

基于 DBN 深度学习的期货市场价格预测建模与决策

陈俊华 郝彦惠 郑丁文 陈思宇

(中央财经大学管理科学与工程学院 北京 100081)

摘 要 深度学习通过学习深层非线性网络结构即可实现复杂函数的逼近,可以从大量无标注样本集中学习数据集的本质特征。而深度信念网络(DBN)是由多层随机隐变量组成的贝叶斯概率生成模型,可以作为深度神经网络的预训练环节,为该网络提供初始权重。基于该模型的一个高效学习算法不仅解决了模型训练速度慢的问题,还能产生非常好的参数初始值,极大地提升了模型的建模能力。金融市场是一个多变量非线性系统,通过运用 DBN 模型进行分析预测可以很好地解决其他预测方法初始权重难以确定的问题。文中以原油期货市场价格预测为例,说明了运用 DBN 模型进行预测和决策的可行性及有效性。

关键词 深度学习,DBN 算法,期货市场

中图分类号 TP181 **文献标识码** A

Modeling and Decision-making of Futures Market Price Prediction with DBN

CHEN Jun-hua HAO Yan-hui ZHENG Ding-wen CHEN Si-yu

(School of Management Science and Engineering, Central University of Finance and Economics, Beijing 100081, China)

Abstract The deep learning algorithm can realize the approximation of complex functions by learning the deep nonlinear network structure, and it can learn the essential characteristics of data sets from a large number of unlabeled samples. Deep belief network (DBN) is a model of deep learning, which is a Bayesian probability generation model composed of multi-layer random hidden variables. DBN can be used as a pre-training link for deep neural networks, providing initial weight for the network. This learning algorithm not only solves the problem of slow training, but also produces very good initial parameters, greatly enhances the model's modeling capabilities. The financial market is a multi-variable and nonlinear system. The DBN model can solve the problems like initial weights and so on, that other prediction methods are difficult to analyze and predict. This paper used oil futures market price forecast as an example, to prove the feasibility of using DBN model to predict futures market price.

Keywords Deep learning, DBN algorithm, Futures market

1 引言

期货市场被誉为国民经济的“气象预报”。诺贝尔经济学奖的获得者,美国经济学家米勒曾说过:“真正的市场经济是不能缺少期货市场的经济体系的”。期货市场具有规避风险、预测发行价格的功能;对于期货投机者来说,期货交易还具备进行风险投资、获取风险收益的功能,因此成为了一种重要的投资工具;期货市场能够合理利用社会闲散资金,在市场经济中发挥着越来越重要的作用^[1],对期货市场价格进行较为精确的预测,对于企业决策和个人投资都将具有重要的指导和参考意义。传统的时间序列预测方法有移动平均法、指数平滑法、趋势延伸法、回归预测法、ARIMA 模型等,应用传统的预测方法可以预测变量在一段时间内的大致变化趋势,但需要较多的前提条件,比如预测对象的变化要平缓、需要知道多种参数以及各参数在不同情况下的修正处理。而期货市场

的价格受到许多因素的共同影响,这些影响因素往往具有非线性性和不确定性,由此造成的价格波动具有十分显著的时变性和随机性。利用传统预测方法来预测非线性的数据时,结果误差会大大增加^[2]。

深度学习算法源于生物学对人类大脑进一步的认知,将神经-中枢-大脑的工作原理设计成一个不断迭代、不断抽象的过程,从而得到最优数据特征表示的机器学习算法。深度学习算法从原始输入信号开始,先做底层抽象,然后不断迭代完成高层的抽象,由此构成这类算法的基本框架,其处理能力已经在某些识别任务上达到了近乎人类的水平。相比于最初的神经网络模型,深度学习算法提升了寻找最优特征表达的学习效率和速度。

深度学习算法的一种常用模型是深度信念网络(Deep Belief Networks, DBN)。深度信念网络可以作为深度神经网络的预训练环节,并为整个网络提供初始的权重,再使用反向

本文受国家自然科学基金面上项目(71473283, 71373295)资助。

陈俊华(1977—),男,博士,副教授,硕士生导师,主要研究方向为复杂网络算法的金融学应用, E-mail: junhuachen@cufe.edu.cn; 郝彦惠(1993—),男,硕士,主要研究方向为神经网络、数据挖掘; 郑丁文(1992—),男,硕士,主要研究方向为卷积神经网络; 陈思宇(1994—),女,硕士,主要研究方向为社交网络。

