

基于改进回声状态神经网络的个股股价预测^①



李莉, 程露

(江苏大学 计算机科学与通信工程学院, 镇江 212013)

摘要: 当今社会股价预测是研究的热门问题, 人们越来越关注对股价预测模型的建立, 提高股价预测的精度对股票投资者有实际的应用价值. 目前股价的预测方法层出不穷, 其中较为典型的有传统的技术分析和 ARMA 模型等. 为了提升预测的精度, 同时考虑到股市的非线性, 本文提出一种改进的回声状态神经网络的个股股价预测模型, 针对回声状态神经网络 (ESN) 泛化能力不强的特点, 应用改进的粒子群算法 (GTPSO) 对回声状态神经网络 (ESN) 的输出连接权进行搜索, 最终得到最优解, 即 ESN 的最优输出连接权, GTPSO 算法概括来说就是在传统粒子群算法 (PSO) 的基础上引入禁忌搜索算法 (TS) 中禁忌的思想和遗传算法 (GA) 中变异的思想, 从而降低 PSO 在学习过程中陷入局部最小值的状况, 同时提高 PSO 搜寻全局的能力. 将预测模型用于个股每日收盘价预测中, 使用每 10 天的收盘价预测第 11 天的收盘价. 通过实验验证了模型的正确性, 实验证实, 该模型拥有较好的预测效果.

关键词: GA; 个股股价; ESN; PSO; TS

引用格式: 李莉, 程露. 基于改进回声状态神经网络的个股股价预测. 计算机系统应用, 2020, 29(2): 212-218. <http://www.c-s-a.org.cn/1003-3254/7297.html>

Forecast of Individual Stock Closing Price Based on Improved Echo State Neural Network

LI Li, CHENG Lu

(School of Computer Science and Communication Engineering, Jiangsu University, Zhenjiang 212013, China)

Abstract: The current stock price forecast is a hot issue in research. People are paying more and more attention to the establishment of stock price forecasting model, and improving the accuracy of stock price forecast has practical application value for stock investors. At present, the forecasting methods of stock prices are endless, among which the typical ones are traditional technical analysis and ARMA models. In order to improve the accuracy of prediction and consider the nonlinearity of stock market, this study proposes an improved stock price forecasting model of echo state neural network. The improved particle is applied to the characteristics of Echo State Neural Network (ESN). The group algorithm (GTPSO) searches the output connection weight of the ESN, and finally obtains the optimal solution, i.e., the optimal output connection weight of the ESN. The GTPSO algorithm is generally in the traditional Particle Swarm Optimization (PSO) algorithm. Based on the idea of taboo in the Tabu Search algorithm (TS) and the idea of mutation in the Genetic Algorithm (GA), the PSO is reduced to a local minimum during the learning process, and the ability of the PSO to search globally is improved. The forecasting model is used in the daily closing price forecast of individual stocks, and the closing price of the 11th day is predicted using the closing price of every 10 days. The correctness of the model is verified by experiments, and it is proved that the model has a good prediction effect.

Key words: GA; individual stock prices; ESN; PSO; TS

^① 收稿时间: 2019-07-13; 修改时间: 2019-08-22; 采用时间: 2019-09-04; csa 在线出版时间: 2020-01-16

1 引言

股市发展趋势的变化在一定程度上反映了国民经济的强弱,因此,几十年来,对股市预测的研究是人们关注的重点之一.20世纪,国外的学者提出了ARMA系列模型,该模型能较好地处理线性稳定性问题,在很长一段时间里,成为了预测研究的热点,但是股市中遇到的大多是非平稳和非线性的,ARMA系列模型不能很好地处理这些问题.20世纪后期,一些学者提出ARIMA模型,在ARIMA模型的基础上对该模型进行了改进,以提高模型预测的精确度.

