

Application of Combined Forecasting Model Based on Optimal Weighting Method in Forecast of Housing Price in Haikou City

Jiatong Chen¹, Jiankai Zuo², Cheng Chen¹

¹Aviation Engine Academy, Shenyang Aerospace University, Shenyang Liaoning

²School of Computer Science and Technology, Shenyang Aerospace University, Shenyang Liaoning

Email: 1183362134@qq.com

Received: Nov. 7th, 2018; accepted: Nov. 22nd, 2018; published: Nov. 29th, 2018

Abstract

Aiming at the problem of house price forecasting, a combined forecasting model based on the optimal weighting method was established to forecast the house price. The analysis of two major indicators affecting housing prices and historical information was carried out. BP neural network model and NAR neural network model were established to predict housing prices and the structure of the network was determined by experimental methods. The optimal weighting method is used to establish a nonlinear programming model with the sum of squared errors of the combined forecasting model as the objective function, and the weights corresponding to the two models are determined. Based on the data of housing prices and its influencing factors in Haikou City from 2007 to 2017, the three models are simulated. The test results show that the prediction error of the combined forecasting model is smaller than the single model and more stable than the single model. And the combined forecasting model established in the paper gives the housing price forecast for Haikou in the next five years.

Keywords

House Price Forecast, Combined Forecast, NAR Neural Network, BP Neural Network, Grey Prediction

基于最优加权法的组合预测模型在海口市房价预测中的应用

陈嘉彤¹, 左剑凯², 陈 铖¹

¹沈阳航空航天大学航空发动机学院, 沈阳 辽宁

²沈阳航空航天大学计算机学院, 沈阳 辽宁

Email: 1183362134@qq.com

收稿日期: 2018年11月7日; 录用日期: 2018年11月22日; 发布日期: 2018年11月29日

摘要

针对房价预测问题, 建立了基于最优加权法的组合预测模型对房价进行预测。选取多个主要影响房价的指标和历史信息两个方面分析, 分别建立BP神经网络模型和NAR神经网络模型对房价进行预测, 并通过试验法确定网络的结构。采用最优加权法, 建立以组合预测模型的误差平方和为目标函数的非线性规划模型, 确定了两种模型对应的权值。以海口市2007~2017年的房价及其影响因素数据为基础, 对三种模型进行仿真, 检验结果表明, 组合预测模型的预测误差小于单一模型, 比单一模型的误差更稳定。并由文中建立的组合预测模型, 给出海口市未来五年的房价预测。

关键词

房价预测, 组合预测, NAR神经网络, BP神经网络, 灰色预测

Copyright © 2018 by authors and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着房地产行业的不断发展, 房价作为房地产行业运行的“晴雨表”逐渐受到人们的关注。房价一方面能够影响国民经济发展, 另一方面也会对居民的生活水平产生调节作用, 在市场价格体系中占有重要地位。而房价的预测也是近年来人们关注的一个问题, 针对房价的合理预测对于房价的调控具有重要意义。

针对房价的预测问题, 国内外学者做了很多研究: 张荣艳[1]从房地产需求、房地产供给和宏观经济三个方面入手, 对房价的影响因素进行了灰色关联度分析。并根据主要因素建立 GM(1,4)模型预测了郑州市 2017~2021 年的房价; 高玉明, 张仁津[2]使用遗传算法对 BP 神经网络进行了权值优化, 从而建立了基于遗传算法优化的 BP 神经网络模型对贵阳市 2009~2011 年的房价进行了预测, 得出了比 BP 神经网络更好的结果; 侯普光, 乔泽群[3]将小波分析理论和 ARMA 时间序列模型相结合。利用小波分析对原始数据进行去噪处理, 并对处理后的数据进行平稳性检验和参数估计, 建立 ARIMA 模型预测了太原市 2001~2012 年的房价, 结果较为合理, 同样将 ARIMA 模型应用于房价预测并得出较好结果的还有 Arvydas Jadevicius 和 Simon Huston [4]; 申瑞娜, 曹昶, 樊重俊[5]使用主成分分析对原始数据进行降维处理, 然后建立了支持向量机模型对上海市 2013 年和 2014 年的房价进行预测, 结果相较于 ARIMA 模型来说误差较小。除此之外, 文献[6]-[11]也将不同的方法用在房价的预测中, 并取得较好结果。

