

研发部

分析师：程毅敏

SAC 执业证书编号：S1340511010001

联系电话：010-67017788

Email: chengyimin@cnpsec.com

基于机器学习的量化投资策略

——系列一：概述

- 人工智能，在金融领域已经开始逐步从探索走向应用，从金融大数据，到智能投顾、智能投研，在不断取得新的应用进展。依托于计算机和数据信息的发展，“AI+”的模式将给我们的投资研究带来更多的助益。未来将在“AI+”量化投资中探索更多的想法和应用。

一、概述

(一) 从 Alpha 系列谈起

近几年随着人工智能概念的再度提起，各种相应的算法也随之发展。

人工智能，是建立在统计学基础上，研究使计算机模拟人的某些思维过程和智能行为，从而能够通过对环境感知，做出最大化效果预期的行动。

AlphaGo 是第一个击败人类职业围棋选手、第一个战胜围棋世界冠军的围棋 AI；此后，DeepMind 又推出新一代的围棋 AI，把这个新版本称之为“Alpha Zero”。在 Alpha Zero 之前的所有版本都是经过人类知识的训练，它们被告知人类高手如何下棋。而最新发布的 AlphaGo Zero 使用了更多原理和算法，从 0 开始，使用随机招式，40 天后成为围棋界的绝世高手，真正的自学成才。新的 AlphaGo Zero 使用了一种全新的强化学习方式，从 0 基础的神经网络开始，与搜索算法结合，不断进化调整、迭代升级。


(二) “AI+”量化投资

1、与传统的量化投资相比，“AI+”的优势体现在何处？

传统的量化投资策略是通过建立各种数学模型，在各种金融数据中试图寻找市场的规律。无论是依据人的经验，还是通过数学模型，目前所取得的效果都是一般；在股票等金融市场的探索中，人类的研究或许只是接近了其中某一个局部最优解，而真正的全局最优解或许超出了传统量化所能达到的范畴(如图表 1 示)。

一方面，金融市场中蕴含着复杂的非线性行为和金融数据的非稳态问题，很难通过传统的数学模型挖掘，另一方面，交易数据的量相当巨大，对于海量数据的挖掘，受限于计算机运算能力，若不合理的利用相关算法，往往需要耗费大量时间。而 AI 的优势在于：AI 能够提供非线性关系的模糊处理，弥补了人脑思维模式，同时利用相关算法，可以大幅提高数据挖掘、处理效率。借助 AI，量化投资策略会变得更加丰富，例如：基于 AI 在多因子选股领域对因子的挖掘。

图表 1：“全视角”的 AI



资料来源：网络，WIND 资讯，中邮证券研发部

2、“AI+”如何应用到量化投资领域？

人工智能的发展，需要经历“机器辅助——人机合作——机器自主”三个发展阶段。目前 AI 在众多领域取得了突破，但仅在解决封闭空间的简单任务中取得了成功，离普适还有一定距离，可以预见，在未来相当长的一段时间内，将会是人机融合的模式，对于处理金融数据更是如此。

对于量化投资来说，将会是分析师的经验和人工智能的融合，“AI+”的模式将会成为量化投资领域的发展方向。人脑的抽象思维、情感思维是目前 AI 所不具备的，而 AI 的模糊运算和计算能力也是人脑所不能达到的，二者相互结合或许会成为未来量化投资领域的一个方向。

(三) AI 在投资领域的应用和发展

1、AI 的发展历程

人工智能的概念最早由 McCarthy 在 1956 年提出，此后经历了三次大的发展浪潮。

第一次浪潮出现于 20 世纪 60 年代：机器通过严密的逻辑符号来进行一些推理证明。

第二次浪潮出现于 20 世纪 70 年代末：Feigenbaum 提出“知识工程”的概念和 BP 神经网络的诞生，人类开始让机器模仿神经网络进行知识的学习。

第三层浪潮出现在 2006 年，Geoffrey Hinton 提出深度学习的概念，随着模型训练方法的改进和计算能力的不断发展，打破了 BP 神经网络发展的瓶颈。