近些年来,随着预测技术的逐步发展,神经网络模型开始被人们应用到股价的预测研究中.神经网络具有良好的自适应能力和较强的非线性逼近能力,能够较好地解决股市中存在的非线性和非平稳的特点.Göçken M等^[1]运用混合人工神经网络模型研究了股市指标与股市之间的关系.Adebiyi AA等^[2]对ARIMA模型和人工神经网络模型进行了对比研究,利用股票数据进行了实验,对比了两者的预测性能.卢辉斌等为了提高预测的准确性,运用改进的PSO对BP神经网络进行优化^[3].由于经典的神经网络预测模型(如BP神经网络),使用梯度下降算法完成对权值和阈值的训练,但是,如果没有选择正确的初始位置,该算法将陷入局部最小值,无法获得全局最优解.2004年Jaeger等^[4]使用回声状态神经网络对时间序列进行了预测,同比于之前的实验,效果得到了显著的提高.

回声状态神经网络(ESN)是递归神经网络的一种,递归神经网络拥有较好的非线性学习能力,当前已成为时间序列预测的主流工具,并且得到了学者们的认可,但经典的ESN学习能力有限,当用于实际问题下进行预测时,其泛化能力有待提高.

针对以上缺点,本文提出一种基于改进的回声状态神经网络(ESNGTP)的个股股价预测模型,使用改进的粒子群算法(GTPSO)对ESN的输出连接权进行搜索,获得较优输出连接权,进而提高算法的学习能力.

GTPSO算法是在经典的PSO算法搜索的过程中,引入了禁忌搜索算法(TS)中禁忌的思想和遗传算法(GA)中变异的思想,降低PSO陷入局部最小值的状况,同时提高PSO搜寻全局的能力.

2 回声状态神经网络(ESN)

ESN是递归神经网络的一种,如图1所示.




图1 ESN结构图

ESN有3层:输入层、储备池和输出层,其中ESN的储备池,在训练过程中,它类似于传统神经网络的隐层.拥有 N 个节点, N 的数值较大.因此,它拥有一定的短期记忆能力.ESN的输入和输出则分别有 K 和 L 个节点.图1中输入层与储备池之间的反馈用 W_{in} 表示,储备池内部反馈矩阵用 W 表示,储备池到输出层的反馈以及输出层到储备池之间的反馈则分别用 W_{out} 和 W_{back} 表示.当 t 时刻时,输入层的输入为 $u(t) = [u_1(t), u_2(t), \dots, u_K(t)]^T$,储备池内部状态为 $x(t) = [x_1(t), x_2(t), \dots, x_N(t)]^T$,输出层的输出为 $y(t) = [y_1(t), y_2(t), \dots, y_L(t)]^T$, x_i 和 y_i 的计算方式如式(1)和式(2)所示,其中 f 和 $F(\cdot)$ 为对应的激活函数.

$$x(t+1) = f(W_{in} \times u(t+1) + W \times x(t) + W_{back} \times y(t)) \quad (1)$$

$$y(t+1) = F(W_{out}[x(t+1), u(t+1), y(t)]) \quad (2)$$

ESN在训练的过程中, W_{in} , W_{back} 和 W 是随机初始生成,确定后将不再改变,然而 W_{out} 是通过训练生成的,所以,ESN的学习过程能够看作是 W_{out} 的确定过程.

ESN的核心是用大规模的递归神经网络代替传统神经网络的隐层.某种意义上,降低了算法因递归下降而陷入局部最小值的状况,同时减少了训练过程中的计算量.但是在ESN的学习过程中,如果数据集略有偏差,最终结果变化会较大,存在过拟合和泛化能力降低等问题.

3 粒子群优化算法(PSO)

粒子群优化算法(PSO)首先是由Kennedy等^[5]在1995年提出,该算法将搜索最优解的过程看成是鸟类觅食活动.一群鸟在一个地区寻找食物,假设该地区只

有一个食物. 这些鸟之间相互分享信息, 并且它们知道自身的位置以及自身距离食物的位置, 但是它们不清楚食物的位置. PSO 从这一活动中受到了启发, 将每只鸟看成是一个拥有速度与位置的粒子, 食物是最优位置, 寻优的问题则看成是所有粒子在多维空间中搜索的过程.

