

基于python 算法分析特朗普和拜登对中美经济的影响

卿 枫 周 林 王芋钦 刘玉婷

(西华大学 电气与电子信息学院, 四川 成都 610039)

摘 要 特朗普和拜登两个总统所做的决策大多数是来自于他们所在的两个党派, 也就是民主党和共和党。根据相关渠道获取两个党派分别在位时美国的数据集, 利用python 对其进行数据分析, 并且做了数据预处理, 将数据集整理为一个新的数据集, 然后对这个数据集进行因子分析, 得到了较强的几个因子和他们的因子系数, 将这几个数据集投入到SVR等模型中进行预测, SVR得到的准确率都在90%以上, 得到的预测数据就可以看出接下来他们对美国经济所造成的影响最终可以认为在拜登的领导下美国经济会平稳上升, 在特朗普的领导下会先上升后下降。

关键词 相关性分析 SVR BP神经网络 经济预测

中图分类号: F11

文献标识码: A

文章编号: 1007-0745(2021)01-0059-06

1 问题背景和重述

1.1 问题背景

由于美国总统大选是每四年举行一次。在2020年也会有美国大选, 这次的美国大选候选人是特朗普和拜登, 他们分别是共和党和民主党的代表人。两人分别在金融贸易, 经济金融治理还有一些其他的发展领域, 例如对于新冠病毒的措施、基础设施的建设、税收、环境保护、医疗保险、就业、贸易、移民和教育等。他们在对这些方面的问题处理上都有着不同的立场, 同时他们在处理这些问题也有不同的行政纲领和政治立场。无论是特朗普还是拜登当选都会对美国的经济发展以及全球经济金融发展形成新的并且是不同的战略格局。不同的候选人当选会对美国有着不同的影响, 那么到底会产生怎么样的影响呢? 而中国又应该如何去应对这些问题呢?

1.2 开放的问题

1. 建立数学模型, 利用相关数据定量分析不同候选人当选对美国经济可能产生的影响。(您可以选择一个或者多个字段分别回答此问题或给出一个全面的答案)

2. 建立数学模型, 利用相关数据定量分析不同候选人当选对中国经济可能产生的影响。(您可以选择一个或者多个字段分别回答此问题或给出一个全面的答案)

3. 假设你是中国经济发展智库的成员, 结合问题1和问题2的数学模型, 在这两种情况下(哪一方获胜), 你会对中国在相关领域的经济对策和政策提出什么建议? 请具体说明你的观点。

2 问题分析

2.1 问题分析一

首先, 问题一我们认为拜登和特朗普的政策会取决于他们背后的两个党派的想法, 而党派会以之前的方法继续施行, 所以我们打算将之前两个党派分别执政的时候美国

的数据提取出来, 分成两个数据集, 一个是共和党执政期间的数据, 一个是民主党执政期间的数据。例如基础设施建设, 人均GDP, 就业情况等几十个数据集, 经过团队的考量与筛选得到了十个数据集, 并且对这十个数据集进行数据预处理, 数据预处理之后得到的清洗后的数据, 再将这十个数据集放入到因子分析模型, 得到落石图, 并且找到其中的拐点, 也就是那几个主要影响美国经济的因子, 得到这几个因子过后, 我们就可以将其放入我们写好的几个机器学习算法和神经网络模型, 得到最后的预测数据, 取其中最优的一个模型的预测值, 并且分析这样的预测值会对美国的经济产生什么样的影响。^[1]

2.2 问题分析二

对于问题二来说, 我们将会获取新的数据集, 例如分别收集在共和党和民主党两党执政期间的中美贸易量, 中国出口贸易量, 中国进口贸易量, 中国税收等, 并且清洗整理数据内容, 得到一份完整的数据集, 将这份数据集放入到SVR中, 得到新的预测值, 再利用这个预测值预测两个候选人分别会对中国的经济影响, 而两个党派也就是分别代表了拜登与特朗普所会实行的政策。

