

基于生成对抗网络的高频算法及其回测研究

孟徐然¹, 毕秀春², 张曙光¹

(1. 中国科学技术大学管理学院, 安徽合肥 230026; 2. 贵州财经大学数学与统计学院, 贵州贵阳 550025)

摘要: 在金融工程的分类任务中, 由于金融数据噪音大、信息比率低的特点, 传统深度算法的有监督训练模式往往过于依赖数据本身的绝对标签从而进一步放大了噪音对最终结果的影响。生成对抗网络(generative adversarial network, GAN)能够利用深度网络挖取数据特征, 增强数据, 减少噪音影响, 应用于金融序列分析时效果优异。这里将GAN模型用于高频交易, 具体做法为: 将数据按波动性分为有标签数据与无标签数据两类, 利用生成网络G与判别网络D互相对抗训练来深度学习这些数据的内在特性, 训练好后的D网络根据有标签数据信息亦可对真实数据进行类别判别, 得到涨跌分类模型, 进而给出量化交易策略。基于期货主力合约数据进行了实证分析, 结果表明, 基于GAN训练下的LSTM模型显著优于有监督训练下的LSTM等深度模型和Logistics回归模型。

关键词: 深度学习; 生成对抗网络; 涨跌分类模型; 量化策略

中图分类号: F830.9 **文献标识码:** A doi: 10.3969/j.issn.0253-2778.2020.06.012

引用格式: 孟徐然, 毕秀春, 张曙光. 基于生成对抗网络的高频算法及其回测研究[J]. 中国科学技术大学学报, 2020, 50(6): 801-810.

MENG Xuran, BI Xiuchun, ZHANG Shuguang. High frequency algorithm and its back-testing results based on GAN[J]. Journal of University of Science and Technology of China, 2020, 50(6): 801-810.

High frequency algorithm and its back-testing results based on GAN

MENG Xuran¹, BI Xiuchun², ZHANG Shuguang¹

(1. School of Management, University of Science and Technology of China, Hefei 230026, China;

2. School of Mathematics and Statistics, Guizhou University of Finance and Economics, Guiyang 550025, China)

Abstract: In the financial classification mission, due to the big noise and low information-ratio in financial data, traditional supervised-learning regime may extend the noise influence because of the over dependent on the data label. GAN (generative adversarial network) can learn the data characters and reduce the influence of noise. When it is used to analyze the financial data, it has great results. We apply GAN to the high frequency trading: set the data labeled or unlabeled based on its volatility, then use the adversarial training between generative network G and discriminative network D to learn the intrinsic characters of the data, finally use the well trained D to get the up and down classification model and the quantization strategy. The sample is based on the future data, and the final results show that the LSTM model training by GAN is better than the deep learning models such as LSTM with supervised training and the Logistic regression model.

Key words: deep learning; generative adversarial network; up and down classification model; quantization strategy

0 引言

随着计算机科学技术的发展, 量化投资逐渐兴起。量化投资策略指的是通过一定方法形成的程序化交易策略。这类程序, 一般先是对历史数据进行分析, 再利用统计方法建立相应交易模型, 例如 Logistic 回归^[1], 最终在模型通过回测之后根据模型编译而成。由于计算机程序化模型策略的高效性特点, 高频交易这一交易领域也受到了前所未有的发展。高频交易, 顾名思义指的是高频率地开仓和

平仓交易, 这样的交易主要利用 tick 或分钟级别的数据, 寻找细微的价格偏差, 捕捉交易机会。这种高频交易, 能够增加市场的流动性, 提高市场效率, 对市场起到了促进作用^[2-4]。

同时, 随着计算机硬件水平的提高, 计算机算力得到了极大发展。Hinton 等提出了深度学习概念^[5]。深度学习指的是利用复杂神经网络来模拟人脑分析问题, 往往需要极大的计算机算力。目前主流的神经网络有全连接网络 (multi-layer perceptron, MLP)、卷积神经网络 (convolutional

收稿日期: 2020-03-06; 修回日期: 2020-06-21

基金项目: 国家自然科学基金(11471304), 贵州财经大学科研项目(2020YJ021, 2020YJ026)资助。

作者简介: 孟徐然, 男, 1997年生, 硕士。研究方向: 量化金融。E-mail: mmxxrr@mail.usct.edu.cn

通讯作者: 毕秀春, 博士/副教授。E-mail: xcbi@ustc.edu.cn

neural network, CNN)、循环神经网络(recycle neural network, RNN, 包括 LSTM)等^[6]. 这些深度模型相比传统的统计模型, 不仅能通过非线性函数来提取深层次的数据特征, 而且可适用于半监督学习或无监督学习, 有着更广的应用范围, 例如空间数据中 CNN 的人脸识别^[7]、视频分类^[8]以及时序数据中 LSTM 的机器翻译^[9]、语音识别^[10]等, 这些例子都是深度模型的成功应用. 这些深度模型以及应用的不断丰富, 也使得人们产生了不单单利用数据训练网络, 而是令网络互相训练的想法, 最著名的是由 Goodfellow 等^[11]提出的生成对抗网络(generative adversarial nets, GAN), GAN 主要由生成网络 G 和判别网络 D 组成, 其思想是令两网络博弈从而达到纳什均衡. 但是, 最初始的 GAN 网络存在着训练不稳定、模式崩溃、任务单一等问题, 这也促进了后继许多优秀的新的 GAN 构架的诞生, 例如 DCGAN, LRGAN, MGAN 等^[12-14].

