



的预测方法. 组合模型展现出了更大的优势. 本文使用粒子群和动态学习率优化 BP 神经网络模型, 结合支持向量机模型对农产品物价进行预测, 将两组预测结果使用优化的 BP 神经网络进行组合得到预测结果, 提高模型的泛化能力和预测准确度.

## 2 BP-SVR-BP 组合模型

### 2.1 组合模型组合方式

组合模型是利用两种或者两种以上的模型, 分别对实际问题进行模型训练, 将结果使用权重进行组合, 得到最终结果的过程. 组合模型目标就是利用一组最优权重系数, 对单独模型结果进行加权求值, 使得结果

更加接近真实值.

目前, 单一预测模型准确率不高, 考虑因素单一, 没有结合模型的适用场景, 所以本文研究了组合模型. 由于 BP 神经网络能够更好地模拟线性和非线性数据, 适合于长期预测模型的训练; SVR 是基于时间序列的回归预测模型, 适合于短期预测. 将适合中长期预测的 BP 模型和适合于短期预测的 SVR 模型组合, 使模型具有更高的准确率, 更强的泛化能力. 所以选用了优化后的 BP 神经网络模型和 SVR 模型进行组合. 提出了基于 BP-SVR-BP 的组合模型算法, 即 BP 神经网络-支持向量机回归-BP 神经网络的组合模型, 并且使用农产品价格数据对模型进行验证评估.

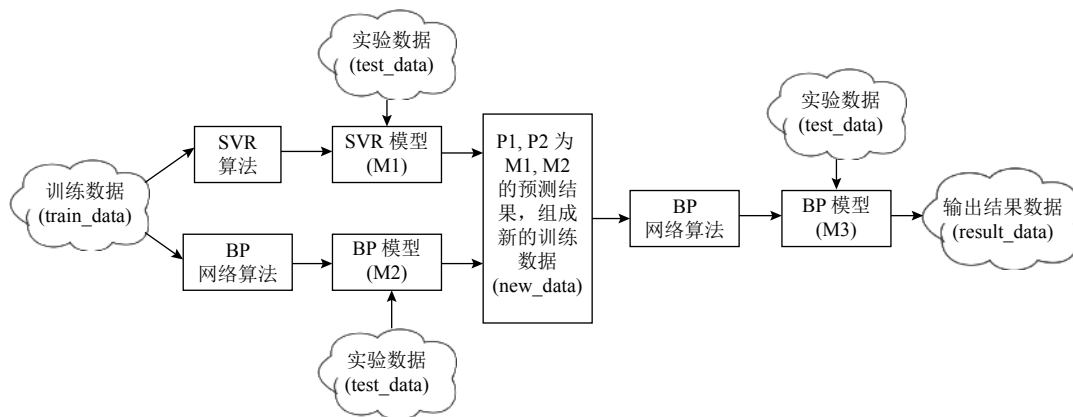


图1 BP-SVR-BP 组合模型

图1为BP-SVR-BP组合模型的结构图. 第一步将经过数据预处理的训练集数据 (train\_data) 输入到 SVR 算法中, 经过训练, 得到 SVR 模型 (M1); 同时将训练集数据输入到第一轮的 BP 神经网络算法中, 经过训练, 得到 BP 神经网络模型 (M2). 第二步将实验数据或者称之为测试数据 (test\_data) 输入到 SVR 和 BP 模型中, 得到两组实验结果数据 (P1, P2), 将其组成两列数据, 并且将其对应的真实数据 (Price) 加入, 作为第三列, 形如 (P1, P2, Price) 组成第二轮 BP 神经网络算法的训练集数据 (new\_data). 第三步将新的训练集数据 (new\_data) 输入 BP 神经网络算法, 这一步主要是利用 BP 拟合组合模型的权重系数, 寻找最优的权重系数组合. 经过训练, 得到第二轮的 BP 模型 (M3). 第四步将实验数据 (test\_data1) 输入模型 (M3), 得到预测结果, 评价组合模型的预测准确度.

在组合模型中, 第一轮我使用了优化的 BP 神经网络

模型和基于多项式核函数的 SVR 模型, 第二轮使用了优化的 BP 神经网络模型训练组合模型权重系数.

