股也将大概率面临价值回归。

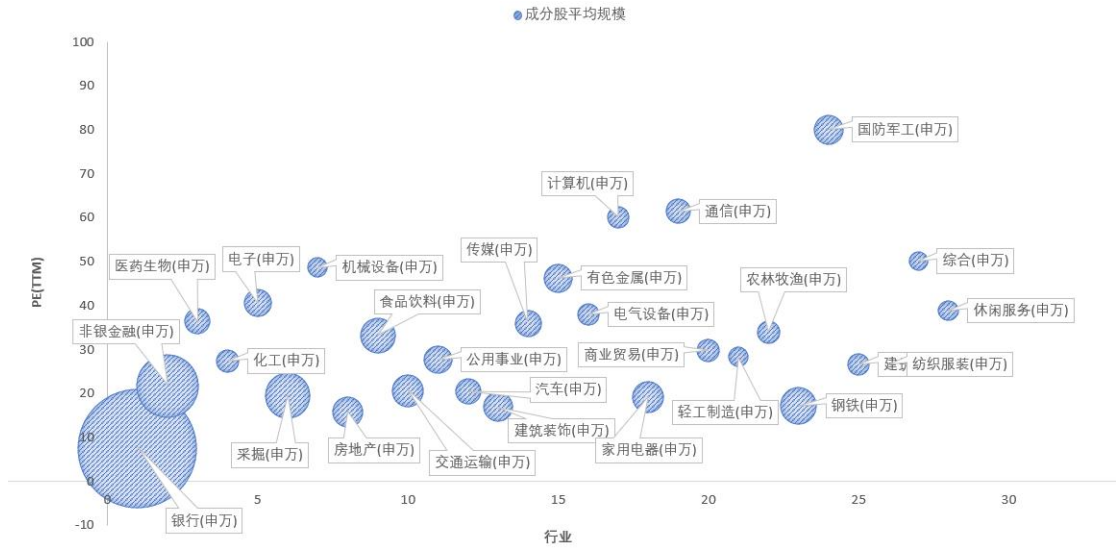


图 4 A 股的行业估值与市值分布

(四) 估值变化的周期探析

以上围绕市值和行业对 A 股估值进行了探讨，这些可视作 A 股的“静态”规律，为构建一个能够实现稳定盈利的策略体系，还应对 A 股的“动态”规律进行研究，周期规律即是一类重要“动态”规律。为此，我们基于估值，通过计算当前估值与历史估值的相似情况，对市场估值波动周期进行分析。

图 5 中的下图描述了 2016 年至今 A 股全市场基于估值分布的相似度情形，从该图可看出，历史上与当前市场相似的时期多集中在 2011 至 2014 年初，在这一时期 A 股中小盘股呈现震荡下跌趋势，中证 500 指数从 5100 点震荡下行至 2014 年年初的 3800 点，下跌近 25%，且当前市场估值在过去 10 年历史中较为常见。从波动周期（蓝线）看，市场估值变化的短周期特征并不明显。因此，估值对于构建策略体系最大的意义在于长期风险控制，估值规律可用于构建长期风险控制模块用于控制年度持仓结构。除此之外，我们还对 28 个行业的估值周期进行了分析，得出的结论与上述全市场分析一致。




图5 A 股的重要指数与估值波动周期

二、A 股的趋势

（一）券商对于趋势的研究

相对于估值，券商金工近年对趋势的研究较多。一般认为，价格走势是由趋势和震荡两种走势类型组合而成，震荡结束后转为趋势，趋势结束之后便是震荡。券商对于趋势的研究主要围绕趋势技术指标展开，在提高技术指标胜率这一终极目标的指引下，一些研究从价格曲线自身出发，创造性的提出均线交叉等量化策略，另一些研究则针对指数成分股，通过分析成分股的动量反转或走势分化来判断指数走势，还有一些研究运用了深度学习等新的工具，对趋势策略进行了增强。

对于价格曲线自身，国泰君安在《动量测评之均线策略——数量化专题之五十六》中，探讨动量策略中常见的单均线策略，定义为价格上穿均线或下穿均线后产生的可能趋势行情。该策略既不需要分析市场走势也不需要预测市场，具备信号清晰简单、策略成本低、无参数拟合等诸多优点。进一步地，国泰君安在《国泰君安数量化专题之六十九：基于均线择时的保本基金设计》中，针对传统 CPPI 和 TIPP 的仓位管理方法的不足，利用改进后的单均线择时策略，测算出股票资产波动的最大风险，从而根据风险偏好选择合理的风险乘数，同时加入择时策略后有效降低了下跌趋势中的股票仓位。广发证券在《均线交叉策略的另类创新研究——另类交易策略系列之二十七》中，提出了一种改进的均线交叉策略，通过改变传统均线交叉策略的平仓条件，使得风险收益表现显著提升，