图表 2：AI 的发展历程

| | | |
|--------|--------|--------------------------|
| 推理时期 | 1960s | 赋予机器逻辑推理的能力，使机器获得智能 |
| 知识时期 | 1970s | 将人类的知识总结出来教给机器，使机器获得智能 |
| 机器学习时期 | 1980s | 符号主义学习与连接主义学习，代表决策树和神经网络 |
| | 1990s | 统计学习占据舞台，代表方法：支持向量机 |
| | 21Cent | 深度神经网络被提出 |

资料来源：网络，WIND 资讯，中邮证券研发部

2、AI 在量化投资领域的应用

目前，AI 在智能投顾领域的应用包括非结构化信息获取、分析，构建知识图谱，提供投资建议，优化投资结构。

(1)、AI 在境外投研领域

Rebellion Research 的人工智能系统通过自我学习全球 53 个国家股票、债券、外汇和大宗商品的交易数据，评估各种资产组合的未来收益和潜在风险，帮助客户合理配置资产。公司的人工智能系统基于贝叶斯算法，对宏观、行业和公司三个层面的数据进行分析，且模型能够自动将历史数据和最新数据进行整合，使模型能够自动预测市场走势。公司在 2007 年推出的第一个人工智能投资基金，基于贝叶斯机器学习，结合预测算法，对历史的金融和贸易数据进行分析之后，成功地预测 2008 年的股市崩盘，并在 2009 年 9 月给希腊债券 F 评级，当时惠誉的评级仍然为 A，Rebellion 比官方提前一个月给希腊债券降级。

英国另类投资管理业务集团 Man Group 规模最大的一只基金 AHL Dimension Programme 目前管理着 51 亿美元资产，从 2014 年开始使用机器学习技术，至今年 6 月 3 年间获得了 15% 的收益，约为行业平均水平的 2 倍，其一半的利润是由人工智能贡献的。目前，Man Group 已经有四只基金融合了人工智能技术，共计约 123 亿美元资产。

Two Sigma 和 Renaissance Technologies 这些以数据为中心的对冲基金也依靠智能投资系统。系统可以完全自主地识别和执行交易，借助了包括基于遗传算法、概率逻辑等多种形式的人工智能技术。

美国 EquBot 公司和 ETF Managers Group 合作推出的 AIEQ 利用人工智能和机器学习，对全美 6000 多家上市公司进行分析，构建上百万份资料和众多金融模型，从当前经济形势、未来趋势以及公司重大事件等方面进行深度分析后，再挑选出包含 70 只股票的投资组合；然后由 ETF Managers Group 的一个基金经理团队对投资组合进行再权衡。

据调研公司 LCH 在今年初出具的调研报告，美国业绩排前 20 的对冲基金，包括桥水基金、索罗斯基金，全部采用计算机根据算法自动交易。2016 年第二季度，美国花旗银行的一份行业研究报告指出，从 2012 年到 2015 年年底，美国智能投资顾问管理的资产规模从 0 上升至 290 亿美元，而且其管理的资产规模将在未来十年中呈现几何级数的上升，预计 2025 年将达到 5 万亿美元的水平。

(2)、AI 在境内投研领域

国内也有多家公募基金、私募基金、资管纷纷试水，设立或在积极筹备相关研究部门及团队，运用 AI 辅助投资决策。2017 年 6 月 13 日华夏基金宣布与微软公司在亚太地区设立的微软亚洲研究院合作，就人工智能在金融服务领域的应用展开战略合作研究。也有些机构与互联网公司合作，并在积极研究布局融合人工智能技术的主动量化基金。

3、AI 在量化投资领域的局限

AI 对数据的质量要求很高，学习效果跟数据质量有很大关系，我国 A 股市场发展的时间还不长，数据量不够充足，噪声也比较多，使得 AI 学习效果的稳定性不能充分得到保证；另外，脱离人类经验的完全强化学习目前仅在特定约束条件的环境下成功运用，离普适还有相当长的距离，深度学习、强化学习等技术仍需要 GPU、TPU 的发展支持。

二、人工智能简析

(一) AI 和机器学习

人工智能是一个大概念，其研究范畴包含机器学习、自然语言处理、语音识别等。

(二) 机器学习算法

机器学习算法主要分为三类：监督学习（Supervised Learning），无监督学习（Unsupervised Learning）和强化学习（Reinforcement Learning）。