深度学习的不断发展对量化交易策略产生了巨大影响. 传统的统计时序模型, 例如 ARMA 和 ARIMA, 只关注于收盘价本身的数据特征, 在单一数据特征上建立模型, 具有一定的局限性, 而深度模型对于样本数据的特性不具有限制性, 例如深度学习可以对高维数据进行建模分析, 这是 ARIMA 所不具有的. 这种特点让越来越多的学者开始尝试用深度模型代替传统的统计模型, 建立量化策略. Persio 等^[15]将 MLP, CNN 等模型运用于标普 500 的价格变动预测之中, 并提出一种基于小波与 CNN 结合的新型策略. 龙奥明等^[16]利用 LSTM 神经网络构建了黑色金属期货套利策略, 实证表明 LSTM 神经网络的效果在金属期货数据上要优于 CNN 与 MLP 神经网络. 杨青等^[17]对全球股票指数预测进行了研究, 展示了 LSTM 神经网络相对于 MLP 以及传统统计模型 ARIMA 的优越性. 孙达昌等^[18]利用深度学习中的各种神经网络, 对沥青期货的 tick 级高频数据进行了研究, 比较展示了 LSTM 网络的优越性. Sai 等^[19]将 LSTM 模型与 SVM 模型进行了深度的对比研究, 发现了基于 LSTM 的深度模型在预测时 MSE, RMSE 等指标的优越性, Dev 等^[20]将 LSTM 神经网络与 DNN 深度神经网络进行了预测对比分析, 发现了 LSTM 相对于 DNN 的预测优越性. 研究发现, 在时序性较强的金融数据中, 深度模型尤其是 LSTM 神经网络相较于传统统计模型能更有效地抓住时序信息, 展现强大预测能力. 针对 LSTM 模型本身, Arvand 等^[21]也给出了对于 LSTM 模型自身的结构优化, 并给出了相应的不同优化器下的预测结果, 具有极大的参考意义.

由于金融数据存在着延时、噪音大、信息比率低等特点, 如何利用金融数据训练深度模型尤其是高频交易模型, 是学术界和业界共同关注的焦点问题. 杨青等^[17]在进行全球指数预测时, 主要通过添加技术指标, 如最低价、最高价等, 来丰富样本信息, 从而提高准确率. 在高频交易策略中, 孙达昌等^[17]对数据进行了进一步处理, 不仅添加各种技术指标来丰富样本信息, 而且对于金融数据的缺陷,

有针对性地选取了显著性涨跌幅数据来作为训练样本进一步提高预测精度. 这种做法有一定的可取性, 因为对于高频策略来说, 需要瞬时抓住较大的价格波动进行盈利, 故在进行训练时, 价格波动较大的样本显得尤为重要. 在训练模型时, 我们同样给予波动高的样本显著性标签, 但对于低波动的样本, 由于数据噪音大、信息比率低等特点, 若给予显著性标签, 则会加重模型的不确定性, 影响最终的高频策略. 面对这种仅有一部分标签数据的问题, 本文尝试采取半监督分类方法. 半监督分类指的是通过对少部分具有标签的数据与大部分无标签的数据的学习, 理解数据分类规则, 进行分类. 该方法能够在一定程度上自己抓取数据特征, 减少数据的绝对标签对深度模型的影响, 从而优化高频策略.

目前, 人们对于半监督分类方法的研究主要有对抗生成网络(GAN)、自训练算法(self-training)、联合算法(co-training)、半监督支持向量机(SVMs)与图论方法^[22-23]. 本文主要基于 Goodfellow 等提出的改进型 GAN 网络框架^[12], 这种改进型算法相较于传统的 GAN 网络, 稳定性得到了很大的提升. 在改进型 GAN 网络中, 我们将判别网络 D 设置成 LSTM 神经网络, 利用生成网络 G 与判别网络 D 进行相互训练, 构建期货的涨跌分类模型, 并以其主力合约作为样本进行回测. 回测结果表明, 基于 GAN 的半监督训练对交易信号具有显著的优化作用. 同时将这种方法对比已有的深度模型方法(LSTM, CNN)以及传统的统计量化方法(Logistic 回归), 实证发现基于 GAN 训练的模型在进行高频回测时要优于上述方法.

1 方法与模型搭建

1.1 基于主流神经网络的模型设计

主流的深度学习模型包含全连接神经网络(MLP)、卷积神经网络(CNN)与循环神经网络(RNN). 我们使用上述深度模型进行模型构建.

对于 MLP 网络, 本文使用经典的三层神经网络, 分别是输入特征、三层隐藏层以及输出特征. 输入特征在经过前两层隐藏层后, 采用 ReLU 函数作为激活函数, 第三层不采用激活函数, 隐藏层神经元个数是 1024, 从隐藏层到输出层, 采用 Sigmoid 函数作为激活函数, 输出层个数为 240(最后转化为 20×12 的数据阵与样本一致).

对于 CNN 网络, 本文使用 BP 优化参数结构. 网络由三层卷积层以及一层全连接组成, 每层卷积层按顺序包含卷积池化以及 dropout 部分. 当 CNN 网络作为 GAN 的生成网络时, 首先将输入层 100 个服从 $U(0, 1)$ 分布的随机噪音转为 10×10 的随机矩阵, 经过卷积层后, 维度演变过程为

$$10 \times 10 \times 1 \rightarrow 5 \times 5 \times 32 \rightarrow 4 \times 4 \times 128 \rightarrow 2 \times 2 \times 256.$$

将拉直后的数据加上一层全连接网络, 经过处理后变为 20×12 的输出特征, 激活函数选择 Sigmoid. 当 CNN 用于有监督判别时, 此时输入层为 20×12 的数据阵, 经过卷积后的演变过程为

$$20 \times 12 \times 1 \rightarrow 10 \times 6 \times 32 \rightarrow 5 \times 5 \times 128 \rightarrow 3 \times 3 \times 256.$$

经过全连接层后将输出维度设置为 3 维, 激活函数

设置为 Softmax, 对应上涨下跌与涨跌不明显三类.

本文使用基于 RNN 改进的门控神经网络 LSTM, 如图 1 所示, 输入特征经过的 LSTM 层包括 2 个 LSTM Cell 以及相应的 dropout 层, 经过拉直处理连入全连接层, 全连接层个数为 1024, 激活函数选择 ReLU 函数, 再从全连接层经过 Softmax 处理后, 变为一个三维的输出特征. 这也是金融数据研究中常用的方法^[17-21].




图 1 LSTM 模型
Fig.1 LSTM model

1.2 GAN 的构建

Goodfellow 等提出的 GAN^[11] 主要由生成网络 G 与判别网络 D 组成. 在最初的 GAN 中, 生成网络 G 的目的是抓取数据分布特征, 从而生成与真实数据分布相同的虚拟数据; 判别网络 D 用来判别一个数据是样本而不是 G 生成的概率. 这是一个二者博弈问题, G 的目标在于最大化 D 犯错的概率, 而 D 则尽可能减小判别错误概率.