2.3 问题分析三

对于问题三来说, 我们会将之前所得到的影响美国经济几个主要因子中最后的预测数据提取出来, 并且这几个数据分别乘以他们的因子系数, 而这个值就是我们最后所得到的解, 因为我们可以通过这个值来判断究竟两个党派也就是两个候选人所做的事情谁会影响经济正发展的更多, 或者谁会导致经济回退也就得到了两党后面会对美国造成的影响, 并且选择这个数据大的一位, 还有一个问题是对中国的相关经济提出的问题, 在我看来, 我认为中国的相关领域的经济对策是应当实行反制措施, 将中国的教育和医疗水平, 公共设施等数据与美国的人均GDP做一个分析, 将其相关性为负相和相关性较小的因子提出来, 中国则需




图 1 BP 神经网络拓扑结构图

要大量的提升这些方面的能力就可以了。^[2]

3 模型假设

- (1) 假设从网上获得的数据都是真实可实用的。
- (2) 假设主要因素是相互独立的，并且不会互相影响。
- (3) 假设两个党派中仍然会坚持自己的政策方针。
- (4) 假设没有其他特定的因素影响美国大选。
- (5) 假设其他候选人被选上的可能性远低于题中所给两位候选人。

4 建立模型并且解决问题一

4.1 数据预处理

为了收集美国相关的数据，我们在很多数据库上进行搜寻，得到了下列的一百多个数据集，为了满足本题所要求的情况，我们将其数据按时间分成共和党执政和民主党执政期间进行处理。

并且我们利用了 python 对其进行数据预处理，包括在可以用每列的平均值的插入填补空值，重复值的删除、异常值使用 3σ 原则，最终得到的干净整洁的数据。

最终经过我们的考虑与斟酌，我们留下了九列数据用于相关性分析。

4.2 相关性分析模型的建立

相关性分析 python 实现。将所有共和党的数据代入 python 中的相关性分析模型得出其热力图。将所有民主党的数据代入 python 中的因子分析模型得出其热力图。并且最终将其相关性提出。最终得出影响美国经济较大的几个数据为进出口贸易量、教育人口数、可替代核能和保险服务等。

4.3 BP 神经网络模型的建立

4.3.1 BP 神经网络的基本原理

BP 神经网络即为 Backpropagation 的缩写，即反向传播的意思，正向传播时，输入样本从输入层传入，经过各个隐层逐层处理后，传向输出层。

4.3.2 BP 神经网络的拓扑结构

BP 神经网络的拓扑结构如图 1 所示。

4.3.3 BP 神经网络的传递函数

我们在这里的 BP 神经网络用的传递函数是非线性变换函数——Sigmoid 函数。因为函数本身及其导数都是连续的，所以非常好处理，并且也较为容易上手：

$$f(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

4.3.4 BP 神经网络学习算法

BP 网络的学习算法就是 BP 算法，又叫 σ 算法（在 ANN 的学习过程中我们会发现不少具有多个名称的术语），以三层感知器为例，当网络输出与期望输出不等时，存在输出误差 E，定义如下：

$$E = \frac{1}{2} (d - O)^2 = \frac{1}{2} \sum_{k=1}^{\ell} (d_k - O_k)^2 \quad (2)$$

将以上误差定义式展开至隐层，有：

$$E = \frac{1}{2} \sum_{k=1}^{\ell} [d_k - f(\text{net}_k)]^2 = \frac{1}{2} \sum_{k=1}^{\ell} [d_k - f(\sum_{j=0}^m \omega_{jk} y_j)]^2 \quad (3)$$

进一步展开至输入层，有：

$$E = \frac{1}{2} \sum_{k=1}^{\ell} d_k - f[\sum_{j=0}^m \omega_{jk} f(\text{net}_j)]^2 = \frac{1}{2} \sum_{k=1}^{\ell} d_k - f[\sum_{j=0}^m \omega_{jk} f(v_j, x_j)]^2 \quad (4)$$

