

基于灰度预测与神经网络的大宗商品价格预测对比研究

——以黄金期货为例

张 钰

武汉大学经济与管理学院, 中国·湖北 武汉 430072

【摘要】随着我国经济发展, 大宗商品价格的影响因素及其影响机制趋于复杂化, 准确预测大宗商品价格走势对指定更加准确且具有时效性的投资策略, 建立有效的对冲工具和指导宏观经济等具有重要意义。本文以黄金期货为例, 分别构建LSTM神经网络和BP神经网络模型对其价格进行走势预测, 并将其与传统的灰度预测模型进行对比研究, 模型优劣采用多指标综合评估准则。另外, 本文提出了一种通过对LSTM神经网络和BP神经网络模型进行加权处理的简单方法, 通过网格搜索法寻找最优参数。实证结果表明: 使用BP神经网络, LSTM神经网络以及加权模型均表现出优良的预测效果, 加权模型结果最优。

【关键词】 大宗商品; 价格预测; GM; ADF; test; LSTM; BP-ANN

引言

近年来, 我国大宗商品期货市场蓬勃发展, 然而当前研究我国商品期货市场价格变化的实证文献并不多。大宗商品价格的影响因素众多, 准确预测大宗商品价格对我国宏观经济平稳运行具有重大意义。

传统的时间序列模型被广泛用于大宗商品价格预测, 殷红[2]等人以广义自回归条件异方差(GARCH)模型和自回归移动平均(ARMA)模型相结合的组合预测模型对甲醇价格的中长期趋势预测, 并对各类组合模型的预测效果进行动态比较。而由于传统时间序列模型的局限性, 单一模型与组合模型预测效果都不佳, 以及随着机器学习技术逐渐成熟, 许多学者使用改进的机器学习算法对金融资产价格预测做出大量探索。曾濂[1]等人提出一种投影寻踪优化的BP神经网络改进模型, 先通过定性分析得到影响黄金价格波动的因子, 然后采用投影寻踪方法选择很强影响力的因子作为神经网络的输入节点, 并采用改进的算法进行学习寻找最优的BP网络结构利用改进模型, 为黄金价格预测提供了一种有效的高精度预测工具。黄仁全[4]等人以具有良好时间序列预测性能的Elman神经网络为基础, 用小波函数代替其隐含层的sigmoid函数作激励函数, 构建处理非线性问题能力更强的WEIman神经网络, 通过实证分析验证了方法的有效性和在价格预测上的可行性。

本文选取黄金期货作为代表, 预测价格波动趋势。黄金作为国际储备的一部分以及重要的投资和对冲工具, 更高精度地预测黄金价格走势对指导宏观经济有重大意义。由于传统时间序列分析对因素的选取具有主观性, 影响黄金期货价格的因素错综复杂, 且传统时间序列模型不能很好描述黄金期货非线性、非平稳性和高噪声的特点。而神经网络适用于处理非线性、不平稳数据, 因此本文基于BP神经网络、LSTM神经网络对黄金期货进行价格预测。

1 模型原理和数据说明

1.1 数据来源

对大宗商品的期货价格数据建立BP-LSTM模型, 分析并预测期货价格, 具体数据选择如下: 选取从2019年5月——2021年5月的黄金期货价格进行研究。黄金期货价格为上海期货交易所的日度数据, 价格使用结算价。由于期货的收盘价指的是期货交易时间结束时最后一笔合约的成交价格, 而结算价是指某一期货合约当天的全部成交价按照总交易量的加权平均价, 因此结算价更能代表期货当日平均价格水平, 反映日度变化。黄金期货价格数据来源于Choice金融终端。

1.2 数据预处理

为避免LSTM对输入数据的限制, 同时也有利于提高模型性能, 加快训练网络的收敛性, 在对序列进行量化分析前, 首

先将数据进行归一化处理。根据选取数据的特点和LSTM的要求, 本文采用线性函数归一化方法对数据进行预处理:

$$x_i = \frac{x_i - \min x_i}{\max x_i - \min x_i}$$

1.3 神经网络基本原理

BP(back propagation)神经网络是当前应用最广泛的神经网络。BP网络是在输入层与输出层之间增加若干层神经元称为隐单元, 它们与外界没有直接的联系, 但其状态改变能影响输入与输出之间的关系, 每一层可以有若干个节点。BP神经网络的计算过程由正向计算和反向计算组成。正向传播过程, 输入模式从输入层经隐单元层逐层处理, 并转向输出层, 每层神经元的状态只影响下一层神经元的状态。如果在输出层不能得到期望的输出, 则转入反向传播, 将误差信号沿原来的连接通路返回, 通过修改各神经元的权值, 使得误差信号最小。