针对半监督任务中的分类问题, 本文主要基于 Goodfellow 等的 GAN 改进算法^[12] 进行研究, 构建的 GAN 网络结构如图 2 所示.




图 2 本文 GAN 结构
Fig.2 GAN's structure

GAN 网络结构: 设置 LSTM 神经网络判为判别网络 D, 将数据分为 k 类, 与监督学习分成 k 类最小化交叉熵不同, 我们将判别器分为 k+1 类, 多出来的一类用以判别是否是 G 网络所生成. 这样在进行训练时, G 网络亦可对 D 网络进行训练. 而对于生成网络 G, 我们设置为上文描述的 MLP 或 CNN 神经网络, 其基于随机噪声 z 产生虚拟数据 G(z), 然后虚拟数据会与真实数据一同输入进 D 网络中用以训练 D 网络, 而 G 网络生成的数据进入 D 网络后的判别结果又会再次反馈到 G 网络之中用以指导 G 网络生成相似虚拟数据. 本文设定的 k 值为 2.

损失函数: 确定 GAN 网络结构以后, 需要分别说明 G 网络与 D 网络的损失函数. D 网络的损失分为监督学习损失与无监督学习损失. 即

$$L_D = L_{\text{supervised}} + L_{\text{unsupervised}} \quad (1)$$

其中,

$$\left. \begin{aligned} L_{\text{supervised}} &= -E_{x,y \sim p_{\text{data}}(x,y)} \log p_{\text{model}}(y | x, y < k + 1), \\ L_{\text{unsupervised}} &= -\{E_{x \sim p_{\text{data}}(x)} \log[1 - p_{\text{model}}(y = k + 1 | x)] + E_{x \sim G} \log p_{\text{model}}(y = k + 1 | x)\} \end{aligned} \right\} \quad (2)$$

令 $D(x) = 1 - p_{\text{model}}(y = k + 1 | x)$, 表示是真实数据的概率, 则有

$$L_{\text{unsupervised}} = -\{E_{x \sim p_{\text{data}}(x)} \log[D(x)] + E_{z \sim \text{noise}} \log[1 - D(G(z))]\},$$

恰为初始 GAN 网络中 D 的损失函数^[11].

对于 G 网络损失函数, 并没有特定的表达式, 文献^[12]仅给出了一些经验上的指导, 我们选择最小化 GAN-value + feature matching, 这里,

$$\text{GAN-value} = E_{z \sim \text{noise}} \log[1 - D(G(z))],$$

$$\text{feature matching} = \lambda \sum (T_i - F_i)^2,$$

其中, λ 是调控参数, 设为 0.01, T_i, F_i 分别为真实数据与虚拟数据输入到判别网络 D 中的对应神经节点数值, i 对应着 D 中每一个神经节点. feature matching 的主要作用是将 D 网络中的信息作为指导反馈到 G 网络之中, 对 G 网络训练进行指导从而形成互相的对抗.

1.3 训练方法与优化器选择

本文采用 mini-batch 方法训练传统的 LSTM 模型与 GAN 模型, 对比研究他们在高频回测中的表现. 对于传统 LSTM 神经网络, 采取交叉熵作为其损失函数进行有监督训练, 可将数据分为上涨、下跌以及涨跌不明显三类. 而对于 GAN 网络, 设置结构相同的 LSTM 网络作为判别网络 D, 唯一不同点为 output 第三个维度设置表示判别虚拟数据概率. 我们用上述 MLP 或 CNN 网络作为 GAN 网络的生成网络 G, 与 LSTM 互相训练. 训练方法如下:

第一步, 进行有监督训练. 用半监督参数 fl 表示一个 epoch (即一个循环) 内有监督训练的次数, 在训练次数小于 fl 时, D 网络中所有输入数据均为带标签数据, 此时以训练 D 为主, 但同样给了 G 网络一定的训练指导. 每一次训练首先优化 D 网络损失函数 $L_{\text{supervised}}$, 然后优化 G 网络损失函数.

第二步, 在同样的 epoch 中, 当训练次数大于 fl 时, 进行无监督对抗训练, 此时 D 的训练数据分为真实数据以及一部分由 G 生成的数据, 在训练过程中, 每次训练首先优化 D 网络损失函数 $L_{\text{unsupervised}}$, 然后优化 G 网络损失函数. 这样由 G 网络进行数据特征挖掘并由 D 网络进行判别, 从而达到网络互相训练, 进行数据分类的目标.

第三步, 不断重复上述两步进行模型训练, 得到最终用以进行涨跌分类判别的 D 网络.

可以看到, 半监督参数 fl 为 GAN 中一个十分重要的参数. 若将一个 epoch 内的训练次数设置为 200, 当 fl=0 时, LSTM 不会有任何的涨跌分类能力, 而当 fl=200 时, 由于均是有标签数据, 半监督过程实际上完全变成了有监督过程. 在优化器选取方面, 本文采取 Kingma 和 Ba^[24] 在 2015 年提出的 Adam 优化器 (Adaptive Moment Estimation, 自适应矩估计) 进行优化训练. 相较于传统的各种优化器, Adam 优化器收敛速度更快, 学习效果更为有效. 在编程语言方面, 本文基于 Python 语言环境,

用 tensorflow 作为深度学习框架进行训练及回测。

2 实证检验

本文以 1 min 级别的期货主力合约为本构建高频策略. 主要流程如图 3 所示, 左连线两步骤均为数据预处理步骤, 在数据预处理后, 利用深度模型学习数据特征, 根据模型建立相应的交易策略, 进行回测分析。

2.1 样本构建及预处理

1 min 级别数据指的是 1 min 一条的数据流快照. 本文主要基于螺纹钢、上证 50 与中证 500 主力合约的 1min 级别行情数据作为实证检验数据, 数据可从 Tbquant 上下载得到. 每条行情数据都是一维向量, 包括开盘价、收盘价、成交量等, 样例如表 1 所示. 选取期货主力合约可以很好地解决期货的非连续性问题^[18]. 同时, 为了提高模型的精度与准确

率, 也为了降低样本内数据的共线性等问题, 我们在原始数据中添加技术特征来丰富信息, 例如 MA 线, KDJ 指标等, 同样也删去一些指标例如开盘价等, 技术因子如表 2 所示。