显然，调整权值的原则是使误差不断减小，因此应使权值与误差的梯度下降成正比，即：

$$\Delta \omega_{jk} = -\eta \frac{\partial E}{\partial \omega_{jk}} \quad j = 0, 1, 2, \dots, m; k = 1, 2, \dots, \ell$$

$$\Delta v_{ij} = -\eta \frac{\partial E}{\partial v_{ij}} \quad i = 0, 1, 2, \dots, n; j = 1, 2, \dots, m$$

(5)

The true and predicted values are: GDP (local currency) (local currency)			y_pred
0	10621824000000	1.501191e+14	
1	14964372000000	1.501191e+14	
2	15517926000000	1.501191e+14	
3	16155255000000	1.501191e+14	
4	16691517000000	1.501191e+14	
5	17427609000000	1.501191e+14	
6	18120714000000	1.501191e+14	
7	18624475000000	1.501191e+14	
8	19390604000000	1.501191e+14	

图 2 民主党的预测值与准确值

The true and predicted values are: GDP (local currency) (local currency)			y_pred
0	10977514000000	1.067672e+14	
1	11510670000000	1.067672e+14	
2	12274928000000	1.067672e+14	
3	13093726000000	1.067672e+14	
4	13855880000000	1.067672e+14	
5	14477635000000	1.067672e+14	
6	14718582000000	1.067672e+14	
7	14418739000000	1.067672e+14	

图 3 共和党的预测值与准确值

对于一般多层感知器，设共有 h 个隐层，各个点分别命名为 m_1, m_2, \dots, m_h ,

各个隐藏层输出分别命名为 $y_1, y_2, y_3, \dots, y_h$ ，矩阵命名为 $w_1, w_2, \dots, w_h, w_{h+1}$ 输出层：

$$\Delta \omega_{jk}^{h+1} = \eta \delta_{h+1}^k y_j^h = \eta (d_k - o_k) o_k (1 - o_k) y_j^k \quad (6)$$

第 h 隐层：

$$\Delta \omega_{ij}^h = \eta \delta_j^h y_i^{h-1} - 1 = \eta \sum_{k=1}^l \delta_k^0 \omega_{jk}^{h+1} y_j^k (1 - y_j^k) y_i \quad (7)$$

按以上规律逐层类推，则第一层隐藏权值调整公式

$$\Delta \omega_{pq}^1 = \eta \delta_q^1 \chi_p = \eta \left(\sum_{r=1}^{m_2} \delta_r \dots 2 - r \omega_{qr}^2 \right) y_q^1 (1 - y_q^1) \chi_p \quad (8)$$

容易看出，BP 神经算法中，权值的调整公式均由这几个东西决定，即：学习率 η ，本层输出的误差信号 σ ，本层输入信号 X (或 Y)。

BP 算法属于 σ 学习规则类。 σ 学习规则可以看成是 Widrow-Hoff(LMS) 学习规则的一般化 (Generalize) 情况。神经元的变换函数与 LMS 学习规则没有什么关联，没有必要

对变换函数求导， σ 学习规则则并没有此性质，要求变换函数可导。这就是为什么我们前面采用 Sigmoid 函数的原因。^[3]

4.3.5 BP 神经网络前向传输

我们需要将权重和偏置随机初始化，并且对每一个权重取 [-1,1] 随机的实数，每一个偏置同样也取 [0,1] 实数，之后就可以前向传输的运作。

4.3.6 BP 神经网络的 python 实现

本次的我们选择 python 实现 BP 神经网络是因为 python 作为一门开源编程语言，在里面有比较友好的库，例如 pandas 库可以提供高性能的分析工具，而 shuffle 则可以随机打乱工具，将原有序列打乱，返回一个全新的顺序错乱的值。

这次的 BP 神经网络的效果非常的差，因为数据量过少，所以导致了过拟合的状态，但是所幸我们仍然还有其他的选择，BP 神经网络只是我们的一种选择，接下来我们将会介绍我们其他的模型。