假定 PSO 在 n 维空间中进行搜索, 将食物视为最优解, 所有的粒子都清楚它们自身的位置. 同时, 能够依据适应度的值 ($fitness_i$) 判断位置的优劣. 粒子根据它们自身的经验和群体的经验更新粒子的速度和方向. 直到能够达到停止条件为止. PSO 在搜索的过程中, 速度快, 结构简单, 在网络优化和函数训练中, 应用广泛. 首先对 i 个粒子进行初始化, 粒子 i 的位置矢量和速度矢量分别记做 $X_i = (x_{i1}, x_{i2}, x_{i3} \cdots, x_{in})$ 和 $V_i = (v_{i1}, v_{i2}, v_{i3} \cdots, v_{in})$, 粒子 i 的自身最优解为 P_{best} , 记为 $P_i = (p_{i1}, p_{i2}, p_{i3} \cdots, p_{in})$, 群体最优解为 G_{best} , 记为 $G_i = (g_{i1}, g_{i2}, g_{i3} \cdots, g_{in})$, 在迭代期间, 粒子依据以下公式更新 X_i 和 V_i .

$$X_i(k+1) = X_i(k) + V_i(k+1) \quad (3)$$

$$V_i(k+1) = V_i(k) + c_1 \times rand \times (P_i(k) - X_i(k)) + c_2 \times rand \times (G_i(k) - X_i(k)) \quad (4)$$

其中, k 代表迭代期间的步骤, c_1 和 c_2 为学习因子. 文献[6]中总述了粒子群 (PSO) 在 1995~2017 年的研究进展、改进、修改和应用, 这里不再一一复述.

在 PSO 的搜索过程中, 粒子之间会互相分享信息. 这样的分享方式可以让粒子在刚开始的时候拥有较快的收敛速度. 但是在迭代的后期, 粒子的更新受到限制, 速度变慢, 陷入局部最优的状况增大.

4 禁忌搜索算法

禁忌搜索算法 (TS)^[7] 首先是由 Glover F 等 1986 年提出, Glover 在文献[8,9]中提出了大部分禁忌搜索使用的原则. 禁忌搜索算法如今被广泛用于解决路径规划和排序等问题, 例如 Zhang 等利用改进后的禁忌搜索算法^[10]解决了汽车排序问题.

TS 模拟人的记忆思维模式, 本质上, 它是一种全局逐步最优搜索算法. 在搜索的过程中将过去搜索的方案存储在禁忌表中, 为了避免重复, 使用禁忌即禁止的方法, 这减少了搜索陷入局部最优的状况. 同时在邻域的方案中选择最优的方案, 并且引入特赦的原则, 释放符合原则的禁忌对象, 可以在一定程度上避免搜索过程中因为早熟而达到局部优化.

禁忌搜索的核心是禁止重复之前的操作, 降低陷入局部最优的概率, 但是 TS 容易过分依赖初始解, 同时, 还需要提高全局搜索的能力.

5 GTPSO 算法思想

传统的 PSO 在搜索的过程中容易发生群体粒子集体向当前最优解飞行的现象, 进而出现粒子过早收敛的情况, 提高了算法陷入局部最小值的状况. 为此, 提出改进的 PSO 算法—GTPSO 算法. 通过引入 TS 中禁忌的思想, 使粒子逃离局部最优的束缚, 同时为了增强 PSO 对全局的搜寻能力, 引入 GA 中变异的思想, 并且根据 $repeatStep$ 的变化状态来判断是否变异, 变异率 ρ 可以取 0.01 到 0.1 之间的数, ρ 的增加在扩大搜索的范围的同时也会加长搜索的时间, 经过实验证明, ρ 取 0.04 可以得到较好的结果. 传统使用 GA 算法对 PSO 算法进行优化时, 是在每次迭代的过程中均发生变异, 这样容易破坏粒子的结构, 并且减低了搜索的速度. 基于此, 本文采用 $repeatStep$ 来判断是否发生变异, 只有当粒子群聚集严重时才会发生变异, 扩大了粒子搜索的范围, 同时搜索速度相比于传统的 GA 算法对 PSO 算法的优化有所提升.