图 3 交易模型流程图
Fig. 3 Flow chart of trading model

表 1 行情样本数据
Tab. 1 Samples of market data

	time	open	high	low	close	volume	hold
螺纹钢	2018-3-8 9:10	3866	3866	3862	3862	10890	3418372
	2018-3-8 9:11	3861	3862	3857	3857	33320	3418872
	2018-3-8 9:12	3857	3857	3850	3852	49622	3413492
	2018-3-8 9:13	3851	3854	3851	3851	26118	3407068
	2018-3-8 9:14	3852	3852	3847	3848	34348	3407060
	2018-3-8 9:15	3849	3853	3848	3852	22344	3405150
...						
上证 50	2018-1-3 9:30	2925.8	2929.4	2924.4	2926	109	21103
	2018-1-3 9:31	2926.4	2929.2	2926	2929.2	136	21003
	2018-1-3 9:32	2929.6	2931	2928.6	2931	122	20930
	2018-1-3 9:33	2930	2931	2927.8	2927.8	126	20851
	2018-1-3 9:34	2928.2	2929	2926.8	2928.8	123	20797
	2018-1-3 9:35	2928.4	2928.4	2926.6	2927	87	20760
...						
中证 500	2019-3-7 10:10	5427	5427.2	5415.2	5419	335	48841
	2019-3-7 10:11	5419.2	5422.8	5411.6	5413.6	299	48804
	2019-3-7 10:12	5414	5422.2	5414	5422	203	48777
	2019-3-7 10:13	5421.2	5423	5414.2	5416.8	195	48754
	2019-3-7 10:14	5416.4	5434.6	5416.6	5426.2	201	48720
	2019-3-7 10:15	5426	5435	5420	5435	182	48691

表 2 技术指标与特征
Tab. 2 Technical indicators and features

技术指标	特征个数	技术指标	特征个数
收盘价	1	价格涨速	1
成交量	1	成交量涨速	1
总量	1	STD	1
成交量 MA20	1	收盘价 MA20	1
KDJ	4		

表 2 中, MA(moving average) 表示移动平均, 指的是一定时间节点的价格或者成交量的平均值, 例如收盘价 MA20 表示的是从当前时刻开始直到 20 min 前的所有以分钟为结点的 20 个收盘价的平

均值. 成交量和价格涨速分别指的是当前成交量和价格与上一时间节点的比值. STD 为前 20 个时间节点收盘价的标准差. KDJ 又称为随机指标, 包含 RSV_t, K_t, D_t 和 J_t 四个指标. 在这样的分钟级别的数据中,

$$RSV_t = (Close_t - Low_t) / (High_t - Low_t),$$

$$K_t = SMA(RSV_t, m_1, 1),$$

$$D_t = SMA(K_t, m_2, 1), J_t = 3 \times K_t - 2 \times D_t,$$

这里 SMA 为简单滑动平均, 参数 m_1 和 m_2 均设置为 3.

在建立相应的技术指标后, 为了通过价格浮动获取价差收益, 需要给出与数据对应的上涨或下跌

标签构建涨跌分类模型. 将 1 min 后上涨或下跌超过一定幅度的数据给予上涨类或下跌类标签, 对于涨跌不明显的样本数据, 有监督训练时给予其涨跌不明显的标签, 而在半监督训练时, 我们认为标签不够精确, 不给予标签信息, 而是通过半监督对抗训练深度分析数据. 由于期货波动性差异, 在不同期货品种上设置标签时的标准不同. 对于螺纹钢期货, 当收盘价在下一分钟上涨或下跌超过 1.5% 时给予上涨类别或下跌类别标签, 而对于上证 50 与中证 500, 当收盘价在下一分钟上涨或下跌超过 1% 时给予上涨类别或下跌类别标签.

训练时, 对于每一个时间节点, 选择其前 20 min 的所有数据作为训练样本, 得到 20×12 的矩阵数据, 对应的标签为该时间节点的标签. 如表 1 所示, 数据量纲存在数量级差异, 故对其进行归一化处理, 这种处理方式在解决量纲问题的同时也保留了数据一定的时序信息. 归一化处理公式为

$$v_{ij} = (x_{ij} - \min_j) / (\max_j - \min_j).$$

式中, x_{ij} 为样本矩阵中 i 行 j 列的元素, \max_j 与 \min_j 分别为数据阵第 j 列的最大与最小值. 经过预处理后, 样本所有值都在 $[0, 1]$ 内, 我们选择这样处理后的前 20 min 所有数据构成样本矩阵 (v_{ij}) .

2.2 构建交易策略

在训练有一定能力进行涨跌判别的模型后, 模型进行涨跌预测时, 会输出预测为某一类的概率, 这样的输出概率即可作为交易信号的参考. 本文的策略如下: ①为保持策略稳定性, 设置阈值 $\alpha > \frac{1}{2}$.

在回测区间的任意 1 min 级时间节点, 若模型上涨下跌概率均小于 α , 则使自己成为空仓. ②若模型处于上涨类概率大于 α , 有多仓则继续持有, 否则清仓并建立多仓. ③相反的若模型处于下跌概率大于 α , 有空仓则继续持有, 否则清仓并建立空仓. 对于不同的模型, 由于 α 对策略的收益影响较大^[18], 我们在保证适当交易频率的前提下寻求具有最优收益的 α^* .

回测时, 用训练好的模型处理归一化后的测试集样本. 通过上海期货交易所信息, 得到手续费率 s . 当交易发生时, 做多收益率计算公式为

$$P_2 \times \text{Vol} - P_1 \times \text{Vol} - P_1 \times \text{Vol} \times s - P_2 \times \text{Vol} \times s \over P_1 \times \text{Vol} \tag{3}$$

做空收益率公式为

$$P_1 \times \text{Vol} - P_2 \times \text{Vol} - P_1 \times \text{Vol} \times s - P_2 \times \text{Vol} \times s \over P_1 \times \text{Vol} \tag{4}$$

式中, P_1, P_2 分别为开仓与平仓价格, Vol 为成交量, s 为手续费率.

回测中计算的胜率 p_w 为盈利次数占总交易次数的比例, 平均盈利(亏损)指所有盈利(亏损)交易中收益率的平均值, 期望收益

$$ER = p_w \times W + (1 - p_w) \times L,$$

其中 W 与 L 分别为平均盈利和亏损.

