华泰证券 HUATAI SECURITIES

金工研究/深度研究

2020年12月22日

林晓明 研究员
SAC No. S0570516010001
SFC No. BPY421
0755-82080134
linxiaoming@htsc.com

李子钰 研究员
SAC No. S0570519110003
0755-23987436
liziyu@htsc.com

何康 研究员
SAC No. S0570520080004
021-28972039
hekang@htsc.com

王晨宇 联系人
SAC No. S0570119110038
02138476179
wangchenyu@htsc.com

相关研究

1《金工：周频量价选股模型的组合优化实证》2020.12
2《金工：行业配置落地：指数增强篇》2020.11
3《金工：农业板块迎来全新工具型投资产品》2020.11

微软 AI 量化投资平台 Qlib 体验

华泰人工智能系列之四十

核心观点

本文介绍微软 AI 量化投资平台 Qlib 基础和进阶功能，对比传统量化策略开发流程和 Qlib 提供的解决方案，提炼 Qlib 特色及优势，并探讨笔者使用体会。Qlib 于 2020 年 9 月公开初版源码，2020 年 12 月获微软官网报道并引发热议。我们认为 Qlib 的主要优势在于：1）覆盖量化投资全过程，用户无需切换工具包或编程语言，降低 AI 算法使用门槛；2）从工程实现角度，对因子数据储存、因子计算等环节提出创新解决方案，提升运算性能和开发效率，或能解决量化投资研究中的部分痛点。

笔者使用体会：侧重量价选股，解决部分痛点，开源或推动技术发展

笔者使用 Qlib 的体会是，Qlib 在“术”层面的创新要大于在“道”层面的创新。Qlib 在宣传中称其为“业内首个 AI 量化投资开源平台”，而就目前公开的功能看，Qlib 的核心是“量价因子结合 AI 模型选股流程”，在“道”的层面未脱离传统因子选股方法论。在“术”的层面， Qlib 提出的数据存储方案、表达式引擎等工程创新一定程度上能够解决研究中的部分痛点。微软此次的开源尝试能够降低整个行业的学习和研发成本，或能推动量化投资行业的技术发展。

Qlib 基础功能：以港股日频量价因子 LightGBM 选股策略为例

Qlib 官方推荐的学习素材有 GitHub 文档和在线文档，包含 A 股日频量价因子 AI 选股策略案例，然而直接学习官方代码的“代入感”不强，并且官方代码绕过了很多“坑”，但研究者在实际学习使用时可能绕不开这些“坑”。为了帮助读者快速上手 Qlib，我们参考官方代码，设计新的应用场景，以港股日频量价因子 LightGBM 选股策略为例，分 Qlib 安装、数据准备、因子生成、策略构建、结果展示各步骤，讲解 Qlib 基础功能。

Qlib 进阶功能：自定义策略组件

我们以自定义因子、标签、数据预处理方式、AI 模型为例讲解 Qlib 的进阶功能。AI 选股模型包含因子生成和预处理、模型训练、策略回测等组件，在 Qlib 中这些组件通过工作流 workflow 串联在一起，每个组件均有对应参数控制。因此最简单的自定义策略方式是直接修改参数。另外，每个组件都有其对应源码，更灵活的自定义策略方式是修改源码或仿照源码创建新的继承类。

Qlib 特色：覆盖量化投资全过程，拥有多项工程上的创新

Qlib 的设计初衷之一在于覆盖量化投资的全过程，为用户的 AI 算法提供高性能的底层基础架构，降低 AI 算法的使用门槛，便于金融从业者使用。Qlib 的“高性能底层基础架构”体现在多项工程上的创新，例如数据存储方案、表达式引擎和缓存系统。据论文 *Qlib: An AI-oriented Quantitative Investment Platform* 测试显示，Qlib 在读取原始数据和生成因子任务上的性能表现优于传统关系型数据库 MySQL、非关系型数据库 MongoDB、时序数据库 InfluxDB 和 HDF5。

风险提示：本文的港股 AI 选股策略仅作案例教学使用，不具备实际投资价值，例如未剔除低价股、低流动性股票，训练集和测试集较短，未进行参数优化等。Qlib 仍在开发中，部分功能未加完善和验证，使用存在风险。人工智能挖掘市场规律是对历史的总结，市场规律在未来可能失效。人工智能技术存在过拟合风险。

免责声明和披露以及分析师声明是报告的一部分，请务必一起阅读。

正文目录

研究导读 4
快速上手 Qlib：以港股日频量价因子 AI 选股策略为例 5
Qlib 安装 5
安装 Microsoft C++生成工具 5
setup.py 安装 6
数据准备 7
get_data 下载官方数据 7
dump_all 转换用户数据格式 7
港股日频量价因子生成 9
初始化运行环境和原始数据读取 9
自定义股票池 11
Alpha158 因子库 11
LightGBM 选股策略构建 13
选股策略回测 16
回测和绩效分析结果展示 18
Qlib 进阶：自定义策略组件 20
自定义特征 20
自定义标签 21
更换数据预处理方法 21
更换 AI 模型 23
其它功能 24
Qlib 特色及使用体会 25
Qlib 覆盖量化投资全过程 25
传统量化投资策略开发 25
Qlib 的改进 26
工程创新：数据存储设计，表达式引擎，缓存系统 27
数据存储方案 28
表达式引擎 29
缓存系统 30
使用体会：侧重量价选股，解决部分痛点，开源或推动技术发展 30
参考文献 30
风险提示 31

图表目录

图表 1： Microsoft C++生成工具下载 5
图表 2： Microsoft C++生成工具安装 6
图表 3： setup.py 安装 Qlib 6
图表 4： get_data 下载官方数据 7
图表 5： dump_all 转换前的 csv 文件 7
图表 6： 港股行情 csv 数据（以腾讯控股 0700 HK 为例） 8
图表 7： csv 数据字段说明 8

图表 8： dump_all 转换用户数据格式 9
图表 9： dump_all 转换后的 bin 和 txt 文件 9
图表 10： 初始化运行环境 10
图表 11： 获取交易日期和全部股票代码 10
图表 12： 获取指定股票指定日期指定字段数据 10
图表 13： 自定义股票池 11
图表 14： 生成 Alpha158 特征（当期因子）和标签（下期收益） 12
图表 15： 获取 Alpha158 因子库标签（下期收益） 12
图表 16： 获取 Alpha158 因子库特征（当期因子） 13
图表 17： 导入 Qlib 模块代码 14
图表 18： 定义股票池和基准指数代码 14
图表 19： 模型训练参数 task 的 AI 模型参数 model 14
图表 20： 模型训练参数 task 的 AI 模型参数 dataset 15
图表 21： 因子生成参数 data_handler_config 和模型训练参数 task 设置代码 15
图表 22： 模型训练代码 16
图表 23： 策略回测参数 port_analysis_config 16
图表 24： 选股策略回测参数设置代码 17
图表 25： 选股策略回测代码 17
图表 26： 回测和绩效分析结果读取代码 18
图表 27： AI 模型预测结果 IC 和 Rank IC 18
图表 28： 策略净值、超额收益净值、最大回撤和换手率 19
图表 29： 各组件参数及对应源码所在路径 20
图表 30： 自定义特征代码 20
图表 31： 通过设置参数自定义标签代码 21
图表 32： 通过修改因子库源码自定义标签代码 21
图表 33： Qlib 内置数据预处理方法（qlib.data.dataset.processor） 22
图表 34： Alpha158 和 Alpha360 因子库默认预处理方式 22
图表 35： 自定义数据预处理代码 22
图表 36： Qlib 内置 AI 模型（qlib.contrib.model） 23
图表 37： 通过设置参数自定义 AI 模型代码 23
图表 38： 通过创建新 Model 子类（如 SVR 支持向量回归）自定义 AI 模型代码 24
图表 39： 某团队人工智能选股模型开发流程 25
图表 40： Qlib 提供的人工智能选股模型开发解决方案 26
图表 41： Qlib 的三层框架：基础架构层、量化投资流程层和交互层 26
图表 42： Qlib 各模块的另一种拆解：静态流程、动态建模和分析模块 27
图表 43： Qlib 高性能底层基础架构 28
图表 44： 不同因子数据存储方案的长处和短板 28
图表 45： Qlib 数据存储方案 29
图表 46： 不同因子数据存储方案下的性能比较 29
图表 47： Qlib 缓存系统 30

研究导读

2020 年 9 月，微软亚洲研究院在学术论文预印本平台 arXiv 发布论文 *Qlib: An AI-oriented Quantitative Investment Platform*，公开其开发的业内首个 AI 量化投资开源平台 Qlib，并在代码托管平台 GitHub 上开放源代码。2020 年 12 月，微软亚洲研究院在官网报道该消息，一石激起千层浪。微软称 Qlib“通过创建一个通用的技术平台，帮助实现量化投资流程的 AI 闭环”。

AI 量化投资开源平台对于量化投资领域的意义不凡。一套标准化的代码能提升整个行业的研究效率，避免重复造轮子；代码开源使得研究者能够学习业内同行的先进经验，并根据实际需求自由修改和添加功能。投资者关心的问题是，Qlib 是否如宣传得那么强大？Qlib 包含哪些功能，有哪些使用场景？Qlib 解决了传统量化策略开发流程中的哪些痛点？Qlib 的实际使用体验如何？

带着上述问题，笔者将从实操层面一探究竟。本文第一部分以港股日频量价因子 LightGBM 选股策略为例，带领读者快速上手 Qlib。第二部分深入讲解如何自定义策略中的各个组件，如自定义因子、标签、数据预处理方式、AI 模型等环节。第三部分结合 Qlib 论文，介绍 Qlib 的特色以及相比传统量化策略开发流程的改进之处，最后谈谈笔者的使用体会。

我们认为，Qlib 的主要优势在于：1）覆盖量化投资全过程，用户无需切换工具包或编程语言，降低 AI 算法使用门槛；2）从工程实现角度，对因子数据储存、因子计算等环节提出创新解决方案，提升运算性能和开发效率，或能解决量化投资研究中的部分痛点。

快速上手 Qlib：以港股日频量价因子 AI 选股策略为例

Qlib 官方推荐的学习素材有 GitHub 文档（https://github.com/microsoft/qlib）和在线文档（https://qlib.readthedocs.io/en/latest/index.html）。学习素材包含 A 股日频量价因子 AI 选股策略案例。然而直接学习官方代码的“代入感”不强，并且官方代码绕过了很多“坑”，但研究者在实际学习使用时可能绕不开这些“坑”。为了帮助读者快速上手 Qlib，我们参考官方代码，设计新的应用场景，以港股日频量价因子 AI 选股策略为例，分 Qlib 安装、数据准备、因子生成、策略构建、结果展示各步骤，讲解 Qlib 使用方法。

Qlib 安装

Qlib 安装是读者容易遇到的第一个“坑”。首先推荐在 Python 3.7 及更新版的 Python 环境下安装。Qlib 官方提供 1）pip 和 2）setup.py 两种安装方式。其中 pip 安装较为简单，在命令行直接运行 **pip install pyqlib** 即可，将自动安装最新的 Qlib 稳定版。不过笔者经 Windows 和 Mac 系统下测试，更推荐 setup.py 方式。具体安装步骤如下。

安装 Microsoft C++生成工具

Qlib 运行依赖 Microsoft Visual C++ 14.0，否则安装过程中会报如下错误：
error: Microsoft Visual C++ 14.0 is required. Get it with "Build Tools for Visual Studio": https://visualstudio.microsoft.com/downloads/

注意这里仅安装运行组件（Microsoft Visual C++ Redistributable）无法解决此问题，需要安装完整版 Microsoft Visual Studio 或者参考报错信息安装 Microsoft C++生成工具。生成工具的下载链接为：https://visualstudio.microsoft.com/zh-hans/visual-cpp-build-tools/

图表1： Microsoft C++生成工具下载

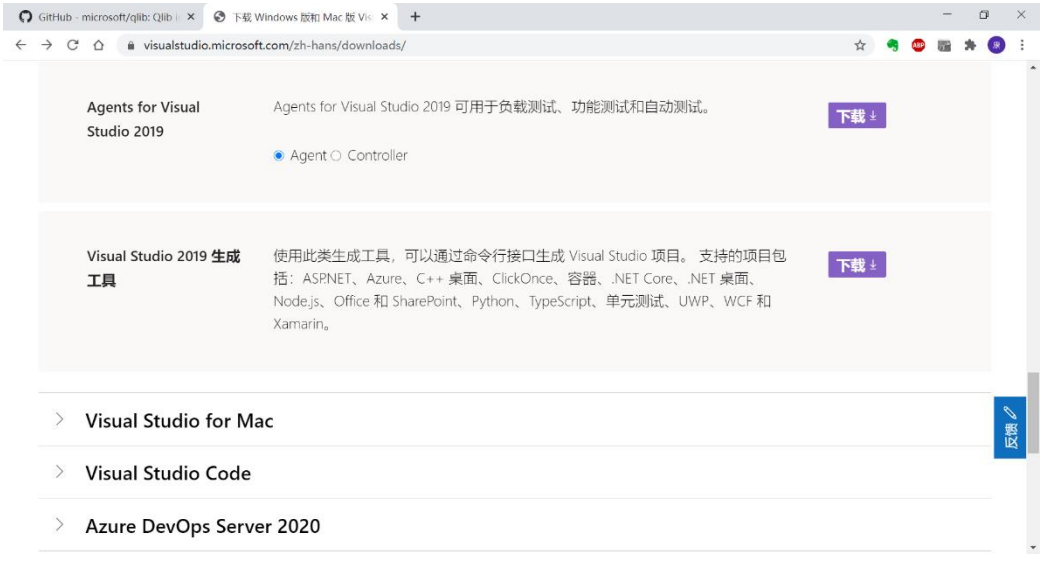

资料来源：微软官网，华泰证券研究所

安装生成工具过程中，需要点选部分选项，参考微软官方建议链接及下图：
https://docs.microsoft.com/en-us/answers/questions/136595/error-microsoft-visual-c-140-or-greater-is-require.html