以上研究大致集中在两个方面: 一是针对房价数据的时间序列预测, 即根据往年的数据序列对未来进行预测。二是通过分析与被预测指标相关的因素, 并建立影响因素与被预测指标之间的关系, 从而达到预测的目的。但很少有学者将两种方法结合在一起, 即同时考虑历史信息和其他因素对房价的影响。

本文从以上两个角度出发, 分别建立了基于 BP 神经网络的预测模型和 NAR 神经网络预测模型。从

影响因素的角度出发,分析可能会对房价产生影响的因素,并通过BP神经网络拟合了多个指标和房价之间的非线性关系。使用GM(1,1)模型对所有的房价指标进行预测,并将预测结果代入BP神经网络,从而得出房价的预测值。另一方面,从时间序列的角度出发,建立NAR神经网络对房价进行预测。最后使用最优加权方法,根据两种模型的预测误差计算出对应的权值,并以加权求和结果作为最终的预测值。这种方法同时考虑到了历史信息和其他因素的影响作用,预测结果较为合理。

2. 房价影响因素分析及数据选取

房产价格的变化受到很多因素的影响,例如经济发展、国家政策、房产供应与需求等。将影响房价的所有因素考虑进来是不现实的,因此本文在选取指标的时候,既要使所选指标具有代表性,同时还要保证所有指标均可以量化。本文从房产供求关系、社会因素和经济因素三个方面进行考虑,选取房地产开发投资额(A₁)、商品房销售面积(A₂)、GDP(A₃)、城市人均可支配收入(A₄)、平均地价(A₅)和年末户籍人口(A₆)六个指标来衡量房价(A₇)的变化。

本文以国家统计局公开数据中海口市2007年~2017年的数据和中国地价监测网的数据为基础,探究上述指标与房价之间的关系,并对海口市未来的房价进行预测。本文采集的数据见表1。

Table 1. Haikou City Housing Price and Its Impact Indicators Data from 2007 to 2017

表 1. 2007~2017 年海口市房价及其影响指标数据

年份	A ₁ (亿元)	A ₂ (万平方米)	A ₃ (亿元)	A ₄ (元)	A ₅ (元/)	A ₆ (万人)	A ₇ (元/)
2007	59.97	170.46	393.69	12,289	995	152.94	3515.2
2008	76.17	176.29	443.18	14,150	1155	155.82	4533
2009	78.44	191.78	490	15,237	1319	158.27	5344
2010	103.79	209.76	595.1	16,720	2001	160.44	5989.2
2011	144.64	221.8	713.3	19,730	2255	162.39	6634.5
2012	175.66	266.95	818.8	22,331	2876	161.59	6821.2
2013	256.40	338.19	904.64	24,461	3062	163.23	7423
2014	300.47	337.66	1091.7	26,530	3195	165.31	7903
2015	456.39	373.4	1161.96	28,535	3478	164.8	7948
2016	551.29	432.71	1257.67	30,775	3591	167.03	9043
2017	603.25	549.47	1390.4	33,320	3897	171.05	11,989.6

3. 数据预处理

在BP神经网络的房价预测中,不同指标数据所对应的数量级不同,对房价变化的影响也不相同。为了能够使网络预测结果更加精确,本文在建立预测模型之前需要对原始数据进行归一化处理:

$$x_1 = \frac{x_0 - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

其中 x_1 和 x_0 分别表示处理后的数据和原始数据, x_{\max} 和 x_{\min} 分别表示某一指标数据序列中的最大值和最小值。

图1为2007~2017年海口市房价真实值,从图中可以看出,2010年的房价明显高于相邻省份。为了使模型的预测结果更加准确,排除异常值的干扰,本文将该数据剔除,使用线性规划对缺失数据进行补充,并且在模型预测性能检验时,将插值结果作为房价真实值。




Figure 1. Haikou City 2007~2017 house price line chart
图 1. 海口市 2007~2017 年房价折线图

4. 使用 BP 神经网络预测房价

4.1. BP 神经网络模型的建立

BP 神经网络是一种典型的多层前馈神经网络，该网络在训练过程中首先从输入层输入数据，通过信号在隐含层神经元中传播，最终从输出层神经元输出结果。输出结果后根据输出值与真实值的误差进行反向传播，对各神经元的权值进行修正。由此可见，BP 神经网络能够根据预测结果的误差对网络参数进行自我修正，具有非常好的非线性映射能力，能够有效拟合出影响因素与房价之间的关系。