2.3 模型训练及回测分析

训练过程中, 将 1 个 epoch 设置为 200 次训练, 并在这 200 次训练中分为有监督训练与无监督训练. 参数 fl 为首先进行的有监督训练的次数. 对 fl 进行调节, 并对每个 fl 值按照节 1.3 设置, 训练 epoch 多次至模型稳定, 分别得到不同 fl 值下对应的涨跌分类模型. 基于训练的模型, 我们进行模拟交易与回测分析. 对于每一个模型尝试不同的 α , 在保证策略适当交易次数的情况下选择具有相对较优收益的 α 进行回测分析. α 取值于集合 $\{0.6, 0.65, 0.7, 0.75, 0.8, 0.85, 0.9, 0.95, 0.995\}$.

在进行回测分析时, 将基于 GAN 的 LSTM 与有监督 LSTM 进行对比, 同时为了对 LSTM 模型本身进行考察, 将模型对比已有的深度学习模型 CNN 以及传统的统计量化模型 Logistic 回归, 得到相应的回测结果.




图 4 RB 走势

Fig. 4 The trend of RB

2.3.1 螺纹钢期货

观察黑色金属板块中的螺纹钢期货(市场代码:RB). 对于螺纹钢期货, 从其期货主力合约中选取 2017-10-20 到 2019-10-18 的数据, 共 165685 条. 将 2019-04-19 之前的 124399 条数据作为训练样本, 其余的 41286 条数据作为测试样本. 观察图 4 中螺纹钢期货的价格走势, 可以发现期货主力合约价格波动十分明显, 存在一定高频套利空间. 设置手续费率 $s = 0.15\%$.

表 3 与表 4 给出参数 fl 不同值(即有监督与无监督部分呈现不同数量)的情形下螺纹钢期货的回测结果, 对于有监督情形有回测结果如表 5 所示. 在螺纹钢期货中, 用 GAN 网络进行半监督训练时, 交易与半监督参数 fl 亦十分相关. 调整 α 给出模型相对较优的交易信号进行比较, 发现利用 GAN 进行半监督训练 LSTM 的时候, LSTM 模型能够产生非常优质的交易信号, 不仅有着较高的胜率, 还有着不错的收益, 然而随着 fl 的不断变大, 相同 α 情形下策略的交易次数不断变大, 金融数据的不稳定性以及高昂的手续费用会使得策略盈利能力下降. 对于每一个 fl , 我们选择具有最优胜率以及期望收益的 α^* . 同时我们发现, 随着 fl 的不断变大, 最优 α^* 下策略的胜率和期望收益开始降低, 胜率从 0.63 到 0.58 下降了 0.05, 期望收益也逐渐从盈利转向亏损.

比较不同 fl 下策略的预测以及盈利能力, 如图

5,6 所示: 当 fl 逐渐变大到 30 左右时, 策略逐渐接近于有监督训练下 LSTM 模型的表现, 从胜率到期望收益均体现出了这样一种接近趋势。

望收益均体现出了这样一种接近趋势。

表 3 RB 中 GAN(MLP+LSTM)回测

Tab. 3 Backtest of GAN(MLP+LSTM) in RB

fl(螺纹钢)	α^*	交易次数	胜利次数	胜率	平均盈利	平均亏损	期望收益
10	0.6	472	299	0.633	0.5147‰	-0.7602‰	0.0468‰
15	0.65	617	383	0.621	0.5117‰	-0.7644‰	0.0281‰
20	0.8	1132	695	0.614	0.5036‰	-0.7775‰	0.0091‰
30	0.95	974	581	0.597	0.5033‰	-0.7718‰	-0.0106‰
60	0.995	803	467	0.582	0.4977‰	-0.7739‰	-0.0338‰
100	0.995	952	551	0.579	0.5014‰	-0.7693‰	-0.0336‰
200	0.995	1067	623	0.584	0.4960‰	-0.7673‰	-0.0295‰

表 4 RB 中 GAN(CNN+LSTM)回测

Tab. 4 Backtest of GAN(CNN+LSTM) in RB

fl(螺纹钢)	α^*	交易次数	胜利次数	胜率	平均盈利	平均亏损	期望收益
10	0.6	619	388	0.627	0.5162‰	-0.7547‰	0.0422‰
15	0.65	579	348	0.601	0.5135‰	-0.7609‰	0.0051‰
20	0.85	1021	609	0.596	0.5060‰	-0.7643‰	-0.0072‰
30	0.95	796	467	0.587	0.5003‰	-0.7630‰	-0.0214‰
60	0.995	868	502	0.578	0.4963‰	-0.7684‰	-0.0374‰
100	0.995	1047	611	0.584	0.4987‰	-0.7705‰	-0.0293‰
200	0.995	1263	734	0.581	0.5016‰	-0.7621‰	-0.0279‰

对策略进行整体考量, Logistic 回归与 CNN 作为 benchmark 进行与 LSTM 的比较, 进行训练和分析 benchmark 后, 发现在螺纹钢期货中, benchmark 表现亦不理想, 胜率与期望收益均低于有监督 LSTM, 而基于 GAN 训练下的 LSTM 表现均优于有监督 LSTM 神经网络, 这也展现了 GAN 网络训练思想的优越性。

2.3.2 上证 50 期货

观察股指期货中的上证 50 期货(市场代码:

IH)。从上证 50 期货主力合约中选取的 2017-10-9 到 2019-10-31 共 120702 条数据中, 将 2019-05-24 之前的 95021 条数据作为训练样本, 其余的 25681 条数据作为测试样本。观察图 7 中上证 50 期货的价格走势, 可以发现期货主力合约价格同样具有一定的波动性, 存在高频套利空间。此处, 手续费率 s 设置为 0.05‰。