监督学习是使用已知正确答案的示例来训练网络的，无监督学习适用于你具有数据集但无标签的情况，强化学习是针对你再次没有标注数据集的情况而言的，但你还是有办法来区分是否越来越接近目标（回报函数（reward function））。

图表 3：机器学习算法应用场景

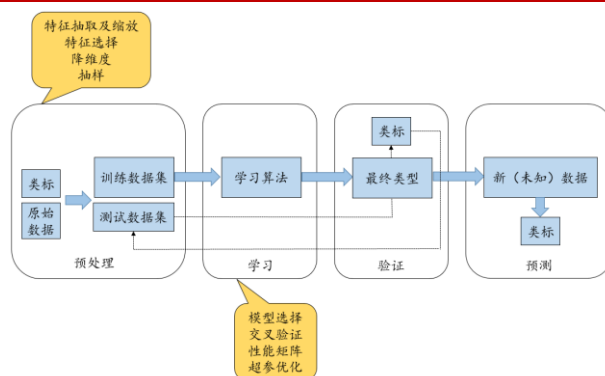
| | |
|-----------|-----------------------|
| 市场状态转换模型 | 隐马尔可夫，条件随机场 |
| 多因子组合 | 线性回归，Lasso 回归，岭回归，决策树 |
| 新闻文本、舆情分析 | 自然语言处理，文本挖掘 |
| 证券买卖定价模型 | 卡尔曼滤波 |
| 金融经济数据挖掘 | 神经网络，深度学习 |
| 股价预测的特征选取 | SVM，决策树，随机森林 |
| 股价走势预测 | K-means |
| 因子模式分类 | 逻辑回归 |

资料来源：网络，WIND 资讯，中邮证券研发部

（三）机器学习流程

1、建模流程

图表 4：机器学习流程示意



资料来源：网络，WIND 资讯，中邮证券研发部

2、数据处理

数据的质量直接影响了机器学习算法最终学习的效果，数据处理一般包含以下步骤：

缺失数据处理：处理缺失值的两个方法是删除或者填充。删除是直接包含缺失值的特征或样本删除。填充是为了避免删除整个特征或样本会损失很多有价值的信息。缺失值的填充可以使用各种插值技术，最常用的是均值插值、中位数插值等。

类别数据的处理：类别数据有两个类型，标称特征（nominal feature）和有序特征（ordinal feature）。

对于有序特征，我们可以建立一个映射字典，将类别字符串与整数建立映射。比如：大盘股、中盘股、小盘股分别映射为 1、2、3。对于标称特征，

我们可以将字符串分别映射为不同的整数，比如将价值股定义为 0，周期股定义为 1，成长股定义为 2，但这样会导致机器学习算法认为这两个特征是有大小顺序的，这样学习的结果不是最优结果。解决这一问题的常用技术是 one-hot encoding 技术。one-hot encoding 是构建一个虚拟特征 (dummy feature)，用二进制来标识样本类别，利用 one-hot encoding，价值股的虚拟特征为 (1,0,0)，周期股的特征为 (0,1,0)，成长股为 (0,0,1)。

数据集的划分：为了保证算法不仅在训练数据集上有效，同时还能很好地应用于新数据，我们通常会随机的将数据集划分为训练数据集和测试数据集。我们使用训练数据集来训练及优化我们的机器学习模型，用测试数据集对模型进行评估，如果对评估效果满意，那么可以用此模型对新的数据进行预测。为了找出能在实测数据上有更好表现的模型，可以采用交叉验证技术，将训练数据进一步分为训练子集和验证子集，对模型的泛化能力进行评估。

特征缩放：如果数据尺度相差较大，一般的学习算法将主要根据较大值的误差进行权重优化，为了避免此类错误，需要将不同的特征数据缩放到同一区间。决策树和随机森林是机器学习算法中为数不多的不需要进行特征缩放的算法。