同时策略的稳定性也有较大的改善。

对于分析指数成分来判断指数走势，中信建投证券在《基于成分股动量反转效应的均线择时研究：以深次新股指数为例》中，利用成分股技术指标构建了指数结构化指标，根据指数历史波动率的大小将历史分为低波动和高波动两种区间，通过判断当前属于哪种区间，从动量策略和反转策略中选择对当前区间相对合适的参数进行择时。国信证券在《金融工程专题：指数投资系列，基于股票分化度的指数趋势策略》中，构建了度量市场指数成分收益率风华程度的股票分化度指标，利用该指标对华夏 50ETF、嘉实 200ETF、华泰柏瑞 300ETF 和南方 500ETF，使用基于股票分化度的 4 周趋势策略，年化收益率分别为 11%、16%、20%和 22%，全面优于简单趋势策略和 ETF 走势本身。

对于深度学习技术应用于趋势分析。广发证券在《深度学习研究报告之四：趋势策略的深度学习增强》中，提出了一种趋势策略的深度学习增强方案，在每个交易日取早盘行情数据，用循环神经网络模型来预测当日趋势策略能否盈利。若判断可以盈利，则根据早盘行情的走势进行趋势跟踪；若判断盈利机会小，则当日不开仓交易。实证分析证实策略在历史回测中表现良好，样本外（2014 年至 2017 年）年化收益率 18.47%，最大回撤为-8.63%，盈亏比为 2.27。同时，策略的单笔交易的平均收益率比较高，对交易成本不敏感。

以上分析尝试从多个维度分析趋势，试图从中挖掘部分规律，指导具体的投资决策。在实操过程中，以上这些基于趋势方法的指标属简易指标，单一指标的胜率不高。为获取稳定盈利，需要组合多个指标使用，但这些指标基于不同的前提假定，组合之后指标之间匹配度较低，难以实现“共振”。产生这一现象的原因同样在于基于简易技术指标的“共振”方法体系缺乏完备性。与多因子方法体系类似，“共振”方法体系试图从技术指标组合或技术指标和人结合（人技结合）中获取稳定收益，但从周期的视角来看，“共振”方法体系有效的基础与多因子方法体系相同，均为体系鲁邦周期低于市场风格切换周期。

（二）趋势变化的重要指数周期探析

与估值分析不同，对指数趋势的分析将不考虑成分股的估值分布，仅仅利用价格曲线，试图只从价格曲线中找到可重现的规律，构造出策略体系并通过识别、判断、行动等流程将该规律转换成稳定回报。