表 6,7 给出上证 50 期货在不同 fl 时的回测结果, 表 8 给出了有监督情形下策略的回测结果。

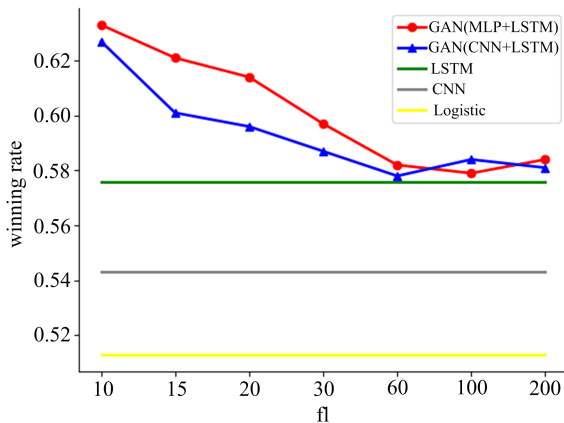


图 5 RB 中策略胜率

Fig. 5 Winning rate of strategies in RB

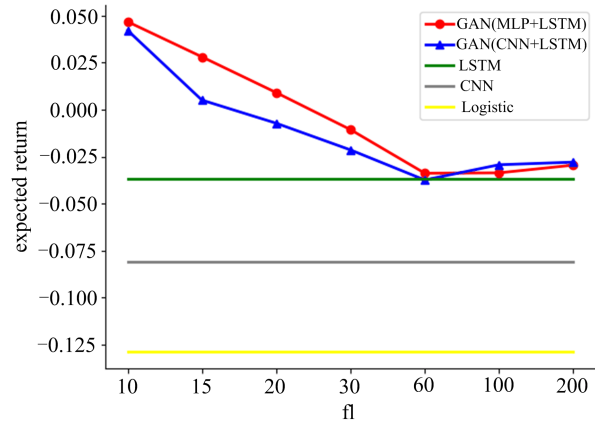


图 6 RB 中策略期望回报

Fig. 6 Expected return of strategies in RB

表 5 RB 中有监督训练模式回测

Tab. 5 Backtest of supervised learning regime in RB

模型(螺纹钢)	α^*	交易次数	胜利次数	胜率	平均盈利	平均亏损	期望收益
LSTM	0.995	1167	672	0.576	0.4970‰	-0.7619‰	-0.0368‰
CNN	0.995	1349	733	0.543	0.4987‰	-0.7693‰	-0.0808‰
Logistic	0.95	1279	656	0.513	0.4631‰	-0.7519‰	-0.1286‰

表 6 IH 中 GAN(MLP+LSTM)回测
Tab. 6 Backtest of GAN(MLP+LSTM) in IH

f1(上证)	α^*	交易次数	胜利次数	胜率	平均盈利	平均亏损	期望收益
10	0.6	644	395	0.613	0.3511‰	-0.4465‰	0.0424‰
15	0.7	516	317	0.604	0.3469‰	-0.4420‰	0.0345‰
20	0.75	722	425	0.589	0.3501‰	-0.4533‰	0.0199‰
30	0.85	1304	743	0.570	0.3474‰	-0.4494‰	0.0048‰
40	0.95	627	344	0.549	0.3523‰	-0.4560‰	-0.0122‰
60	0.95	1105	596	0.539	0.3484‰	-0.4601‰	-0.0243‰
100	0.95	1313	705	0.537	0.3466‰	-0.4572‰	-0.0256‰
200	0.95	1453	784	0.540	0.3490‰	-0.4587‰	-0.0225‰

表 7 IH 中 GAN(CNN+LSTM)回测
Tab. 7 Backtest of GAN(CNN+LSTM) in IH

f1(上证 50)	α^*	交易次数	胜利次数	胜率	平均盈利	平均亏损	期望收益
10	0.6	451	283	0.627	0.3577‰	-0.4503‰	0.0563‰
15	0.7	560	339	0.605	0.3516‰	-0.4429‰	0.0378‰
20	0.8	1262	744	0.590	0.3480‰	-0.4506‰	0.0206‰
30	0.85	1138	656	0.576	0.3439‰	-0.4523‰	0.0063‰
40	0.9	964	533	0.553	0.3495‰	-0.4514‰	-0.0085‰
60	0.95	1033	559	0.541	0.3432‰	-0.4520‰	-0.0218‰
100	0.95	1258	677	0.538	0.3458‰	-0.4549‰	-0.0241‰
200	0.95	1521	815	0.536	0.3477‰	-0.4540‰	-0.0243‰

表 8 IH 中有监督训练模式回测
Tab. 8 Backtest of supervised learning regime in IH

模型(上证 50)	α^*	交易次数	胜利次数	胜率	平均盈利	平均亏损	期望收益
LSTM	0.95	1464	786	0.537	0.3490‰	-0.4565‰	-0.0239‰
CNN	0.95	1847	935	0.506	0.3442‰	-0.4613‰	-0.0537‰
Logistic	0.95	793	382	0.482	0.3204‰	-0.4521‰	-0.0798‰

如表 6,7 所示,基于 GAN 网络训练的 LSTM 模型,在利用 α 寻找到较优的量化信号后,具有一定的预测涨跌能力,当 f1 较小时,基于 GAN 训练的 LSTM 的交易胜率依然达到了 60%,而收益亦有部分跑赢了手续费,产生了盈利.随着 f1 逐渐变大,我们亦可以发现,GAN 网络所筛选出来的交易信号呈现出逐渐下降的趋势.




图 7 IH 走势
Fig. 7 The trend of IH

观察图 8,9,对比螺纹钢期货可以发现,在上证 50 期货中,当 f1 逐渐上升的时候,同样呈现出预测胜率与交易信号的质量逐渐降低的情形.在图中随着 f1 的增加,当 f1 接近 40 左右的时候,对抗过程亦逐渐趋向于有监督训练,导致交易次数与交易信号

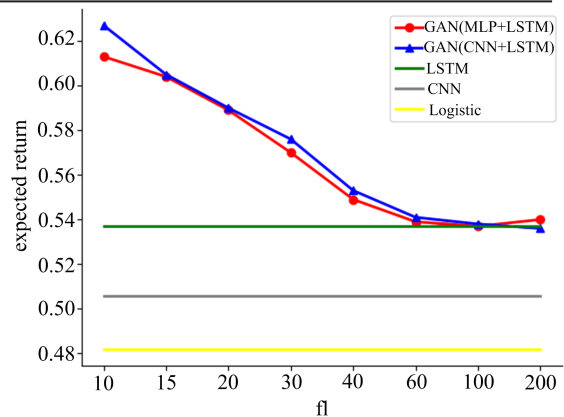


图 8 IH 中策略胜率
Fig. 8 Winning rate of strategies in IH

质量也逐渐接近有监督训练.这种随着 f1 增加,交易信号质量不断降低的情形在螺纹钢与上证 50 期货中都是成立的.

