

联合谐波小波与递归神经网络的股市时间序列预测

吴纯

(武汉商学院 信息工程系, 武汉 430056)

摘要: 为了提高神经网络对股市时间序列的预测精度,首先利用谐波小波对股票市场数据进行多尺度分解,将其分解为不同尺度且具有平移不变特征的谐波小波分量;然后根据股市时间序列的特点,构建递归神经网络模型进行短期预测,以不同尺度的谐波小波分量为输入数据,对股市数据进行多尺度预测;最后对不同尺度的预测结果进行谐波小波重构,得到最终的股市预测数据。对我国股票市场进行了实验分析,结果表明:股市时间序列经谐波小波分解后,股市数据中不同投资时间水平的价格波动可以被较好的分离,有效地提高了股票市场数据的预测精度。

关键词: 谐波小波分解;股市时间序列预测;神经网络;小波多尺度分解

中图分类号: TP27 **文献标志码:** A **文章编号:** 1671-1807(2016)05-0105-04

股市投资人的投资分析以及我国政府部门对股票市场的监管都需要对股市价格进行较准确的预测,股票市场价格波动具有混沌特性^[1],因此对我国股市价格波动进行长期预测不是可行的,但可以进行较准确的短期预测。神经网络已被广泛应用于股市分析和预测中,但直接利用神经网络对股市数据进行预测结果并不是很理想。因为股票投资市场是由短期、中期和长期等不同投资水平的投资人构成的,各类型的投资者以不同的时间尺度特征来看待市场^[2],并造成市场不同时间尺度特征的波动,他们所引起的股市价格变换具有完全不同的时间尺度特征。因此直接将股市时间序列作为输入数据进行神经网络预测,会使得不同特征量交织在一起,导致特征量的特征不清晰,降低了神经网络的学习效率和预测精度^[3-5]。

谐波小波没有二进制限制而且严格正交,其频谱特性具有严格的“盒形”特征,因此可将信号无混叠、无遗漏的分解到不同的时间尺度上,分解出的各分量相互独立,很好地消除了其他尺度分量对该尺度分量的影响^[6]。股市时间序列经谐波小波分解后,得到一系列相互独立且不同尺度的小波分量,这些分量代表了不同投资时间水平的投资者所造成的股市价格波动。利用这些小波分量作为神经网络的输入数据,可以在很大程度上减弱股市信号中不同时间尺度的特征量之间的相互干涉,从而简化神经网络中的训练,使得在预测过程中能够更好的获取信号的特征信息,有效提高神经网络学习的效率和预测的准确度^[4]。

本文提出一种基于谐波小波和递归神经网络的股市价格预测方法,首先利用谐波小波降股市数据分解为不同尺度且的谐波小波分量;然后构建递归神经网络模型,以不同尺度的谐波小波分量为输入数据,对股市数据进行多尺度短期预测;再根据各个谐波分量的预测值重构原股市信号的预测序列,以提高价格波动的预测精度。利用我国股票市场的上证综合指数和深证成份指数作为实验数据,对数收益率进行了预测,实验结果表明本文方法是有效的。

1 谐波小波基础

谐波小波的的时域表达式为^[6]:

$$\Psi_{m,n}(t) = \frac{\exp(in2\pi t) - \exp(im2\pi t)}{i(n-m)2\pi t} \quad (1)$$

其傅里叶变换为:

$$\hat{\Psi}_{m,n}(\omega) = \begin{cases} \frac{1}{2\pi(n-m)}, & \omega \in [m2\pi, n2\pi] \\ 0, & \text{else} \end{cases} \quad (2)$$

式中 $m, n \in R^+$ 。谐波小波的时域及频域波形图如图1所示。由谐波小波的傅里叶变换(公式(2))可知,谐波小波在频率域具有严格的盒形谱特征,因此利用谐波小波对信号进行分解时,可将信号无重叠、无遗漏的分解到不同尺度的频率段上,不同尺度上的分量相互独立,从而可精确的分析信号在不同尺度上的特征信息。

