

基于 Richards-BP 神经网络的交通运输碳排放量组合预测模型

高 洁^{1,2}, 王建伟¹, 李琳娜¹

(1. 长安大学 经济与管理学院, 陕西 西安 710064; 2. 江苏大学 管理学院, 江苏 镇江 212013)

摘 要:为提高交通运输碳排放量的预测精度,根据交通运输碳排放量时间曲线具有的非线性饱和增长及随机性波动特点,建立基于 Richards 模型和 BP 神经网络的组合预测模型;以 1985~2010 年中国交通运输碳排放量数据为样本对模型进行了拟合和检验,并将 Richards-BP 神经网络组合模型预测结果与单项 Logistic 模型、GM(1,1)模型、Richards 模型、BP 神经网络及 Logistic-BP 神经网络组合模型、GM(1,1)-BP 神经网络组合模型进行了误差对比分析。研究表明:3 种组合模型的预测误差明显小于单一模型的预测误差,通过 BP 神经网络对单一预测模型进行误差修正可显著提高交通运输碳排放量预测精度;Richards-BP 神经网络组合模型预测结果的平均绝对误差、平均绝对百分比误差及标准差值分别达到 118.439×10^4 t、0.254% 及 136.915×10^4 t,比 Logistic-BP 神经网络组合模型及 GM(1,1)-BP 神经网络组合模型精度提高了近 5 倍;以 Richards 模型的拟合误差作为 BP 神经网络输入效果要优于其他模型,Richards-BP 神经网络组合模型具有更高的预测精度。

关键词:交通工程;交通运输;碳排放量;组合预测;Richards 模型;BP 神经网络

中图分类号:U491,F224

文献标志码:A

A combined model of Richards model and BP neural network to predict transportation carbon emission

GAO Jie^{1,2}, WANG Jian-wei¹, LI Lin-na¹

(1. School of Economics and Management, Chang'an University, Xi'an 710064, Shaanxi, China;

2. School of Management, Jiangsu University, Zhenjiang 212013, Jiangsu, China)

Abstract: In order to improve the prediction accuracy of transportation carbon emission, a combined prediction model based on Richards model and BP neural network was established according to the characteristics of nonlinear and saturated growth in transportation carbon emission time series. The time series of transportation carbon emission from 1985 to 2010 in China was used to for fitting and validation of the combined model. The results of Richards-BP network model were compared with that of the individual Logistic model, GM (1,1) model, Richards model, BP neural network model, Logistic-BP network model and GM (1,1)-BP network model respectively. The results show that the prediction errors of three combined prediction models are significantly

收稿日期:2012-08-20

基金项目:教育部人文社科基金项目(10YJA790184);教育部博士点基金项目(20100205110006);

中央高校基本科研业务费专项资金重点项目(Z1101)

作者简介:高 洁(1978-),女,甘肃兰州人,江苏大学讲师,长安大学工学博士研究生,E-mail:gaojiechd@163.com。

less than the errors of one single model. It is indicated that the BP neural network can improve the accuracy of the single model by error correction. In addition, the prediction error indexes such as average absolute error, average absolute percentage error and standard deviation of the combined Richards-BP network model are respectively 118.439×10^4 t, 0.254% and 136.915×10^4 t, which means about five times of the accuracy of the Logistic-BP network model and GM (1,1)-BP network model are improved. The Richards model is better than the other single models as an input for BP network study. The combined Richards-BP network model is a reasonable method of higher accuracy for prediction of transportation carbon emission. 5 tabs, 2 figs, 14 refs.