同样将策略与 benchmark 比较,在上证 50 期货数据中,LSTM 模型所得到的回测结果相对 benchmark 是较好的,而基于 GAN 网络框架训练出的 LSTM 模型在胜率以及期望收益等方面,均较之前的模型有较大的提升,体现了半监督方法在金融分析中的优势.

2.3.3 中证 500 期货

最后观察股指期货板块中的中证 500 期货(市




图 9 IH 中策略期望回报

Fig. 9 Expected return of strategies in IH

场代码: IC). 从 IC888 期货主力合约中选取 2017-10-9 到 2019-10-21 共 118987 条数据, 并将 2019-03-07 之前的 82746 条数据作为训练样本, 其余的 36241 条数据作为测试样本. 图 10 为期货的价格走势, 其较大的波动性同样给予策略一定套利空间. 与上证 50 一致, 设置手续费率 $s = 0.05\%$.

表 9~11 与图 11~12 给出了相应的回测结果.

观察中证 500 的回测结果, 如表 9, 10 所示. 在中证 500 中 fl 等于 20 的时候, 以 MLP 和 CNN 为生成网络的 GAN 网络在预测胜率上均达到了 60%. 调控 α 给出各模型下产生的较优的交易信号并进行比较, 发现 fl 较小时均能有一定的胜率与收益保障. 当 fl 逐渐变大时, 在中证 500 期货中, 与前

面一致, 胜率与期望收益开始逐渐降低. 随着 fl 的增加, GAN 网络筛选出的交易信号的胜率逐渐从 0.6 左右下降到 0.54, 期望收益也逐渐接近有监督情形. 观察图 11, 12, 在中证 500 中, 半监督参数 fl 接近于 60 的时候, GAN 网络的表现便逐渐接近于有监督的 LSTM 神经网络, 这种接近是全方位的, 从交易次数到胜率再到期望收益, GAN 网络均逐渐接近于了有监督训练下的 LSTM 神经网络.

对比策略与 benchmark 的情形, 发现基于 Logistic 回归与 CNN 的策略相较有监督情形下 LSTM 的策略并未有较大降低, 联系前面三种情形, 有监督训练 LSTM 模型实际在一定程度上确实存在着受噪音影响和过拟合等问题. 而基于 GAN 训练的 LSTM 模型通过调整半监督参数, 能够在一定程度上优化 LSTM 模型对于数据的分析, 体现了半监督训练模式的优越性.




图 10 IC 走势

Fig. 10 The trend of IC

表 9 IC 中 GAN(MLP+LSTM)回测

Tab. 9 Backtest of GAN(MLP+LSTM) in IC

fl(中证 500)	α^*	交易次数	胜利次数	胜率	平均盈利	平均亏损	期望收益
20	0.65	523	319	0.610	0.6104%	-0.7874%	0.0623%
25	0.7	647	381	0.589	0.6059%	-0.7905%	0.0320%
30	0.75	874	498	0.570	0.5994%	-0.7913%	0.0014%
40	0.8	1432	808	0.564	0.5920%	-0.8015%	-0.0156%
60	0.95	928	511	0.551	0.5879%	-0.7916%	-0.0315%
100	0.95	1594	859	0.539	0.5891%	-0.8021%	-0.0522%
150	0.95	1793	961	0.536	0.5872%	-0.7962%	-0.0547%
200	0.95	1962	1054	0.537	0.5885%	-0.7940%	-0.0516%

表 10 IC 中 GAN(CNN+LSTM)回测

Tab. 10 Backtest of GAN(CNN+LSTM) in IC

fl(中证 500)	α^*	交易次数	胜利次数	胜率	平均盈利	平均亏损	期望收益
20	0.6	492	302	0.614	0.6011%	-0.7928%	0.0631%
25	0.65	533	317	0.595	0.5962%	-0.7965%	0.0322%
30	0.75	712	411	0.577	0.5934%	-0.8031%	0.0027%
40	0.85	1272	716	0.563	0.5967%	-0.7959%	-0.0119%
60	0.95	892	483	0.541	0.5890%	-0.7983%	-0.0478%
100	0.95	1369	732	0.535	0.5842%	-0.8004%	-0.0596%
150	0.95	1874	1010	0.539	0.5905%	-0.7977%	-0.0495%
200	0.95	2038	1092	0.536	0.5829%	-0.7936%	-0.0558%

表 11 IC 中有监督训练模式回测
Tab. 11 Backtest of supervised learning regime in IC

模型(中证 500)	α^*	交易次数	胜利次数	胜率	平均盈利	平均亏损	期望收益
LSTM	0.95	1935	1039	0.537	0.5844%	-0.8029%	-0.0579%
CNN	0.95	1839	973	0.529	0.5710%	-0.8061%	-0.0776%
Logistic	0.95	917	478	0.521	0.5610%	-0.8133%	-0.0973%

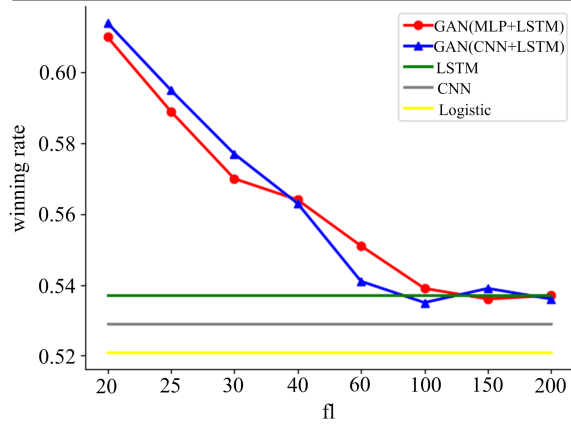


图 11 IC 中策略胜率

Fig. 11 Winning rate of strategies in IC




图 12 IC 中策略期望回报

图 12 Expected return of strategies in IC

3 结论

本文主要工作是采取半监督训练模式训练 LSTM 神经网络模型,并对模型进行高频交易回测.具体做法为采用 GAN 网络进行 LSTM 网络训练,给出价格上涨或下跌的预测概率,根据该预测概率进行模拟高频交易并进行回测.对比发现基于 GAN 训练的 LSTM 回测表现要优于有监督训练下的 LSTM.同时,本文将模型与已有的深度模型以及统计模型进行了对比,亦发现基于 GAN 训练的 LSTM 神经网络回测表现优于已有的深度模型与统计模型.工作的创新点如下:

(I)根据金融数据噪音大、信息比率低的特点,采取深度学习中半监督学习模式进行金融数据分析;

(II)采用改进型 GAN 深度学习框架,并将框架中判别网络 CNN 改为 LSTM 神经网络,空间数据敏感型神经网络变成了时序数据敏感型神经网络,能更好地做出判断;

(III)将半监督学习与 GAN 网络运用进金融数据,并用期货主力合约 1 min 级别行情数据进行检验回测,发现半监督参数 fl 可以在一定程度上优化深度模型的交易信号质量,这也丰富了深度学习在金融市场中的应用.