本文所建立的 BP 神经网络输入层节点数为 6，对应房价影响因素的六个指标；输出层节点为 1，对应房价。除此以外，网络的其余参数设置如下：网络训练目标误差等于 10^{-10} ，学习率设置为 0.1，最大训练步数为 10,000，隐含层传递函数和输出层传递函数分别为 `tansig` 函数和 `purelin` 函数。网络的训练函数设置为梯度下降函数 `traingd`。

对于 BP 网络隐藏层的选取，由于目前还没有较为完善的理论，因此本文在这里以一个经验公式作为参考：

$$m = \sqrt{n+1} + a \quad (2)$$

其中 m 表示隐藏层节点数， n 表示输入层节点数， a 表示 [1,12] 之间的正整数。根据公式(2)和本文所选房价影响指标，隐藏层节点数的取值范围取为 [3,15]。为了能够找出隐藏层节点的最优值，本文对每一种情况进行模拟，使用 2007~2017 年的数据对网络进行训练，训练集、验证集和测试集的比例为 7:2:2。训练结束后，再次对所有数据进行仿真，并选取仿真结果误差最小的情况来决定网络的结构。为了能够衡量预测结果的准确度，选取均方误差作为预测性能评价指标：

$$MSE = \frac{1}{n} \sum_{i=1}^n (s_i^1 - s_i^0)^2 \quad (3)$$

其中 n 示被预测数据的个数， s_i^1 和 s_i^0 分别表示预测值和真实值。

考虑到神经网络初始权值的随机性可能会对结果造成一定的影响，每种情况重复进行 5 次模拟，并

以这 5 次模拟的均方误差值的均值作为最后结果。计算结果见表 2 和图 2。

Table 2. Comparison of BP Network Prediction Performances with Different Number of Hidden Layer Nodes

表 2. 不同隐藏层节点数的 BP 网络预测性能比较

隐藏层节点数	均方误差计算结果
3	148847.86
4	105693.77
5	83467.59
6	117866.06
7	199695.86
8	537962.22
9	234702.03
10	196106.28
11	54422.03
12	258791.26
13	51802.95
14	154915.31
15	84857.88

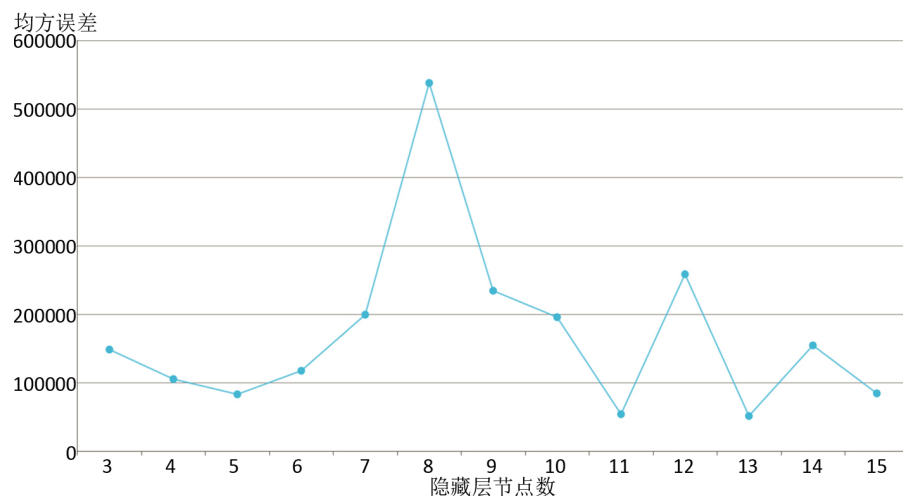


Figure 2. BP network prediction performance line graph with different hidden layer nodes

图 2. 不同隐藏层节点数的 BP 网络预测性能折线图

从结果中可以看出，当隐藏层节点数等于 13 的时候，对应均方误差最小值为 51802.95。因此本文将神经网络隐藏层节点数设置为 13。

4.2. 利用 BP 神经网络进行预测

按照 4.1 所述将神经网络结构设置好之后，利用海口市 2007~2017 年的数据对网络进行训练，其中训练集、验证集和测试集的比例为 7:2:2。本文进行多次测试后选择出预测效果较好的一次作为网络的最终预测结果(见表 3)。

Table 3. BP neural network training results
表 3. BP 神经网络训练结果

年份	房价真实值(元/)	房价预测值(元/)	误差(%)
2007	3515.72	4485.19	27.575
2008	4533	4534.46	0.032
2009	5344	5342.58	-0.027
2010	5989.28	6081.50	1.540
2011	6634.56	6633.92	-0.010
2012	6821.26	6976.44	2.275
2013	7423	7257.81	-2.225
2014	7903	7905.79	0.035
2015	7948	7942.38	-0.071
2016	9043	9047.81	0.053
2017	11,989.55	11,988.09	-0.012