图表2： Microsoft C++生成工具安装

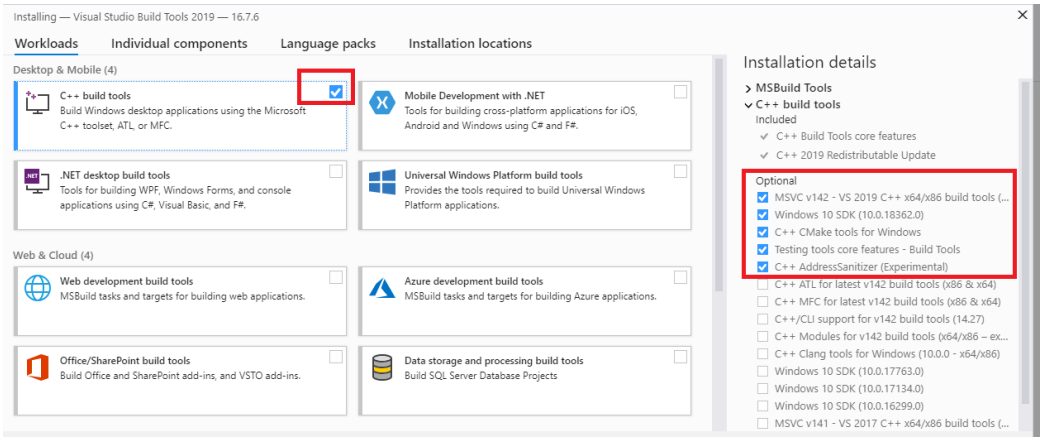

资料来源：微软官网，华泰证券研究所

setup.py 安装

Qlib 官方给出的 setup.py 安装方式如下。首先安装或更新 numpy 和 cython 库，在命令行运行 **pip install numpy** 和 **pip install --upgrade cython** 即可。

接下来的安装分两种情况：

1. 若已安装 git 并完成环境配置，在命令行运行下列指令即可：
   git clone https://github.com/microsoft/qlib.git && cd qlib
   python setup.py install
2. 若未安装 git，可在 GitHub 下载 zip 源码包（https://github.com/microsoft/qlib），解压缩至任意路径，如笔者放在 C:/Users/username/anaconda3/Lib/site-packages/qlib，确保 setup.py 文件在该路径下，随后在该路径下启动命令行，运行如下指令即可：
   python setup.py install

Qlib 的 setup.py 安装方式将自动安装包含开发版在内的最新版。例如笔者在 2020 年 12 月 14 日安装的版本为 0.6.1.dev0。笔者办公网络环境不支持 git 安装，故采用上述第二种方式，命令行安装过程如下图。

图表3： setup.py 安装 Qlib

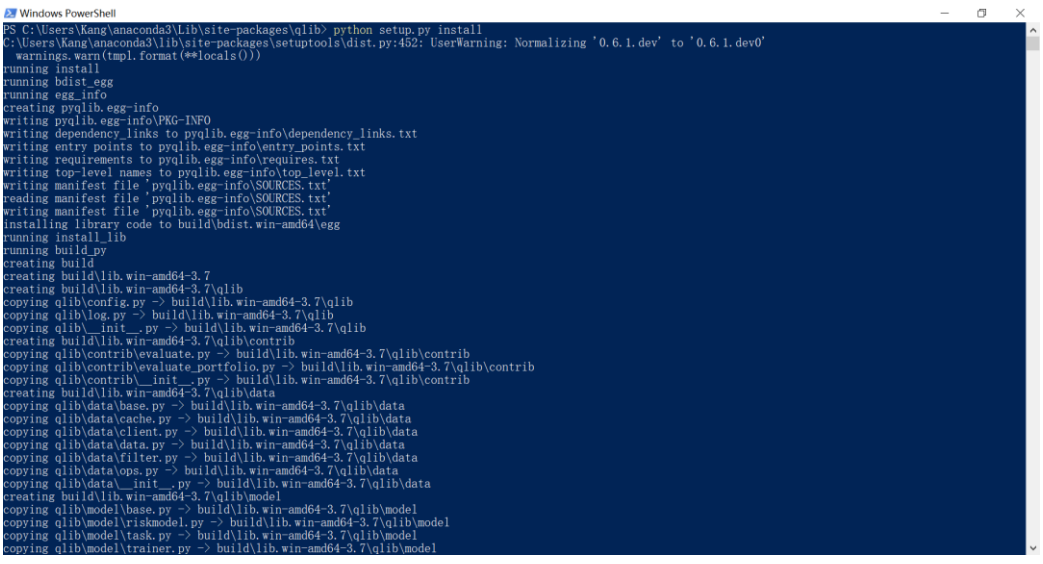

资料来源：Qlib，华泰证券研究所

数据准备

get_data 下载官方数据

Qlib 提供 A 股和美股两类数据作学习测试使用。Qlib 官方给出的 A 股数据下载方法为：在 Qlib 安装路径（如 C:/Users/username/anaconda3/Lib/site-packages/qlib）启动命令行，运行如下 get_data 指令：

python scripts/get_data.py qlib_data --target_dir ~/.qlib/qlib_data/cn_data --region cn

若读者采用 pip 方式安装 Qlib，运行上述指令可能报错：ModuleNotFoundError: No module named 'qlib.tests'。解决方法为：在 GitHub 下载 Qlib 的 zip 源码包，将 tests 文件拷贝至安装路径。

图表4： get_data 下载官方数据

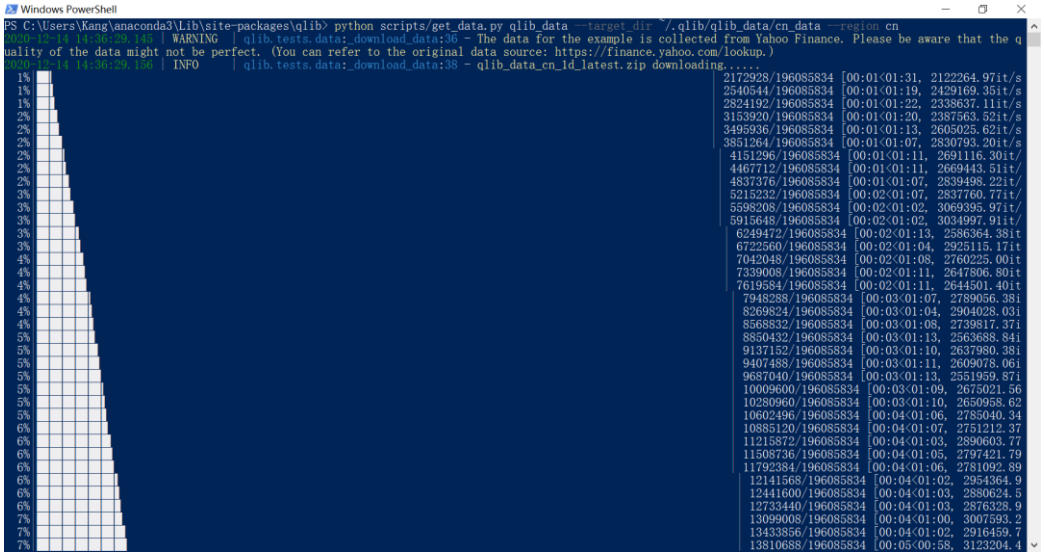

资料来源：Qlib，华泰证券研究所

笔者下载 Qlib 官方数据过程如上图所示。下载成功后，数据保存在如下路径：C:/Users/username/.qlib/qlib_data/cn_data。

dump_all 转换用户数据格式

除官方数据外，Qlib 支持用户提供的 csv 格式数据，需要调用 dump_all 指令将 csv 格式数据转换为 bin 和 txt 格式。下面笔者以港股行情数据为例，展示数据格式转换的步骤。

图表5： dump_all 转换前的 csv 文件

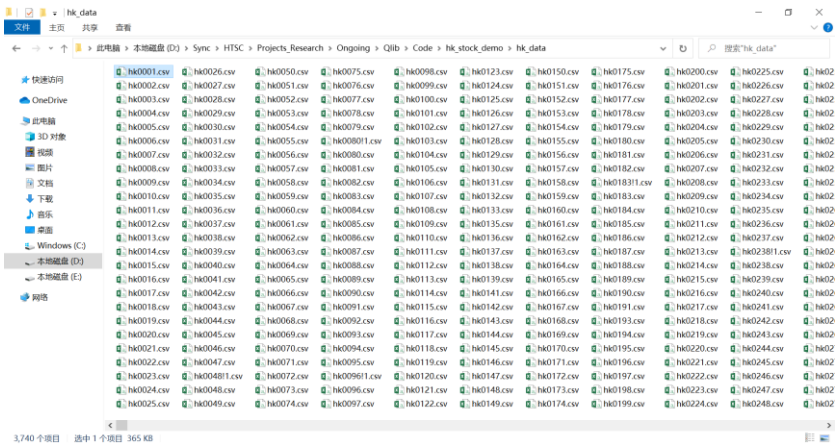

资料来源：Wind，华泰证券研究所

将原始港股行情数据保存为上图形式，即每只股票存成一个 csv 文件，文件名为股票代码，文件夹命名为 hk_data。数据从 2008 年初至 2020 年 11 月末，共计 3739 只股票（含权证，含已退市）。每个 csv 文件内部如下图所示。

图表6： 港股行情 csv 数据（以腾讯控股 0700 HK 为例）

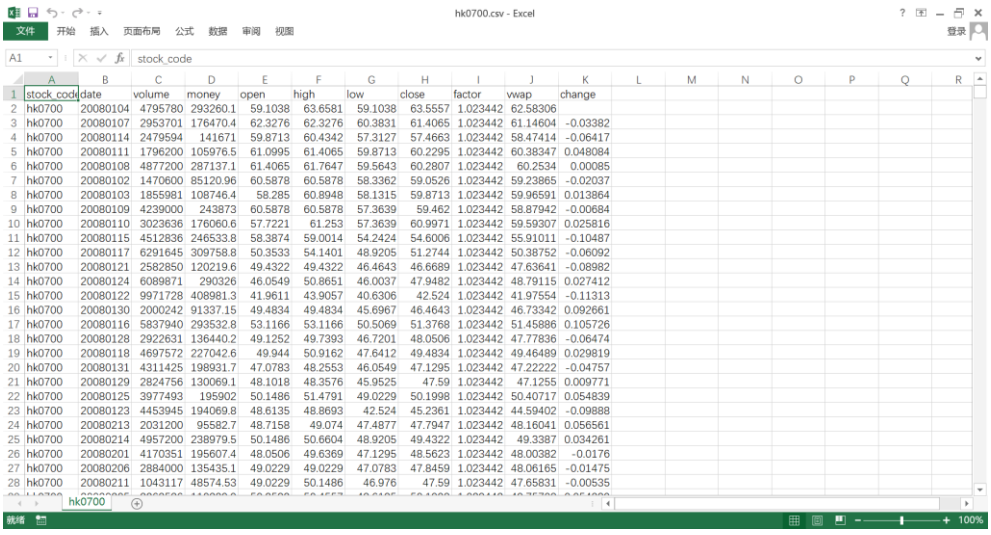

资料来源：Wind，华泰证券研究所

股票 csv 数据需要至少包含下表所示字段。其中有两个“坑”需要注意：

1. 价格数据的要求在官方文档中未提及，笔者建议采用复权价格，原因在于后续数据标注（源码见 qlib.contrib.data.handler）采用 close 或 vwap 计算股票未来收益率，且回测（源码见 qlid.contrib.evaluate.backtest）使用 close、open 或 vwap 进行交易。
2. 数据需包含 factor 或 change 字段，否则运行 Qlib 官方提供的策略全流程范例代码 examples/workflow_by_code.py 时，策略收益和净值将出现异常。

图表7： csv 数据字段说明

字段名称	字段说明	字段名称	字段说明
stock_code	股票代码，和文件名一致，字段名称不唯一	low	复权最低价
date	日频日期，字段名称不唯一	close	复权收盘价
volume	成交量	factor	复权因子
money	成交额	vwap	复权均价
open	复权开盘价，前后复权均可（下同），笔者采用后复权	change	相对前一个交易日涨跌幅
high	复权最高价		

资料来源：Wind，华泰证券研究所

除个股数据外，还需准备指数数据作为基准。笔者将恒生指数行情数据以和股票数据相同形式保存在相同路径下，命名为 hkhsi.csv。回到 Qlib 安装路径，在命令行运行 dump_all 指令：

python scripts/dump_bin.py dump_all --csv_path ~/.qlib/csv_data/hk_data --qlib_dir ~/.qlib/qlib_data/hk_data --symbol_field_name stock_code --date_field_name date --include_fields open,high,low,close,volume,money,factor,vwap,change

上述 dump_all 指令包含如下参数：

1. symbol_field_name：csv 文件中股票代码列名，此处为 stock_code；
2. date_field_name：csv 文件中日期列名，此处为 date；
3. include_fields：其余字段名，注意逗号后不能有空格，否则数据转换将出现错误。

使用 dump_all 将用户 csv 数据格式转为 bin 数据格式的过程如下图所示。

图表8： dump_all 转换用户数据格式

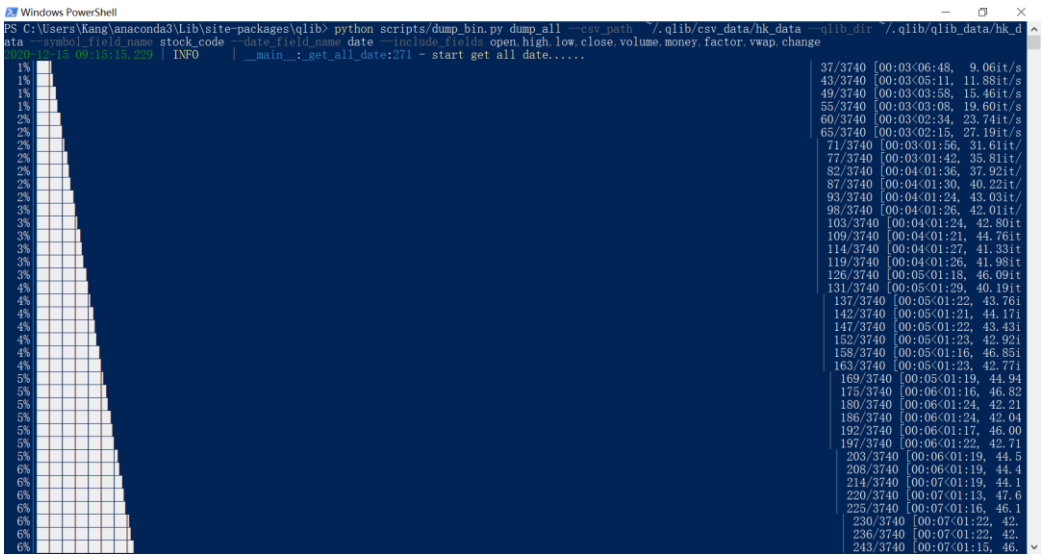

资料来源：Wind，Qlib，华泰证券研究所

转换完成后，新数据保存在如下路径：C:/Users/username/.qlib/qlib_data/hk_data。该路径下包含 calendar、features 和 instruments 三个子文件夹，分别存放交易日历、行情特征和股票池。其中行情特征为 bin 格式，这与传统量化策略开发使用的数据格式类型不同，Qlib 数据存储方案的优势将在后文介绍。