传播(BP)或者其他判定算法作为调整优化的手段。这在训练数据较少时很有价值,因为不恰当的初始权重会显著干扰预测模型的最终性能,而在预训练环节得到的权重在权重空间中比随机权重更接近最优权重,这不仅能够提升模型的整体性能,也可以加快调优阶段的收敛速度,提高模型的效率。

深度信念网络克服了前馈神经网络容易陷入局部最小的缺陷,同时能够收敛到全局最优,从而获得更精确的预测结果。考虑到训练时间较长,在训练阶段,将其与共轭梯度法结合起来,以加速训练过程^[3]。

2 DBN 模型的原理

深度信念网络是一个贝叶斯概率生成模型,由多层随机隐藏变量组成,其结构如图 1 所示。上面的两层具有无向对称连接,相互之间的连接没有指向性,第三层得到来自上一层的自上而下的有向连接,最底层单元构成可视层。深度信念网络就是在靠近可视层的部分使用贝叶斯信念网络(即有向图模型),同时在最远离可视层的部分使用受限玻尔兹曼机(RBM)的复合结构。




图 1 DBN 网络结构

2.1 受限的 Boltzmann 机

受限的 Boltzmann 机(Restricted Boltzmann Machine, RBM),是一类可通过输入数据集进行学习概率分布的随机生成神经网络,是一种玻尔兹曼机的变体,但是其限定模型必须是二分图^[4]。RBM 的结构如图 2 所示。




图 2 RBM 的结构

RBM 具有与 Boltzmann 机相似的结构,有两种神经元:可视层和隐藏层。可视层包括了网络的输入和输出。可视层与输入层各个结点之间有双向的对称连接,即 $v_{ij} = v_{ji}$,但是同一层的神经元之间没有相互连接,这一点与 Boltzmann 机的结构不同。隐藏层,可视作一组特征提取器,对应训练结果,该层被训练用来提取在可视层中表现出来的高阶数据相关性。每个神经元都有二值的状态,可视结点的状态用 w 表示,隐藏结点的状态用 g 表示。结点的状态由式(1)和式(2)决定。

$$p_{wi} = p(w_i = 1) = \frac{1}{1 + \exp(-\sum_j v_{ij} g_j)} \quad (1)$$

$$p_{gj} = p(g_j = 1) = \frac{1}{1 + \exp(-\sum_i v_{ij} w_i)} \quad (2)$$

2.2 连续型受限的 Boltzmann 机(CRBM)

为了解决经典的 RBM 只能处理二值数据的问题,Chen 等^[5]提出了一种连续型受限的 Boltzmann 机(Continuous Restricted Boltzmann Machine, CRBM)。由于 CRBM 的神经元具有连续的状态值,因此该模型具有处理实值数据的能力。同时,他们还给出了一种简单可靠的学习算法,该算法与 RBM 的学习算法相似。考虑到金融市场数据是连续的实值数据,我们在相关预测的研究中采用了 CRBM,而没有使用经典的 RBM^[6]。

对于 CRBM,神经元 j 的状态用 c_j 表示,与神经元 j 相连的神经元的状态记为 $\{c_i\}$ 。神经元的状态 c_j 按式(3)来确定:

$$c_j = \varphi_j(\sum_i v_{ij} c_i + \sigma \cdot N_j(0, 1)) \quad (3)$$

其中

$$\varphi_j(x_j) = \theta_L + (\theta_H - \theta_L) \cdot \frac{1}{1 + e^{(-a_j x_j)}} \quad (4)$$

其中, $N_j(0, 1)$ 表示一个均值为 0、方差为 1 的高斯随机变量, σ 是一个 0 到 1 之间的常数。 $\varphi_j(x)$ 是一个 s 型函数, θ_L 和 θ_H 分别是函数的下界和上界。参数 a_j 是一个噪声控制参数,它控制着 s 型函数的斜率,从而影响着神经元随机表现的程度和性质。权重 v_{ij} 和 a_j 的更新公式如下:

$$\Delta v_{ij} = \eta_w (\langle s_i s_j \rangle - \langle s_i' s_j' \rangle) \quad (5)$$

$$\Delta a_j = \frac{\eta_a}{a_j^2} (\langle s_j^2 \rangle - \langle s_j'^2 \rangle) \quad (6)$$