常用的特征缩放方法有归一化和标准化：

归一化：将值缩放在区间[0,1]内，通常使用 min-max 缩放：

$$x_{norm}^{(i)} = \frac{x^{(i)} - x_{\min}}{x_{\max} - x_{\min}}$$

标准化：将值转换为服从均值为 0，方差为 1 的标准正态分布：

$$x_{std}^{(i)} = \frac{x^{(i)} - \mu_x}{\sigma_x}$$


对于大多数算法来说，标准化方法更易于权重的更新；此外，还可以进行数据降维。

3、模型评估和参数优化

过拟合和欠拟合

若模型的训练准确率和验证准确率之间有很大的差距，说明模型过拟合，是一个高方差模型；若模型的训练准确率和验证准确率都很低，说明模型欠拟合，是一个高偏差模型。

图表 5：欠拟合、过拟合、完美拟合



资料来源：网络，WIND 资讯，中邮证券研发部

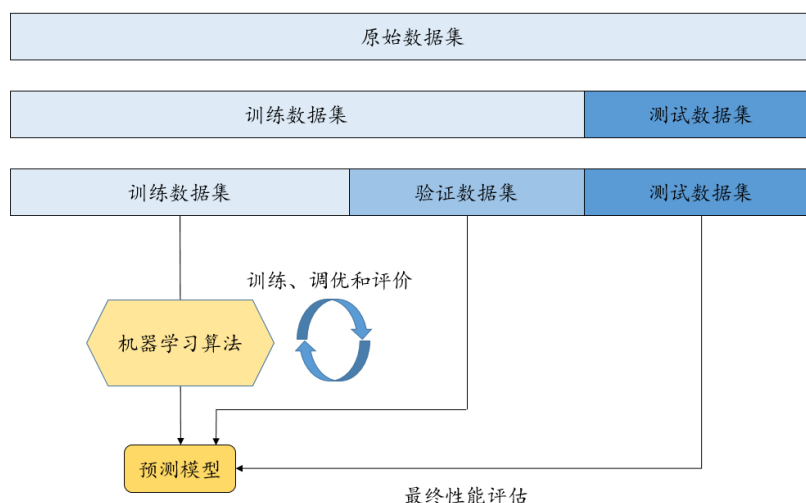
对于欠拟合，通常做法有：增加参数数量，构建额外特征、降低模型的正则化程度；对于过拟合模型，通常做法有：增加训练样本数、降低模型复杂度、特征提取、降维。降低模型复杂度可以通过增加正则化参数实现，增加训练集样本数不适用于数据中噪声过多的情况。

交叉验证

为了使模型在欠拟合和过拟合之间找到最优平衡点，我们可以使用 holdout 交叉验证或者 k 折交叉验证优化模型的泛化能力。

Holdout 交叉验证是将模型划分为三部分：训练数据集、验证数据集和测试数据集。验证集用于评估模型的性能。


图表 6: Holdout 方法



资料来源：网络，WIND 资讯，中邮证券研发部

k 折交叉验证使用无重复抽样技术，在 k 个训练数据子集上重复 holdout 方法 k 次。不重复地随机将训练数据集划分为 k 个，其中 k-1 个用于模型训练，剩余 1 个用于测试，重复此过程 k 次，通常 k 取为 10，相较于 holdout 方法具有更好的鲁棒性。

图表 7: k 折交叉验证方法

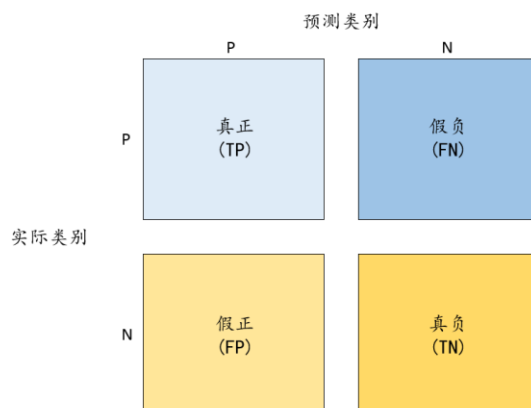


资料来源：网络，WIND 资讯，中邮证券研发部

性能评价指标

我们可以用一个混淆矩阵展示学习算法预测结果，并通过混淆矩阵构建模型的性能评价指标。

图表 8：混淆矩阵



资料来源：网络，WIND 资讯，中邮证券研发部

4、预测

在使用训练数据集勾出一个模型后，可以采用测试数据集对模型进行测试，预测该模型在未知数据上的表现并对模型的泛化误差进行评估。若我们对模型的评估结果表示满意，就可以使用此模型对以后新的未知数据进行预测。