图表9： dump_all 转换后的 bin 和 txt 文件

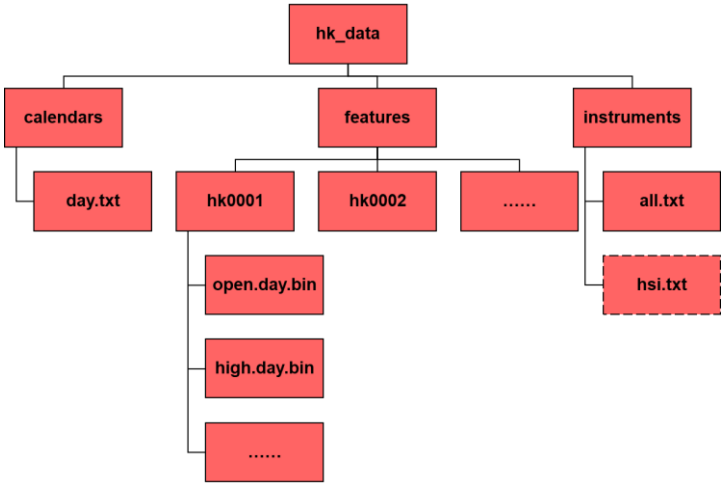

资料来源：Wind，Qlib，华泰证券研究所

港股日频量价因子生成

接下来我们将构建港股日频量价因子 AI 选股策略，核心环节之一是生成量价因子。Qlib 提供两套自带的因子库，分别为 **Alpha158** 和 **Alpha360**，分别包含 158 和 360 个 Alpha 因子。这里的因子库并非是计算好的因子值，而是一套生成因子的算法（Qlib 中称表达式），因此可迁移至任意股票池。

初始化运行环境和原始数据读取

在 Python 中运行 Qlib 程序前，需要首先初始化运行环境，命令为 qlib.init，参数 provider_uri 为港股数据所在路径，如下图所示。

图表10： 初始化运行环境

```
In [1]: # 初始化港股数据环境
        import qlib
        qlib.init(provider_uri='~/.qlib/qlib_data/hk_data')

[11780:MainThread](2020-12-17 11:09:56,698) INFO - qlib.Initialization - [__init__.p
y:42] - default_conf: client.
[11780:MainThread](2020-12-17 11:09:58,704) WARNING - qlib.Initialization - [__init_
_.py:58] - redis connection failed(host=127.0.0.1 port=6379), cache will not be used!
[11780:MainThread](2020-12-17 11:09:58,709) INFO - qlib.Initialization - [__init__.p
y:77] - qlib successfully initialized based on client settings.
[11780:MainThread](2020-12-17 11:09:58,713) INFO - qlib.Initialization - [__init__.p
y:80] - data_path=C:\Users\Kang\.qlib\qlib_data\hk_data
```

资料来源：Wind，Qlib，华泰证券研究所

调用 qlib.data 模块可读取原始数据。例如 qlib.data.calendar 命令可读取指定时间区间内交易日期；qlib.data.instruments 命令可定义股票池，参数 market='all'代表选取全部个股构成股票池；qlib.data.list_instruments 命令可以展示指定时间区间内的股票池，时间区间的意义在于，股票池可能会随时间动态变化，如指数成分股票池。

图表11： 获取交易日期和全部股票代码

```
In [2]: from qlib.data import D

        # 获取港股2020年1~11月交易日期
        trade_date = D.calendar(start_time='2020-01-01', end_time='2020-11-30', freq='day')
        # 展示前5个交易日期
        print(trade_date[:5])

[Timestamp('2020-01-02 00:00:00') Timestamp('2020-01-03 00:00:00')
 Timestamp('2020-01-06 00:00:00') Timestamp('2020-01-07 00:00:00')
 Timestamp('2020-01-08 00:00:00')]

In [3]: # 获取2020年7~11月全部港股代码
        instruments = D.instruments(market='all')
        stock_list = D.list_instruments(instruments=instruments,
                                        start_time='2020-07-01',
                                        end_time='2020-11-30',
                                        as_list=True)
        # 展示后5个股票代码
        print(stock_list[-5:])

['HK9996', 'HK9997', 'HK9998', 'HK9999', 'HKHSI']
```

资料来源：Wind，Qlib，华泰证券研究所

调用 qlib.data.features 模块可以获取指定股票指定日期指定字段数据，例如下图展示获取腾讯控股（0700 HK）在 2020 年 1 月初至 11 月底的日频后复权收盘价和成交量。需注意，Windows 系统下 Qlib 安装路径以及数据文件默认在 C 盘，笔者的经验是读取数据的程序最好也在 C 盘下运行，否则获取 feature 时可能无响应。

图表12： 获取指定股票指定日期指定字段数据

```
In [5]: # 获取指定股票指定日期指定字段数据
        features_df = D.features(instruments=['HK0700'], fields=['$close', '$volume'],
                                 start_time='2020-01-01', end_time='2020-11-30', freq='day')
        print(features_df.head())

                                $close     $volume
instrument datetime
HK0700     2020-01-02  2024.225952  13991006.0
           2020-01-03  2027.401978  15313106.0
           2020-01-06  1997.758545  12123194.0
           2020-01-07  2041.165039  17686346.0
           2020-01-08  2022.108643  15529153.0
```

资料来源：Wind，Qlib，华泰证券研究所

自定义股票池

上述代码中，股票池定义为全部个股，这种定义方式存在两个问题。首先，我们的原始数据中包含恒生指数，但恒生指数是作为基准用，不参与到选股中，在计算因子和后续选股模型构建环节应予以剔除。其次，股票是否进入选股池需考虑其它因素，如 A 股选股模型通常剔除风险警示股票、次新股等，港股中的低价股也不适合纳入。

这里我们采用 qlib.data.filter 模块自定义股票池。首先，使用 qlib.data.filter.NameDFilter 命令进行股票名称静态筛选，参数 name_rule_re 为纳入股票代码的正则表达式，如 HK[0-9!]表示以 HK 开头，后续为数字或感叹号的股票代码，感叹号代表目前已退市股票。其次，使用 qlib.data.filter.ExpressionDFilter 命令进行股票因子表达式的动态筛选，参数 rule_expression 为入选的因子表达式，如$close>=1 代表收盘价应大于等于 1 元。随后，通过 qlib.data.instruments 命令的参数 filter_pipe，将两个筛选条件组装到一起。

下图展示自定义股票池的过程，展示股票池（按数字排序）的后 5 个股票代码，相比于全股票池，自定义股票池缺少 HKHSI（恒生指数）和 HK9998（光荣控股，9998 HK，2020 年 7~11 月收盘价均低于 1 元），表明我们的两步筛选起到作用。

图表13： 自定义股票池

```
In [4]: from qlib.data.filter import NameDFilter, ExpressionDFilter
        # 静态Filter：除恒指（HKHSI）外的港股
        nameDFilter = NameDFilter(name_rule_re='HK[0-9!]')
        # 动态Filter：后复权价格大于等于1元
        expressionDFilter = ExpressionDFilter(rule_expression='$close>=1')
        # 获取2020年7~11月满足条件的港股代码
        instruments = D.instruments(market='all', filter_pipe=[nameDFilter,expressionDFilter])
        stock_list = D.list_instruments(instruments=instruments,
                                        start_time='2020-07-01',
                                        end_time='2020-11-30',
                                        as_list=True)
        # 展示后5个股票代码
        print(stock_list[-5:])
['HK9993', 'HK9995', 'HK9996', 'HK9997', 'HK9999']
```

资料来源：Wind，Qlib，华泰证券研究所

Alpha158 因子库

下面进入核心的因子计算部分。Qlib 提供 Alpha158 和 Alpha360 两类量价因子库，用户也可根据需要自定义因子库。Alpha158 和 Alpha360 的因子定义方式可以参考源码文件 qlib/contrib/data/handler.py。我们以 Alpha158 为例进行展示说明。

生成 Alpha158 因子调用 qlib.contrib.data.handler 模块下的 Alpha158 类，具体命令为：

```
from qlib.contrib.data.handler import Alpha158
h = Alpha158(**data_handler_config)
```

其中参数 data_handler_config 相当于配置文件，字典类型，用来定义完整数据起止日期（start_time 和 end_time），拟合数据起止日期（fit_start_time 和 fit_end_time），股票池（instruments）等。拟合数据起止日期区间应为完整数据起止日期数据的子集。拟合数据日期（训练和验证集）和余下日期（测试集）在数据预处理的方式上有所不同，将在下章展开讨论。

执行上述指令后，程序将计算从 start_time 至 end_time 的当期因子值和下期收益，分别作为后续 AI 模型训练的特征和标签。在笔者运行环境下（CPU：Intel i5-8265U @ 1.60GHz；RAM：16.0GB），生成 2020 年 1~11 月港股日频 158 个因子的时间开销约为 695 秒。下图展示生成 Alpha158 因子过程以及 158 个因子简称。以前两个因子 KMID 和 KLEN 为例，查看源码知，KMID=(close-open)/open，其含义为日内涨跌幅，KLEN=(high-low)/open，其含义为日内振幅。

图表14： 生成 Alpha158 特征（当期因子）和标签（下期收益）

```
In [6]: # 计算Alpha158特征（因子）和标签（收益）
from qlib.contrib.data.handler import Alpha158

# 设置日期、股票池等参数
data_handler_config = {
    "start_time": "2020-01-01",
    "end_time": "2020-11-30",
    "fit_start_time": "2020-01-01",
    "fit_end_time": "2020-06-30",
    "instruments":instruments,
}

h = Alpha158(**data_handler_config)

# 获取列名（因子名称）
print(h.get_cols())
```

```
[11780:MainThread](2020-12-17 11:21:56,500) INFO - qlib.timer - [log.py:81] - Time co
st: 694.383s | Loading data Done
[11780:MainThread](2020-12-17 11:21:56,870) INFO - qlib.timer - [log.py:81] - Time co
st: 0.130s | DropnaLabel Done
[11780:MainThread](2020-12-17 11:21:57,434) INFO - qlib.timer - [log.py:81] - Time co
st: 0.563s | CSZScoreNorm Done
[11780:MainThread](2020-12-17 11:21:57,435) INFO - qlib.timer - [log.py:81] - Time co
st: 0.933s | fit & process data Done
[11780:MainThread](2020-12-17 11:21:57,436) INFO - qlib.timer - [log.py:81] - Time co
st: 695.319s | Init data Done

['KMID', 'KLEN', 'KMID2', 'KUP', 'KUP2', 'KLOW', 'KLOW2', 'KSFT', 'KSFT2', 'OPEN0',
'HIGH0', 'LOW0', 'VWAP0', 'ROC5', 'ROC10', 'ROC20', 'ROC30', 'ROC60', 'MA5', 'MA10',
'MA20', 'MA30', 'MA60', 'STD5', 'STD10', 'STD20', 'STD30', 'STD60', 'BETA5', 'BETA1
0', 'BETA20', 'BETA30', 'BETA60', 'RSQR5', 'RSQR10', 'RSQR20', 'RSQR30', 'RSQR60', 'R
ESI5', 'RESI10', 'RESI20', 'RESI30', 'RESI60', 'MAX5', 'MAX10', 'MAX20', 'MAX30', 'MA
X60', 'MIN5', 'MIN10', 'MIN20', 'MIN30', 'MIN60', 'QTLU5', 'QTLU10', 'QTLU20', 'QTLU3
0', 'QTLU60', 'QTLD5', 'QTLD10', 'QTLD20', 'QTLD30', 'QTLD60', 'RANK5', 'RANK10', 'RA
NK20', 'RANK30', 'RANK60', 'RSV5', 'RSV10', 'RSV20', 'RSV30', 'RSV60', 'IMAX5', 'IMAX
10', 'IMAX20', 'IMAX30', 'IMAX60', 'IMIN5', 'IMIN10', 'IMIN20', 'IMIN30', 'IMIN60',
'IMXD5', 'IMXD10', 'IMXD20', 'IMXD30', 'IMXD60', 'CORR5', 'CORR10', 'CORR20', 'CORR3
0', 'CORR60', 'CORD5', 'CORD10', 'CORD20', 'CORD30', 'CORD60', 'CNTP5', 'CNTP10', 'CN
TP20', 'CNTP30', 'CNTP60', 'CNTN5', 'CNTN10', 'CNTN20', 'CNTN30', 'CNTN60', 'CNTD5',
'CNTD10', 'CNTD20', 'CNTD30', 'CNTD60', 'SUMP5', 'SUMP10', 'SUMP20', 'SUMP30', 'SUMP6
0', 'SUMN5', 'SUMN10', 'SUMN20', 'SUMN30', 'SUMN60', 'SUMD5', 'SUMD10', 'SUMD20', 'SU
MD30', 'SUMD60', 'VMA5', 'VMA10', 'VMA20', 'VMA30', 'VMA60', 'VSTD5', 'VSTD10', 'VSTD
20', 'VSTD30', 'VSTD60', 'WVMA5', 'WVMA10', 'WVMA20', 'WVMA30', 'WVMA60', 'VSUMP5',
'VSUMP10', 'VSUMP20', 'VSUMP30', 'VSUMP60', 'VSUMN5', 'VSUMN10', 'VSUMN20', 'VSUMN3
0', 'VSUMN60', 'VSUMD5', 'VSUMD10', 'VSUMD20', 'VSUMD30', 'VSUMD60', 'LABEL0']
```

资料来源：Wind，Qlib，华泰证券研究所

通过 h.fetch(col_set='label')指令可获取标签。默认参数下，股票 t 日的标签对应 t+2 日收盘价相对于 t+1 日收盘价的涨跌幅，相当于 t 日收盘后发信号，t+1 日收盘时刻开仓，t+2 日收盘时刻平仓。如下图，2020 年 1 月 2 日 HK0001（长和；0001 HK）的标签值为-0.007423，对应 2020 年 1 月 6 日该股票涨跌幅为-0.7423%（2020 年 1 月 4~5 日非交易日）。

图表15： 获取 Alpha158 因子库标签（下期收益）

```
In [7]: # 获取标签（收益）
Alpha158_df_label = h.fetch(col_set="label")
print(Alpha158_df_label)
```

```
                          LABEL0
datetime   instrument
2020-01-02 HK0001     -0.007423
           HK0002     -0.006086
           HK0003     -0.002625
           HK0004     -0.017822
           HK0005     -0.006623
...                         ...
2020-11-30 HK9993           NaN
           HK9995           NaN
           HK9996           NaN
           HK9997           NaN
           HK9999           NaN

[274385 rows x 1 columns]
```

资料来源：Wind，Qlib，华泰证券研究所

通过 h.fetch(col_set='feature')指令可获取特征。默认参数下，股票 t 日的特征对应 t 日收盘后计算出的因子值。下图展示部分股票部分交易日的部分因子值。