由于 LSTM 神经网络在时序数据中的巨大优势,越来越多的学者将 LSTM 运用到时序性较强的金融数据之中并取得成功.但在金融实盘中,LSTM 并不是万能的,价格序列本身的不稳定性以及超高的交易频率等等同样会使得 LSTM 在量化交易中处于不利地位.但基于现有的技术手段,以 LSTM 为核心的交易模型还是具有很大的技术优势,所以本文同样运用了 LSTM 神经网络提出相应的交易策略,发现半监督训练下 LSTM 给出的交易信号相

对传统的 LSTM 有一定的优化.相比传统的统计与量化模型,深度学习更像是一种黑匣子操作,其投资交易机制尚未可知,这也是深度学习的魅力所在.

基于深度学习的量化交易策略在金融市场不断普及,尤其随着 LSTM 模型的广泛应用,促使着我们不断创新深度模型,并寻找更为隐含的技术因子.在未来的研究中,我们不仅可以寻找更多的技术面、基本面与宏观面因子作为预测依据,还可以结合各种各样的深度模型,提出不同的交易策略.

参考文献 (References)

- [1] 王锴. 主成分 Logistic 回归模型在国债期货跨品种套利中的应用[N]. 期货日报, 2020-06-15.
- [2] ALDRIDGE I. High-Frequency Trading: A Practical Guide to Algorithmic Strategies and Trading Systems[M]. Hoboken, NJ: Wiley, 2010.
- [3] BROGAARD J, HENDERSHOTT T, RIORDAN R. High frequency trading and price discovery [J]. The Review of Financial Studies, 2014, 27(8): 2267-2306.
- [4] ANGEL J, MCCABE D. Fairness in financial markets: The case of high frequency trading[J]. Journal of Business Ethics, 2013, 112: 585-595.
- [5] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets [J]. Neural Computation, 2006, 18: 1527-1554.
- [6] GOODFELLOW I, BENGIO Y, COURVILLE A. Deep Learning[M]. Cambridge, MA: The MIT Press, 2017.
- [7] WANG M, DENG W. Deep face recognition[C]// [2020-02-10]. <https://arxiv.org/abs/1804.06655>.
- [8] KARPATY A, TODERICI G, SHETTY S, et al. Large-scale video classification with convolutional neural networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2014: 1725-1732.
- [9] DING Y, LIU Yang, LUAN H, et al. Visualizing and understanding neural machine translation [C]//

- Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics, Vancouver, Canada; ACL, 2017: 1150-1159.
- [10] QIAN Y, BI M, TAN T, et al. Very deep convolutional neural networks for noise robust speech recognition[C]// IEEE/ACM Transactions on Audio, Speech, and Language Processing. IEEE, 2016, 42(12): 2263-2276.
- [11] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]// Advances in Neural Information Processing Systems 27. ACM, 2014.
- [12] SALIMANS T, GOODFELLOW I, ZAREMBA W, et al. Improved techniques for training GANs [C]// Advances in Neural Information Processing Systems 29. ACM, 2016: 2234-2242.
- [13] YANG J, KANNAN A, BATRA D, et al. LR-GAN: Layered recursive generative adversarial networks for image generation[DB/OL]. [2020-02-10]. <https://arxiv.org/abs/1703.01560>.
- [14] HOANG Q, NGUYEN T D, LE T, et al. MGAN: Training generative adversarial nets with multiple generators[C]// 6th International Conference on Learning Representations. La Jolla, CA: International Conference on Representation Learning, 2018.
- [15] PERSIO L D, HONCHAR O. Artificial neural networks architectures for stock price prediction: Comparisons and applications[J]. International Journal of Circuits, Systems and Signal Processing, 2016, 10: 403-413.
- [16] 龙奥明, 毕秀春, 张曙光. 基于 LSTM 神经网络的黑色金属期货套利策略模型[J]. 中国科学技术大学学报, 2018, 48(2): 125-132.
- [17] 杨青, 王晨蔚. 基于深度学习 LSTM 神经网络的全球股票指数预测研究[J]. 统计研究, 2019, 36(3): 67-79.
- [18] 孙达昌, 毕秀春. 基于深度学习算法的高频交易策略及其盈利能力[J]. 中国科学技术大学学报, 2018, 48(11): 58-67.
- [19] LAKSHMINARAYANAN S K, MCCRAE J. A comparative study of SVM and LSTM deep learning algorithms for stock prediction[DB/OL]. [2020-02-10]. http://CEURWS.org/Vol-2563/aics_41.pdf.
- [20] DEV S, WESLEY C, FARHANA H Z. A comparative study of LSTM and DNN for stock market forecasting [C]// 2018 IEEE International Conference on Big Data. IEEE, 2018.
- [21] ARVAND F, SHERIDAN H. Deep learning for the prediction of stock market trends [C]// 2019 IEEE International Conference on Big Data. IEEE, 2019.
- [22] 陆广泉, 谢扬才, 刘星, 等. 一种基于 KNN 的半监督分类改进算法[J]. 广西师范大学学报(自然科学版), 2012, 30(1): 48-52.
- [23] 刘蓉. 半监督学习的 Co-training 算法研究[J]. 电脑编程技巧与维护, 2010(14): 6-7.
- [24] KINGMA D P, BA J. Adam: A method for stochastic optimization [DB/OL]. [2020-02-10]. <https://arxiv.org/abs/1412.6980>.