Key words: traffic engineering; transportation; carbon emission; combined prediction; Richards model; BP neural network

0 引言

交通运输碳排放量预测是制定交通运输低碳发展战略及设置交通运输领域碳减排目标的决策依据。目前国内外关于交通运输碳排放量的预测方法主要包括情景分析预测法、回归模型预测法及灰色模型预测法等。Meyer 等基于行为和技术情景设置对全球 11 个地区的客运碳排放量进行了预测^[1]; He 等设置了汽车燃料经济性的 3 个情景,预测了中国道路运输碳排放量^[2];岳超等基于 Kaya 等式设置了碳排放量预测的不同情景^[3];Marcotullio 等采用回归方法预测了亚洲地区道路运输碳排放量^[4];刘建翠应用线性回归模型预测了中国交通运输碳排放量^[5];赵爱文等研究了碳排放量的灰色预测方法^[6]。上述单一预测模型在预测精度上存在较大差异,情景预测和回归预测需要依赖相关影响参数的未来取值,使得预测结果存在较大的主观性;灰色预测模型虽然具有较多的建模优势,但是不能准确描述碳排放量时间曲线的波动情况。组合预测模型能够通过多个单一预测模型所包含的重要信息进行最优组合,达到提高预测精度和预测结果可靠性的效果,按组合的层次不同,可分为预测信息组合、预测方法组合及预测结果组合^[7]。

交通运输碳排放量时间曲线同时存在趋势性变动和随机性变动特征,两者的变化规律并不相同。为此,本文提出一种基于 Richards 模型和 BP 神经网络的交通运输碳排放量组合预测模型,通过能够反映非线性饱和增长特征的 Richards 模型预测交通运输碳排放量时间曲线的趋势项部分,利用 BP 神经网络进一步去除或降低随机因素的影响,从而提高模型的预测精度。

1 Richards-BP 组合预测模型

根据 IEA 的统计数据,交通运输碳排放量持续增长的趋势较为明显,并且碳排放量逐年变动呈现出增长速度由慢到快,又由快到慢的非线性特征,同时考虑到环境的有限容纳性,交通运输碳排放量增长存在资源条件限制下的有限值,因此交通运输碳排放量与时间的关系接近“S”形曲线,具有饱和增长特征^[8-9]。

拟合“S”形曲线的模型主要有 Logistic 模型、Gompertz 模型和 Richards 模型等^[10-12]。前 2 种模型适宜于拟合和预测曲线增长率的变化随碳排放量增长而下降的速度为常数或与碳排放量成反比的情况;Richards 模型由于引入了形状参数,曲线增长率的变化随碳排放量增长而下降的速度相对灵活,比前 2 个模型具有更广的适应性,因此,本文选择 Richards 模型作为交通运输碳排放量预测的初始模型。

1.1 Richards 模型

设 $x(t)$ 为 t 时刻交通运输碳排放量,则交通运输碳排放量 Richards 模型为

$$x(t) = \frac{M}{(1 + e^{\beta - rt})^{1/\lambda}} \quad (1)$$

式中: M 为社会经济发展条件下可容纳的交通运输最大碳排放量; β 为初始值参数; r 为增长速率参数; λ 为曲线形状参数。

当 $\lambda=1$ 时,式(1)为 Logistic 模型;

当 $\lambda=-1$ 时,式(1)为 Mitscherlich 模型;

当 $\lambda=0$ 时,式(1)为 Gompertz 曲线模型。

上述 Richards 模型是一个含有四参数的非线性回归模型,本文采用文献[13]提出的四点法对其进行参数估计。

1.2 BP 神经网络预测模型

BP 神经网络是一种按误差逆传播算法训练的

多层前馈网络,具有良好的非线性组合特性,能够实现输入和输出之间的任意非线性映射^[14]。BP 算法是一种有监督式的学习算法,通过修改各层神经元的权值,使得误差平方和达到最小。

本文采用 3 层 BP 网络建模进行预测,网络结构包括输入层、输出层和若干隐含层。设输入神经元数量为 n ,输出神经元数量为 m ,隐含层神经元数量为 p ,则隐含层神经元输出为

$$x_i^j = \sigma \left[\sum_{i=1}^n w_{ij} x_i + b_j \right], j=1,2,\dots,p \quad (2)$$

式中: x_i^j 为隐含层神经元的输出; x_i 为输入值; w_{ij} 为输入层到隐含层的权重; b_j 为阈值, x_i 输入为 Richards 模型的计算结果。