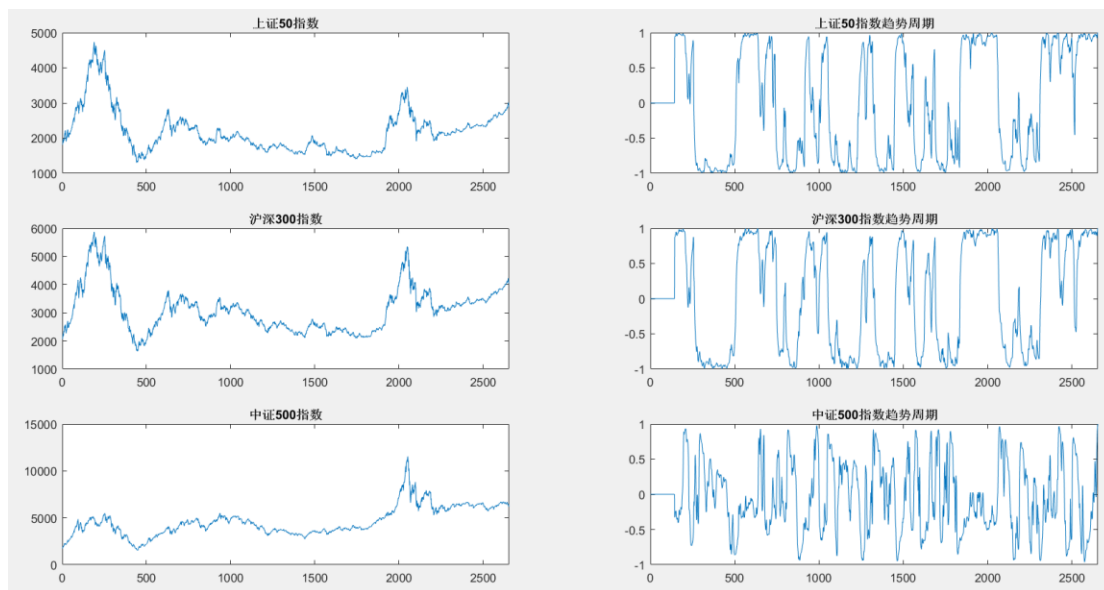


图 6 A 股的重要指数与趋势波动周期

图 6 展示了上证 50、沪深 300 和中证 500 三大指数趋势变化的周期特征，从右图可以明显看出，与沪深 300 指数和上证 50 指数比较，中证 500 在周期长度和期限分布方面存在明显差异。沪深 300 和中证 50 近十年可识别波动周期平均为 420 个交易日，而中证 500 的可识别波动周期为 230 个交易日，从期限分布看，沪深 300 和上证 50 的周期特征更加明显，而中证 500 周期特征稍显散乱。然而，我们发现深度强化学习体系，即便对于中证 500 等稍显散乱的周期特征，都能够有效地挖掘出该曲线所隐含的规律，再结合识别和决策体系，一定程度上能够对人工技术分析范式形成替代。

（三）趋势变化的行业周期探析

我们对申万 28 个行业过去十年指数曲线的周期进行了分析，从图 7 可以看出，这些行业指数与沪深 300 或上证 50 在周期长度和期限分布上存在明显区别，而且各个行业指数也差异显著。

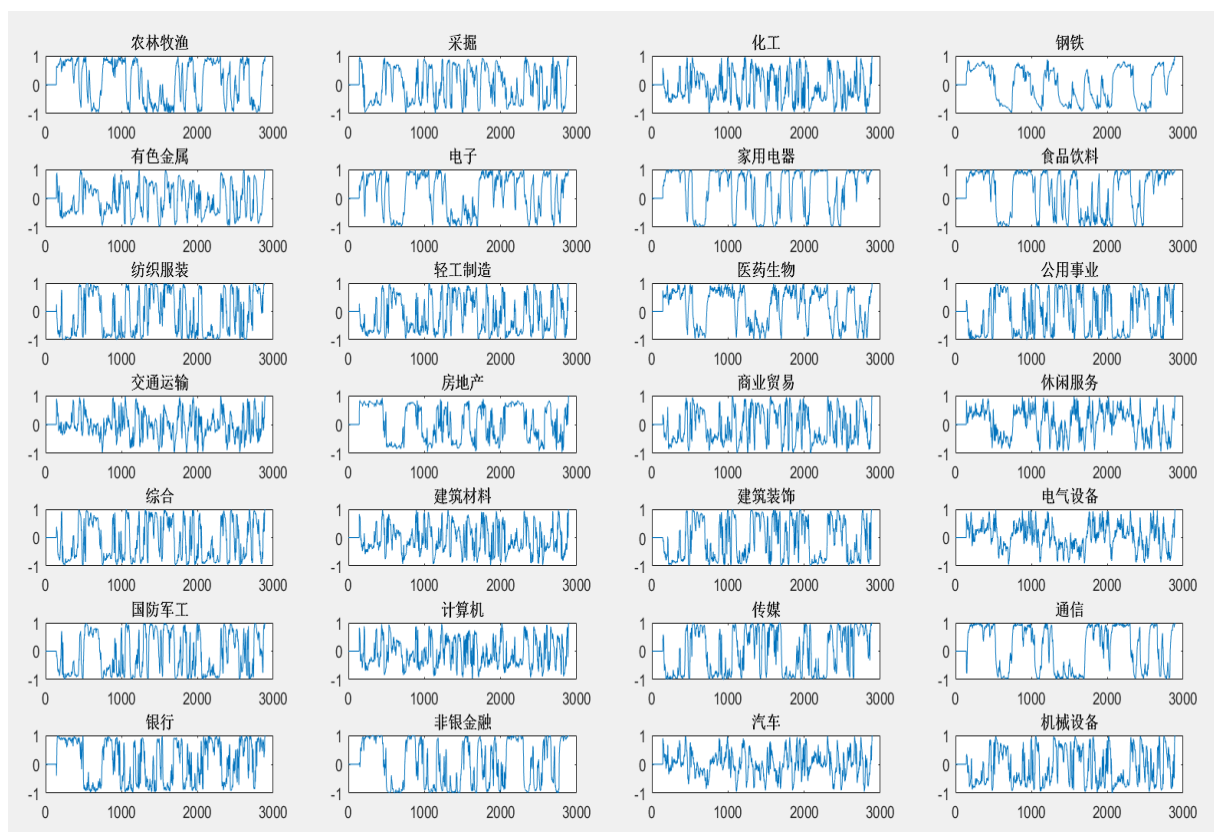


图7 A 股的行业指数与趋势波动周期

进一步对周期均值进行了计算。发现房地产和钢铁指数的可识别波动周期最长，周期值也十分接近，分别为 1373 天和 1371 天；采掘、有色金属、计算机、建筑材料、汽车、交通运输和休闲服务的可识别波动周期值次之，分别为 450、450、389、301、247、226 和 208 个交易日；化工、机械设备、商业贸易、轻工制造、电气设备、建筑装饰、国防军工和综合的可识别波动周期值居中，分别为 192、189、178、176、150、126、125 和 117 个交易日；纺织服装、公用事业、医药生物、传媒、非银金融、农林牧渔、银行、电子、家用电器、食品饮料和通信的可识别波动周期值最少，分别为 87、86、73、67、66、52、51、50、46、39 和 34 个交易日。