图表16： 获取 Alpha158 因子库特征（当期因子）

```
In [8]: # 获取特征（因子）
        Alpha158_df_feature = h.fetch(col_set="feature")
        print(Alpha158_df_feature)
```

```
                                KMID      KLEN     KMID2       KUP      KUP2  \
datetime   instrument
2020-01-02 HK0001       0.000000  0.012081  0.000000  0.009396  0.777778
           HK0002       0.005488  0.010366  0.529415  0.001220  0.117646
           HK0003      -0.002614  0.006536 -0.399990  0.000000  0.000000
           HK0004       0.020429  0.029111  0.701760  0.008682  0.298240
           HK0005       0.000822  0.005752  0.142862  0.000822  0.142846
...                          ...       ...       ...       ...       ...
2020-11-30 HK9993       0.007092  0.016549  0.428573  0.009456  0.571427
           HK9995      -0.007092  0.041844 -0.169492  0.015603  0.372881
           HK9996      -0.016706  0.064439 -0.259259  0.026253  0.407407
           HK9997       0.029449  0.049936  0.589743  0.011524  0.230769
           HK9999      -0.006873  0.016495 -0.416678  0.000000  0.000000

                               KLOW     KLOW2      KSFT     KSFT2     OPEN0  ...  \
datetime   instrument                                                        ...
2020-01-02 HK0001       0.002685  0.222222 -0.006711 -0.555556  1.000000  ...
           HK0002       0.003659  0.352939  0.007927  0.764707  0.994542  ...
           HK0003       0.003922  0.600010  0.001307  0.200020  1.002621  ...
           HK0004       0.000000  0.000000  0.011747  0.403520  0.979980  ...
           HK0005       0.004108  0.714292  0.004109  0.714308  0.999179  ...
...                          ...       ...       ...       ...       ...  ...
2020-11-30 HK9993       0.000000  0.000000 -0.002364 -0.142853  0.992958  ...
           HK9995       0.019149  0.457627 -0.003546 -0.084746  1.007143  ...
           HK9996       0.021480  0.333334 -0.021480 -0.333332  1.016990  ...
           HK9997       0.008963  0.179487  0.026889  0.538461  0.971393  ...
           HK9999       0.009622  0.583322  0.002749  0.166643  1.006921  ...

                             VSUMN5    VSUMN10    VSUMN20    VSUMN30    VSUMN60  \
datetime   instrument
2020-01-02 HK0001       0.544894  0.592516  0.508214  0.524462  0.521402
           HK0002       0.539498  0.613241  0.522375  0.507934  0.513920
           HK0003       0.488631  0.624797  0.529989  0.514712  0.507599
           HK0004       0.475671  0.435411  0.491965  0.500669  0.500494
           HK0005       0.437927  0.491091  0.481283  0.503394  0.511789
...                          ...       ...       ...       ...       ...
2020-11-30 HK9993       0.378035  0.359733  0.492068  0.864125  0.864125
           HK9995       0.548241  0.844881  0.937981  0.937981  0.937981
           HK9996       0.555900  0.418286  0.483890  0.485210  0.506420
           HK9997       0.631832  0.484724  0.472356  0.476894  0.506170
           HK9999       0.721138  0.489578  0.505377  0.493962  0.509888

                             VSUMD5    VSUMD10    VSUMD20    VSUMD30    VSUMD60
datetime   instrument
2020-01-02 HK0001      -0.089788 -0.185032 -0.016428 -0.048923 -0.042804
           HK0002      -0.078996 -0.226482 -0.044749 -0.015868 -0.027841
           HK0003       0.022737 -0.249593 -0.059978 -0.029424 -0.015198
           HK0004       0.048658  0.129178  0.016071 -0.001338 -0.000987
           HK0005       0.124147  0.017817  0.037434 -0.006788 -0.023577
...                          ...       ...       ...       ...       ...
2020-11-30 HK9993       0.243929  0.280535  0.015863 -0.728250 -0.728250
           HK9995      -0.096482 -0.689762 -0.875962 -0.875962 -0.875962
           HK9996      -0.111801  0.163428  0.032221  0.029580 -0.012840
           HK9997      -0.263664  0.030552  0.055287  0.046212 -0.012340
           HK9999      -0.442276  0.020845 -0.010755  0.012076 -0.019775

[274385 rows x 158 columns]
```

资料来源：Wind，Qlib，华泰证券研究所

LightGBM 选股策略构建

下面进入核心的选股策略构建部分，这一部分同样参考 Qlib 范例 workflow_by_code_py，将范例代码中的 A 股策略改为港股策略。首先，导入后续将会调用的相关 Qlib 模块，如下图所示。

图表17： 导入 Qlib 模块代码

```
In [1]: import time
import numpy as np
import pandas as pd

import qlib
from qlib.config import REG_CN
from qlib.contrib.model.gbdt import LGBModel
from qlib.contrib.data.handler import Alpha158
from qlib.contrib.strategy.strategy import TopkDropoutStrategy
from qlib.contrib.evaluate import (
    backtest as normal_backtest,
    risk_analysis,
)
from qlib.utils import exists_qlib_data, init_instance_by_config
from qlib.workflow import R
from qlib.workflow.record_temp import SignalRecord, PortAnaRecord
from qlib.utils import flatten_dict
```

资料来源：Wind，Qlib，华泰证券研究所

初始化环境和定义股票池的代码不再赘述，股票池采用全部港股（含权证），剔除作为基准的恒生指数。

图表18： 定义股票池和基准指数代码

```
In [4]: market = instruments
benchmark = "HKHSI"
```

资料来源：Wind，Qlib，华泰证券研究所

接下来定义因子生成参数 data_handler_config 和模型训练参数 task。因子生成参数前文已作介绍，不再赘述。模型训练参数 task 为字典类型，较复杂，也是整个模型的核心部分，又可以分为 model 和 dataset 两个字典。

第一项 model 为 AI 模型参数，必须包含 class（AI 模型名称）和 module_path（AI 模型所在路径）两个子键；kwargs 为 model 的可选子键，通过 kwargs 设置指定 AI 模型的超参数。下图展示 model 的键、示例值与说明。这里我们选用固定超参数，不进行参数优化。

图表19： 模型训练参数 task 的 AI 模型参数 model

键		示例值	说明
model			AI 模型参数
	class	LGBModel	AI 模型名称，此处为 LightGBM
	module_path	qlib.contrib.model.gbdt	AI 模型所在路径
	kwargs		LightGBM 模型超参数
	loss	mse	损失函数，此处为均方误差
	colsample_bytree	0.8879	列采样比例
	learning_rate	0.0421	学习率
	subsample	0.8789	行采样比例
	lambda_l1	205.6999	L1 正则化惩罚系数
	lambda_l2	580.9768	L2 正则化惩罚系数
	max_depth	8	最大树深
	num_leaves	210	最大叶子节点数
	num_threads	20	最大并行线程数

资料来源：Wind，Qlib，华泰证券研究所

第二项 dataset 为数据集参数，必须包含 class（数据集名称）和 module_path（数据集所在路径）两个子键；kwargs 为 dataset 的可选子键，通过 kwargs 设置指定数据集的参数。下图展示 dataset 的键、示例值与说明。

图表20： 模型训练参数 task 的 AI 模型参数 dataset

键			示例值	说明
dataset				数据集参数
	class		DatasetH	数据集名称
	module_path		qlib.data.dataset	数据集所在路径
	kwargs			DatasetH 模型参数
		handler		因子库参数
			class	Alpha158	因子库名称
			module_path	qlib.contrib.data.handler	因子库路径
			kwargs	data_handler_config	Alpha158 因子库参数
		segments		时间划分参数
			train	("2020-01-01", "2020-04-30")	训练集时间区间
			valid	("2020-05-01", "2020-06-30")	验证集时间区间
			test	("2020-07-01", "2020-11-30")	测试集时间区间

资料来源：Wind，Qlib，华泰证券研究所

因子生成参数 data_handler_config 和模型训练参数 task 的代码实现过程如下所示。通过 qlib.utils.init_instance_by_config 命令将上述参数分别写入模型，分别返回模型 model 和数据集 dataset。

图表21： 因子生成参数 data_handler_config 和模型训练参数 task 设置代码

In [5]:
```
###################################
# train model
###################################
data_handler_config = {
    "start_time": "2020-01-01",
    "end_time": "2020-11-30",
    "fit_start_time": "2020-01-01",
    "fit_end_time": "2020-06-30",
    "instruments": market,
}

task = {
    "model": {
        "class": "LGBModel",
        "module_path": "qlib.contrib.model.gbdt",
        "kwargs": {
            "loss": "mse",
            "colsample_bytree": 0.8879,
            "learning_rate": 0.0421,
            "subsample": 0.8789,
            "lambda_l1": 205.6999,
            "lambda_l2": 580.9768,
            "max_depth": 8,
            "num_leaves": 210,
            "num_threads": 20,
        },
    },
    "dataset": {
        "class": "DatasetH",
        "module_path": "qlib.data.dataset",
        "kwargs": {
            "handler": {
                "class": "Alpha158",
                "module_path": "qlib.contrib.data.handler",
                "kwargs": data_handler_config,
            },
            "segments": {
                "train": ("2020-01-01", "2020-04-30"),
                "valid": ("2020-05-01", "2020-06-30"),
                "test": ("2020-07-01", "2020-11-30"),
            },
        },
    },
}

# model initiaiton
model = init_instance_by_config(task["model"])
dataset = init_instance_by_config(task["dataset"])
```

资料来源：Wind，Qlib，华泰证券研究所

完成模型训练参数定义后，调用 qlib.workflow 模块正式进行训练，依次执行如下命令：qlib.workflow.start 开启训练；model.fit 拟合模型；qlib.workflow.save_objects 保存模型；qlib.workflow.get_recorder().id 获取“实验”（即模型训练）记录的编号。下图展示模型训练的代码实现过程。笔者运行环境下，读入数据及数据预处理时间开销约为 372 秒，训练模型时间开销约为 9 秒。LightGBM 模型迭代的实质是参数优化，当验证集损失连续 50 轮未降低时停止迭代，此处迭代 71 次后结束训练。

图表22： 模型训练代码

```
# start exp to train model
t_start = time.time()

with R.start(experiment_name="train_model"):
    R.log_params(**flatten_dict(task))
    model.fit(dataset)
    R.save_objects(trained_model=model)
    rid = R.get_recorder().id

t_end = time.time()
print('train model - Time count: %.3fs'%(t_end-t_start))
```

```
[2060:MainThread](2020-12-15 16:55:42,712) INFO - qlib.timer - [log.py:81] - Time cos
t: 370.142s | Loading data Done
[2060:MainThread](2020-12-15 16:55:43,449) INFO - qlib.timer - [log.py:81] - Time cos
t: 0.256s | DropnaLabel Done
[2060:MainThread](2020-12-15 16:55:44,127) INFO - qlib.timer - [log.py:81] - Time cos
t: 0.677s | CSZScoreNorm Done
[2060:MainThread](2020-12-15 16:55:44,128) INFO - qlib.timer - [log.py:81] - Time cos
t: 1.415s | fit & process data Done
[2060:MainThread](2020-12-15 16:55:44,128) INFO - qlib.timer - [log.py:81] - Time cos
t: 371.558s | Init data Done
[2060:MainThread](2020-12-15 16:55:44,129) INFO - qlib.workflow - [expm.py:245] - No
tracking URI is provided. Use the default tracking URI.
[2060:MainThread](2020-12-15 16:55:44,133) INFO - qlib.workflow - [expm.py:168] - No
valid experiment found. Create a new experiment with name train_model.
[2060:MainThread](2020-12-15 16:55:44,141) INFO - qlib.workflow - [exp.py:181] - Expe
riment 1 starts running ...
[2060:MainThread](2020-12-15 16:55:44,225) INFO - qlib.workflow - [recorder.py:236] -
Recorder 79cea3afbd4a4e2fa131ecce5c53db41 starts running under Experiment 1 ...

Training until validation scores don't improve for 50 rounds
[20]    train's l2: 0.957767    valid's l2: 0.900906
[40]    train's l2: 0.954599    valid's l2: 0.900364
[60]    train's l2: 0.95203     valid's l2: 0.900279
[80]    train's l2: 0.949768    valid's l2: 0.900328
[100]   train's l2: 0.947697    valid's l2: 0.900449
[120]   train's l2: 0.945859    valid's l2: 0.900483
Early stopping, best iteration is:
[71]    train's l2: 0.950702    valid's l2: 0.900244
train model - Time count: 8.961s
```

资料来源：Wind，Qlib，华泰证券研究所

选股策略回测

图表23： 策略回测参数 port_analysis_config

键		示例值	说明
strategy			策略参数
	class	TopkDropoutStrategy	策略名称
	module_path	qlib.contrib.strategy.strategy	策略所在路径
	kwargs		TopkDropout 策略参数
	topk	50	每日持仓股票数
	n_drop	5	每日换仓股票数
backtest			回测参数
	verbose	False	是否实时显示回测信息
	limit_threshold	np.inf	涨跌停限制，港股不设涨跌停
	account	100000000	起始资金
	benchmark	benchmark	业绩比较基准，此处为恒生指数
	deal_price	close	成交价格，此处为收盘价
	open_cost	0.0015	开仓交易费率
	close_cost	0.0015	平仓交易费率
	min_cost	20	最低交易费用

资料来源：Wind，Qlib，华泰证券研究所

接下来设置策略回测参数 port_analysis_config，该参数为字典类型，又可以分为 strategy 和 backtest 两个子键。第一项 strategy 为策略参数，例如此处使用 TopkDropout 策略，每日等权持有 topk=50 只股票，同时每日卖出持仓股票中最新预测收益最低的 n_drop=5 只股票，买入未持仓股票中最新预测收益最高的 n_drop=5 只股票。第二项 backtest 为回测参数，用于设置涨跌停限制、起始资金、业绩比较基准、成交价格、交易费率等信息。

图表24： 选股策略回测参数设置代码

```
In [6]: ###################################
        # prediction, backtest & analysis
        ###################################
        port_analysis_config = {
            "strategy": {
                "class": "TopkDropoutStrategy",
                "module_path": "qlib.contrib.strategy.strategy",
                "kwargs": {
                    "topk": 50,
                    "n_drop": 5,
                },
            },
            "backtest": {
                "verbose": False,
                "limit_threshold": np.inf,
                "account": 100000000,
                "benchmark": benchmark,
                "deal_price": "close",
                "open_cost": 0.0015,
                "close_cost": 0.0015,
                "min_cost": 20,
            },
        }
```