输出层神经元输出为

$$y_k = \sum_{j=1}^p w_{jk} x_j + b_k, k=1,2,\dots,m \quad (3)$$

式中: y_k 为输出层神经元的输出; x_j 为输入值; w_{jk} 为隐含层到输出层的权重; b_k 为阈值,在本文研究中,输出层神经元个数为 1,即 $k=1$ 。

神经元作用的激励函数通常选取 S 型函数,如式(4)所示为

$$\sigma(x) = \frac{1}{1 + e^{-x/Q}} \quad (4)$$

式中: Q 为调整激励函数形式的 Sigmoid 参数。

1.3 组合预测模型

首先,拟合交通运输碳排放量预测的 Richards 模型,模拟交通运输碳排放量的趋势变动部分;其次,将 Richards 模型预测结果的绝对误差作为 BP 神经网络的输入值和输出值,通过 BP 算法对误差进行修正,构建 BP 神经网络误差修正模型,从而提高模型预测精度。组合预测模型计算流程如图 1 所示。

2 计算分析

2.1 数据来源

利用 Richards-BP 神经网络组合模型对 1985~2010 年中国交通运输碳排放量进行预测分析。交通运输碳排放量根据《IPCC 国家温室气体清单指南》(2006)中的移动源化石燃料燃烧排放的“自上而下”方法计算,仅核算由能源消耗产生的交通运输直接碳排放量,不包括交通基础设施建设过程中产生的间接碳排放,碳排放因子数据来源于《中国能源统计年鉴》(2011)及《国家温室气体排放清单指南》(2006)。

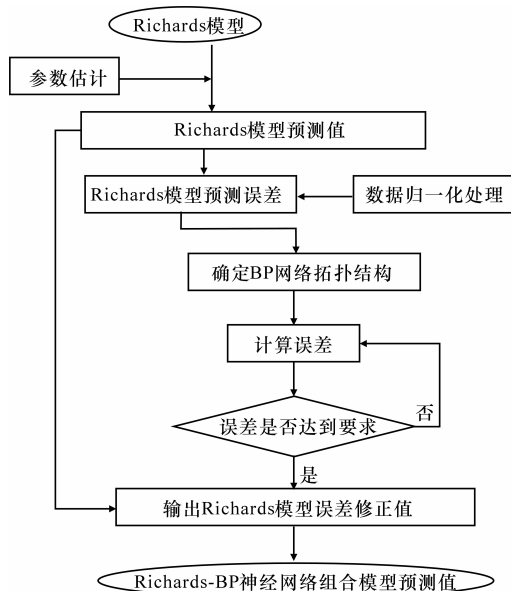


图1 基于 Richards 模型和 BP 神经网络组合预测模型计算流程

Fig. 1 Process of combined Richards-BP neural network model

2.2 预测结果

利用四点法对 Richards 模型进行参数估计,可得拟合 Richards 模型如式(5)所示, Richards 模型拟合结果及拟合误差见下页表 1。

$$x(t) = \frac{74\ 294.961\ 5}{(1 + 6\ 723\ 365.312\ 2e^{-0.551t})^{1/6.369}} \quad (5)$$

$$R^2 = 0.97$$

可以看出, Richards 模型对交通运输碳排放量整体具有较好的拟合效果, R^2 达到 0.97,但是在部分年份存在较大的拟合误差。

选取 1985~2004 年 Richards 模型绝对误差数据用于网络训练,首先采用离差标准化计算方法对 Richards 模型预测绝对误差进行归一化处理,并以 1985~1990 年,1986~1991 年, ..., 1999~2003 年标准化后的误差数据分组作为 BP 神经网络输入变量,以 1991 年,1992 年, ..., 2004 年误差数据作为 BP 神经网络的理想输出变量。因此, BP 神经网络的输入神经元为 5,输出神经元为 1,可以得到 15 个样本对网络进行训练。