GTPSO 算法思想如下:

Step 1. 初始化 X_i, V_i , 迭代次数 $Iter$, 连续不发生改变次数的阈值 $Maxstep$ ^[11] (经过多次实验可知 $Maxstep=10$ 可以取得较好的结果), 粒子群规模 ($m=20$), m 数量的多少影响着搜索的范围和计算量, 取值范围一般在 20 到 40 之间, 经过实验可知, m 取 20 可以得到较好的结果. 设置粒子群维度 n , $\rho=0.04$, 学习因子 $c_1=c_2=2$, 设置禁忌列表 (TL), TL 长度设置为 100.

Step 2. 计算 PSO 中每个粒子的 $fitness_i$, 同时寻找 PSO 最优适应度值 ($fitness_{best}$), G_{best} 和 P_{best} , 记录粒子群上一次最优适应度值 ($fitness_{bestbefore}$).

Step 3. 判断 $fitness_{best}$ 连续不变的次数是否超过 $Maxstep$, 如果是, 则按照变异率 ρ 对粒子群中每个粒子的 X_i 和 V_i 重新初始化, 同时更新 $fitness_i, fitness_{best}, G_{best}, P_{best}, repeatStep$, 否则转 Step 4.

Step 4. 判断当前 $fitness_{best}$ 的值是不是小于 $fitness_{bestbefore}$ 的值, 如果不是, G_{best} 不发生改变, 更新 $V_i, X_i, fitness_i, fitness_{best}, G_{best}, P_{best}, V_i, X_i, repeatStep$, 如果是转 Step 5.

Step 5. 判断当前 $fitness_{best}$ 的值是不是在 TL 中,

如果不是将当前 $fitness_{best}$ 的值加入 TL 中, 同时更新 TL , 否则转 Step 6.

Step 6. 用该次迭代的次优解取代 G_{best} , 同时判断该次迭代次数是否超过最大迭代次数, 如果是输出最优的 G_{best} , 如果不是转 Step 2.

GTPSO 算法思想如图 2 所示.