其中, η_w 是 η_a 学习率, s_j' 表示对结点 j 的状态的再次更新, $\langle \cdot \rangle$ 表示全部样本的平均值。偏差的更新公式与式(5)相似^[7]。

3 DBN 的学习算法

Hinton 等按照构成 DBN 的每个部分对其学习过程进行训练,提出了一个快速且有效的学习算法:一层接一层地持续训练。这种算法的基本思想是:随机选择样本并直接输入到学习网络来训练第一个隐藏层,使得隐藏层的神经元能够把握到输入数据所特有的重要特征,该隐藏层作为 DBN 的第一个隐藏层。将通过训练得到的特征作为输入数据,并将之用于训练第二个隐藏层。上述训练过程可以看作是学习特征的特征,一直持续到规定层数的隐藏层都被训练过时停止。由于金融数据都是连续的实值数据,我们使用 CRBM 来构建用于预测金融价格的 DBN,使之能够处理实值数据^[8]。

3.1 连续型的学习算法

第 1 步 初始化,设结点的状态用 $\{c_i\}$ 表示, c_j 表示与结点 i 相连的结点 j 的状态,随机初始化各个结点的状态作为权重矩阵 W 。

第 2 步 随机选择一个训练样本输入到网络中,根据式(3)更新第一个隐藏层中各个结点的状态 c_j 。

第 3 步 根据第 2 步求出的隐藏结点状态 c_j 更新可视结点的状态 c_i' :

$$c_i' = \varphi_j(\sum_j v_{ij} c_j + \sigma \cdot N_i(0,1)) \quad (7)$$

其中, φ_j 是按照式(4)定义的函数。

第 4 步 根据步骤 3 计算得到可视结点的状态 c_i' , 再次更新隐藏层状态, 记为 c_j' :

$$c_j' = \varphi_j(\sum_i v_{ij} c_i' + \sigma \cdot N_i(0,1)) \quad (8)$$

第 5 步 随机选择下一个训练样本, 转到步骤 2, 若本轮中训练集的样本都被输入过, 则根据式(5)和式(6)分别计算权重的改变量 Δv_{ij} 、噪声控制参数的改变量 Δa_j , 更新权重矩阵和噪声控制数:

$$v_{ij}(k+1) = v_{ij}(k) + \Delta v_{ij} \quad (9)$$

$$a_j(k+1) = a_j(k) + \Delta a_j \quad (10)$$

第 6 步 转到步骤 2, 进入下一轮训练, 直到达到预先设定的次数或者权重矩阵的变化足够小(即 $\|\Delta(k)\| < \epsilon$)时, 第一个训练结束。

第 7 步 将第一个 CRBM 得到的输出作为第二个 CRBM 的输入, 重复上面的步骤 1—步骤 6, 训练第二个 CRBM, 直到构成 DBN 的所有 CRBM 都训练完毕时, DBN 的训练结束。

4 小波变换与 DBN 模型

近年来, 小波理论发展迅速并被广泛应用于许多领域, 其中小波去噪的表现尤为突出。小波变换是一种新的变换分析方法, 它继承和发展了短时傅立叶变换局部化的思想, 同时也克服了窗口大小不随频率变化等缺点, 能够提供一个随频率改变的“时间-频率”窗口, 是进行信号时频分析和处理的理想工具。它的主要特点是通过变换能够充分突出问题某些方面的特征, 能对时间(空间)频率的局部化进行分析, 通过伸缩平移运算对信号(函数)逐步进行多尺度的细化, 最终达到高频处时间细分、低频处频率细分, 自动适应时频信号分析的要求, 从而可聚焦到信号的任意一个细节, 解决了傅立叶变换的困难问题, 成为了继傅立叶变换以后在科学方法上的又一重大突破^[9]。