### 2.2 优化 BP 神经网络

本文采用三层结构, 即输入层、隐含层、输出层. 假设输入层  $n$  个节点, 隐含层  $k$  个节点, 输出层 1 个节点.  $X(X_1, X_2, \dots, X_n)$  为输入层输入数据;  $M(M_1, M_2, \dots, M_n)$  为经输入层加权求和的结果, 即隐含层的输入数据;  $N(N_1, N_2, \dots, N_k)$  为隐含层由激活函数求得的结果, 即隐含层的输出数据;  $Z$  为经隐含层加权求和的结果, 即输出层的输入数据;  $Y$  为预测值,  $W$  为各层链接的权值,  $B(B_1, B_2, \dots, B_l)$  表示偏置值.

根据输入  $X$ , 得隐含层的输入为:

$$M_j = \sum_{i=1}^n W_{ij}^{(l)} X_i + B_i^{(l)} \quad (1)$$

其中,  $l$  为层数,  $b$  为偏置值. 则隐含层的输出为:

$$N_j = \psi_1(M_j) = \psi_1 \left( \sum_{i=1}^n W_{ij}^{(l)} X_i + B_j^{(l)} \right) \quad (2)$$

其中,  $\psi_1$  为隐含层 Sigmoid 激活函数,  $j=1, 2, \dots, n$ .

输出层的输入为:

$$Z = \sum_{j=1}^k W_{j1}^{(l)} N_j + B_j^{(l)} \quad (3)$$

输出层的输出为:

$$Y = \psi_2(Z) = \psi_2 \left( \sum_{j=1}^k W_{j1}^{(l)} N_j + B_j^{(l)} \right) \quad (4)$$

由于 BP 神经网络的权值和阈值对价格的预测准确度有一定影响, 可以通过粒子群算法对网络中的权值和阈值进行全局寻优, 合理优化调整. 假设给定  $n$  个粒子:

$p_i = (p_{i1}, p_{i2}, \dots, p_{iD})$  粒子  $i$  的位置  $x_i = (x_{i1}, x_{i2}, \dots, x_{iD})$ ; 粒子  $i$  的速度  $v_i = (v_{i1}, v_{i2}, \dots, v_{iD})$ ; 粒子  $i$  经过的历史最优位置; 粒子群整体经历的最优位置:  $g = (g_1, g_2, \dots, g_D)$ ; 则 PSO 速度更新公式为:

$$v_{iD}^{k+1} = \omega v_{iD}^k + c_1 r_1 (p_{iD}^k - x_{iD}^k) + c_2 r_2 (p_{gD}^k - x_{iD}^k) \quad (5)$$

位置更新为:

$$x_{iD}^{k+1} = x_{iD}^k + v_{iD}^{k+1} \quad (6)$$

$k$  为: 第  $k$  次迭代;  $c_1, c_2$  为学习率变量,  $r_1, r_2$  为  $[0, 1]$  范围内的随机数,  $\omega$  为粒子群权重变量.

假设输入层、隐含层、输出层节点数为  $L1\_Num, L2\_Num, L3\_Num$ . 种群参数初始化为: 种群数目  $N$ ; 维度为  $D=L1\_Num \times L2\_Num + L2\_Num \times L3\_Num$ ; 使用真实值与预测值的均方误差作为粒子群适应度函数:

$$e = \frac{1}{n} \sum_{j=1}^n (O_j - Y_j)^2 \quad (7)$$

其中,  $O_j$  为第  $j$  个记录的真实值,  $Y_j$  为第  $j$  个记录的预测值. 得到的最优位置数据, 分配到网络中训练.

BP 神经网络的学习率对网络的收敛速度有影响.  $\eta$  过大, 收敛速度过快;  $\eta$  过小, 导致收敛速度过慢. 因此需采用一种动态改变的学习速率  $\eta$ .

$$\eta(k) = \begin{cases} 1.05\eta(k-1), & E(k+1) < E(k) \\ 0.75\eta(k-1), & E(k+1) > E(k) \\ \eta(k), & E(k+1) = E(k) \end{cases} \quad (8)$$

### 2.3 支持向量回归机 (SVR) 模型

支持向量回归机 (SVR) 模型是在 SVM 基础上, 加

以改进, 可以用于基于回归的预测模型. 模型主要是通过核函数将数据映射到一个高维空间, 然后在高维空间寻找一个最优的超平面, 使所有点到该平面的距离误差最小. 这个函数即是 SVR 函数模型. SVR 函数为:

$$f(X) = W^T \phi(X) + b \quad (9)$$

其中,  $W$  为权值向量;  $\phi(X)$  为映射函数;  $b$  为常数. 在此基础增加松弛度变量  $\xi_i$  和  $\hat{\xi}_i$ , 则式子可转化为:

$$\min_{w, \xi_i, \hat{\xi}_i} \left( \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m (\xi_i + \hat{\xi}_i) \right) \quad (10)$$

同时必须满足:

$$\begin{cases} f(x_i) - y_i + b \leq \varepsilon + \xi_i \\ y_i - f(x_i) - b \leq \varepsilon + \hat{\xi}_i \\ \xi_i \geq 0, \hat{\xi}_i \geq 0, i = 1, 2, \dots, m \end{cases} \quad (11)$$

## 3 训练组合模型

### 3.1 数据集

数据选用 2009-2016 年上海农产品日价格数据作为实验数据.