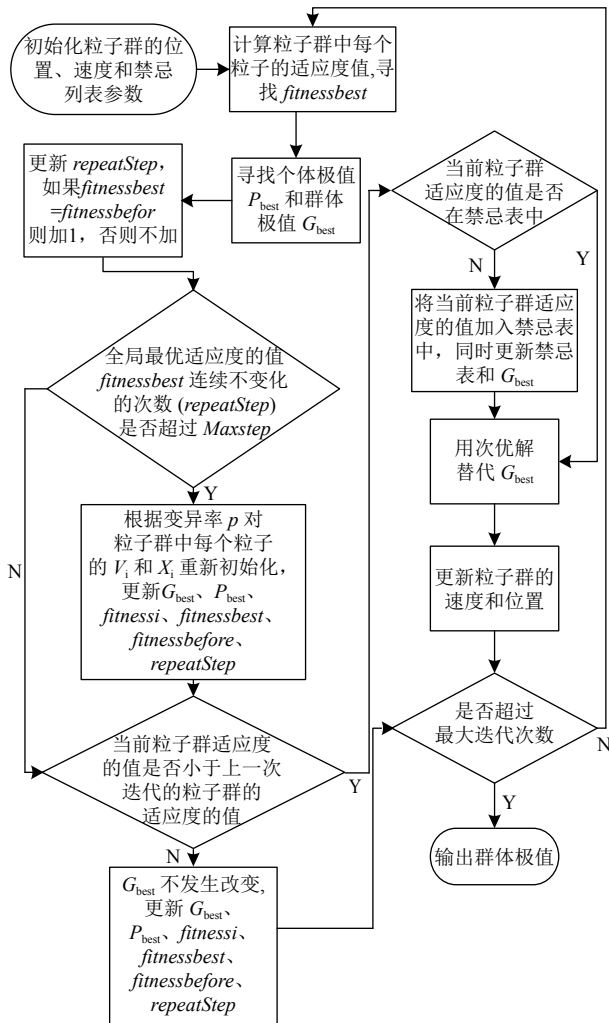


图 2 GTPSO 混合算法流程图

GTPSO 伪代码如下:

```

输入: Iter, m, n, TL, Maxstep, c1, c2, ρ
输出: Gbest

初始化:
Randomly initialize Vi and Xi
Initialize TL
for Iter from 1 to Iter do
if Iter==1
update fitnessi, fitnessbest, Gbest, Pbest
    
```

```

end if
if repeatStep >= Maxstep
repeatStep=0
for it from 1 to n
for it from 1 to m
按照 ρ 对 Vi 和 Xi 重新初始化
update fitnessi, fitnessbest, fitnessbestbefore, Gbest, Pbest,
repeatStep(连续不变化的次数)
end for
end for
end if
if fitnessbest < fitnessbestbefore
if fitnessbest 在 TL 中
用次优解取代 Gbest
else 将 fitnessbest 加入 TL
update TL
end if
else Gbest 不发生改变
for it from 1 to n
for it from 1 to m
update Vi, Xi
update fitnessi, fitnessbest, fitnessbestbefore, Gbest, Pbest,
repeatStep(连续不变化的次数)
end for
end for
end if
end for
    
```

6 改进的回声状态神经网络

针对 ESN 的泛化能力有待提升的特点, 本文提出一种改进的回声状态神经网络算法—ESNGTP 算法. Dutoit 等^[12]把对 ESN 的 W_{out} 的优化看做是特征子集选取过程, 本文中使用的 GTPSO 算法完成对 ESN 的 W_{out} 的选择, 增强了 ESN 的泛化能力.

首先把 ESN 储备池和输入神经元的数量之和作为 PSO 的维数. 接着把 ESN 的误差函数作为 PSO 的适应度函数, 然后将最优值作为 ESN 的 W_{out} .

ESNGTP 算法思想如下.

Step 1. 初始化 ESN 的参数以及 W_{in} 和 W , 其中 W_{in} 和 W 是随机生成的, 一旦确定, 不再改变. 同时初始状态 $x(0)$ 设置为 0, 加载样本数据到输入与输出, 更新 $x(t)$, 确定优化的粒子的维数 n , $n = K + N$, K 和 N 分别为 ESN 输入和储备池神经元数量, 初始化 X_i 和 V_i , 对数据进行处理以确保数据的完整性.

Step 2. 加载数据到输入输出, 更新 $x(t)$, 使用 Wiener-Hopf 的方法确定 W_{out} .

Step 3. 使用 GTPSO 算法对 W_{out} 进行选择, 得到 G_{best} , 即最优 W_{out} .

Step 4. ESN 预测数据, 最终获得预测结果.

ESNGTP 算法流程图如图 3 所示.

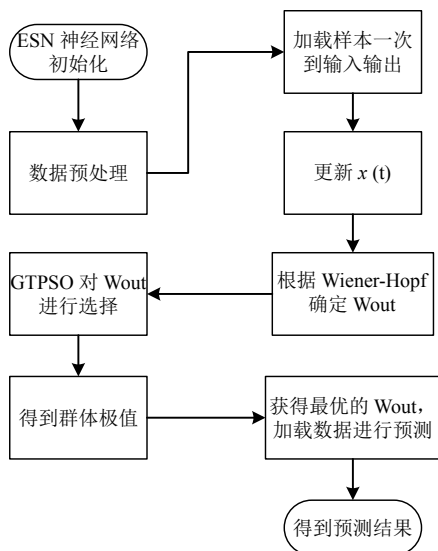


图 3 ESNGTP 混合算法流程图

7 实验结果与分析

7.1 实验环境

实验计算机配置: CPU Core(TM)3.40 GHz, 内存 16 GB, 显存 8 GB; 操作系统: Windows7; 软件环境: Mtlab 2014.