LSTM(Long Short-Term Memory)是一种时间循环神经网络, 是为了解决一般的RNN(循环神经网络)存在的长期依赖问题而设计出来的。原始的RNN隐藏层只有一个状态, 保存短期输入, 而LSTM每一个神经元其内部增加一个单元状态(Cell)和三个门(Gates)。在某一时刻t, LSTM有三个输入, 当前时刻外部输入值x、上一时刻LSTM输出值以及上一时刻单元状态输入。通过三个门分别为输入门、遗忘门、输出门控制, 输入门的控制可以过滤X_{t-1}不重要的信息, 遗忘门的控制可以过滤上一时期单元状态中不重要的信息, 输出门决定单元状态多大程度输出到LSTM当前值。

1.4 建模流程

Step1: 对黄金期货价格序列进行平稳性检验, 探究序列是否具有平稳性;

Step2: 将数据划分为训练集, 验证集, 测试集, 并对数据进行归一化预处理;

Step3: 分别使用LSTM, BP-ANN和GM模型对时间序列进行预测, 通过对评估择优指标的反复对比, 最终输出多指标评估准则下最优参数向量, 其中b1, b2, b3, b4分别为LSTM, BP-ANN, GM和加权模型通过训练集与验证集得到的参数向量。

Step4: 建立加权模型, 其中a(0≤a≤1)作为加权模型中LSTM模型所占贡献程度, 利用网格搜索法遍历权重取值范围, 寻找预测趋势相同率最高的权重值。

Step5: 将4种预测模型的预测结果进行综合评估对比分析, 探究神经网络方法及加权处理的优缺点。

2 实证分析

2.1 价格序列平稳性分析

使用 python 编程求解, 由 ADF 检验结果可知, ADF 统计量为 0.251, 显著性检验 P 值为 $0.76 > 0.05$, 下图 2 为自相关图与偏自相关图, 可以看到自相关不收敛, 综上所述说明黄金期货价格序列不平稳; 而传统时间序列模型例如 ARMA 模型等要求时间序列数据平稳, 因此不使用传统时间序列模型。

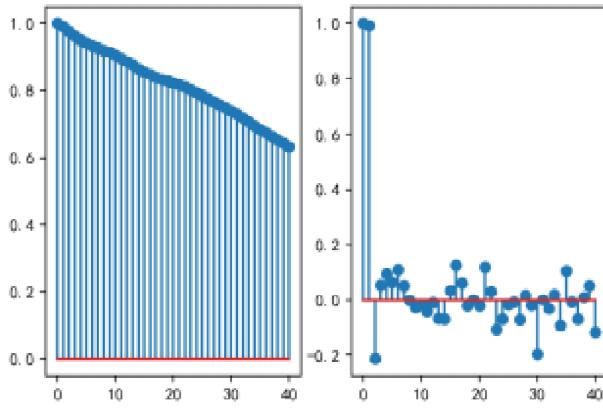


图 2 自相关与偏自相关

2.2 BP 神经网络、LSTM 神经网络预测与 GM(1, 1) 预测对比分析

通过 python 编程求解, 模型初步建立后, 为了使模型更加适合本数据, 进行了模型内部的参数优化。首先将数据分为总训练集和测试集, 测试集为最后 10 期价格, 对总训练集按 0.618: 0.382 的比例划分为训练集与验证集。其中验证集用于对模型超参数进行选择。

最终得到 BP 神经网络、LSTM 神经网络预测与 GM(1, 1) 预测模型的各评估结果, 如下表 1 所示: 从表 1 中可以看出 GM 模型预测存在较大误差, BP 神经网络与 LSTM 神经网络都取得了较好的预测效果, 且 BP 神经网络与 LSTM 神经网络的各项指标之间相差不大。另外, 在趋势预测过程中发现不同时期 LSTM 神经网络与 BP 神经网络预测值对真实值的偏离方向不同, 因此采用将两者进行加权处理的模型或许可以减小偏差, 提高模型预测精度。

表 1 BP 神经网络、LSTM 神经网络预测与 GM 预测评估

模型	MSE	相对误差	后验比	小误差概率
GM(1, 1)	525.97979	0.0495455	0.0021825	0.54973822
LSTM	26.96389476	0.009756422	0.000510899	0.994764397
BP	17.39098108	0.007800676	0.000378324	0.997382198

2.3 加权模型预测结果

为选出最优加权结果, 基于与真实序列趋势相同率为评优指标的前提下, 通过网格搜索法遍历 0-1 的所有权重 (以 0.01 为步长), 筛选出与测试集趋势相同率最高权重。通过下图 3 可知, 当 LSTM 所占权重为 0.7-0.74 时, 集成模型与真实序列趋势相同率最高, 高于单独的 LSTM 模型和 BP 神经网络模型, 说明通过加权提升了预测模型的预测精度。根据趋势预测图结果可知, LSTM 趋势相同率为 0.7, BP 趋势相同率为 0.6, GM 趋势相同率为 0.6, 而最优加权模型下的趋势相同率为 0.8。这说明了在最优解位于参数空间时, 存在至少一个权重阈值使得其趋势预测相同率高于单个神经网络。