资料来源：Wind，Qlib，华泰证券研究所

图表25： 选股策略回测代码

```
# backtest and analysis
t_start = time.time()

with R.start(experiment_name="backtest_analysis"):
    recorder = R.get_recorder(rid, experiment_name="train_model")
    model = recorder.load_object("trained_model")

    # prediction
    recorder = R.get_recorder()
    ba_rid = recorder.id
    sr = SignalRecord(model, dataset, recorder)
    sr.generate()

    # backtest & analysis
    par = PortAnaRecord(recorder, port_analysis_config)
    par.generate()

t_end = time.time()
print('backtest and analysis - Time count: %.3fs'%(t_end-t_start))
```

```
[2060:MainThread](2020-12-15 16:55:53,102) INFO - qlib.workflow - [expm.py:245] - No tracking URI is provided. Use the default tracking URI.
[2060:MainThread](2020-12-15 16:55:53,106) INFO - qlib.workflow - [expm.py:168] - No valid experiment found. Create a new experiment with name backtest_analysis.
[2060:MainThread](2020-12-15 16:55:53,117) INFO - qlib.workflow - [exp.py:181] - Experiment 2 starts running ...
[2060:MainThread](2020-12-15 16:55:53,150) INFO - qlib.workflow - [recorder.py:236] - Recorder a414fb15a75c4ee0a9fe7c79fdebb5d3 starts running under Experiment 2 ...
[2060:MainThread](2020-12-15 16:55:53,978) INFO - qlib.workflow - [record_temp.py:127] - Signal record 'pred.pkl' has been saved as the artifact of the Experiment 2
[2060:MainThread](2020-12-15 16:55:54,067) INFO - qlib.Evaluate - [evaluate.py:161] - Create new exchange
[2060:MainThread](2020-12-15 16:55:54,073) WARNING - qlib.online operator - [exchange.py:72] - limit_threshold may not be set to a reasonable value

'The following are prediction results of the LGBModel model.'
                                score
datetime   instrument
2020-07-02 HK0001      -0.018582
           HK0002      -0.020668
           HK0003      -0.015716
           HK0004      -0.039070
           HK0005      -0.006372

[2060:MainThread](2020-12-15 16:56:09,025) INFO - qlib.workflow - [record_temp.py:256] - Portfolio analysis record 'port_analysis.pkl' has been saved as the artifact of the Experiment 2

'The following are analysis results of the excess return without cost.'
                         risk
mean                 0.007799
std                  0.017297
annualized_return    1.965411
information_ratio    7.157980
max_drawdown        -0.096032
'The following are analysis results of the excess return with cost.'
                         risk
mean                 0.007450
std                  0.017304
annualized_return    1.877380
information_ratio    6.834413
max_drawdown        -0.099835
backtest and analysis - Time count: 15.944s
```

资料来源：Wind，Qlib，华泰证券研究所

回测代码实现如上图所示。调用 qlib.workflow 模块正式进行回测，依次执行如下命令：qlib.workflow.start 开启回测；qlib.workflow.get_recorder 获取此前模型训练“实验”记录；recorder.load_object 读取模型；qlib.workflow.get_recorder 初始化回测“实验”记录；qlib.workflow.record_temp.SignalRecord 初始化调仓信号；sr.generate 生成调仓信号；qlib.workflow.record_temp.PortAnaRecord 初始化回测及绩效分析；par.generate 生成回测及绩效分析结果。

回测代码运行过程中，还显示部分预测结果。例如在测试集第一个交易日（2020 年 7 月 2 日）对个股下期收益的预测值，如 HK00001 预测值为-0.018582；又如不扣费及扣费后的日均收益、日度波动率、年化收益、信息比率和最大回撤。

回测和绩效分析结果展示

完成策略回测后，调用 qlib.contrib.report 模块展示回测和绩效分析结果。展示前首先执行 qlib.workflow.get_recorder 获取回测“实验”记录，相关结果均储存为 pkl 格式，执行 recorder.load_object 读取预测结果 pred.pkl、回测报告 report_normal.pkl、仓位情况 positions_normal.pkl 和持仓分析 port_analysis.pkl。

图表26： 回测和绩效分析结果读取代码

```
In [7]: from qlib.contrib.report import analysis_model, analysis_position
        from qlib.data import D
        recorder = R.get_recorder(ba_rid, experiment_name="backtest_analysis")
        pred_df = recorder.load_object("pred.pkl")
        pred_df_dates = pred_df.index.get_level_values(level='datetime')
        report_normal_df = recorder.load_object("portfolio_analysis/report_normal.pkl")
        report_normal_df = report_normal_df.dropna(axis=0)
        positions = recorder.load_object("portfolio_analysis/positions_normal.pkl")
        analysis_df = recorder.load_object("portfolio_analysis/port_analysis.pkl")
```

资料来源：Wind，Qlib，华泰证券研究所

执行下列命令展示 AI 模型预测个股收益的 IC 和 Rank IC 值，可视化结果如下图所示。

```
label_df = dataset.prepare("test", col_set="label")
label_df.columns = ['label']
pred_label=pd.concat([label_df,pred_df],axis=1,sort=True).reindex(label_df.index)
analysis_position.score_ic_graph(pred_label)
```

图表27： AI 模型预测结果 IC 和 Rank IC

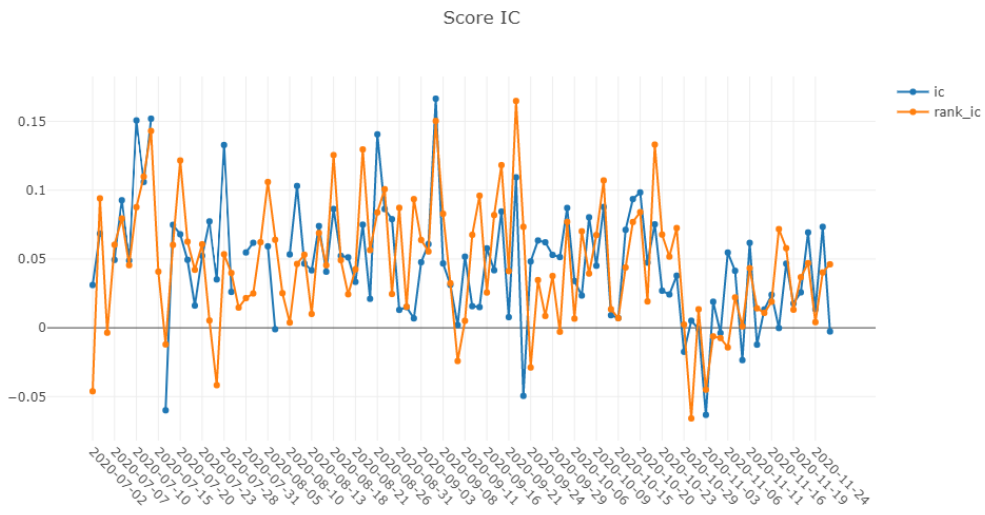

资料来源：Wind，Qlib，华泰证券研究所

执行 analysis_position.report_graph(report_normal_df)展示回测净值相关结果。如下图所示，7 张子图自上而下分别为：不扣费、扣费和基准净值；不扣费净值最大回撤；扣费净值最大回撤；不扣费和扣费超额收益净值；换手率；不扣费超额收益最大回撤；扣费超额收益最大回撤。观察知，选股模型在 2020 年 7~10 月超额收益较稳定，但在 11 月份出现回撤。

图表28： 策略净值、超额收益净值、最大回撤和换手率

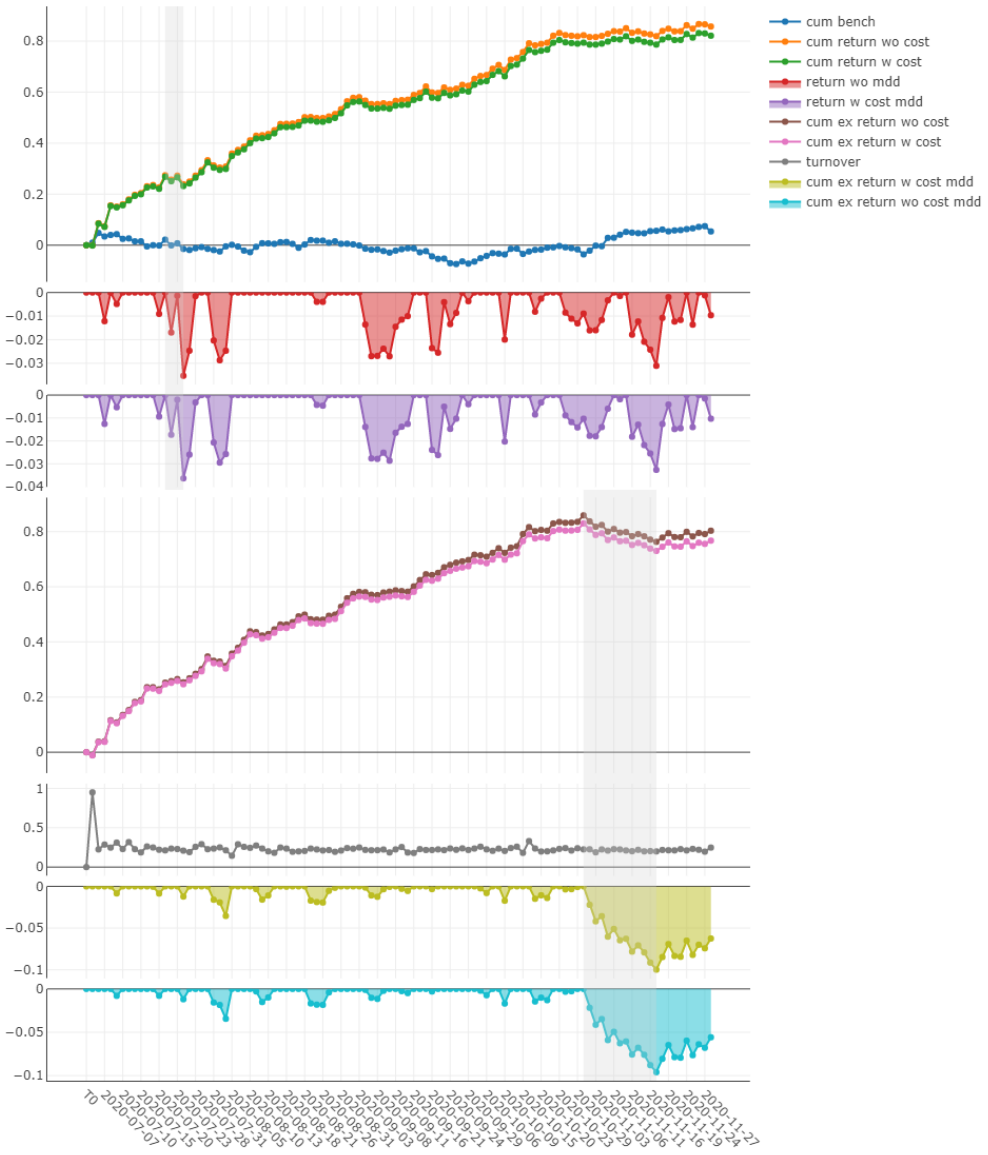

资料来源：Wind，Qlib，华泰证券研究所

至此，我们走完了港股日频量价因子 AI 选股策略的全流程，希望帮助读者快速上手 Qlib。下面我们将介绍 Qlib 进阶功能，如需自定义 AI 选股策略的组件，应如何通过代码实现。

Qlib 进阶：自定义策略组件

下面我们讲解如何自定义策略。AI 选股模型包含因子生成和预处理、模型训练、策略回测各组件。在 Qlib 中这些组件通过工作流 workflow 串联在一起，每个组件均有参数控制。因此最简单的自定义策略方式是直接修改参数。另外，每个组件都有其对应源码，更灵活的自定义策略方式是修改源码或者仿照源码创建新的继承类。

图表29： 各组件参数及对应源码所在路径

参数		参数说明	对应源码所在路径
data_handler_config		数据集参数（特征标签生成和预处理）	qlib.contrib.data.handler
task		模型训练参数	
	model	AI 模型参数	qlib.contrib.model
	dataset	数据集参数（训练、验证、测试集划分）	qlib.data.dataset
port_analysis_config		策略回测参数	
	strategy	策略参数	qlib.contrib.strategy
	backtest	回测参数	qlib.contrib.evaluate.backtest

资料来源：Qlib，华泰证券研究所

自定义特征

如果不满足于 Qlib 自带的 Alpha158 和 Alpha360 两个因子库，如何自定义新的特征（因子）？Alpha158 和 Alpha360 的源码位于 qlib.contrib.data.handler，这两个因子库继承了 qlib.data.dataset.handler.DataHandlerLP 类。DataHandlerLP 类计算因子的核心方法是 get_feature_config。通过修改 get_feature_config 以及它所调用的方法，可以自定义特征。

下图展示自定义特征代码，笔者定义了一个新的因子库类 AlphaSimpleCustom，它继承了 Alpha158 类，共包含 6 个因子，分别为 5/10/20/30/60 日均线与当前收盘价比值以及 MACD。定义单个因子的方式是直接写出该因子的表达式，例如 5 日均线可写作 Mean($close,5)，5 日均线与收盘价比值可写作 Mean($close,5)/$close。这种因子定义方式简洁直观，便于研究者构建新因子。

图表30： 自定义特征代码

In [ ]:

```
# 先将AlphaSimpleCustom类保存在以下路径：
#     C:/Users/Kang/anaconda3/Lib/site-packages/pyqlib-0.6.1.dev0-py3.7-win-amd64.egg/
#     qlib/contrib/data/handler_custom.py
# 再通过参数dataset下的参数handler调用：
#     "handler": {
#         "class": "AlphaSimpleCustom",
#         "module_path": "qlib.contrib.data.handler_custom",
#         "kwargs": data_handler_config,
#     },
class AlphaSimpleCustom(Alpha158):
    def get_feature_config(self):
        # 6个因子：5/10/20/30/60日均线与当前收盘价比值，macd
        conf = {
            "ma":{"windows":[5,10,20,30,60]},
            "macd": {},
        }
        return self.parse_config_to_fields(conf)

    @staticmethod
    def parse_config_to_fields(config):
        """create factors from config
        """
        fields = []
        names = []

        if "ma" in config:
            windows = config["ma"].get("windows")
            fields += ["Mean($close, %d)/$close" % d for d in windows]
            names += ["MA%d" % d for d in windows]

        if "macd" in config:
            MACD_EXP = '(EMA($close, 12) - EMA($close, 26))/$close - EMA((EMA($close, 12) - EMA($close, 26))/$close, 9)/$close'
            fields += [MACD_EXP]
            names += ["MACD"]

        return fields, names
```

资料来源：Wind，Qlib，华泰证券研究所

自定义标签

Alpha158 因子库默认的标签定义方式为：股票 t 日的标签对应 t+2 日收盘价相对于 t+1 日收盘价的涨跌幅，相当于 t 日收盘后发信号，t+1 日收盘时刻开仓，t+2 日收盘时刻平仓。下面我们展示两种自定义标签方法。

如果希望以 vwap 价交易，将标签定义为 t+2 日 vwap 价相对于 t+1 日 vwap 价的涨跌幅，那么可以在设置模型训练参数 task 时，将 task['dataset']['handler']['class']的值从 Alpha158 改为 Alpha158vwap，同时在设置回测参数 port_analysis_config 时，将交易价格 deal_price 的值从 close 改为 vwap 即可，代码实现如下图。