图8 A股的行业指数周期均值

以上仅是趋势的周期特征中的期限进行了简要比较，基于深度强化学习算法，我们还能对更多隐含特征进行分析，由于篇幅有限，这些特征将不予论述。这些特征形成特征集，将作为一个完备深度强化学习交易体系的基础数据。

三、深度强化学习交易体系构建与交易方法论

(一) 一个深度强化学习交易体系的构建：基于估值与趋势

A股市场现存较为成熟的量化策略体系主要为多因子体系，以及在此基础上衍生出的多策略体系和团队“共振”体系。根据之前的文献分析，为获取持续稳定回报，这些体系需要解决两个重要问题——人机结合和鲁棒周期，由于人决策的高度不稳定，以及估值因子鲁棒周期的不确定，上述三种体系的有效运行需要高额的制度维护成本。本文提出的深度强化学习交易体系或能有效的降低这一成本。



图9 一种可行的深度强化学习交易体系

从上文的估值和趋势分析中，我们尝试构建了涵盖估值、趋势和周期分析三个模块，深度强化学习一个核心的深度强化学习交易体系，三个模块主要用于从大量历史数据中提取该类型 **Pattern**，深度强化学习核心用于对短期市场变化形成反馈，整个体系涵盖长、中、短三个交易期限，最终实现决策体系的完备化。深度强化学习核心部分则可以通过构建一个策略网络实现。所谓的策略网络，即建立一个神经网络模型，它可以通过观察环境状态，直接预测出目前最应该执行的策略 (**policy**)，执行这个策略可以获得最大的期望收益 (包括现在的和未来的 **reward**)。和之前的任务不同，在深度强化学习中可能没有绝对正确的学习目标，样本的 **feature** 和 **label** 也不再一一对应。我们的学习目标是期望价值，即当前获得的 **reward** 和未来潜在的可获取的 **reward**。所以在策略网络中不只是使用当前的 **reward** 作为 **label**，而是使用 **Discounted Future Reward**，即把所有未来奖励一次乘以衰减系数 γ 。

(二) 技术变迁下的交易方法论

在当前主流的经济类学科设置中，高级宏观经济学、高级微观经济学和高级计量经济学是最重要的三门课程，这些课程主要采用“基本假设——数理模型——回归分析”的方法论，这也对 A 股市场的量化方法论产生了深刻影响。当前市场中主流的多因子和多策略算法高度依赖回归分析。但事实上，金融市场是一个嘈杂的、具有非参数特点的动态系统，现有分析预测方法在不同的程度上都体现出一定的“不适应性”：传统计量方法或含参数的方程并不适合用于分析复杂、高维度、具有噪音的金融市场数据序列。这导致了当前多因子、多策略和“共振”体系对于“周期”因素的阶段有效，有效应对周期变化成为了配套制度建设的重要目标，但这种有效性难以回测。因而这些体系更适合应用于选股/基金，而非择时。

伴随着大数据积累、计算机并行计算能力的发展，人工智能逐渐渗透到各个领域，在经济社会发展中引导行业进行着深刻变革。而在变革过程中，深度学习风靡于多样化的人工智能任务中，成为解决人工智能发展瓶颈的关键技术。深度学习及由此衍生的优化技术改进了金融领域预测分析方法，在一定程度上能够更有效地从高噪声和非参数的动态数据中提取有用数据并用于完备化交易决策，其在金融领域中的应用不仅在一定程度上缓解了上述分析与预测的难题，更带来了

金融学乃至经济学实证分析范式的改变。

而在 A 股市场这种改变的直接体现是量化方法体系从 Q-quant 到 P-quant 的转变，从传统的多因子体系向强化体系转变，从依赖制度建设到完备交易体系的构建。这种改变也会对量化业态产生深远影响，随着算法逐步取代制度，量化团队规模将逐步缩小，业界将会出现一批掌握完备交易体系的独立投顾，为服务这些独立投顾，互联网量化平台将逐步取代传统区域资金供应网络，高端互联网量化平台将取代传统中低端平台。而在此机器替代制度的大潮之下，传统金融机构是否能持续发展关键在其是否能够快速适应市场并构建出灵活的多方合作模式。