从表 3 中可以看出, 误差最大的年份为 2007 年的 27.575%。其余年份的预测误差均在 3%以内, 最小值可达 0.01%。所以从预测结果来看, BP 神经网络能够较为合理地海口市房价进行预测, 结果具有一定的参考价值。

接下来, 本文使用灰色 GM(1,1)模型对 2018~2022 年所有的房价影响指标进行预测。灰色预测通过从少量的、信息不完全的数据中寻找规律, 并建立灰色微分方程, 最终对事物未来的发展进行预测。考虑到本文所使用的各项指标数据均为 2007 年至 2017 年, 包含数据量较少, 因此适合使用灰色模型进行预测。

使用 GM(1,1)模型进行预测时, 首先需要对原始数据进行一次累加操作得到新序列:

$$t^{(0)} = (t^{(0)}(1), t^{(0)}(2), \dots, t^{(0)}(n)) \quad (4)$$

$$t^{(1)}(k) = \sum_{i=1}^k t^{(0)}(i) \quad (5)$$

其中 $t^{(0)}$ 和 $t^{(1)}$ 分别表示原始数据和经过一次累加后的数据。根据一次累加数据, 建立 GM(1,1)的白化模型:

$$\frac{dx^{(1)}}{dk} + ax^{(1)} = b \quad (6)$$

其中 a 表示“发展系数”, b 表示“灰作用量”。通过对白化方程的变形推导, 得出方程的结果, 再对结果进行一次累减得出最终的预测值。

使用 GM(1,1)模型对房价影响指标进行预测时, 为了能够使预测结果更加准确, 采用滚动预测的方法, 即先使用原始数据完成未来一年内的预测, 将预测值加入到原始数据序列里形成新的序列, 使用新的数据序列完成下一年的预测, 以此类推。最后将灰色预测结果代入训练好的 BP 神经网络中计算出 2018~2022 年的海口市房价预测值。

5. 使用 NAR 神经网络预测房价

5.1. NAR 神经网络预测模型的建立

NAR 神经网络是一种具有延时记忆和反馈功能的动态神经网络, 能够根据历史数据对未来进行预测。由于 NAR 神经网络的输入值为被预测指标前一次或前几次的历史数据, 因此可以用于系统输入未知的时

间序列预测中。

本文将 NAR 神经网络应用于海口市房价走势的预测中。网络相关参数设置如下：目标误差为 10^{-10} ，最大迭代次数为 2000。为了提高网络的训练速度，本文采用 `trainlm` 训练函数对网络进行训练。

对于 NAR 网络延迟阶数和隐藏层节点数的选取，本文同样采用试验的方法，并以预测结果的均方误差作为依据来确定网络结构。延时阶数的取值范围为 1:2 至 1:6，隐藏层节点数的取值范围为 1 至 10。每种情况同样重复进行 5 次试验，以均方误差的平均值作为最后结果，每一种参数设置的检验结果见表 4。同时绘制出均方误差折线图(见图 3)。

Table 4. NAR neural network prediction performance with different parameter settings
表 4. 不同参数设置的 NAR 神经网络预测性能

隐藏层节点数	延时阶数为 1:2	延时阶数为 1:3	延时阶数为 1:4	延时阶数为 1:5	延时阶数为 1:6
1	412,816.84	1,711,314.41	2,142,368.91	3,029,573.65	2,291,175.09
2	583,038.33	1,163,135.70	1,322,083.79	978,957.16	1,785,630.09
3	1,052,999.37	433,136.75	1,120,002.94	2,874,277.21	746,291.09
4	597,078.54	31,941.87	577,148.75	1,361,644.58	1,043,650.06
5	2,134,515.92	155,275.92	352,094.65	707,018.62	1,340,981.25
6	1,155,516.08	6,441,306.01	2,754,042.26	1,314,337.48	518,486.72
7	1,479,148.93	291,768.31	489,330.12	875,432.42	706,411.40
8	1,531,954.74	794,630.83	291,162.93	1,633,335.34	1,221,448.90
9	561,602.14	217,386.48	1,512,196.47	3,988,283.61	1,490,414.25
10	720,542.41	815,551.49	429,679.58	802,904.96	2,415,277.47