4.4 SVR 模型的建立

4.4.1 SVR 模型的支持向量回归

给定训练样本如下：

$D = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}, y_i \in R$ ，希望学得一个回归模型使得 $f(x)$ 与 y 尽可能的相似， ω 和 b 是待确定的模型参数。^[4]

SVR 问题可形式化为：

共和党期间中国经济影响

Accuracy 0.9492678410186113

The range of predicted value under linear kernel function [-0.8902704 0.04009723 0.31779845]

民主党期间中国经济影响

Accuracy 0.8432952188863041

The range of predicted value under linear kernel function [0.82029119 -0.09933402 1.12230227]

共和党期间对美国经济影响

Accuracy 0.9779743974348291

The range of predicted value under linear kernel function [-0.73078865 0.25651053 -1.4939384]

民主党期间对美国经济的影响

Accuracy 0.8942663833756179

The range of predicted value under linear kernel function [-1.15940336 0.32721636 0.52866834]

图 4 SVR 模型线性预测准确率

$$\min_{w,b} \frac{1}{2} |w|^2 + C \sum_{i=1}^m l_{\epsilon}(f(x_i) - y_i) \quad (9)$$

其中 C 为正则化常数, l_{ϵ} 是图中所示的 ϵ 不敏感损失 (ϵ Insensitive Loss) 函数:

$$l_{\epsilon}(z) = \begin{cases} 0, & \text{if } |z| \leq \epsilon; \\ |z| - \epsilon, & \text{otherwise} \end{cases} \quad (10)$$

引入松弛变量 ξ_i ($\hat{\xi}_i$) 和, 可将式重写为:

$$\min_{w,b,\xi_i,\hat{\xi}_i} \frac{1}{2} |w|^2 + C \sum_{i=1}^m (\xi_i, \hat{\xi}_i) \quad (11)$$

$$s.t. f(x_i) - y_i \leq \epsilon + \xi_i, \quad (12)$$

$$y_i - f(x_i) \leq \epsilon + \hat{\xi}_i \quad (13)$$

$$\xi_i \geq 0, \hat{\xi}_i \geq 0, i = 1, 2, \dots, m. \quad (14)$$

引入拉格朗日乘子 μ_i , 可得:

$$\begin{aligned} L(w, b, a, \hat{a}, \xi, \hat{\xi}, \mu, \hat{\mu}) \\ = \frac{1}{2} |w|^2 + C \sum_{i=1}^m (\xi_i, \hat{\xi}_i) - \sum_{i=1}^m \xi_i \mu_i - \sum_{i=1}^m \hat{\xi}_i \hat{\mu}_i + \sum_{i=1}^m a_i (f(x_i) - y_i \\ - \epsilon - \xi_i) + \sum_{i=1}^m \hat{a}_i (y_i - f(x_i) - \epsilon - \hat{\xi}_i) \end{aligned} \quad (15)$$

再另 L 对几项参数偏导为零可得:

$$w = \sum_{i=1}^m (\hat{a}_i - a_i) x_i \quad (16)$$

上述过程满足 KKT 条件, 即要求:

$$\begin{cases} \sum_{i=1}^m a_i (f(x_i) - y_i - \epsilon - \xi_i) \\ \sum_{i=1}^m \hat{a}_i (y_i - f(x_i) - \epsilon - \hat{\xi}_i) \\ a_i \hat{a}_i = 0, \xi_i \hat{\xi}_i = 0 \\ (C - a_i) \xi_i = 0, (C - \hat{a}_i) \hat{\xi}_i = 0, \end{cases} \quad (17)$$