7.2 实验数据获取

实验数据的数量一定程度上影响实验的预测效果, 因此本文实验数据选取金螳螂 (002018) 2012 至 2018 年每日收盘价格和 中国 石油 (601857) 2013 至 2019 年每日收盘价格作为实验数据集. 数据来源于同花顺, 首先对数据进行手动清理, 将缺失的数据及当日收盘价为 0 的数据进行清除, 选取两个个股的 1152 天收盘价格作为训练数据, 选取 288 天收盘价格作为测试数据. 将前 10 天的收盘价作为输入, 第 11 天的收盘价作为输出.

7.3 评价标准

使用平均绝对误差 (MAE) 和平均绝对百分比误差 (MAPE) 对算法的优劣进行评估. MAE 越小, 预测值与真实值之间的误差越小. 在同组数据下进行实验, 对比不同算法结果, MAPE 越小, 算法性能更优.

$$MAE = \frac{1}{n} \sum_{i=1}^n |\bar{y}_i - y_i| \quad (5)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\bar{y}_i - y_i}{y_i} \right| \quad (6)$$

其中, \bar{y}_i 代表预测的值, y_i 代表真实的值.

7.4 ESNGTP 算法预测结果与分析

建立 ESN 模型, K, N, L 分别设置为 10, 500, 1, 学习因子 $c1 = c2 = 2, m = 20, n = K + N$, PSO 中粒子的 V_i 和 X_i 在允许的范围内随机产生. 本文将金螳螂 (002018) 和中国石油 (601857) 两支个股的每日收盘价作为实验数据, 金螳螂 (002018) 选取 2012 年至 2018 年 1152 条数据作为训练数据, 选取 288 条数据作为训练数据. 中国石油 (601857) 选取 2013 年至 2019 年 1152 条数据作为训练数据, 选取 288 条数据作为训练数据.

分别采用 BP、ESN、ESN-PSO 和 ESNGTP 算法对数据进行训练, 同时针对训练好的模型带入实验数据进行测试, 其中金螳螂 (002018) 测试结果如图 4 至图 6 所示, 中国石油 (601857) 测试结果如图 7 至图 9 所示. 为了使图像效果更加清晰, 将 ESNGTP 算法结果单独画出. 对预测结果展开分析:

(1) 由图 5 和图 8 可知, ESN 的效果明显优于 BP 的预测结果, 因为 ESN 可以较好的寻找历史输入与输出之间的关系.

(2) 由图 5 和图 8 可知, 为了提高实验预测的精度, 在接下来的实验中对 ESN 的 W_{out} 进行优化. ESN-PSO 的效果优于 ESN.

(3) 由图 4、图 6、图 7 和图 9 可知, 在个股收盘价的预测上, ESNGTP 相比于传统的 ESN 更加精准, 对抗局部收敛的能力较强, 达到了预期的效果.