BP 网络隐含层神经元 p 的取值范围根据公式 $p = \sqrt{n+m} + a$ 来确定,其中, n 为输入神经元个数, m 为输出神经元个数, a 为 $[1,10]$ 之间的常数。为防止过度拟合及拟合不足,由小到大改变神经元个数,训练并检验其精度,以不同隐含层神经元个数的预测误差平方和最小为判断依据,模拟得出隐含层神经元

个数为 7,因此本文 BP 神经网络的拓扑结构为5-7-1。

神经元转换函数采用 S 型正切函数,即 tansig 函数,输入和输出层神经元的转换函数采用线性 purelin 函数,通过 Matlab 编程,得到网络隐含层及输出层的权重矩阵 w_{ij} 和 w_{jk} ,误差修正结果及组合模型拟合结果见表 1。

$$w_{ij} = \begin{bmatrix} 0.284\ 7 & 6.890\ 3 & -1.624\ 6 & 2.634\ 2 & 0.404\ 8 & 3.038\ 5 & -0.664\ 0 \\ -0.790\ 4 & 2.192\ 9 & -1.543\ 9 & -5.399\ 6 & -0.822\ 4 & -1.905\ 7 & 0.406\ 2 \\ -2.170\ 2 & -9.265\ 5 & -1.881\ 0 & -4.732\ 7 & -1.448\ 6 & 0.030\ 2 & 1.153\ 6 \\ -0.363\ 2 & -3.888\ 2 & 3.555\ 7 & -3.818\ 7 & -0.985\ 9 & -2.690\ 4 & 1.753\ 9 \\ -0.219\ 7 & -10.340\ 7 & 1.211\ 5 & 11.067\ 2 & -0.871\ 5 & -2.085\ 0 & 0.891\ 4 \end{bmatrix}, \quad w_{jk} = \begin{bmatrix} -5.690\ 2 \\ 12.381\ 9 \\ -5.587\ 4 \\ 6.712\ 9 \\ -5.587\ 0 \\ -7.177\ 1 \\ 2.416\ 2 \end{bmatrix}$$

表 1 Richards 模型及 Richards-BP 网络组合模型拟合结果

Tab. 1 Simulated values of Richards model and combined Richards-BP neural network model

年份/年	实际值/ 10^4 t	Richards 模型/ 10^4 t		BP 神经网络/ 10^4 t		Richards-BP 组合模型/ 10^4 t
		拟合值	绝对误差	修正误差	预测误差	
1985	8 428.815 1	6 865.470	1 563.344 9			
1986	9 665.991 7	7 485.995	2 179.997 0			
1987	9 953.175 2	8 162.604	1 790.571 0			
1988	10 387.650 7	8 900.368	1 487.283 1			
1989	10 773.635 2	9 704.812	1 068.823 4			
1990	10 718.564 2	10 581.960	136.601 1	287.838 1	-151.237 00	10 869.80
1991	11 150.686 8	11 538.390	-387.704 9	-521.703 0	133.997 90	11 016.69
1992	11 679.492 9	12 581.260	-901.768 0	-868.577 0	-33.190 80	11 712.68
1993	12 211.749 9	13 718.380	-1 506.629 2	-1 810.830 0	304.201 00	11 907.55
1994	12 232.175 1	14 958.260	-2 726.081 4	-2 942.730 0	216.653 20	12 015.52
1995	13 242.806 6	16 310.170	-3 067.359 2	-3 769.330 0	701.975 40	12 540.83
1996	13 351.130 6	17 784.200	-4 433.072 7	-3 580.140 0	-852.933 00	14 204.06
1997	22 290.173 9	19 391.350	2 898.821 5	2 908.139 0	-9.317 03	22 299.49
1998	22 639.843 1	21 143.540	1 496.303 3	1 583.516 0	-87.212 50	22 727.06
1999	23 521.889 1	23 053.680	468.211 9	472.992 3	-4.780 44	23 526.67
2000	24 593.015 3	25 135.670	-542.652 5	-535.998 0	-6.654 06	24 599.67
2001	25 471.413 5	27 404.340	-1 932.925 6	-2 140.510 0	207.580 60	25 263.83
2002	26 928.053 1	29 875.230	-2 947.180 8	-2 761.360 0	-185.821 00	27 113.87
2003	31 106.342 9	32 564.120	-1 457.780 8	-1 660.970 0	203.189 80	30 903.15
2004	36 597.071 1	35 486.010	1 111.064 8	1 147.420 0	-36.355 60	36 633.43