5、集成学习

我们可以将不同的分类器组合，成为一个元分类器，使得元分类器的整体性能优于其中任意一个单独分类器。集成学习就如同把 N 位专家的预测进行组合，比单独一个的预测具有更好的鲁棒性和准确性。有两种常见的集成学习框架：并行方法 bagging，串行方法 boosting。

Bagging

将训练数据进行 N 次又放回的随机抽样得到 N 个训练数据子集，对每个子集使用相同的算法分别建立决策，最终的分类（或者回归）结果是 N 个决策结果的多数投票（或平均）。

Boosting

基本思想是先赋予每个训练样本相同的权重，然后进行 T 次迭代，每次迭代后，对分类错误的样本加大权重（重采样），使得在下一次的迭代中更加关注这些样本。如此重复进行，直到弱学习器数达到事先指定的数目 T，最终这 T 个弱学习器通过集合策略进行整合，得到最终的强学习器。

三、机器学习在量化投资中的应用

(一) 监督学习：对未来事件预测

1、回归——预测连续型目标变量

(1)、OLS 回归

OLS 回归的目标是：求误差的最小平方和。对于线性回归模型，最小二乘法有解析解：

$$w_1 = (X^T X)^{-1} X^T y, w_0 = \mu_y - \mu_x \mu_y$$

对于非线性回归而言，最小二乘没有解析解，只有迭代解。常用的迭代法有：梯度下降法（可用于线性和非线性模型），高斯-牛顿法（适用于非线性模型），Levenberg-Marquardt 法（结合了梯度下降法和高斯-牛顿法，用于非线性模型）。

(2)、正则化方法——岭回归、LASSO 回归、弹性网络

正则化是通过在模型中加入额外信息来解决过拟合的一种方法，加入的信息称为惩罚项，惩罚项增加了模型的复杂度，但是降低了模型参数的影响。

常用的正则化线性回归方法有：基于 L2 罚项的岭回归、基于 L1 罚项的 LASSO 回归，以及 L1 和 L2 结合的弹性网络。

岭回归：在最小二乘的代价函数中加入权重的平方和，其中增加超参 λ 的值可以增加正则化的强度，同时降低了权重对模型的影响。

$$J(w)_{Ridge} = \sum_{i=1}^n (y^{(i)} - \hat{y}^{(i)})^2 + \lambda \|w\|_2^2$$

其中：L2：

$$\lambda \|w\|_2^2 = \lambda \sum_{j=1}^m w_j^2$$

LASSO 回归：在最小二乘的代价函数中加入权重绝对值的和。

$$J(w)_{LASSO} = \sum_{i=1}^n (y^{(i)} - \hat{y}^{(i)})^2 + \lambda \|w\|_1$$

其中：L1：

$$\lambda \|w\|_1 = \lambda \sum_{j=1}^m |w_j|$$

弹性网络：包含 L1 罚项和 L2 罚项。

$$J(w)_{ElasticNet} = \sum_{i=1}^n (y^{(i)} - \hat{y}^{(i)})^2 + \lambda_1 \sum_{j=1}^m w_j^2 + \lambda_2 \sum_{j=1}^m |w_j|$$

(3)、回归模型性能评价

残差图：对于一个好的回归模型，期望误差随机分布，残差也随机分布于中心线附近。

均方误差 (MSE)：最小化误差平方和 (SSE) 的均值，可用于不同回归模型的比较，

参数调优和交叉验证。

2、分类——预测分组或标签

(1) logistic 回归

逻辑回归 (logistic regression) 是一个分类模型。它通过一个 Logistic 函数将输入映射到 [0,1] 区间，logistic 函数又称 sigmoid 函数，形式如下：