SVR 的解形如:

$$f(x) = \sum_{i=1}^m (\hat{a}_i - a_i) k(x_i^T x) + b \quad (18)$$

$$b = y_i + \epsilon - \sum_{i=1}^m (\hat{a}_i - a_i) x_i^T x \quad (19)$$

实际中常常采用一种更棒的方法, 选取多个满足条件 $0 < \alpha_i < c$ 的样本求解 b 后取平均值。

若考虑特征映射形式, 则:

$$w = \sum_{i=1}^m (\hat{a}_i - a_i) \phi(x). \quad (20)$$

则 SVR 表示为:

$$f(x) = \sum_{i=1}^m (\hat{\alpha}_i - \alpha_i) k(x_i^T x) + b \quad (21)$$

其中 $k(x_i^T x) = \phi(x_i)^T \phi(x)$ 为核函数。

4.4.2 利用 SVR 模型的支持向量回归求解最终得到的预测值如图 2, 图 3 所示:

最终我们得到使用 SVR 模型中的三种方法, 线性、核、径向得出了它的准确率, 最终线性的预测效果最高可以达到 97.79%, 分别为如图 4。

所以使用线性模型进行预测得到的效果是不错的。

4.5 决策树, 模型的建立

4.5.1 决策树的原理

决策树 (Decision Tree) 是一种基本的分类与回归方法, 分类树是决策树在分类时的称呼, 回归树是用于回归时的称呼。本文主要讨论决策树中的分类树与回归树的一些基本理论, 后续文章会继续讨论决策树的 Boosting 和 Bagging 相关方法。^[5]

4.5.2 利用决策树解决预测问题

先假设给定的数据集为:

$$D = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$$

其中 $x_i = (x_i^{(1)}, x_i^{(2)}, \dots, x_i^{(n)})^T$, 为输入实例, 即特征向量, n 为特征个数, $i=1, 2, \dots, N$, N 为样本容量, $y_i \in \{1, 2, \dots, K\}$ 为类标。

决策树学习是由训练数据集估计条件概率模型。基于特征空间划分的类的条件概率模型有无穷多个, 所以我们就可以根据这个方案对我们的数据进行预测。

决策树学习算法包含特征选择、决策树的生成与决策树的剪枝过程。

建立回归树的过程大致可以分为两步:

(1) 将预测变量空间 $(X_1, X_2, X_3, \dots, X_p)$ 的可能取值构成的集合分割成 J 个互不重叠的区域 $\{R_1, R_2, R_3, \dots, R_j\}$;

(2) 对落入区域 R_j 的每个观测值做同样的预测, 预测值等于 R_j 上训练集的各个样本取值的算术平均数。

比如在第一步中得到两个区域 R_1 和 R_2 , R_1 中训练集的各个样本平均数为 10, R_2 中训练集的各个样本取值的算术平均数为 20, 则对给定的观测值 $X=x$, 若 $x \in R_1$, 给出的预测值为 10, 若 $x \in R_2$, 则预测值为 20。

类似于上述决策树分类算法的第 (10) 步, 关键在于如何构建区域划分 $\{R_1, R_1, R_1, \dots, R_j\}$ 。事实上, 区域的形状是可以为任意形状的, 但出于模型简化和增强可解释性的考虑, 这里将预测变量空间划分成高维矩形, 我们称这些区域为称盒子。RSS 的定义为:

$$RSS = \sum_{j=1}^J \sum_{i \in R_j} (y_i - \hat{y}_{R_j})^2$$

其中, \hat{y}_{R_j} 是第 j 个矩形区域中训练集中各个样本取值的算术平均数。但是, 要想考虑将特征空间划分为 j 个矩形区域的所有可能性, 在计算上是不可行的。因此一般采用一种自上而下的贪婪法: 递归二叉分裂。“自上而下”指的是它从树顶端开始依次分裂预测变量空间, 每个分裂点都产生两个新的分支。“贪婪”意指在建立树的每一步中, 最优分裂确定仅限于某一步进程, 而不是针对全局去选择