Figure 3. NAR network prediction performance line chart with different parameter settings
图 3. 不同参数设置的 NAR 网络预测性能折线图

从试验结果中可以看出，当延时阶数等于 1:3，隐藏层节点数等于 4 的时候，网络具有最小均方误差，等于 31,941.87。因此本文将 NAR 神经网络的延时阶数定为 1:3，隐藏层节点数设置为 4。

5.2. NAR 神经网络的训练和预测

按照 5.1 中的参数设置确定网络结构后，将海口市 2007~2017 年的房价数据代入网络进行训练。其

中网络训练集、验证集与测试集的比例为 7:2:2。NAR 网络训练误差图见表 5 和图 4。

Table 5. NAR neural network training results
表 5. NAR 神经网络训练结果

年份	房价真实值(元/)	房价预测值(元/)	误差(%)
2010	5989.28	5973.05	-0.271
2011	6634.56	6620.24	-0.216
2012	6821.26	6847.94	0.391
2013	7423.00	7432.37	0.126
2014	7903.00	7493.26	-5.185
2015	7948.00	7946.42	-0.020
2016	9043.00	9048.40	0.060
2017	11989.55	11979.58	-0.083




Figure 4. NAR network training error
图 4. NAR 网络训练误差

从表 5 和图 4 可以看出，NAR 神经网络的预测误差均较低，总体预测效果较好。与 BP 神经网络预测结果相比，NAR 神经网络的预测误差更稳定。因此，NAR 神经网络可以用于房价的预测中。

图 5 表示 NAR 神经网络的误差自相关图。模型预测误差的自相关性是用来衡量模型预测结果的重要




Figure 5. Error autocorrelation map
图 5. 误差自相关图

指标, 对于一个理想的预测模型来说, 其结果的自相关性应当是在时间间隔等于 0 的时候自相关性最大, 其余情况均为 0。但是事实上模型的预测结果不可能完全没有误差, 因此当其余情况的自相关性在 95% 的置信区间内的时候认为模型的预测性能良好。从图 5 中可以看出, 除了 0 时间间隔以外, 其他情况的自相关性均在置信区间内, 因此 NAR 神经网络的预测结果较为可靠。

6. 基于最优加权法的预测结果优化

组合预测是指将多种预测方法的预测结果组合到一起, 从而对预测结果的精度提高的方法。最优加权组合预测法是以多个单一预测方法结果的加权总和的误差总和为依据, 对每种预测方法计算对应权值, 使得组合后的预测结果误差最小的方法。目前已有学者将最优加权组合预测法应用到房价的预测中, 如参考文献[12]。

最优加权法首先计算每一种预测方法在每一时刻的预测误差, 假设使用第 i 中预测方法对 t 时刻的数据进行预测, 预测结果为 d_{it} , 以 d_t 表示 t 时刻的真实值, 则 t 时刻每一种模型的预测误差和加权后的预测误差如下:

$$e_{it} = d_{it} - d_t \quad (7)$$

$$e_t = \sum_i w_i e_{it} = \sum_i w_i (d_{it} - d_t) \quad (8)$$

要想使得组合模型的预测误差达到最小, 就要通过对权值进行调整, 从而使所有时刻预测结果的误差平方和达到最小。因此, 以预测结果的误差平方和为目标函数, 建立非线性规划模型:

$$\begin{aligned} \min \quad & \sum_t \left(\sum_i w_i (d_{it} - d_t) \right)^2 \\ \text{s.t.} \quad & \sum_i w_i = 1, w_i \geq 0 \end{aligned} \quad (9)$$

根据以上规划模型便可以求出当预测误差最小时, 每种预测模型所对应的权值。本文以 BP 神经网络和 NAR 神经网络的预测结果为基础, 计算两种预测模型对应的权值。考虑到 NAR 神经网络的延时阶

数为 1:3, 仅能对 2010~2017 年的房价进行预测, 本文仅根据预测模型在 2010~2017 年的预测结果进行计算。最终计算得出 BP 神经网络对应权值等于 0.7385, NAR 神经网络对应权值为 0.2615。使用计算出的权值对两种模型的计算结果进行优化, 并与单一模型的预测误差进行对比(见表 6, 表 7 和图 6)。