2.4 预测走向趋势对比分析

进一步地, 对全部时间序列预测模型进行画图分析: 如图 5 所示: 从图中可以看出相对于 GM(1, 1) 模型, LSTM, BP 等神经网络能够将时间序列的局部特征刻画得更加详细和准确, 并且随着神经网络的复杂性加深, 模型拟合效果将会变得

更加优化, 在将过拟合情况考虑进来后, 适度地选取合适的神经网络超参数成为了模型预测好坏的重要条件。因为神经网络具有拟合逼近任意连续函数的特性, 使得其对于时间序列的刻画能够十分细致。将其作为大宗商品价格预测手段是一个比较合适的选择。至于预测出现部分滞后性, 是由于训练集数据输入形式所导致的, 这对于趋势预测并无较大影响。最后可以看出加权模型表现出比单个神经网络更加优异的预测效果, 这说明将多个神经网络有机地集成在一起, 将可能使得最后的预测效果更优, 类似于随机森林, XGBoost 算法。

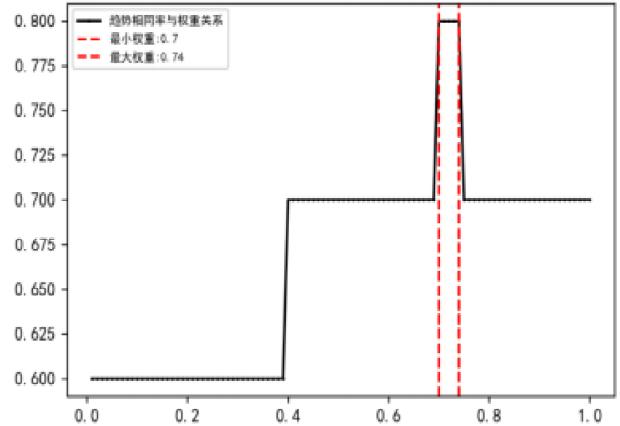


图 3 基于趋势相同率下的加权模型最优参数选择



图 5 LSTM, BP, GM 和加权模型整体时间序列预测

3 结论与建议

神经网络与 GM 对比的优点: 由于 GM(1, 1) 为一阶单序列线性预测模型, 在训练中只能预测出长期趋势, 而不能拟合出波动情况, 用于预测时有较大误差。而神经网络是非线性映射, 适用于黄金期货价格的非线性性, 且实证结果表明神经网络的自学习能力强, 预测精度高, 很好地拟合了价格趋势的变动。LSTM 神经网络模型和 GM 神经网络模型都明显优于 GM(1, 1)。

每个模型都存在自身优势与劣势, 且不同模型的拟合程度会存在时间的差异。而大宗商品价格变化较为复杂, 单一模型的解释力度有限; 因此需要进行多种模型进行加权平均, 并通过观察集成后的预测效果进行调整。使用网格搜索法, 可以找到最优拟合权重参数, 得到预测趋势与真实趋势最接近的加权模型。使大宗商品价格趋势更明显, 更好地识别价格特征, 更精准地预测价格。从预测结果看, 在市场大幅波动时, 应该抱有审

慎心态，由于期货的杠杆对收益与损失的放大作用，应谨慎交易防止造成较大损失。对于模型未来的进一步改进方向，考虑可以使用马尔科夫链进行修正，根据集成模型的预测值和实际值计算相对值，将其分为若干状态区间，形成状态转移矩阵，最后将状态与集成模型得出的预测值结合，即可得到修正后的预测值，也可使用 Kmeans 动态聚类技术进行修正。

参考文献：

[1] 曾濂, 马丹頔, 刘宗鑫. 基于BP神经网络改进的黄金价格预测 [J]. 计算机仿真, 2010, 27 (09): 200-203.

[2] 舛红, 张霞, 王长波. 基于组合模型的大宗商品价格预测与可视分析——以甲醇价格为例 [J]. 东华大学学报(自然科学版), 2017, 43 (04): 541-546+551.

[3] 王珏, 齐琛, 李明芳. 基于SSA-ELM的大宗商品价格预测研究 [J]. 系统工程理论与实践, 2017, 37 (08): 2004-2014.

[4] 黄仁全, 王娟娟, 田径. 基于ADLEDE-WElman神经网络的大宗商品价格预测研究 [J]. 中国物价, 2020 (08): 23-26.

作者简介：

张钰 (2000.04) 女, 汉族, 河南省安阳市, 本科, 金融学。