图表31： 通过设置参数自定义标签代码

```
In [ ]: # 方法一：
        # 修改task参数
        # 标签改为vwap价格计算的下期收益，回测改为使用vwap价格交易
        task = {
            "model": {...},
            "dataset": {
                "class": "DatasetH",
                "module_path": "qlib.data.dataset",
                "kwargs": {
                    "handler": {
                        "class": "Alpha158vwap",
                        "module_path": "qlib.contrib.data.handler",
                        "kwargs": data_handler_config,
                    },
                    "segments": {...},
                },
            },
        }

        port_analysis_config = {
            "strategy": {...},
            "backtest": {
                ...
                "deal_price": "vwap",
                ...
            },
        }
```

资料来源：Wind，Qlib，华泰证券研究所

更灵活的自定义标签方式是修改因子库源码。在 DataHandlerLP 类（即 Alpha158 因子库的父类）中，计算标签的核心方法是 get_label_config，修改该方法可以自定义标签。如下图展示两个案例，分别以 t+1 日 vwap 价与 t+2 日 vwap 价之间的区间收益为标签，和以 t+1 日开盘价与 t+6 日开盘价之间的区间收益为标签。

图表32： 通过修改因子库源码自定义标签代码

```
In [ ]: # 方法二：
        # 参考qlib.contrib.data.handler
        # 自定义data.dataset.handler.DataHandlerLP类的get_label_config方法

        # Alpha158vwap继承Alpha158类，仅更改标签计算方式
        class Alpha158vwap(Alpha158):
            def get_label_config(self):
                return (["Ref($vwap, -2)/Ref($vwap, -1) - 1"], ["LABEL0"])

        # 若t日收盘生成因子，t+1日开盘买入，t+6日开盘卖出
        class AlphaSimpleCustom(Alpha158):
            def get_label_config(self):
                return (["Ref($open, -6)/Ref($open, -1) - 1"], ["LABEL0"])
```

资料来源：Wind，Qlib，华泰证券研究所

更换数据预处理方法

Qlib 中内置多种数据预处理方法，源码位于 qlib.data.dataset.processor，包含样本处理、特征处理、异常值处理、缺失值填充和标准化共 5 大类 13 小类，如下表所示。

图表33： Qlib 内置数据预处理方法（qlib.data.dataset.processor）

类别	方法	说明
样本处理	DropnaProcessor	删除指定特征为缺失值的样本
	DropnaLabel	删除标签为缺失值的样本
特征处理	DropCol	删除指定特征
	FilterCol	筛选指定特征
异常值处理	TanhProcess	tanh 处理
	ProcessInf	inf 以均值替换
缺失值填充	Fillna	以 0 填充缺失值
	CSZFillna	以截面均值填充缺失值
标准化	MinMaxNorm	最小最大值标准化至[0,1]范围
	ZScoreNorm	Z 分数标准化至标准正态分布，即对原始数据减去均值除以标准差
	RobustZScoreNorm	稳健 Z 分数标准化，即对原始数据减去中位数除以 1.48 倍 MAD 统计量
	CSZScoreNorm	截面 Z 分数标准化至标准正态分布
	CSRankNorm	截面先转换为 rank 序数，再 Z 分数标准化至标准正态分布

资料来源：Qlib，华泰证券研究所

实际数据预处理是上述操作的任意组合。例如 Alpha158 和 Alpha360 因子库中，训练集和验证集的预处理是先剔除标签为缺失值的样本，再对标签（即收益）进行截面标准化；测试集的预处理是先将 inf 替换为均值，再进行 Z 分数标准化，最后将缺失值填充为 0。下图为因子库数据预处理的源码，训练集和验证集对应 learn_processors，测试集对应 infer_processors，两者均为多项预处理操作组合而成的列表形式。

图表34： Alpha158 和 Alpha360 因子库默认预处理方式

```
In [ ]: # Alpha158和Alpha360默认预处理方式
        # 见qlib.contrib.data.handler
        _DEFAULT_LEARN_PROCESSORS = [
            {"class": "DropnaLabel"},
            {"class": "CSZScoreNorm", "kwargs": {"fields_group": "label"}},
        ]
        _DEFAULT_INFER_PROCESSORS = [
            {"class": "ProcessInf", "kwargs": {}},
            {"class": "ZScoreNorm", "kwargs": {}},
            {"class": "Fillna", "kwargs": {}},
        ]
```

资料来源：Wind，Qlib，华泰证券研究所

图表35： 自定义数据预处理代码

```
In [ ]: # 自定义预处理方式
        # 更多预处理方式见qlib.data.dataset.processor
        data_handler_config = {
            ...
            "infer_processors":[
                {
                    "class": "FilterCol",
                    "kwargs": {"col_list": ["RESI5", "WVMA5", "RSQR5"]},
                },
                {
                    "class": "RobustZScoreNorm",
                    "kwargs": {"fields_group": "feature", "clip_outlier": "true"},
                },
                {
                    "class": "Fillna",
                    "kwargs": {"fields_group": "feature", "fill_value":0},
                },
            ],
            "learn_processors": [
                "DropnaLabel",
                {"class": "CSRankNorm", "kwargs": {"fields_group": "label"}},
            ],
        }
```

资料来源：Wind，Qlib，华泰证券研究所

自定义数据预处理方法的较简单方式是直接修改数据集参数 data_handler_config，增加 learn_processors 和 infer_processors 两个键，值为目标预处理操作组合而成的列表。如上图所示，训练集和验证集的预处理是先剔除标签缺失的样本，再将每个截面的标签转换为 rank 序数；测试集的预处理是先提取指定的三个因子，再对因子做稳健 Z 分数标准化，最后将因子缺失值填充为 0。

更换 AI 模型

Qlib 内置了丰富的 AI 模型，官方文档称为 Quant Model Zoo，源码位于 qlib.contrib.model，支持的模型如下表所示。

图表36： Qlib 内置 AI 模型（qlib.contrib.model）

分类	模型
线性模型	Linear（参数可选择"ols", "nnls", "ridge"和"lasso"）
Boosting 集成学习模型	LightGBM
	Catboost
	XGBoost
时间序列相关神经网络模型	GRU
	LSTM
	ALSTM
	SFM
	TFT
图神经网络	GATs
其它神经网络	MLP
	DNN

资料来源：Qlib，华泰证券研究所

如果希望使用 Qlib 内置模型，可以较方便地通过设置模型训练参数 task 下的 AI 模型参数 model 实现，模型本身的超参数也在 model 中设置。下图分别展示 Lasso 回归和 XGBoost 两类模型的参数设置过程。

图表37： 通过设置参数自定义 AI 模型代码

```
In [ ]: # Lasso回归
# qlib.contrib.model.linear
task = {
    "model": {
        "class": "LinearModel",
        "module_path": "qlib.contrib.model.linear",
        "kwargs": {
            "estimator": "lasso",
            "alpha": 0.5,
            "fit_intercept": False,
        },
    },
    ...
}

# XGBoost
# qlib.contrib.model.xgboost
# 参数参考https://xgboost.readthedocs.io/en/latest/parameter.html
task = {
    "model": {
        "class": "XGBModel",
        "module_path": "qlib.contrib.model.xgboost",
        "kwargs": {
            "num_boost_round": "1000",
            "early_stopping_rounds": 50,
            "eta": 0.1,
            "max_depth": 3,
            "subsample": 0.8,
            "colsample_bytree": 0.8,
        },
    },
    ...
}
```

资料来源：Wind，Qlib，华泰证券研究所

如果希望使用的模型并未在 Qlib 提供的 Quant Model Zoo 中，可以创建新的类继承 Model 类，再通过参数 model 调用新创建的类。创建新类的关键是写模型拟合 fit 和模型预测 predict 两个方法。下图展示创建 SVR 支持向量回归类的过程。

图表38： 通过创建新 Model 子类（如 SVR 支持向量回归）自定义 AI 模型代码

```
In [ ]: # 先将SVRModel类保存在以下路径:
#     C:/Users/Kang/anaconda3/Lib/site-packages/pyqlib-0.6.1.dev0-py3.7-win-amd64.egg/
#     qlib/contrib/model/svr.py
# 再通过参数model调用:
#     "model": {
#         "class": "SVRModel",
#         "module_path": "qlib.contrib.model.svr",
#         "kwargs": {
#             "kernel": "rbf",
#         }
#     },
import numpy as np
import pandas as pd
from sklearn import svm
from ...model.base import Model
from ...data.dataset import DatasetH
from ...data.dataset.handler import DataHandlerLP
from ...log import get_module_logger
import logging

class SVRModel(Model):
    def __init__(self, **kwargs):
        self.logger = get_module_logger("SVRModel", level=logging.INFO)
        self._params = {}
        self._params.update(kwargs)
        self.model = None

    def fit(self,dataset: DatasetH):
        df_train = dataset.prepare("train", col_set=["feature", "label"], data_key=Data
HandlerLP.DK_L)
        X, y = df_train["feature"].values, np.squeeze(df_train["label"].values)
        self.model = svm.SVR(**self._params)
        self.model.fit(X, y)

    def predict(self, dataset):
        if self.model is None:
            raise ValueError("model is not fitted yet!")
        x_test = dataset.prepare("test", col_set="feature")
        return pd.Series(self.model.predict(x_test.values), index=x_test.index)
```

资料来源：Wind，Qlib，华泰证券研究所

其它功能

下面讨论用户可能关心的其它功能，这些功能有的尚未实现，有的已实现但源码尚未公开，有的源码或已公开但缺少文档。

预测和调仓频率均为日频，能否更换频率？若数据库为日频，目前可能无法直接通过设置参数的方式实现，相对可行的方式是重新通过 dump_all 方法读入月频或分钟频原始数据。

如何更新数据？据 Qilb 开发团队在 GitHub 上的讨论，目前团队内部已实现该功能，但暂未开源。

能否更换选股组合构建方式？目前仅开源 TopkDropoutStrategy 一种已实现的组合构建方法，如需自定义组合构建方式，需要通过继承 qlib.contrib.strategy.BaseStrategy 类的方式创建新的策略类。

如何实现模型调参？在 Qlib 原始论文中提到 Qlib 提供调参引擎 Hyperparameters Tuning Engine（HTE），同时笔者观察到源码包含 qlib.contrib.tuner 模块，但在官方文档里未公布使用方法。截至 2020 年 12 月 22 日，GitHub 的产品线路图中包含自动调参（automatic parameter tuning）项目，预计该功能未来可能上线。

能否实现模型滚动训练，例如自动实现 2008~2014 年训练 2015 年测试，2009~2015 年训练 2016 年测试，而非手动写循环？笔者在源码和官方文档中暂未找到相关功能。

Qlib 特色及使用体会

本章我们将结合 Qlib 论文，介绍 Qlib 的特色以及相比传统量化策略开发流程的改进之处，最后谈谈笔者的使用体会。

Qlib 覆盖量化投资全过程

传统量化投资策略开发

在传统 AI 量化投资策略开发过程中，策略各环节相对独立，部署在不同项目甚至于不同软件平台。以某团队人工智能选股模型开发流程为例：

1. 首先通过 MATLAB 获取原始数据，存成 MAT 格式文件；
2. 在 MATLAB 中计算因子，存成 CSV 格式文件；
3. 再转到 Python 平台，读取 CSV 文件，使用 scikit-learn、XGBoost、TensorFlow 和 PyTorch 包训练人工智能模型，得到预测值，存成 CSV 格式文件；
4. 再回到 MATLAB 平台进行策略回测和绩效分析。

图表39： 某团队人工智能选股模型开发流程

步骤	编程平台	使用动机
获取保存原始数据	MATLAB	节省存储空间；便于文件传输和管理
计算因子	MATLAB	矩阵运算效率高
训练人工智能模型	Python	拥有成熟机器学习开源项目；及时共享最新 AI 算法
策略回测和绩效分析	MATLAB	路径依赖

资料来源：Mathworks 官网，scikit-learn 官网，TensorFlow 官网，PyTorch 官网，华泰证券研究所

上述开发流程实属繁琐，需要执行四个项目并切换两次编程语言。然而，这种看似“全局非最优”实际上是“局部最优”的结果：

1. 从数据存储的角度来说，MATLAB 的 MAT 格式是一种不错的方案，v7.3 以上版本 MATLAB 的 MAT 文件使用基于 HDF5 格式，MAT（HDF5）格式优点在于：
   1） MATLAB 会对数据进行压缩以节省存储空间，尽管压缩和解压缩需要额外时间，但这是值得的，据 MATLAB 官方文档（链接如下）显示，某些情况下加载压缩数据比加载未压缩数据更快。
   https://ww2.mathworks.cn/help/matlab/import_export/mat-file-versions.html
   2） MAT 格式便于传输和管理，只需将所有数据表打包成单个 MAT 文件即可。如果采用 CSV 格式，每张表（每个股票或每个交易日）单独存成一个文件，需要管理的文件数量过于庞大，不便于增删改查等管理操作。

2. 从计算因子的角度来说，MATLAB 的矩阵数据类型是较为理想的方案。因子数据本质是一个三维数组，包含股票、交易日、因子三个维度，任取两个维度相当于从一个三维立体中切取一个二维平面。而计算因子往往可以通过二维矩阵运算实现，批量计算全部股票全部交易日的因子值，无需执行循环，运算效率较高。

   近年来随着 Python 语言的普及，NumPy 包的 Ndarray 格式也逐渐为广大使用者接受，NumPy 在功能和语法上已经和 MATLAB 较为接近，但运算速度是 NumPy 的短板，即便使用 Numba 等加速包，总体看 Python 的 NumPy 仍比 MATLAB 慢一些。

3. 从训练 AI 模型的角度来说，Python 相比于其它编程语言无疑具有显著优势，scikit-learn、XGBoost、TensorFlow 和 PyTorch 包都是基于 Python 语言的成熟机器学习项目。Python 的开源特性使得全世界研究者都能参与到开发中，及时共享最新 AI 算法，这种开放性是 MATLAB 等商业软件无法比拟的。

4. 从策略回测和绩效分析的角度来说，这部分对于运行效率和算法的依赖度较低，各种编程语言均能胜任。某团队使用 MATLAB 作为回测平台的原因主要是路径依赖，原始数据采用 MAT 格式保存，那么回测使用 MATLAB 也更方便。

Qlib 的改进

Qlib 的设计初衷之一就在于希望覆盖量化投资全过程，为用户的 AI 算法提供高性底层基础架构，降低 AI 算法使用门槛，便于金融从业者使用。“覆盖全过程”这一点更显示出其作为“平台”而不是“工具箱”的特性：从原始数据处理，到 AI 模型训练，再到投资组合的构建以及交易策略的生成全程使用，无需切换至其它编程软件或工具箱。Qlib 提供的人工智能选股模型开发解决方案如下表所示。

图表40： Qlib 提供的人工智能选股模型开发解决方案

步骤	编程平台	对应模块
获取保存原始数据	Python Qlib	数据服务模块（Data Server），数据增强模块（Data Enhancement）
计算因子	Python Qlib	信息抽取模块（Information Extractor）
训练人工智能模型	Python Qlib	训练模块（Trainer），模型管理模块（Model Manager），模型集成模块（Model Ensemble），预测模型（Forecast Model）
策略回测和绩效分析	Python Qlib	投资组合生成模块（Portfolio Generator），模拟订单执行模块（Order Executor），分析模块（Analyser）