Table 6. Combined model results and error comparison
表 6. 组合模型结果和误差对比

年份	房价真实值(元/)	组合预测值(元/)	最优加权预测误差(%)	BP 网络预测误差(%)	NAR 网络预测误差(%)
2010	5989.28	6053.14	-0.466	1.540	-0.271
2011	6634.56	6630.34	-0.054	-0.010	-0.216
2012	6821.26	6942.83	-0.482	2.275	0.391
2013	7423.00	7303.45	0.629	-2.225	0.126
2014	7903.00	7797.91	-1.365	0.035	-5.185
2015	7948.00	7943.43	0.013	-0.071	-0.020
2016	9043.00	9047.97	0.002	0.053	0.060
2017	11989.55	11985.86	-0.019	-0.012	-0.083

Table 7. Average error of three prediction models
表 7. 三种预测模型平均误差

最优加权预测误差(%)	BP 网络预测误差(%)	NAR 网络预测误差(%)
0.38	0.78	0.79




Figure 6. Comparison of prediction errors of three models
图 6. 三种模型预测误差对比

从预测结果中可以看出, 组合预测模型的平均误差比 BP 神经网络和 NAR 神经网络单独预测的误差更小, 各年份的预测误差率比单一模型更稳定。因此基于最优加权法的组合预测模型能够对单一模型的预测结果进行优化。将 BP 网络和 NAR 网络在 2018~2022 年的房价预测结果代入组合模型中, 得出最终房价预测值(见表 8):

Table 8. Combined model prediction result
表 8. 组合模型预测结果

年份	房价预测值(元/)
2018	13234.79
2019	14195.40
2020	14789.28
2021	15899.43
2022	17329.10

7. 结论

从 2010~2017 年的预测结果可以看出, 基于最优加权的组合预测模型的平均预测误差为 0.38%, 小于 BP 神经网络的 0.78% 和 NAR 神经网络的 0.79%。从预测误差折线图可以看出, 两种预测模型经过加权组合后, 误差更加稳定。综上所述, 组合预测模型综合考虑了房价走势和影响因素对未来房价变化的影响, 因此能够做出更加准确的预测, 并且能够在一定程度上抑制单一模型预测误差的波动, 使结果更加稳定。

参考文献

- [1] 张荣艳. 基于 GM(1,N)模型的郑州市房地产价格预测[J]. 数学的实践与认识, 2018, 48(5).
- [2] 高玉明, 张仁津. 基于遗传算法和 BP 神经网络的房价预测分析[J]. 计算机工程, 2014, 40(4): 187-191.
- [3] 侯普光, 乔泽群. 基于小波分析和 ARMA 模型的房价预测研究[J]. 统计与决策, 2014, 30(15).
- [4] Jadedivicius, A. and Huston, S. (2015) ARIMA Modelling of Lithuanian House Price Index. *International Journal of Housing Markets and Analysis*, **8**.
- [5] 申瑞娜, 曹昶, 樊重俊. 基于主成分分析的支持向量机模型对上海房价的预测研究[J]. 数学的实践与认识, 2013, 43(23): 11-16.
- [6] 赵怡爽. 房地产价格影响因素分析及预测[J]. 统计与决策, 2014(13).
- [7] 陆丽丽, 胡斌, 李辉. 中国房价构成与预测的仿真分析[J]. 计算机仿真, 2014, 31(3): 320-328.
- [8] 闫妍, 许伟, 部慧. 基于 TEI_I 方法论的房价预测方法[J]. 系统工程理论与实践, 2007, 27(7): 1-9.
- [9] Yu, W. and Yang, C. (2017) Forecasting House Prices Using Dynamic Model Averaging Approach: Evidence from China. *Economic Modelling*, **61**.
- [10] de La Paz, P.T. and White, M. (2016) The Sources of House Price Change: Identifying Liquidity Shocks to the Housing Market. *Journal of European Real Estate Research*, **9**.
- [11] 谷秀娟, 李超. 基于马尔科夫链的房价预测研究[J]. 消费经济, 2012, 28(5).
- [12] 杨励雅, 邵春福. 基于 BP 神经网络与马尔科夫链的城市轨道交通周边房地产价格的组合预测方法[J]. 吉林大学学报(工学版), 2008, 38(3): 514-519.

知网检索的两种方式：

1. 打开知网页面 <http://kns.cnki.net/kns/brief/result.aspx?dbPrefix=WWJD>
下拉列表框选择：[ISSN]，输入期刊 ISSN：2325-2251，即可查询
2. 打开知网首页 <http://cnki.net/>
左侧“国际文献总库”进入，输入文章标题，即可查询

投稿请点击：<http://www.hanspub.org/Submission.aspx>

期刊邮箱：sa@hanspub.org