2 基于混沌分析的递归神经网络预测模型

由于股票市场时间序列具有混沌特性,因此在利

收稿日期:2016-01-21

作者简介:吴纯(1978—),男,湖北鄂州人,武汉商学院,副教授,研究方向:多尺度理论及其应用、深度学习。

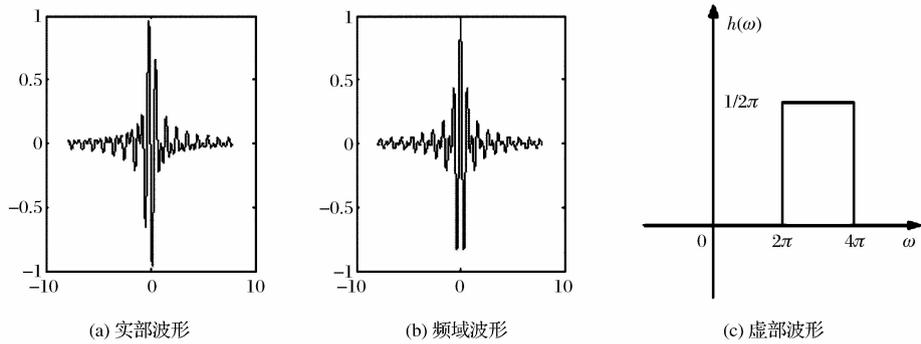


图 1 谐波小波时域波形和频域波形

用神经网络对其预测时需要对其进行相应的混沌特性分析。在混沌序列中,单个分量的改变由序列中与其相互作用的其余分量所共同决定的,因此对混沌序列进行预测时,首先需要利用 Packard^[7]等人提出的相空间重构理论对其进行相空间重构,即把一维的混沌序列嵌入到 m 维空间中,相空间重构后的序列为:

$$X(t) = \{x(t), x(t - T), \dots, x(t - (m - 1)T)\}$$

其中, $X(t)$ 表示序列在 t 时刻的动力学状态, T 为时间延迟, m 为重构空间的嵌入维数。相空间重构后,可建立相空间到嵌入空间的对应映射,即在延时后的状态 $\hat{x}(t + T)$ 和当前状态 $X(t)$ 之间必然存在相对应的映射函数 $f(\cdot)$,使得 $\hat{x}(t + T) = f(X(t))$,函数 $f(\cdot)$ 就是混沌序列预测时所寻找的预测函数。

可采用神经网络模拟上述混沌序列预测模型。首先利用相空间重构后的序列,计算网络结构的相关先验知识,构建神经网络股市预测模型。当对股票时间序列进行预测时,使用内插法对股市序列进行扩展,利用扩展后序列分析其混沌参数。设 ηT 为预测步幅,则对于时间 t_0 ,其预测值和当前值之间满足:

$$\hat{x}(t_0 + \eta T) = f(X(t_0))$$

预测时混沌序列的最佳延迟 T 和嵌入维数 m 按文献[8]中方法进行计算,通过神经网络学习找到预测函数 $f(\cdot)$ 后,股市序列的神经网络单步预测模型可表示为:

$$\hat{x}(t + 1) = f[x(t), x(t - T), \dots, x(t - (M - 1)T)] \quad (3)$$

其中 M 为神经网络输入节点个数。

3 联合谐波小波和递归神经网络的股市预测

基于股市时间序列的混沌特性和多尺度波动特征,本文将谐波小波分解与神经网络预测相结合,构造了一个新的神经网络结构对股市数据进行预测,整个神经网络预测结构分为三个阶段。在第一个阶段利

用谐波小波对股市序列进行分解,得到具有不同时间特征的小波系数分量;在第二阶段利用一个分离的神经网络对相互独立的各小波分量进行单步预测;在第三阶段将原始数据以及第二阶段中的预测数据作为输入,利用另外一个线性神经网络结构,对股市时间序列进行下一个样本的预测。设股市数据为 $\{x(t) | t = 1, 2, \dots, n\}$,则本文提出的方法的具体步骤为:

1) 利用谐波小波对股市数据 $\{x(t) | t = 1, 2, \dots, n\}$ 进行分解,设得到的谐波小波分量为 $\{hw_i(t) | t = 1, 2, \dots, n; i = 1, 2, \dots, q\}$ 。

2) 利用相空间重构定理对小波分量 $hw_i(t)$ 相空间重构,并利用递归神经网络对各小波分量进行预测。在利用神经网络对谐波小波分量 $hw_i(t)$ 进行预测前,首先对原始数据和 $hw_i(t)$ 进行内插,设 λ 为插值倍数,则插值后的序列为:

$$X'(t') = \{x'(t') | t' = 1, 2, \dots, n'\} \text{ 及 } \{hw_i(t') | t' = 1, 2, \dots, n'; i = 1, 2, \dots, q\}$$

此时式(3)变为:

$$\hat{x}(t' + (\lambda + 1)p) = f(x'(t'), x'(t' - T), \dots, x'(t' - (M - 1)T))$$

按照文献[8]中的方法计算最佳时间延迟 T ,嵌入维数通过 $\ln(C_m(r))$ 与 $\ln(r)$ 的关系计算求得。神经网络中网络输入层的数取为 $M = m$,神经网络预测模型可写为:

$$S(t' + (\lambda + 1)) = \Omega(U^{[2 \rightarrow 2]} s(t') + U^{[1 \rightarrow 2]} x'(t') + a^{[2]}) \hat{x}(t' + (\lambda + 1)) = U^{[2 \rightarrow 3]} s(t' + (1 + \lambda)) + a^{[3]}$$

式中 $\Omega(\cdot)$ 表示一个 N 维向量的集合,所有隐层神经元里的激活函数都包括在内。选用正向传播算法^[9]作为网络的学习方法,网络中隐层神经元的状态集合可表示为:

$$S(t' + (\lambda + 1)) = [s_1^{[2]}(t' + (\lambda + 1)), s_2^{[2]}(t' + (\lambda + 1)), \dots, s_N^{[2]}(t' + (\lambda + 1))]$$

3) 设各小波分量的单步预测结果为 $\{\hat{x}_k(t+1), k=1,2,\dots,q\}$, 利用一单层感知器对 $\{\hat{x}_k(t+1)\}$ 进行线性组合构造原股市数据的下一个预测点 $\hat{x}(t+1)$, 即 $\hat{x}(t+1) = \sum_{k=1}^{q+1} \omega_j^3 x_k(t+1)$ 。该层网络的输入数目等于谐波小波的分解层数 q 且没有隐层, 权向量 $\omega_j^3 (j=1,2,\dots,q)$ 的值利用文献[10]中所给方法进行计算。

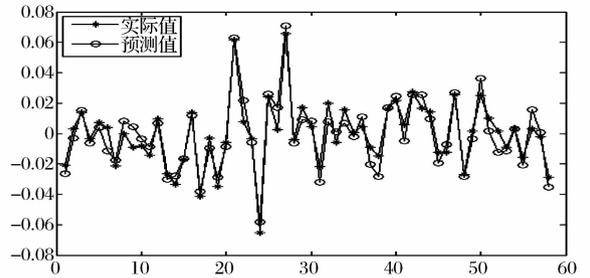
4 实验结果与讨论

本文实验中选取我国 2010 年 2 月 1 日至 2015 年 4 月 30 日的上证综指和深圳成指的日收盘值对数收益率作为预测实验数据, 上证综指记为 Data1, 深圳成指记为 Data2。Data1 和 Data2 的数据长度为 1 259, 考虑到股市数据的混沌特性, 因此仅对其进行短期预测, 将 Data1 和 Data2 中的前 1 200 个数据作为训练数据集, 采用单步预测的方法对后 59 个数据依次进行预测, 将预测值与实际值进行对比以检验模型的预测精度, 以均方根误差作为预测精度的衡量标准。实验中, 分别采用本文方法、人工神经网络预测模型^[3]、混沌预测模型^[2]以及传统的小波神经网络预测模型^[4]对实验数据进行预测。