小波去噪理论的思想主要是通过对含噪信号进行小波时频域变换得到小波系数, 然后对其进行相应的处理, 去除噪声的干扰; 对处理之后的小波系数做小波逆变换, 得到去噪后的信号, 从而改善信号的质量, 以便提供更加准确、无干扰的信号信息。

4.1 小波变换与离散小波变换

小波变换和傅立叶变换的出发点都是将信号表示成基函数的线性组合; 所不同的是傅立叶变换采用时间是属于 $(-\infty, +\infty)$ 的谐波函数 e^{inx} 作为基函数, 而小波变换的基函数是具有紧支集的母函数 $\Psi_{(t)}$, 通过对母函数 $\Psi_{(t)}$ 进行伸缩和平移得到一个小波序列:

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \Psi\left(\frac{t-b}{a}\right) \quad (11)$$

其中, $a, b \in R, a \neq 0, a$ 是伸缩因子, b 是平移因子。

任意函数 $f(t) \in L^2(R)$ 的连续小波变换为:

$$WT_{\Psi}\{x\}(a,b) = \int_{-\infty}^{+\infty} f(t) \Psi_{a,b}(t) dt \quad (12)$$

当函数 $f(t)$ 为离散时间序列时, 要求参数 $a > 1, b > 0$, 以

将尺度和平移离散化为 $(a^i, ja^ib), i, j \in Z$ (整数集合)。针对尺度空间的一个点 (a^i, ja^ib) , 可以有一个离散小波子函数:

$$\Psi_{i,j}(t) = a^{-i/2} \Psi(a^{-i}t - ja^ib) \quad (13)$$

这样, 便得到针对 $f(t)$ 的离散小波变化:

$$WT_{\Psi}\{x\}(i,j) = \sum_{t=-\infty}^{+\infty} f(t) \Psi_{i,j}(t) \quad (14)$$

从而, 原始时间序列 $f(t)$ 就可以分解成离散小波变化的逆变换的合成:

$$f(t) = \sum_{m \in Z} \sum_{n \in Z} WT_{\Psi}\{x\}(i,j) \cdot \Psi_{i,j}(t) \quad (15)$$

一个级别 i 对应一个时间尺度 a^i , 在这时间尺度上, 我们得到一个小波变换序列:

$$\{WT_{\Psi}\{x\}(i,j) = \langle x, \Psi_{i,j} \rangle, j=0,1,2,\dots,t\} \quad (16)$$

其中, 假设 t 为最后已知时间, $t+1$ 为最近要预测的未来时间点^[10]。

4.2 小波变换 Mallat 算法的实现

Mallat 算法是 1989 年由 Mallat 提出的一种快速小波变换算法的。Mallat 算法的分解公式为:

$$p_{j+1,k} = \sum_{n \in Z} p_{j,n} \bar{h}[n-2k], k \in Z \quad (17)$$

$$q_{j+1,k} = \sum_{n \in Z} p_{j,n} \bar{g}[n-2k], k \in Z \quad (18)$$

其中, $p_{j+1,k}, q_{j+1,k}$ 分别为第 $j+1$ 层小波系数的低频分量和高频分量; $p_{j,n}$ 为第 j 层小波系数的低频分量; $\bar{h}[n-2k], \bar{g}[n-2k]$ 分别为低通和高通滤波器系数的共轭值。

Mallat 算法的快速重构公式为:

$$p_{j,k} = \sum_{n \in Z} p_{j+1,n} h[k-2n] + \sum_{n \in Z} q_{j+1,n} g[k-2n], k \in Z \quad (19)$$

Mallat 算法各层分解公式实现的是将离散化的输入信号序列或上一层小波系数的低频分量与低通滤波器 $h(k)$ 或高通滤波器 $g(k)$ 进行卷积运算, 从而得到下一层小波系数的低频分量与高频分量; Mallat 算法的重构过程则是分解过程的逆运算。

4.3 小波与 DBN 组合模型

小波与 DBN 组合预测模型的主要思想是将原始数据经过小波降噪处理, 得到的数据样本用于训练 DBN 模型, 通过将训练好的小波与 DBN 模型组合起来进行预测^[11]。其结构图如图 3 所示。



图 3 基于小波与 DBN 的负荷预测模型

小波与 DBN 的建模与预测步骤如下:

1) 数据准备。

2) 小波降噪处理。对直接采集到的数据先进行小波去噪处理, 然后将其分为训练数据集和预测数据集。

3) 构建 DBN 与梯度下降算法结合的预测模型。用训练数据集对 DBN 模型进行训练, 为了加快训练速度, 计算出实际输出与目标输出的误差, 这一误差可以表示成一个与连接权重 W 相关的函数, 用梯度下降算法调整权重矩阵, 使该误差函数最小, 从而得到小波与 DBN 的负荷组合预测模型。

4) 预测阶段。将训练样本输入到小波与 DBN 组合预测模型, 并将其按时间顺序排列后组成预测值的时间序列。

5 基于 DBN 的汇率预测

石油作为现代社会的重要工业原料,牵动着经济的方方面面,对于稳定世界经济具有重要的意义。自从 20 世纪 70 年代的石油大危机以来,石油就成为了国际上价格波动最为剧烈的商品之一^[12]。

原油期货是最重要的石油期货品种。目前,世界上重要的原油期货合约有 4 个:纽约商业交易所的轻质低硫原油即“西德克萨斯中质油”期货合约、高硫原油期货合约、伦敦国际石油交易所的布伦特原油期货合约、新加坡交易所的迪拜酸性原油期货合约。这些主要的期货市场对于稳定当地乃至全球市场经济,规避企业风险起着积极的作用。本文以布伦特原油期货合约价格为例,利用 DBN 深度学习模型进行金融市场价格预测。图 4 为布伦特原油期货价格走势,数据来源于 wind 数据库。




图 4 布伦特原油期货价格走势

5.1 数据背景介绍

国际原油价格在 20 世纪 80 年代和 90 年代都呈现平稳的走势,只是在 1990 年 3 月—10 月出现了油价瞬间暴涨,但随即又回落至平稳价位。从 2003 年开始,受伊拉克战争的影响,国际原油价格开始不断攀升;2005 年墨西哥遭遇了“卡特里”飓风,国际原油价格首次突破 70 美元/桶;2007 年 11 月开始,受到 OPEC 减产的决定、中国原油需求强劲、美联储大幅降息、美元贬值、投机商炒涨情绪显著等因素共同影响,原油价格加速上扬;2008 年更是出现大幅飙升。但在 2009 年,由于国际金融危机的冲击,国际油价开始跳水回落。2009 年第二季度,全球经济逐渐从金融危机的阴霾中摆脱,此阶段美联储释放大量流动性,美元汇率走低,对油价支撑明显。OPEC 限产、2011 年利比亚战乱和 2012 年伊朗石油禁运等导致油价再度攀高,油价在坠入低谷后迅速反弹,并升至高位区间。由于沙特及 OPEC 组织坚持不减产的立场,导致了原油供应充裕、需求疲软,交易商看空情绪不断增强,多头逃离,再加上美元强势上扬、全球经济减速,中欧均复苏缓慢,美国经济独木难支,从 2014 年下半年开始,油价自高位转头跳水。2015 年,油价再度跌回 50~70 美元的区间,回到了十年前的价格水平。

5.2 实验过程

5.2.1 工作准备

本文收集了从 1988 年至今的布伦特原油期货结算价历史数据,共计 7470 条。可以通过图 4 中的历史数据走势看出,原油期货的价格具有明显的时变性和非线性,尤其是 2000 年以来,原油期货价格变化十分剧烈且随机。

5.2.2 数据处理

将总样本的 80% (共 5796 条) 作为训练数据集,其余 20% (共 1674 条) 作为测试数据集。为方便不同量级的数据

进行比较和加权,提高算法精度,同时为了能使迭代算法快速收敛,对数据进行了归一化处理,将其转化为无量纲的纯数值:将全部数据除以数据中的最大值,这样就可以将数据统一映射到 [0,1] 区间上;学习和预测的结果再乘以最大值即可还原。

5.2.3 利用训练数据集构建 DBN 模型

采用实验的方式来确定 DBN 的最优网络结构,分为 3 方面的内容:1) 确定输入层的结点个数;2) 确定各个隐藏层的结点个数;3) 确定隐藏层的层数^[13]。