资料来源：Qlib 官方文档，华泰证券研究所

Qlib 在官方文档中展示其设计框架，如下图所示。自下而上共三层，分别为基础架构层（Infrastructure）、量化投资流程层（Workflow）和交互层（Interface），下面逐一介绍各自的功能和特色。

图表41： Qlib 的三层框架：基础架构层、量化投资流程层和交互层

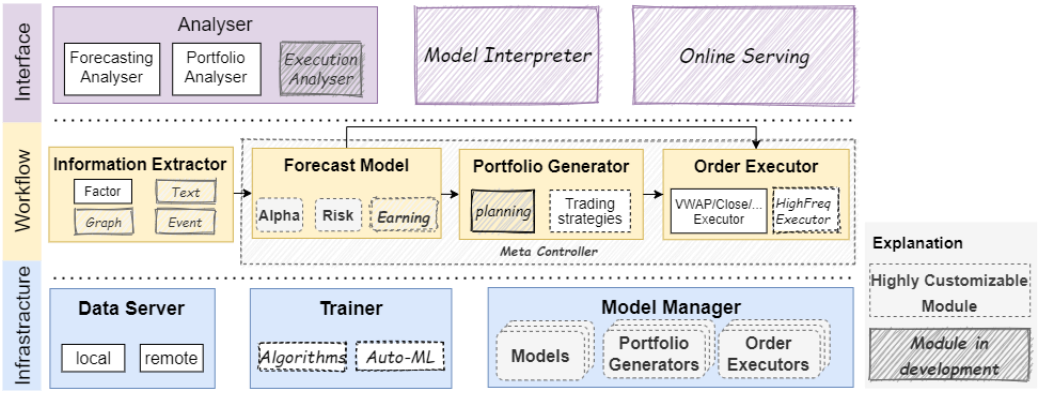

资料来源：Qlib 官方文档，华泰证券研究所

基础框架层：基础框架层从左下角的数据服务模块（Data Server）开始，数据服务模块帮助用户查询和加工原始数据；数据增强模块（Data Enhancement）提供一系列方法，让用户依据实际问题构建相应数据集；训练模块（Trainer）为 AI 算法提供灵活的接口，便于用户自定义训练模型；模型管理模块（Model Manager）便于用户管理众多 AI 模型；模型集成模块（Model Ensemble）能够实现模型集成，提升 AI 模型鲁棒性。

量化投资流程层：该层涵盖量化投资的整个工作流，信息抽取模块（Information Extractor）为 AI 模型提取有效数据，除因子之外，文本、图片、事件等都可以作为自定义信息输入到 AI 模型；预测模型（Forecast Model）接收数据后输出各种预测信号，如预期收益、预期风险等；投资组合生成模块（Portfolio Generator）根据预测模型输出结果生成目标投资组合；订单执行模块（Order Executor）是一套高度仿真的交易模拟系统，使得回测结果更贴近实盘交易。

交互层：最上层的交互层为底层系统提供用户友好界面，分析模块（Analyser）根据下层的预测信号、仓位、执行结果做出详细分析并可视化呈现。上一层的订单执行模块并不是简单的回测函数，而是设计成响应式的模拟器，能够支持强化学习等一些基于环境反馈的学习算法，而这些环境反馈正是来自交互层。

有意思的是，在 Qlib 原始论文 *Qlib: An AI-oriented Quantitative Investment Platform* 中，还提出了另一种各模块的拆解方式，如下图所示，自左向右分别为静态流程（Static Workflow）、动态建模（Dynamic Modeling）和分析模块（Analysis）。其中静态流程和分析模块属于常规模块（Normal Module），动态建模属于高度自定义模块（Highly user-customizable）。

图表42： Qlib 各模块的另一种拆解：静态流程、动态建模和分析模块

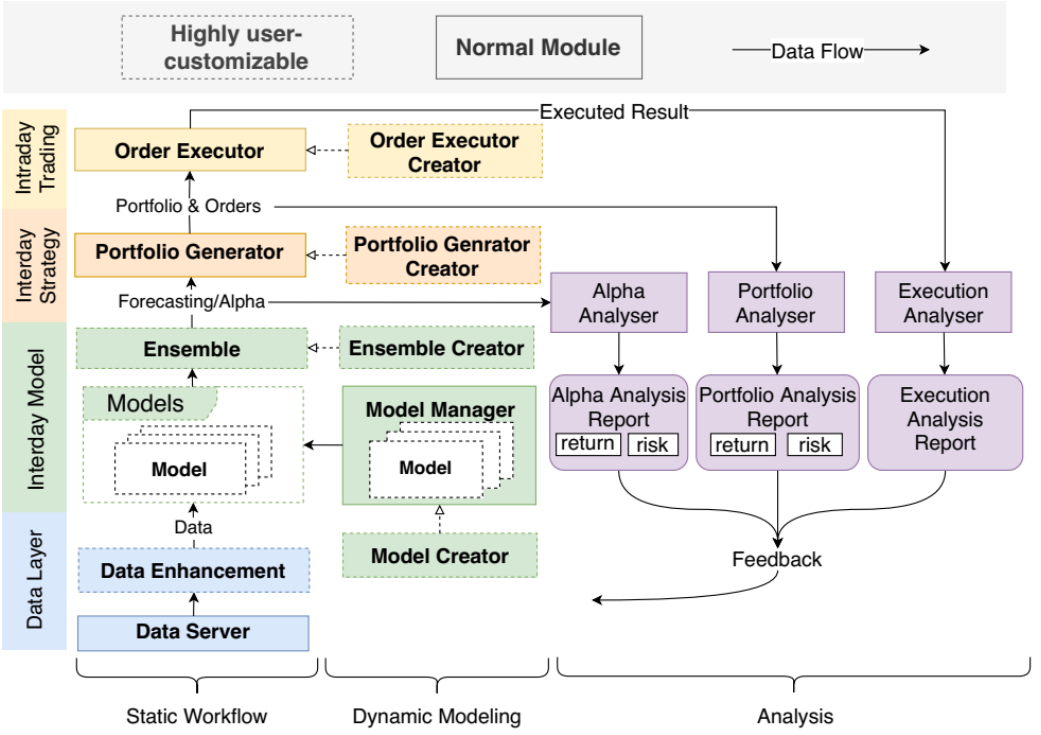

资料来源：*Qlib: An AI-oriented Quantitative Investment Platform*，华泰证券研究所

静态流程涵盖此前提到的数据服务、数据增强、模型集成、投资组合生成和订单执行功能。如果仅仅使用训练完成后就不再更改的静态模型，静态流程通常已经能够满足用户需求。然而对量化投资而言，数据会在时间维度上扩展，今天的“样本外测试集”到明天就可能成为“样本内训练集”，因此模型的更新迭代就变得格外重要。

动态建模正是针对上述“痛点”而开发，包含模型生成器（Model Creator）、模型管理模块、集成模型生成器（Ensemble Creator）、投资组合生成器（Portfolio Generator Creator）和订单执行生成器（Order Executor Creator）。动态建模在 Qlib 论文中有提及，但截至 2020 年 12 月 22 日，该功能未在 Qlib 开源代码中体现，笔者推测该功能尚在开发中或者已开发完成但暂未开源。

分析模块又可分为 Alpha 分析、投资组合分析和交易分析三部分。Qlib 论文对该模块未作介绍，笔者认为这样的拆分具有合理性。AI 模型的 Alpha 并不等于实盘能获得的 Alpha 收益，从模型预测到构建投资组合再到交易执行，每一步都可能存在 Alpha 的“损耗”，因此有必要将三部分拆解开来分析。例如，如果模型 Alpha 较高但投资组合收益不理想，那么可推知组合构建方式需要改进；如果投资组合收益高但执行交易后收益不理想，那么可推知交易时机或交易算法需要改进。

工程创新：数据存储设计，表达式引擎，缓存系统

Qlib 的“高性能底层基础架构”体现在多项工程上的创新，下面分别从数据存储方案（File Storage Design）、表达式引擎（Expression Engine）和缓存系统（Cache System）三方面展开介绍。

图表43： Qlib 高性能底层基础架构

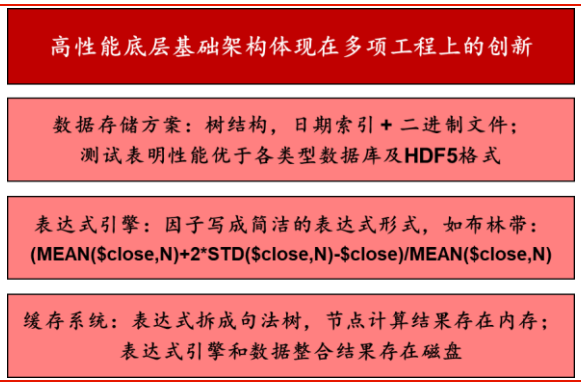

资料来源：*Qlib: An AI-oriented Quantitative Investment Platform*，华泰证券研究所

数据存储方案

因子选股的数据存在股票、时间、因子三个维度。传统因子数据存储方式有以 MySQL 为代表的关系型数据库，以 MongoDB 为代表的非关系型数据库，以 InfluxDB 为代表的时序数据库，以及 NumPy 数组、pandas 数据集（保存为 HDF5、pickle）等科学计算格式。这些数据存储方案各有长处和短板。

各类型数据库的长处在于查询及维护较为便捷，而这正是数据库的设计初衷。其中关系型数据库普适性较好，适用于各类型数据；非关系型数据库更适用于非结构化数据，如基金持仓数据等；时序数据库顾名思义更适用于时序数据。它们的短板是并非针对因子数据设计，因子是结构化的、兼具时序和面板属性的数据，和上述数据库的适用场景不完全匹配，因此会牺牲一定的效率。另外，当处理日内数据等更高频数据时，数据库的查询和计算速度较慢（并非没有解决办法，有商业付费数据库提供分布式集群方案）。

NumPy 数组、pandas 数据集、MATLAB 矩阵也是常用的因子数据存储方案。这些数据类型正是为科学计算而设计，它们的优缺点刚好和数据库相反。由于这些数据类型均为矩阵形式，便于进行矩阵运算，适用于因子数据加工，计算效率较高。它们的短板是查询和维护效率较低。除此以外，MAT 格式对除 MATLAB 以外的编程语言不友好。

图表44： 不同因子数据存储方案的长处和短板

数据库类别	代表性产品	长处	短板
关系型数据库	MySQL	便于查询和维护，适用于各类型数据	数据量较大时，查询和计算速度慢；并非针对因子数据设计
非关系型数据库	MongoDB	适用于非结构化数据	并非针对因子数据设计（因子为结构化数据）
时序数据库	InfluxDB	适用于时序数据	并非针对因子数据设计（因子兼具时序和面板属性）
科学计算格式	NumPy、pandas 保存为 HDF5、pickle 格式；MATLAB 矩阵保存为 MAT 格式	矩阵形式，适用于因子数据，矩阵运算效率高	难以查询及更新数据；MAT 格式对除 MATLAB 以外的编程语言不友好
日期索引+二进制文件	Qlib	兼顾计算效率与查询便捷度	技术尚在发展中，未普及

资料来源：*Qlib: An AI-oriented Quantitative Investment Platform*，MySQL 官网，MongoDB 官网，InfluxDB 官网，NumPy 官网，pandas 官网，Mathworks 官网，华泰证券研究所

总的来看，上述存储方案难以兼顾计算效率与查询便捷度。Qlib 底层为此设计了专用的数据库，即日期索引+二进制文件的形式，将文件组织成一种树结构，数据存放在不同目录下的不同文件中，依据频率、属性和测度来分类。这种针对性的设计使它对金融数据的科学计算更为高效。

下图展示 Qlib 数据存储方案示意图。左半部分为数据存储结构，公共的时间轴存放于 calendar.txt 文件中，用于按时间查询的操作。右半部分显示所有属性值存放于一种紧凑的二进制文件中，共有(N+1)*4 个比特，前 4 个比特存放时间戳信息，用于和时间轴中的时间作匹配，使得程序内部能按比特来取索引。这种数据存储方式适合于科学计算的文件结构，以及按时间顺序的数据组织结构，既能保证运算的高效，又能以低成本对数据进行增删改查操作。

图表45： Qlib 数据存储方案

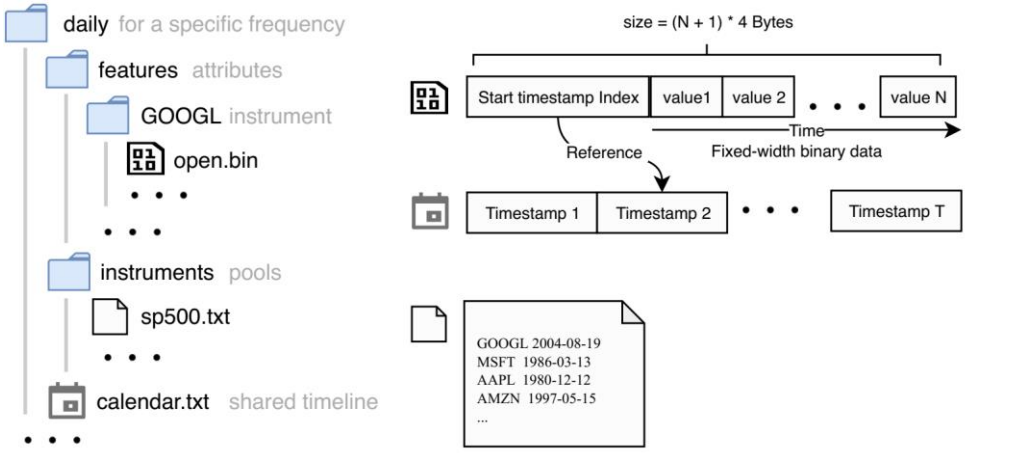

资料来源：*Qlib: An AI-oriented Quantitative Investment Platform*，华泰证券研究所

Qlib 研发团队将 Qlib 的数据存储方案与其它常用的数据存储方案进行比较。实验任务是从 2007 年至 2020 年每个交易日 800 只股票的原始行情数据（开、高、低、收、量）出发，创建一个包含 14 项因子数据集，以 1）占用存储空间，2）读取数据、计算因子等步骤的时间开销为评判标准。

图表46： 不同因子数据存储方案下的性能比较

	HDF5	MySQL	MongoDB	InfluxDB	Qlib -E -D	Qlib +E -D	Qlib +E +D
Storage(MB)	287	1,332	911	394	303	802	1,000
Load Data(s)	0.80±0.22	182.5±4.2	70.3±4.9	186.5±1.5	0.95±0.05	4.9±0.07	7.4±0.3
Compute Expr.(s)	179.8±4.4				137.7±7.6	35.3±2.3	-
Convert Index(s)	-				3.6±0.1		-
Filter by Pool(s)	3.39 ±0.24						-
Combine data(s)	1.19±0.30						-
Total (1CPU) (s)	184.4±3.7	365.3±7.5	253.6±6.7	368.2±3.6	147.0±8.8	47.6±1.0	7.4±0.3
Total(64CPUs) (s)	-				8.8±0.6	4.2±0.2	-