图2 构建模型流程图

### 3.2 数据预处理

选用数据的平均交易价格作为预测目标, 数据发布时间、最低交易价格、最高交易价格、最高温度、最低温度作为模型输入数据, 训练模型.

(1) 将数据发布时间转换为 YYMMDD 的时间格式, 例如 2016/6/11 转换为 20160611.

(2) 采用前后  $k$  个数据的平均值填充缺失值.

(3) 采用 MIN-MAX 方法对特征数据归一化.

### 3.3 组合模型训练

(1) 预处理之后的数据, 选用集合数据 (train\_data) 的 70% 作为训练数据 (Train1), train\_data 的 30% 的数据作为测试数据 (Test1). 将 Train1 数据分别输入到 SVR 算法和 BP 算法中训练出 SVR 模型 (M1) 和 BP 模型 (M2). 将 Test1 输入到 M1 和 M2 模型中, 得到两组预测结果 (P1, P2), 和真实数据 (Price) 组成三列数据 (train\_data2), 形如 (P1, P2, Price). 将 train\_data2 的 80% 作为训练集 (Train2), train\_data2 的 20% 作为测试集 (Test2), Train2 训练集训练 BP 模型, 得到最优权重系数组合, 得到模型 M3. 将 Test2 输入 M3 模型得到预测结果值.

(2) 对 BP 神经网络训练, 选择最优隐含层节点数目. 使用均方根误差 (RMSE) 衡量真实值和预测值之间的准确率, 如图 3.

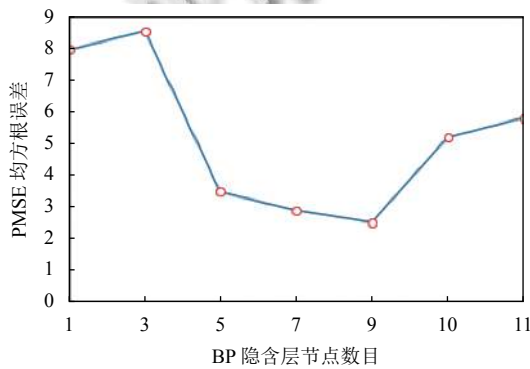


图 3 隐藏层节点数-RMSE 图

根据图 3, BP 隐含层节点数目为 9.

(3) SVR 模型, 选用多项式核函数 (Poly).

## 4 实验结果与分析

### 4.1 与单一模型对比分析

本文基于 BP-SVR-BP 组合模型, 第一个 BP 网络模型使用了 5 个节点的输入层, 9 个节点的隐含层, 1 个节点的输出层, 网络权值和阈值使用粒子群算法进行全局优化, 加以自适应动态调整学习率; SVR 选用多项式核函数进行训练; 第二个 BP 神经网络使用 2 个节点的输入层, 5 个节点的隐含层, 1 个节点的输出层. 预测结果如图 4.

图 4 描绘了时间与价格预测值的折线图, 从图中可以得出 BP 神经网络, SVR 模型, BP-SVR-BP 模型,

总体趋势相近, 但 BP, SVR 局部存在较大差距, BP-SVR-BP 组合模型局部更符合价格数据趋势. 将折线图放大, 如图 5 所示.




图 4 时间-价格图




图 5 时间-价格图

从图 5 中, 可以得出, SVR 模型预测的值离真实值曲线最远, BP 神经网络次之, BP-SVR-BP 模型最近, 说明 BP-SVR-BP 模型的预测准确度最高, 所以 BP-SVR-BP 预测准确率上优于单一的 BP, SVR 模型.

为了更加准确地评价三个预测模型, 采用量化体系进行评价. 采用 MAE, MSE, RMSE 进行量化评价.

测得的结果见表 1.