隐藏层结点数没有具体的规则可循,一般根据经验得出一个大致范围,然后经过多次试算来选取隐藏层结点数。以下是从事神经网络研究的资深科学家提出的计算隐藏层结点数的几个经验公式:

$$m = \sqrt{n+o} + a \quad (20)$$

$$m = lbn \quad (21)$$

$$m = \sqrt{n \times o} \quad (22)$$

其中, m 为隐藏层结点数, n 为输入结点数, o 为输出结点数, a 为 1~10 之间的常数。本实验经过不断的训练和调试,确定输入层有 30 个结点;隐藏层共两层,分别有 20 个结点和 5 个结点。

5.2.4 训练 CRMB 更新 DBN 模型中的权重

DBN 模型中还涉及到一些其他参数,这些参数的取值可能也会影响到网络的预测结果,因此我们对这些参数的设定也做了研究。将学习速率设定为 0.1,迭代次数设为 200。通过以上的过程,构建出了适用于原油期货价格预测的 DBN 模型。图 5 给出数据学习过程中在 RMSE 达到 0.026358 时真实价格和预测价格之间的拟合情况。




图 5 训练阶段的预测价格与真实价格

5.2.5 预测阶段及效果评价

将测试数据输入到 DBN 预测模型,计算得到期货价格的预测值,将预测值按时间顺序排列,组成预测值的时间序列。将模型预测的结果与实际期货价格情况进行对比分析,然后不断调整前面步骤的参数,直到最后结果的偏差在设定的标准之内。在学习之后,运用构建的 DBN 模型进行预测,图 6 给出了预测价格与真实价格之间的拟合关系。




图 6 测试阶段的真实价格与预测价格

- [J]. Expert Systems with Applications, 2011, 38(5): 5373-5383.
- [14] LIU J, et al. Improving nuclear safeguards evaluation through enhanced belief rule-based inference methodology [J]. International Journal of Nuclear Knowledge Management, 2009, 3(3): 312-339.
- [15] 常瑞, 王红卫, 杨剑波. 基于梯度法和二分法的置信规则库参数训练方法[J]. 系统工程, 2007, 25(增刊): 287-291.
- [16] LIU J, et al. Optimization algorithm for learning consistent belief rule base from examples [J]. Journal of Global Optimization, 2011, 51(2): 255-270.
- [17] ZHOU Z J, et al. A sequential learning algorithm for online constructing belief rule based systems [J]. Expert Systems with Applications, 2010, 37(2): 1790-1799.
- [18] 李彬, 王红卫, 杨剑波, 等. 置信规则库结构识别的置信 K 均值聚类算法[J]. 系统工程, 2011(5): 85-91.
- [19] BEZDEK J C. Pattern recognition with fuzzy objective function algorithms [M]. New York: Plenum Press, 1981.
- [20] HOLT C C, et al. A linear decision rule for production and employment scheduling [J]. Management Science, 1955, 2(1): 1-30.
- [21] PICCOLO D. A distance measure for classifying ARIMA models [J]. Journal of Time, 1990, 11(2): 153-164.
- [22] WANG N, BLOSTEIN S. Adaptive zero-padding OFDM over frequency-selective multipath channels [J]. Eurasip Journal on Advances in Signal Processing, 2004, 2004(10): 1478-1488.
- [23] D'URSO P, GIOVANNI L D, MASSARI R. Time series clustering by a robust autoregressive metric with application to air pollution [J]. Chemometrics & Intelligent Laboratory Systems, 2015, 141: 107-124.
- [24] D'URSO P, LALLO D D, MAHARAJ E A. Autoregressive model-based fuzzy clustering and its application for detecting information redundancy in air pollution monitoring networks [J]. Soft Computing, 2013, 17(1): 83-131.
- [25] 刘宇宏, 王士同, 徐红林. 基于 AR 模型的动态模糊聚类算法 [J]. 计算机工程与设计, 2008, 29(1): 144-147, 159.
- [26] 吕志军, 王照飞, 谢福鼎, 等. 基于 FCM 聚类的时间序列模糊关联规则挖掘 [J]. 大连理工大学学报, 2010, 50(5): 806-810.
- [27] 罗艺, 张韬, 李晓松. 基于模糊 C 均值聚类算法的模糊时间序列分析在戊肝发病率预测中的应用初探 [J]. 四川大学学报 (医学版), 2016, 47(3): 406-410.
- [28] 肖瑞, 刘国华. 基于趋势的时间序列相似性度量和聚类研究 [J]. 计算机应用研究, 2014, 31(9): 2600-2605.
- [29] 邵丹, 陈平雁. 模糊 C 均值聚类在时间序列分析中的应用 [J]. 中国卫生统计, 2009, 26(2): 166-167, 170.
- [30] 杨隆浩, 傅仰耿, 吴英杰. 面向最佳决策结构的置信规则库结构学习方法 [J]. 计算机科学与探索, 2014, 8(10): 1216-1230.