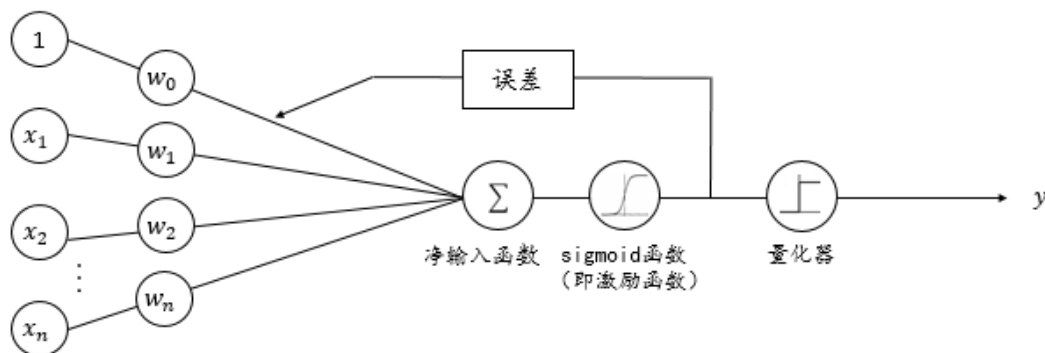
$$\phi(z) = \frac{1}{1+e^{-z}}$$

其中，输入 Z

$$z = w^T x = w_0 x_0 + w_1 x_1 + \dots + w_m x_m$$

逻辑回归模型可以看做由两部分组成，一部分和线性回归一样，另一部分是 sigmoid 函数。直观形式如下图：

图表 9：Logistic Regression



资料来源：网络，WIND 资讯，中邮证券研发部

逻辑回归模型的求解：归结为以似然函数为目标函数的优化问题，用迭代法求解。逻辑回归并不是硬性地分类结果定为 0 或 1，而是给出了 0 和 1 之间的概率，这相当于对分类结果给出一个打分。例如：我们想选出沪深 300 成分股中上涨概率最大的前 30 只股票，我们可以用逻辑回归的结果对每一只股票算出一个打分，分数越接近于 1，上涨概率越大；另外也可以规定一个阈值，大于阈值的归为一类，小于阈值的归为另一类。


(2) SVM

SVM (support vector machine)，俗称支持向量机，是一种监督学习算法，可用于分类和回归，它在解决小样本、非线性及高维度模式识别中表现出许多特有的优势。

支持向量机分类的原理如下：

假设有两个类别：实心圆和空心圆，我们的数据有两个特征： x 和 y ，需要得到一个分类器，给定一对 (x, y) ，输出实心圆和空心圆。我们将已标记的训练数据展示如下：

图表 10：SVM



资料来源：网络，WIND 资讯，中邮证券研发部

假设我们要把实心圆和空心圆分成两类。支持向量机会接受这些数据点，并输出一个超平面（二维图中是一条直线）将两类分隔开

分类算法还有：决策树、随机森林、K-近邻算法、神经网络和深度学习。

（二）非监督学习：发掘数据的潜在规律

1、聚类——无类标数据潜在挖掘

K-means

k-means 计算高效，易于实现，是一种经典的聚类技术。它依据样本之间的相似性对样本进行分组，划分为 k 个类簇，组内的对象之间具有更高的相似度。相似性的度量通常采用欧氏距离的倒数。

初始状态下，随机选取 k 个点作为初始类簇中心；随后将每个样本依据相似度划分到离它最近的中心点，并重新计算每个簇的中心；重复这一步骤，直到中心点不变或者达到预定的迭代次数为止。

实际中，初始 k 个中心点的选取以及聚类簇数 k 对结果的划分有较大影响。因此除了随机选取初始中心外，我们还有其他两种方式选取：层次聚类或 canopy 算法进行初始聚类。

2、降维——数据压缩

主成分分析

对不适合正则化的模型，可以用主成分分析或者线性判别分析降维。主成分分析是一种常用的降维方法，能够在尽可能多地保留相关信息的情况下，把多指标转化为少数几个综合指标。

其基本原理是把数据沿着方差最大的方向映射到维度更低的子空间上，新特征的坐标相互正交。如果原始数据是 d 维，新的子空间是 k 维 ($k \leq d$)，那么我们需要构建一个 $d \times k$ 维的转换矩阵 W。