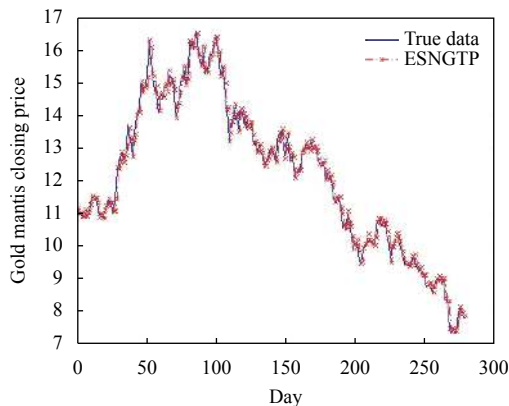


图 4 ESNGTP 预测结果与真实值对比

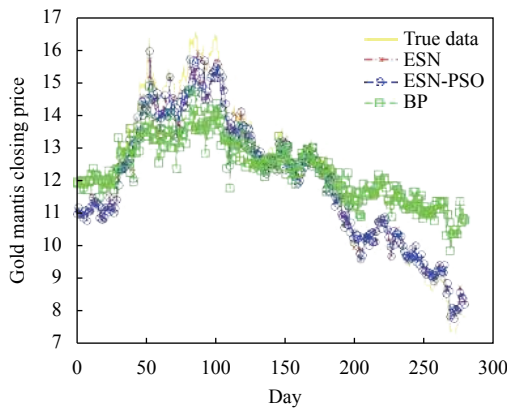


图5 3种算法预测结果对比

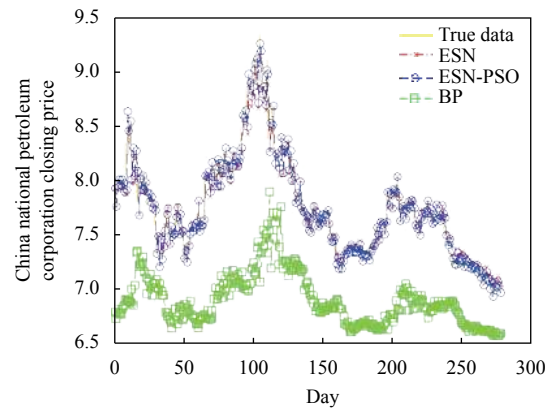


图8 3种算法预测结果对比




图6 ESNGTP与ESN相对误差绝对值对比

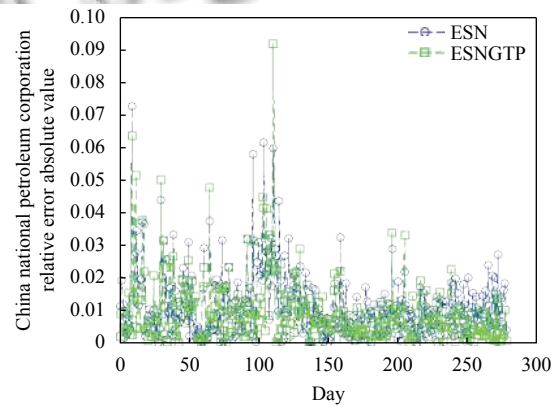


图9 ESNGTP与ESN相对误差绝对值对比

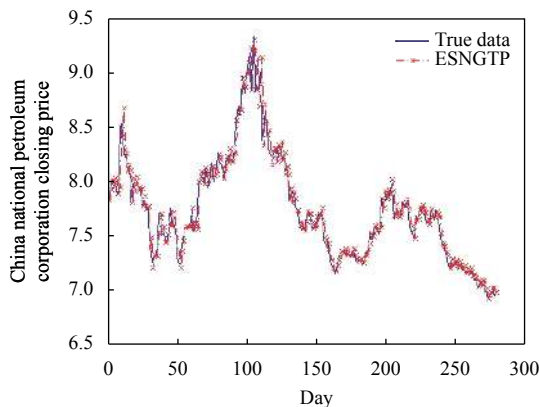


图7 图7 ESNGTP 预测结果与真实值对比

将不同算法的预测结果进行分析,结果如表1所示。

从表1可以看出ESN效果明显优于BP,而ESN-PSO预测效果优于ESN,此外ESNGTP算法的预测结果较优于传统的ESN和ESN-PSO,在ESNGTP算法中,预测精度得到提升,解决了传统ESN泛化能力不强的问题。

表1 不同数据集下算法预测误差对比

数据集	算法	MAPE(%)	MAE
金螳螂	BP	11.09	1.2348
	ESN	3.37	0.4186
	ESN-PSO	3.32	0.4123
	ESNGTP	1.86	0.2295
中国石油	BP	10.67	0.8416
	ESN	1.18	0.0931
	ESN-PSO	1.07	0.0850
	ESNGTP	0.98	0.0775