资料来源：*Qlib: An AI-oriented Quantitative Investment Platform*，华泰证券研究所

实验结果如上表所示，Qlib（即 Qlib –E –D）占用存储空间和读取数据时间均低于关系型数据库 MySQL、非关系型数据库 MongoDB 和时序数据库 InfluxDB，仅高于 HDF5 格式，计算因子时间和运行总时间均低于 MySQL、MongoDB、InfluxDB 和 HDF5，在数据存储方面展现出较高性能。

表达式引擎

表达式引擎主要用于因子生成，基于原始数据构建因子是经典研究方法，但新因子的构建往往开发成本和时间开销都较高。事实上，构建因子的过程无非是编写将原始数据映射成另一种数据的函数，这种函数能够拆分成一系列表达式的组合，表达式引擎的设计出发点正是基于此。

通过 Qlib 的表达式，用户能快速写出简洁而清晰的表达式来生成因子，不再需要写复杂而难以理解的数学函数。例如 N 日布林带可写作：

(MEAN($close,N)+2*STD($close,N)-$close)/MEAN($close,N)

又如 MACD 可写作：

(EMA($close, 12) - EMA($close, 26))/$close - EMA((EMA($close, 12) - EMA($close, 26))/$close, 9)/$close

缓存系统

缓存系统的设计也是 Qlib 的工程创新之一。计算机读取内存的速度快于读取磁盘的速度，而内存的容量则远小于磁盘容量。我们既无法将所有原始数据和运算过程中的数据都存在内存中，又不可能因为内存容量有限而放弃其读写高效的优势。

考虑到这点，Qlib 设计了一套包含内存缓存（In-Memory Cache）和磁盘缓存（Disk Cache）在内的缓存系统。将因子表达式拆解成句法树，句法树节点的运算结果往往可以复用，因而存放在内存缓存中。而将表达式引擎计算结果和数据整合结果存放在磁盘缓存中。

图表47： Qlib 缓存系统

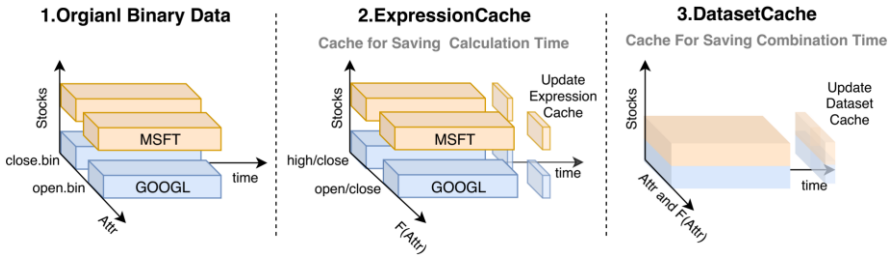

资料来源：*Qlib: An AI-oriented Quantitative Investment Platform*，华泰证券研究所

使用体会：侧重量价选股，解决部分痛点，开源或推动技术发展

笔者使用 Qlib 一周的体会是，Qlib 在“术”层面的创新要大于在“道”层面的创新。Qlib 在宣传中称其为“业内首个 AI 量化投资开源平台”，而就目前公开的功能看，Qlib 的核心是“量价因子结合 AI 模型选股流程”。笔者所期待的诸如 AI 在量化择时上的应用，以及高频交易环境下的强化学习模块，暂未出现在目前的开源代码中。可以说 Qlib 在“道”的层面并未脱离传统的因子选股方法论。

而在“术”的层面，笔者认为 Qlib 提出的解决方案颇有可圈可点之处。笔者在日常研究中常面临一些困惑：比如数据以何种方式存储，能够兼顾计算效率和查询便捷度，又如量价因子计算速度通常较慢。而 Qlib 的数据存储方案和表达式引擎这两处工程创新对笔者而言具有很高的借鉴价值。Qlib 在“术”层面的创新一定程度上能够解决研究中的部分痛点。

笔者认为，不同层次研究者或能够从 Qlib 中各取所需。对于本领域的初学者而言，Qlib 是不错的学习素材，从策略流程到程序设计均可提供参照，同时也节省重复造轮子的时间。对于有一定经验的研究者而言，Qlib 在工程实现等角度的创新或能提供启发，并根据实际需求自由修改和添加功能。当然，对于经验更丰富的研究者而言，目前开源的 Qlib 模块可能仍偏基础，未来期待开源更多的进阶功能。

最后，笔者认为 Qlib 还有一大意义在于开源。量化投资的圈子整体较为封闭，研究者出于策略隐私性的考虑，通常不愿意分享自己的代码。而近三十年来，Linux、安卓、Python 语言等开源项目的成功经验表明，开源能够降低整个行业的学习和研发成本，为行业进步提供源动力。微软此次的开源尝试或能推动量化投资行业的技术发展。

参考文献

Yang, X. , Liu, W. , Zhou, D. , Bian, J. , & Liu, T. Y. . (2020). Qlib: an ai-oriented quantitative investment platform. *arXiv*.

风险提示

本文的港股 AI 选股策略仅作案例教学使用，不具备实际投资价值，例如未剔除低价股、低流动性股票，训练集和测试集较短，未进行参数优化等。Qlib 仍在开发中，部分功能未加完善和验证，使用存在风险。人工智能挖掘市场规律是对历史的总结，市场规律在未来可能失效。人工智能技术存在过拟合风险。

免责声明

分析师声明

本人，林晓明、李子钰、何康，兹证明本报告所表达的观点准确地反映了分析师对标的证券或发行人的个人意见；彼以往、现在或未来并无就其研究报告所提供的具体建议或所表达的意见直接或间接收取任何报酬。

一般声明及披露

本报告由华泰证券股份有限公司（已具备中国证监会批准的证券投资咨询业务资格，以下简称“本公司”）制作。本报告仅供本公司客户使用。本公司不因接收人收到本报告而视其为客户。

本报告基于本公司认为可靠的、已公开的信息编制，但本公司对该等信息的准确性及完整性不作任何保证。本报告所载的意见、评估及预测仅反映报告发布当日的观点和判断。在不同时期，本公司可能会发出与本报告所载意见、评估及预测不一致的研究报告。同时，本报告所指的证券或投资标的的价格、价值及投资收入可能会波动。以往表现并不能指引未来，未来回报并不能得到保证，并存在损失本金的可能。本公司不保证本报告所含信息保持在最新状态。本公司对本报告所含信息可在不发出通知的情形下做出修改，投资者应当自行关注相应的更新或修改。

本公司力求报告内容客观、公正，但本报告所载的观点、结论和建议仅供参考，不构成购买或出售所述证券的要约或招揽。该等观点、建议并未考虑到个别投资者的具体投资目的、财务状况以及特定需求，在任何时候均不构成对客户私人投资建议。投资者应当充分考虑自身特定状况，并完整理解和使用本报告内容，不应视本报告为做出投资决策的唯一因素。对依据或者使用本报告所造成的一切后果，本公司及作者均不承担任何法律责任。任何形式的分享证券投资收益或者分担证券投资损失的书面或口头承诺均为无效。

除非另行说明，本报告中所引用的关于业绩的数据代表过往表现，过往的业绩表现不应作为日后回报的预示。本公司不承诺也不保证任何预示的回报会得以实现，分析中所做的预测可能是基于相应的假设，任何假设的变化可能会显著影响所预测的回报。

本公司及作者在自身所知情的范围内，与本报告所指的证券或投资标的不存在法律禁止的利害关系。在法律许可的情况下，本公司及其所属关联机构可能会持有报告中提到的公司所发行的证券头寸并进行交易，为该公司提供投资银行、财务顾问或者金融产品等相关服务或向该公司招揽业务。

本公司的销售人员、交易人员或其他专业人士可能会依据不同假设和标准、采用不同的分析方法而口头或书面发表与本报告意见及建议不一致的市场评论和/或交易观点。本公司没有将此意见及建议向报告所有接收者进行更新的义务。本公司的资产管理部门、自营部门以及其他投资业务部门可能独立做出与本报告中的意见或建议不一致的投资决策。投资者应当考虑到本公司及/或其相关人员可能存在影响本报告观点客观性的潜在利益冲突。投资者请勿将本报告视为投资或其他决定的唯一信赖依据。有关该方面的具体披露请参照本报告尾部。

本报告并非意图发送、发布给在当地法律或监管规则下不允许向其发送、发布的机构或人员，也并非意图发送、发布给因可得到、使用本报告的行为而使本公司及关联子公司违反或受制于当地法律或监管规则的机构或人员。

本公司研究报告以中文撰写，英文报告为翻译版本，如出现中英文版本内容差异或不一致，请以中文报告为主。英文翻译报告可能存在一定时间迟延。

本报告版权仅为本公司所有。未经本公司书面许可，任何机构或个人不得以翻版、复制、发表、引用或再次分发他人等任何形式侵犯本公司版权。如征得本公司同意进行引用、刊发的，需在允许的范围内使用，并注明出处为“华泰证券研究所”，且不得对本报告进行任何有悖原意的引用、删节和修改。本公司保留追究相关责任的权利。所有本报告中使用的商标、服务标记及标记均为本公司的商标、服务标记及标记。

中国香港

本报告由华泰证券股份有限公司制作,在香港由华泰金融控股（香港）有限公司向符合《证券及期货条例》第 571 章所定义之机构投资者和专业投资者的客户进行分发。华泰金融控股（香港）有限公司受香港证券及期货事务监察委员会监管，是华泰国际金融控股有限公司的全资子公司，后者为华泰证券股份有限公司的全资子公司。在香港获得本报告的人员若有任何有关本报告的问题,请与华泰金融控股（香港）有限公司联系。

香港-重要监管披露

- 华泰金融控股（香港）有限公司的雇员或其关联人士没有担任本报告中提及的公司或发行人的高级人员。

更多信息请参见下方 **“美国-重要监管披露”**。

美国

本报告由华泰证券股份有限公司编制，在美国由华泰证券（美国）有限公司向符合美国监管规定的机构投资者进行发表与分发。华泰证券（美国）有限公司是美国注册经纪商和美国金融业监管局（FINRA）的注册会员。对于其在美国分发的研究报告，华泰证券（美国）有限公司对其非美国联营公司编写的每一份研究报告内容负责。华泰证券（美国）有限公司联营公司的分析师不具有美国金融监管（FINRA）分析师的注册资格，可能不属于华泰证券（美国）有限公司的关联人员，因此可能不受 FINRA 关于分析师与标的公司沟通、公开露面和所持交易证券的限制。华泰证券（美国）有限公司是华泰国际金融控股有限公司的全资子公司，后者为华泰证券股份有限公司的全资子公司。任何直接从华泰证券（美国）有限公司收到此报告并希望就本报告所述任何证券进行交易的人士，应通过华泰证券（美国）有限公司进行交易。

美国-重要监管披露

- 分析师林晓明、李子钰、何康本人及相关人士并不担任本报告所提及的标的证券或发行人的高级人员、董事或顾问。分析师及相关人士与本报告所提及的标的证券或发行人并无任何相关财务利益。声明中所提及的“相关人士”包括 FINRA 定义下分析师的家庭成员。分析师根据华泰证券的整体收入和盈利能力获得薪酬，包括源自公司投资银行业务的收入。
- 华泰证券股份有限公司、其子公司和/或其联营公司，及/或不时会以自身或代理形式向客户出售及购买华泰证券研究所覆盖公司的证券/衍生工具，包括股票及债券（包括衍生品）华泰证券研究所覆盖公司的证券/衍生工具，包括股票及债券（包括衍生品）。
- 华泰证券股份有限公司、其子公司和/或其联营公司，及/或其高级管理层、董事和雇员可能会持有本报告中所提到的任何证券（或任何相关投资）头寸，并可能不时进行增持或减持该证券（或投资）。因此，投资者应该意识到可能存在利益冲突。

评级说明

投资评级基于分析师对报告发布日后 6 至 12 个月内行业或公司回报潜力（含此期间的股息回报）相对基准表现的预期（A 股市场基准为沪深 300 指数，香港市场基准为恒生指数，美国市场基准为标普 500 指数），具体如下：

行业评级

增持：预计行业股票指数超越基准
中性：预计行业股票指数基本与基准持平
减持：预计行业股票指数明显弱于基准

公司评级

买入：预计股价超越基准 15%以上
增持：预计股价超越基准 5%~15%
持有：预计股价相对基准波动在-15%~5%之间
卖出：预计股价弱于基准 15%以上
暂停评级：已暂停评级、目标价及预测，以遵守适用法规及/或公司政策
无评级：股票不在常规研究覆盖范围内。投资者不应期待华泰提供该等证券及/或公司相关的持续或补充信息

法律实体披露

中国：华泰证券股份有限公司具有中国证监会核准的“证券投资咨询”业务资格，经营许可证编号为：91320000704041011J
香港：华泰金融控股（香港）有限公司具有香港证监会核准的“就证券提供意见”业务资格，经营许可证编号为：AOK809
美国：华泰证券（美国）有限公司为美国金融业监管局（FINRA）成员，具有在美国开展经纪交易商业务的资格，经营业务许可编号为：CRD#:298809/SEC#:8-70231

华泰证券股份有限公司

南京
南京市建邺区江东中路 228 号华泰证券广场 1 号楼/邮政编码：210019

电话：86 25 83389999/传真：86 25 83387521
电子邮件：ht-rd@htsc.com

北京
北京市西城区太平桥大街丰盛胡同 28 号太平洋保险大厦 A 座 18 层/邮政编码：100032
电话：86 10 63211166/传真：86 10 63211275
电子邮件：ht-rd@htsc.com

深圳
深圳市福田区益田路 5999 号基金大厦 10 楼/邮政编码：518017
电话：86 755 82493932/传真：86 755 82492062
电子邮件：ht-rd@htsc.com

上海
上海市浦东新区东方路 18 号保利广场 E 栋 23 楼/邮政编码：200120
电话：86 21 28972098/传真：86 21 28972068
电子邮件：ht-rd@htsc.com

华泰金融控股（香港）有限公司
香港中环皇后大道中 99 号中环中心 58 楼 5808-12 室
电话：+852 3658 6000/传真：+852 2169 0770
电子邮件：research@htsc.com
http://www.htsc.com.hk

华泰证券（美国）有限公司
美国纽约哈德逊城市广场 10 号 41 楼（纽约 10001）
电话: + 212-763-8160/传真: +917-725-9702
电子邮件: Huatai@htsc-us.com
http://www.htsc-us.com

©版权所有2020年华泰证券股份有限公