图 2 实际值与 Richards 模型、Richards-BP 组合模型的比较

Fig. 2 Comparison of actual values and simulated values of Richards model and combined Richards-BP model

由表 1 可以看出,通过 BP 神经网络的修正,可以获得较好的误差修正值,图 2 显示了实际值、Richards 模型拟合值及 Richards-BP 网络组合模型拟合值的结果对比,采用 BP 神经网络对 Richards 模型预测误差进行修正后,最小绝对误差可达到 $4.78\times 10^4\text{ t}$,组合模型拟合值与实际值最为吻合。

以 1985~2004 年数据为样本值,对 2005~2010 年中国交通运输碳排放量进行预测,计算结果见下页表 2。

3 预测结果检验

3.1 组合预测模型绝对误差及相对误差检验

对表 2 中 2005~2010 年交通运输碳排放量预测数据进行绝对误差和相对误差分析,见下页表 3。

预测数据与实际交通运输碳排放量数据之间的相对误差在 0.548% 以下,说明预测结果与实际值偏离程度较小,Richards-BP 神经网络组合预测模型预测精度较高。

表 2 2005~2010 年中国交通运输碳排放量预测结果

Tab. 2 Prediction of transportation carbon emission in China from 2005 to 2010

年份/年	BP 神经网络修正误差/ 10^4 t	Richards 模型/ 10^4 t		实际值/ 10^4 t	组合模型预测值/ 10^4 t
		预测值	绝对误差		
2005	1 772.491	38 653.15	1 552.096 5	40 205.250 1	40 425.64
2006	2 239.531	42 071.48	2 163.786 4	44 235.269 9	44 311.01
2007	2 600.530	45 734.14	2 494.337 9	48 228.477 3	48 334.67
2008	549.542	49 610.92	511.335 3	50 122.260 0	50 160.47
2009	-2 070.630	53 633.01	-1 868.669 4	51 764.343 0	51 562.39
2010	-622.514	57 676.02	-554.364 4	57 121.660 0	57 053.51

表 3 Richards-BP 神经网络组合预测模型绝对误差及相对误差

Tab. 3 Prediction errors of combined Richards-BP neural network model

年份/年	2005	2006	2007	2008	2009	2010
绝对误差/ 10^4 t	220.389 9	75.740 1	106.192 7	38.210 0	201.953 0	68.150 0
相对误差/%	0.548	0.171	0.220	0.076	0.390	0.119

3.2 单一预测模型和组合模型预测精度检验

为了对比说明 Richards-BP 神经网络组合模型的预测效果,以 1985~2004 年数据为样本,分别采用 Logistic 模型、GM(1,1)模型、单纯 BP 神经网络以及 Logistic-BP 神经网络组合模型、GM(1,1)-BP 神经网络组合模型对 2005~2010 年中国交通运输

碳排放量进行预测,预测结果见表 4。

选用平均绝对误差(MAE)、平均绝对百分比误差(MAPE)及标准差(SDE)指标作为预测模型检验标准,反映预测数据与实际数据的离散程度,指标值越小表明模型预测精度越好,可靠性越高。单一模型和组合模型预测结果的误差指标比较见表 5。