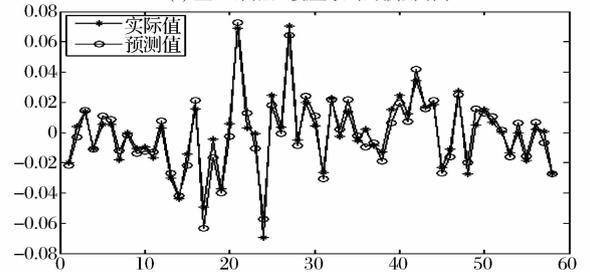
在利用谐波小波和传统小波对实验数据进行分解时, 分解层数 j 取为 $j = \log_2(N/4)$, 其中 N 表示股市信号长度。上证综指数据 Data1 经谐波小波分解后, 被分解为 8 个谐波小波分量 $hw_i, i=1,\dots,8$ 。为了利用神经网络对 hw_i 进行预测, 需要计算原综指数据及 8 个谐波小波分量相对应的最佳延迟和嵌入维数。根据第 2 节中所述的方法, 对数据进行插值并计算 $S-t$ 关系, 可求出 Data1 和 8 个谐波小波分量的最佳延迟分别为: 5, 5, 4, 7, 9, 7, 5, 8, 4; 根据最佳延迟计算嵌入维数, 可求出各分量对应的嵌入维数分别为: 7, 7, 9, 10, 8, 8, 6, 4, 3。神经网络中的隐层节点数采用试凑的方法进行确定, 最终得到原始数据和 8 个谐波小波分量所对应的网络结构分别为: 7-10-1, 7-12-1, 9-5-1, 10-10-1, 8-3-1, 8-5-1, 6-6-1, 4-5-1, 3-6-1。对深圳成指数据 Data2 进行谐波小波分解后, 分别计算 Data2 和 8 个小波分量 $hw_i (i=1,\dots,8)$ 的预测参数, 其最佳延迟分别为: 5, 5, 7, 8, 4, 7, 6, 8, 4; 相空间重构时的嵌入维数为: 12, 14, 11, 11, 7, 7, 4, 5, 2。Data2 和各分量对应的网络的结构分别为: 12-10-1, 14-11-1, 11-8-1, 11-10-1, 7-7-1, 7-6-1, 4-3-1, 5-2-1, 2-2-1。

表 1 Data1 和 Data2 的预测误差均方根比较

| 预测方法 | RMSE/Data1 | RMSE/Data2 |
|--------|------------|------------|
| 人工神经网络 | 0.935 5 | 1.014 7 |
| 混沌预测 | 0.724 6 | 0.834 4 |
| 小波神经网络 | 0.565 4 | 0.782 1 |
| 本文方法 | 0.217 9 | 0.461 4 |



(a) 上证综指日收益序列的预测结果



(b) 深证成指日收益序列的预测结果

图 2 两市对数日收益率预测结果

上证综指和深证成指经 4 种方法预测后的均方误差如表 1 所示。由表 1 可知, 与人工神经网络预测模型、混沌预测模型以及传统的小波神经网络预测模型相比, 本文提出的联合谐波小波和递归神经网络的方法的预测精度有较好的提高, 其预测结果的均方误差 (RMSE) 达到最小。上证综指 Data1 和深证成指 Data2 的经本文方法预测后的结果分别如图 2(a) 和 2(b) 所示, 图中星号线表示股市数据的实际记录值, 而圈号线表示本文方法的预测值。

5 结论

本文提出了一种基于谐波小波分解和递归神经网络的股市时间序列预测方法, 有效改进了股票市场数据的单步预测精度。利用上证综指和深证成指的对数收益率数据对所提方法进行了实验分析, 实验结果表明, 本文方法具有较好的预测效果, 与常用的神经网络预测、混沌预测以及小波神经网络预测等方法相比, 预测精度有了一定程度的提高, 预测结果的均方根误差有了较好的改善。