构造转换矩阵的基本步骤是：首先对数据标准化，并构造样本的协方差矩阵，求协方差矩阵的特征值和特征向量，选择与前 k 个最大特征值对应的特征向量构建映射矩阵。

线性判别分析

线性判别分析 (linear discriminant analysis, LDA) 是一种监督的数据压缩方法。使用 PCA 降维时，PCA 可以把两个特征合并为一个，但 PCA 没有类别标签，如果这两个特征对于类别标签的

分类没有任何影响，那么我们完全可以把这两个特征去除。LDA 就是要从高维特征中抽取出与类别标签关系最密切的低维特征。

假设我们有两个类别标签，当原始数据是二维，想将二维降到一维，我们可以把数据投影到最佳向量 w 上，使得类别间的距离最大，每个类别内部点的离散程度最小。

（三）强化学习：获得最大化收益

强化学习

强化学习 (Reinforcement Learning) 是让计算机实现在特定的情况下，通过不断地尝试，从错误中学习，最后找到规律，找到可以获得最大回报的行为。强化学习有四个基本组件，包括输入：环境 (States)，动作 (Actions)，回报 (Rewards) 以及输出：方案 (Policy)。和监督学习不同，强化学习没有确定的标签，需要机器自己摸索，每一个动作对应一个奖赏，最后得到一个奖赏最大的方式进行数据处理。AlphaGo 就是一个强化学习的实例。强化学习的主要算法有：Sarsa, Q Learning, Policy Gradients, Actor-Critic, Deep-Q-Network 等。

强化学习的目标是发现最优策略 (x) ，使得达到最优价值 Q 。主要有两种途径可以学习最优值函数：一种是基于模型的学习，在学习的过程中对模型进行估计，如实时动态规划 (Real-Time Dynamic Programming, RTDP)；另一种是无模型学习，在学习的过程中直接估计最优行动值。

Q 学习算法是 Watkins 在 1987 年提出的一种无模型强化学习算法：它用状态 s 下采取行动的下一个状态 s' ，对假定的行动 s' 所对应的最大 Q' 值更新当前的 Q 值。

四、总结展望

人工智能，在金融领域已经开始逐步从探索走向应用，从金融大数据，到智能投顾、智能投研，在不断取得新的应用进展。依托于计算机和数据信息的发展，“AI+”的模式将给我们的投资研究带来更多的助益。未来将在“AI+”量化投资中探索更多的想法和应用。

中邮证券投资评级标准

股票投资评级标准：

- 推荐： 预计未来 6 个月内，股票涨幅高于沪深 300 指数 20% 以上；
- 谨慎推荐： 预计未来 6 个月内，股票涨幅高于沪深 300 指数 10%—20%；
- 中性： 预计未来 6 个月内，股票涨幅介于沪深 300 指数-10%—10% 之间；
- 回避： 预计未来 6 个月内，股票涨幅低于沪深 300 指数 10% 以上；

行业投资评级标准：

- 强于大市： 预计未来 6 个月内，行业指数涨幅高于沪深 300 指数 5% 以上；
- 中性： 预计未来 6 个月内，行业指数涨幅介于沪深 300 指数-5%—5% 之间；
- 弱于大市： 预计未来 6 个月内，行业指数涨幅低于沪深 300 指数 5% 以上；

可转债投资评级标准：

- 推荐： 预计未来 6 个月内，可转债涨幅高于中信标普可转债指数 10% 以上；
- 谨慎推荐： 预计未来 6 个月内，可转债涨幅高于中信标普可转债指数 5%—10%；
- 中性： 预计未来 6 个月内，可转债涨幅介于中信标普可转债指数-5%—5% 之间；
- 回避： 预计未来 6 个月内，可转债涨幅低于中信标普可转债指数 5% 以上；

分析师声明

撰写此报告的分析师（一人或多人）承诺本机构、本人以及财产利害关系人与所评价或推荐的证券无利害关系。

本报告所采用的数据均来自我们认为可靠的目前已公开的信息，并通过独立判断并得出结论，力求独立、客观、公平，报告结论不受本公司其他部门和人员以及证券发行人、上市公司、基金公司、证券资产管理公司、特定客户等利益相关方的干涉和影响，特此声明。