(上接第 78 页)

5.3 总结

在不断调试 DBN 模型中的参数后, 学习过程中能实现真实数据和预测数据的基本拟合, 使得预测过程中预测值和真实值之间的 RMSE 达到了 0.0033838, 预测效果良好。

根据预测效果来看, 在整个预测过程中, 预测准确率呈现逐渐上升的趋势, 后期预测值与真实值的拟合程度良好。虽然在样本数据快速变化时拟合效果稍有偏离, 但没有陷入局部最小的情况。

结束语 针对目前金融时序数据分析的复杂性和不确定性等问题, 利用 DBN 深度学习方法对金融大数据进行了建模和分析, 得到金融数据的走势, 并对走势进行了定量分析, 为实际的预测和决策提供了重要的参考。实验结果表明, 基于 DBN 深度学习的期货市场价格预测建模与决策在较长时间内具有可行性。然而, 影响期货市场价格的因素错综复杂, 如何应对突发事件对原油期货价格的影响, 提高预测模型的泛化能力, 是值得进一步研究的重要内容。

参考文献

- [1] 张屹山, 方毅, 黄琨. 中国期货市场功能及国际影响的实证研究 [J]. 管理世界, 2006(4): 28-34.
- [2] RYDER S A, HE Q, SI J, et al. Discussion of Prediction of top-oil temperature for transformers using neural networks and closure [C] // IEEE Transactions on Power Delivery. 2001: 825-826.
- [3] 常松, 何建敏. 基于小波包和神经网络的股票价格预测模型 [J]. 中国管理科学, 2001, 9(5): 9-16.
- [4] GEOFFREY E H, SIMON O, YEE-WHYE T. A fast learning algorithm for deep belief nets [J]. Neural Computation, 2006, 18(7): 1527-1554.
- [5] CHEN H, MURRAY A F. Continuous restricted Boltzmann machine with an implementable training algorithm [J]. IEEE Proceedings-Vision, Image and Signal Processing, 2003, 150(3): 153-158.
- [6] MURRAY A F. Novelty detection using products of simple experts—a potential architecture for embedded systems [J]. Neural Networks, 2001, 14(9): 1257-1264.
- [7] CHEN H, MURRAY A. A Continuous Restricted Boltzmann Machine with a Hardware-Amenable Learning Algorithm [C] // Dorronsoro J R, ed. Artificial Neural Networks (ICANN 2002). Springer, Berlin Heidelberg, 2002.
- [8] ZOU M, SUZANNE D C. A new dynamic Bayesian network (DBN) approach for identifying gene regulatory networks from time course microarray data [J]. Bioinformatics, 2005, 21(1): 71-79.
- [9] CHEN Y, et al. Short-Term Load Forecasting: Similar Day-Based Wavelet Neural Networks [J]. IEEE Transactions on Power Systems, 2010, 25(1): 322-330.
- [10] 郭彤颖, 吴成东, 曲道奎. 小波变换理论应用进展 [J]. 信息与控制, 2004, 33(1): 67-71.
- [11] WU J. Wavelet domain denoising method based on multistage median filtering [J]. The Journal of China Universities of Posts and Telecommunications, 2013, 20(2): 113-119.
- [12] 赵选民, 李丰. 原油期货价格影响因素实证分析 [J]. 商场现代化, 2007(1): 61-62.
- [13] ZHANG G Q, HU M Y. Neural network forecasting of the British Pound/US Dollar exchange rate [J]. Omega, 1998, 26(4): 495-506.