参考文献

[1] PEI-CHANN CHANG, CHEN-HAO LIU. A TSK type fuzzy

- rule based system for stock price prediction[J]. *Expert Systems with Applications*, 2008, 34(1): 135-144.
- [2] PETERS E E. Fractal market analysis: applying chaos theory investment and economics [M]. New York: John Wiley & Sons, 1996: 72-96.
- [3] 欧阳林群. GA 神经网络在证券市场预测中的应用研究[J]. 武汉理工大学学报: 信息与管理工程版, 2006, 28(11): 160-163.
- [4] 杜建卫, 王超峰. 小波分析方法在金融股票数据预测中的应用[J]. 数学的实践与认识, 2008, 38(7): 48-75.
- [5] YOSHINORI K, SHOZO T. Prediction of stock trends by using the wavelet transform and the multi-stage fuzzy inference system optimized by the GA[J]. *IEICE Trans Fundamentals*, 2000, E83-A(2): 357-366.
- [6] NEWLAND D E. Harmonic wavelet analysis[J]. *Proc R Soc Land A*, 1993, 443: 203-225.
- [7] N H PACKARD, J P CRUTCHFIELD, J D FARMER, et al. Geometry from a time series[J]. *Phys. Rev. Lett.*, 1980, 45(9): 712-716.
- [8] 张旭淘, 贺国光, 宇卢. 一种在线实时快速地判定交通流混沌的组合算法[J]. *系统工程* 2005, 23(9): 42-45.
- [9] WILLIAMS R J, ZIPSER D. A learning algorithm for continually running fully recurrent neural networks [J]. *Neural computation*, 1989, 1(2): 270-280.
- [10] GEVA A B. Scalenet-multiscale neural-network architecture for time series prediction[J]. *IEEE Trans on Neural Network*, 1998, 9(6): 1471-1482.

Forecast of China Stock Time Series Combining Harmonic Wavelet and Neural Network

WU Chun

(Department of Information Engineering, Wuhan Business University, Wuhan 430056, China)

Abstract: For improving the prediction accuracy of the stock market data by neural network, the stock market data is decomposed into a series wavelet components by harmonic wavelet, which are shift invariant and have different scale. Then, constructing the recursion neural network based on the characters of the stock market, and each harmonic wavelet component of stock market data is predicted by using of the constructed neural network. At last, the final stock market forecast data is obtained by harmonic wavelet reconstruction for forecasting results of different scale wavelet components. The experimental results shows that the price fluctuations of different investment time horizon in stock market data can be well separated, after the stock time series is decomposed by harmonic wavelet, the predicting accuracy of stock market is improved efficiently.

Key words: harmonic wavelet decomposition; stock time series prediction; neural network; multi-resolution wavelet decomposition

(上接第 91 页)

Study on the Performance Evaluation System of State-Owned Enterprises Based on BSC-EAHP

PAN Li-sheng, ZHA Lu-yao

(School of Management, Hefei University of Technology, Hefei 230009, China)

Abstract: According to the coexist characters of technological, R&D and innovation, high profitability and the nature of State-owned of the state-owned enterprise of science and technology, this article constructs a hierarchy performance evaluation index system from five aspects including the financial, stakeholders, R&D and innovation, internal business processes and operations, learning and growth based on the theory of the Balanced Scorecard. It includes three layers of target layer, criterion layer and index layer from the perspective of hierarchical structure of index system. It fills the gaps in research field of the performance evaluation system of the state-owned scientific and technological enterprises in a certain extent. By using the method of extension analytic hierarchy process, the weights of the performance evaluation system are calculated and the inaccuracy of the fuzzy subjective judgments and the inconsistency of the judgment matrix in the process of model construction are solved. Finally, the weights of the index system are calculated by the judgment of the evaluation index system investigated from the experts.

Key words: state-owned enterprise of science and technology; performance evaluation; Balanced Scorecard (BSC); Extension Analytic Hierarchy Process (EAHP)