表 1 单一模型对比

模型	MAE(%)	MSE(%)	RMSE(%)
BP 模型	3.3815	0.1504	3.87799
SVR 模型	9.0615	0.8417	9.17422
BP-SVR-BP 模型	1.5744	0.0380	1.94813

从表1中,可以从量化的角度分析得出, BP-SVR-BP模型, MAE, MSE, RMSE 的值都比 BP 和 SVR 模型小, 基于以上综合分析, 得出 BP-SVR-BP 组合预测模型对农产品价格曲线拟合效果更优, 预测准确率更高。

#### 4.2 与组合模型对比分析

前人的研究中, 也尝试了很多的组合模型预测算法。比如使用 BP 神经网络模型和 ARIMA 模型进行组合, 首先通过 ARIMA 模型预测结果值, 接着使用预测值作为参数, 输入 BP 神经网络预测, 得出预测结果, 即为 BP-ARIMA 模型。也有采用 BP 神经网络模型和灰色模型 GM(1, 1) 进行组合, 将结果采用标准差确定组合模型组合权重, 将单一模型结果组合, 得出预测结果, 即为 BP-GM(1, 1) 组合模型。现将提到的预测方法用在农产品价格预测上, 对组合模型进行对比分析, 如图6。




图6 组合模型时间-价格图

图6分别描绘了 BP-SVR-BP、BP-ARIMA、BP-GM(1, 1) 组合模型在农产品价格中的预测结果, 从图中可以清晰地看出, 三种组合模型对农产品价格曲线模拟较好, 都能够比较准确地模拟出农产品价格走势, 和真实农产品价格走势相同, 但是从图6中也可以得出, 三种模型虽然走势相同, 但是准确率上却有差别, BP-SVR-BP 模型描绘的曲线相对于 BP-ARIMA、BP-GM(1, 1) 模型描绘的曲线, 更加逼近真实数据曲线, 即为准确率更高。采用量化体系分析结果如表2。

从表2中, 可以从量化的角度分析, BP-SVR-BP 组合模型的 MAE, MSE, RMSE 值都比 BP-ARIMA、BP-GM(1, 1) 组合模型的小, 所以可以得出 BP-SVR-BP 组合模型的准确率更好, 泛化能力更强, 能够更好地实现

农产品物价的预测。

表2 组合模型对比分析

组合模型	MAE(%)	MSE(%)	RMSE(%)
BP-ARIMA 模型	3.6445	0.1407	3.7518
BP-GM(1, 1) 模型	2.8694	0.0881	2.9671
BP-SVR-BP 模型	1.5744	0.0380	1.94813

## 5 结语

本文提出了基于 BP-SVR-BP 的组合模型, 使用图分析和数据量化分析, 分析了 BP 模型、SVR 模型、BP-SVR-BP 组合模型, 得到组合模型准确率更高, 拟合效果更优。紧接着对常见的组合模型进行了对比分析, 对 BP-SVR-BP 组合模型、BP-ARIMA 组合模型、BP-GM(1, 1) 组合模型三种组合模型进行了图分析和数据量化分析, 得出 BP-SVR-BP 组合模型相对于 BP-ARIMA 和 BP-GM(1, 1) 组合模型准确率更好, 泛化能力更强, 能够较好地实现农产品物价的预测。本方法还有继续需要改进的地方, 比如说, 将对农产品价格产生影响的更多影响因素纳入模型训练中, 对 SVR 核函数进行优化, 对组合模型组合预测结果的加权值进行优化等等。未来将继续对组合模型进行深入研究, 深化改进模型, 得到更优组合。

## 参考文献

- 1 陈咏梅. 基于 BP-ARIMA 组合模型的福建滨海旅游市场规模预测. 厦门理工学院学报, 2018, 26(4): 22-26.
- 2 马健, 盛魁, 董辉. 基于改进型误差函数的复值 BP 神经网络对股票价格的预测研究. 长春师范大学学报, 2018, 37(6): 85-90.
- 3 朱叶, 喻晓玲. 基于组合模型的兵团农产品物流市场需求预测. 塔里木大学学报, 2016, 28(2): 52-60. [doi: 10.3969/j.issn.1009-0568.2016.02.010]
- 4 刘金源, 王寿喜, 李婵. 城市燃气日负荷 PCA-GM-BPNN 组合预测模型. 天然气与石油, 2018, 36(5): 13-19. [doi: 10.3969/j.issn.1006-5539.2018.05.003]
- 5 吴叶, 刘婷婷, 方少勇. 基于 MIV-GA-BP 神经网络的我国棉价预测研究. 棉纺织技术, 2018, 46(7): 77-80. [doi: 10.3969/j.issn.1001-7415.2018.07.020]
- 6 江粉桃. 非线性方法的时间序列组合模型在农产品价格预测中的应用研究[硕士学位论文]. 兰州: 兰州交通大学, 2018.