8 结论

本文基于传统的ESN预测模型,使用GTPSO算法完成对ESN的 W_{out} 的选择,获得较优的 W_{out} ,进而使得预测更为精准。GTPSO算法在传统的PSO算法中上提出了两点创新,(1)引入GA算法中变异的思想,只有当粒子群聚集严重时才会发生变异,重新初始化部分粒子,扩大了PSO算法搜索的范围,增强了PSO的全局搜寻能力,同时可以保持较快的前期寻优速度。(2)引入TS中禁忌的思想,TS的局部寻优能力较强,

搜索的过程中拥有记忆,降低算法陷入局部最小值的状况.保持较快的后期寻优能力,当 PSO 陷入局部最优时,可以通过禁忌逃离这种局部最优的状况.本文使用 ESN-GTP 算法对金螳螂(002018)和中国石油(601857)两支个股收盘价进行预测.通过实验说明 ESN-GTP 算法相比于传统的 ESN,预测效果更为精准.在迭代的过程中,从表 1 可知 ESN-GTP 相比于 ESN-PSO 有较好的收敛效果.

虽然引入的变异思想和禁忌思想提高了预测的精度,但是在迭代的过程中消耗的时间稍长,因此在时间上的消耗有待改进.此外,实验中对于个股股价的预测使用的是每日收盘价的数据,未曾考虑其他的影响因素,下一步的工作,需要考虑多种因素对收盘价的影响,同时依据影响因素重要性的不同,给与不同的影响因素相适应的权重.

参考文献

- 1 Göçken M, Özçalıcı M, Boru A, *et al.* Integrating metaheuristics and artificial neural networks for improved stock price prediction. *Expert Systems with Applications*, 2016, 44: 320–331. [doi: 10.1016/j.eswa.2015.09.029]
- 2 Adebisi AA, Adewumi AO, Ayo CK. Comparison of ARIMA and artificial neural networks models for stock price prediction. *Journal of Applied Mathematics*, 2014, 2014: 1–7.
- 3 卢辉斌,李丹丹,孙海艳. PSO 优化 BP 神经网络的混沌时间序列预测. *计算机工程与应用*, 2015, 51(2): 224–229, 264. [doi: 10.3778/j.issn.1002-8331.1306-0342]
- 4 Jaeger H, Haas H. Harnessing nonlinearity: Predicting chaotic systems and saving energy in wireless communication. *Science*, 2004, 304(5667): 78–80. [doi: 10.1126/science.1091277]
- 5 Kennedy J, Eberhart R. Particle swarm optimization. *Proceedings of ICNN'95-International Conference on Neural Networks*. Perth, Australia. 1995. 1942–1948.
- 6 Jain NK, Nangia U, Jain J. A review of particle swarm optimization. *Journal of the Institution of Engineers (India): Series B*, 2018, 99(4): 407–411. [doi: 10.1007/s40031-018-0323-y]
- 7 Glover F, Laguna M. Tabu search, *Handbook of combinatorial optimization*. Boston: Kluwer Academic Publishers, 1998. 2093–2229.
- 8 Glover F. Tabu search —Part I. *ORSA Journal on Computing*, 1989, 1(3): 190–206. [doi: 10.1287/ijoc.1.3.190]
- 9 Glover F. Tabu search —Part II. *ORSA Journal on Computing*, 1990, 2(1): 4–32. [doi: 10.1287/ijoc.2.1.4]
- 10 Zhang XY, Gao L, Wen L, *et al.* A hybrid algorithm based on tabu search and large neighbourhood search for car sequencing problem. *Journal of Central South University*, 2018, 25(2): 315–330. [doi: 10.1007/s11771-018-3739-2]
- 11 李宁,刘飞,孙德宝.基于带变异算子粒子群优化算法的约束布局优化研究. *计算机学报*, 2004, 27(7): 897–903. [doi: 10.3321/j.issn:0254-4164.2004.07.005]
- 12 Dutoit X, Schrauwen B, Van Campenhout J, *et al.* Pruning and regularization in reservoir computing. *Neurocomputing*, 2009, 72(7–9): 1534–1546.