那些能够在未来进程中构建出更好的树的分裂点。

在执行递归二叉分裂时, 先选择预测变量 X_j 和分割点 s , 将预测变量空间分为两个区域 $\{X | X_j < s\}$ 和 $\{X | X_j \geq s\}$, 使 RSS 尽可能地减小。也就是说, 考虑所有预测变量 $X_1, X_2, X_3, \dots, X_p$ 和与每个预测变量对应的 s 的取值, 然后选择预测变量和分割点, 使构造出的树具有最小的 RSS。更详细地, 对 j 和 s , 定义一对半平面:

$$\sum_{x_i \in R_1(j, s)} (y_i - \hat{y}_{R_1})^2 + \sum_{x_i \in R_2(j, s)} (y_i - \hat{y}_{R_2})^2$$

重复上述步骤, 寻找继续分割数据集的最优预测变量和最优分割点, 使随之产生的区域中的 RSS 达到最小。此时被分割的不再是整个预测变量空间, 而是之前确定的两个区域之一。如此一来就能得到 3 个区域。接着进一步分割 3 个区域之一以最小化 RSS。这一过程不断持续, 直到符合某个停止准则, 如我们在分类决策树中讨论到的前剪枝中的停止准则。^[6]

区域 $\{R_1, R_1, R_1, \dots, R_j\}$ 产生后, 就可以确定某一给定的测试数据所属的区域, 并用这一区域训练集的各个样本取值的算术平均数作为与测试进行预测。

上述方法生成的回归树会在训练集中取得良好的预测效果, 却很有可能造成数据的过拟合, 导致在测试集上效果不佳。原因在于这种方法产生的树可能过于复杂。一棵分裂点更少、规模更小 (区域 $\{R_1, R_2, R_3, \dots, R_j\}$ 的个数更少) 的树会有更小的方差和更好的可解释性 (以增加微小偏差为代价)。针对上述问题, 一种可能的解决办法是: 仅当分裂使残差平方和 RSS 的减小量超过某阈值时, 才分裂树结点。这种策略能生成较小的树, 但可能产生过于短视的问题, 一些起初看来不值得的分裂却可能之后产生非常好的分裂。也就是说在下一步中, RSS 会大幅减小。

因此, 更好的策略是生成一棵很大的树 T_0 然后通过后剪枝得到子树。

4.5.3 决策树的回归预测算法

1. 利用递归二叉分裂在训练集中生成一棵大树, 只有当终端结点包含的观测值个数低于某个最小值时才停止。

2. 对大树进行代价复杂性剪枝, 得到一系列最优子树, 子树是 α 的函数。

3. 利用 K 折交叉验证选择 α 。具体做法是将训练集分为 K 折。对所有 $k=1, 2, 3, \dots$, 对训练集上所有不属于第 k 折的数据重复第 (1) 步 ~ 第 (2) 步得到与 α 对应的子树, 并求出上述子树在第 k 折上的均方预测误差。

4. 每个 α 会有相应的 K 个均方预测误差, 对这 K 个值求平均, 选出使平均误差最小的 α 。

5. 找出选定的 α 在第 (2) 步中对应的子树。

4.5.4 利用 python 实现决策树算法

最终我们得到了决策树对两党的预测准确率分别为 66% 和 59%, 如图 5、图 6 所示, 所以这个模型也不是特

别理想。

```

y_predict:
[3 3 3]
准确率为:
0.6666666666666666

```

图5 共和党预测值

```

y_predict:
[0 0]
准确率为:
0.5

```

图6 民主党预测值

4.6 最终模型对本题的求解

最终通过比较三个模型我们选择了SVR模型进行预测，因为它的准确率达到到了97.79%，并且我们将之前的数据输入得到了两党分别在执政后美国的经济增长情况。

5 模型的优化

本次的bp神经网络最终得到的效果不是很好，若是数

据能够多一些，那么我们便能够预测得到较为准确的数据。

在后来我们仔细的思考了自己的模型，我们认为这次的数据量其实可以使用机器学习中的随机森林，再通过对每个模型的特点进行基于AdaBoost的融合，生成一个融合模型，最终可以用融合模型去预测得到最后的数据，这样可以将准确率再次向上提升几个百分比。

参考文献:

[1] 韩文煜. 基于python数据分析技术的数据整理与分析研究[J]. 科技创新与应用, 2020(04):157-158.