免责声明

中邮证券有限责任公司具备经中国证监会批准的开展证券投资咨询业务的业务资格。

本报告信息均来源于公开资料或者我们认为可靠的资料，我们力求但不保证这些信息的准确性和完整性。报告内容仅供参考，报告中的信息或所表达观点不构成所涉证券买卖的出价或询价，中邮证券有限责任公司不对因使用本报告的内容而引致的损失承担任何责任。客户不应以本报告取代其独立判断或仅根据本报告做出决策。

中邮证券有限责任公司可发出其它与本报告所载信息不一致及有不同结论的报告。报告所载资料、意见及推测仅反映研究人员于发出本报告当日的判断，可随时更改且不予通告。

中邮证券有限责任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，也可能为这些公司提供或者争取提供投资银行、财务顾问或者其他金融产品等相关服务。

《证券期货投资者适当性管理办法》于 2017 年 7 月 1 日起正式实施，本报告仅供本公司客户中的专业投资者使用，若您非本公司客户中的专业投资者，为控制投资风险，请取消接收、订阅或使用本报告中的任何信息。本公司不会因接收人收到、阅读或关注本报告中的内容而视其为客户。

本报告版权仅为中邮证券有限责任公司所有，未经书面许可，任何机构和个人不得以任何形式翻版、复制和发布。如引用发布，需注明出处为中邮证券有限责任公司研发部，且不得对本报告进行有悖原意的引用、删节和修改。

中邮证券有限责任公司对于本免责声明条款具有修改权和最终解释权。

公司简介

中邮证券有限责任公司，2002年9月经中国证券监督管理委员会批准设立，注册资本40.6亿元人民币。中邮证券是中国邮政集团公司绝对控股的证券类金融子公司。

中邮证券的经营经营范围包括证券经纪、证券投资咨询、证券投资基金销售、融资融券、代销金融产品、证券资产管理、证券承销与保荐、证券自营和与证券交易、证券投资活动有关的财务顾问等。中邮证券目前已经在北京、陕西、深圳、山东、江苏、四川、江西、湖北、湖南、福建、辽宁、吉林、黑龙江、广东、浙江、贵州、新疆、河南、山西等地设有分支机构。

中邮证券紧紧依托中国邮政集团公司雄厚的实力，坚持诚信经营，践行普惠服务，为社会大众提供全方位专业化的证券投、融资服务，帮助客户实现价值增长。中邮证券努力成为客户认同、社会尊重，股东满意，员工自豪的优秀企业。

业务简介

■ 证券经纪业务

公司经中国证监会批准，开展证券经纪业务。业务内容包括：证券的代理买卖；代理证券的还本付息、分红派息；证券代保管、鉴证；代理登记开户；

公司为投资者提供现场、自助终端、电话、互联网、手机等多种委托通道。公司开展网上交易业务已经中国证监会核准。

公司全面实行客户交易资金第三方存管。目前存管银行有：中国邮政储蓄银行、中国工商银行、中国农业银行、中国银行、中国建设银行、交通银行、民生银行、兴业银行、招商银行、北京银行、华夏银行。

■ 证券自营业务

公司经中国证监会批准，开展证券自营业务。使用自有资金和依法筹集的资金，以公司的名义开设证券账户买卖依法公开发行或中国证监会认可的其他有价证券的自营业务。自营业务内容包括权益类投资和固定收益类投资。

■ 证券投资咨询业务

公司经中国证监会批准开展证券投资咨询业务。为证券投资者或客户提供证券投资的相关信息、分析、预测或建议。

■ 证券投资基金销售业务：公司经中国证监会批准开展证券投资基金销售业务。代理发售各类基金产品，办理基金份额申购、赎回等业务。

■ 证券资产管理业务：公司经中国证监会批准开展证券资产管理业务。

■ 证券承销与保荐业务：公司经中国证监会批准开展证券承销与保荐业务。

■ 财务顾问业务：公司经中国证监会批准开展财务顾问业务。