[2] 杨东红, 吴邦安, 孙晓春. 基于机器学习的网络评论信息有用性预测模型研究[J]. 情报科学, 2019,37(12):34-39,77.

[3] 许彦. Python在财务数据挖掘和分析中的应用[J]. 老字号品牌营销, 2020(11):45-46.

[4] 彭刘阳, 孙元章, 徐箭, 廖思阳, 杨丽. 基于深度强化学习的自适应不确定性经济调度[J]. 电力系统自动化, 2020,44(09):33-46.

[5] 姜疆. 深度学习: 深度挖掘数据新经济[J]. 新经济导刊, 2018(Z1):99-102.

[6] 孙美卫. 一种基于机器学习的经济数据识别方法[J]. 佳木斯大学学报(自然科学版), 2018,36(03):465-468.

(上接第58页)

免这一恶性态势的发展，政府必须从长期的政策出发，对这一现状进行控制。

3 促进房地产价格理性回归的政策建议

3.1 正确认识到房地产具有垄断这一特性

随着房地产市场的规范，近年来小房地产商不断被大房地产商吞并形成几家独大的局面，这样虽然有利于房地产市场的发展，但随之带来的垄断却不容忽视，政府必须认识房地产市场具有这一特性，通过相应政策和手段介入到该市场中，可以起到一个宏观调控的作用，比如出台一些限制房价的政策，通过购买股份的方式参与到房地产企业的决策中去等，一同维持市场的稳定，而不是仍由几家独大的企业完全控制这个市场，同时政府要注意房地产价格的制定，引导行业价格的健康制定，鼓励各企业之间进行非价格竞争，避免出现勾结性寡头垄断市场，在房地产价格监测的制定中多考虑利用模型对房地产价格形成监测的风向标。

3.2 改变地方政府的政绩评价标准，做到摆正自身位置切实为人民考虑

在土地征用的过程中，地方政府往往能够从中获取“暴利”，反而忘了要为人民谋福利这一宗旨，并且地方政府的政绩评价标准正是通过GDP来衡量的，更加助长了地方政府通过土地买卖获得收益的行为，以此来增加政府的财政。为了有效解决这一弊端，国家可以改变地方政府的政

绩评价标准，比如通过落到实处地调研当地居民的生活幸福指数和社会对当地政府的满意指数来衡量该政府的政绩，这样便能有效改观地方政府通过土地买卖来获取收益的行为，阻断土地价格不断高涨。

3.3 落实经济适用房、廉租房的供应

在住房保障体系的完善问题上，应将重点放在经济适用房、廉租房等中低价的商品房供应上，而对高层住房则主要依靠市场调整。经济适用房、廉租屋主要用于满足中低收入家庭的需要，在各个地方实行这一住房保障体系时，必须对落户居民进行详细的核查，同时地方政府必须做到严明公正，避免在经济适用房小区内出现数十万元车的情况，而让真正中低收入的家庭排在外边。

参考文献:

[1] 常伟, 王美萃, 王倩. 我国房地产价格形成机制研究[J]. 北方经济, 2012(09):71-72.

[2] 余凯. 我国寡头垄断下的房地产价格形成机制研究[J]. 城市发展研究, 2007,14(03):63-71.

[3] 郭洪涛. 供求均衡视角下的房地产价格形成机制[J]. 学术交流, 2013(03):138-141.

[4] 杭东. 完善房地产价格形成机制的思考[J]. 广东经济, 2014(08):53-55.

[5] 赵德余, 顾海英, 刘晨. 双寡头垄断市场的价格竞争与产品差异化策略——一个博弈论模型及其扩展[J]. 管理科学学报, 2006,09(05):1-7.