表 4 对比模型预测结果

Tab. 4 Prediction results of models comparison

年份/年	Logistic 模型/ 10^4 t	GM(1,1)模型/ 10^4 t	BP 神经网络/ 10^4 t	Logistic-BP 模型/ 10^4 t	GM(1,1)-BP 模型/ 10^4 t
2005	38 528.505 19	36 493.962 6	42 154.961 0	40 123.04	40 586.157 8
2006	41 705.132 07	39 715.657 0	41 981.033 7	44 232.71	43 695.903 0
2007	45 063.608 96	43 221.763 3	47 247.660 1	47 608.74	47 786.766 0
2008	48 601.415 93	47 037.389 3	49 459.854 2	50 356.18	51 038.057 8
2009	52 313.835 71	51 189.859 6	51 089.860 8	53 284.31	50 944.637 0
2010	56 193.811 29	55 708.910 8	54 256.310 0	56 119.29	57 024.934 9

表 5 单一模型和组合模型预测结果的误差指标比较

Tab. 5 Comparison of prediction error indexes of all models

预测模型		评价指标		
		MAE/ 10^4 t	MAPE/%	SDE/ 10^4 t
单一模型	Logistic 模型	1 728.323	3.695	1 945.305
	GM(1,1)模型	3 051.620	6.595	3 442.626
	Richards 模型	1 524.099	3.254	1 701.637
	BP 神经网络模型	1 564.500	3.270	1 777.118
组合模型	Logistic-BP 神经网络组合模型	576.794	1.109	791.686
	GM(1,1)-BP 神经网络组合模型	532.369	1.110	598.759
	Richards-BP 神经网络组合模型	118.439	0.254	136.915

由表 5 可以看出,3 种组合预测模型的预测误差明显小于单一预测模型的预测误差,说明利用 BP

神经网络对单一预测模型进行误差修正可显著提高预测精度,组合模型预测结果可靠性更高;从单项预测模型来看,Richards 模型预测结果的各项误差指标值要整体优于单项 Logistic 模型、GM(1,1)模型及 BP 神经网络模型的预测结果,MAPE 值达到 3.254%;从组合预测模型来看,本文提出的 Richards-BP 神经网络组合模型预测结果检验的 MAE、MAPE 及 SDE 值分别为 118.439×10^4 t、0.254% 及 136.915×10^4 t,明显小于其他单一模型及组合模型预测误差指标值,与 Logistic-BP 神经网络组合模型、GM(1,1)-BP 神经网络组合模型相比,预测精度提高了近 5 倍,表明 Richards-BP 神经网络组合模型能够显著提高交通运输碳排放量的预测精度,并且以 Richards 模型计算结果作为 BP 神经网络输入值效果要优于其他单项模型。

4 结 语

(1)交通运输碳排放量时间曲线存在趋势性波动和随机性波动,具有非线性饱和增长特征,因此,提出基于 Richards-BP 神经网络的交通运输碳排放量组合预测模型,通过 Richards 模型对趋势项进行预测,利用 BP 神经网络对 Richards 模型进行误差修正。

(2)通过 BP 神经网络对单一预测模型进行误差修正可显著提高交通运输碳排放量预测精度,并且在交通运输碳排放量预测时,以 Richards 模型的拟合误差作为 BP 神经网络输入值的效果要优于其他单项模型。

(3)Richards-BP 神经网络组合模型预测精度较高,MAE、MAPE 及 SDE 值分别为 118.439×10^4 t、0.254% 及 136.915×10^4 t,与 Logistic-BP 神经网络组合模型、GM(1,1)-BP 神经网络组合模型相比,预测精度提高了近 5 倍;并且 Richards-BP 神经网络组合模型基于历史数据进行预测,不需要对影响因素做出估计,相对于情景分析预测和回归模型预测提高了预测结果的客观性,在交通运输碳排放量预测方面优于其他方法。

(4)由于 BP 神经网络拓扑结构参数设置主要依靠经验取值或者进行试算,因此还需要在模型输入层及隐含层神经元个数计算等方面不断改进。

参考文献:

References:

- [1] Meyer I, Leimbach M, Jaeger C C. International passenger transport and climate change: a sector analysis in car demand and associated CO₂ emissions from 2000 to 2050 [J]. Energy Policy, 2007, 35 (12): 6332-6345.
- [2] He K, Huo H, Zhang Q, et al. Oil consumption and CO₂ emissions in China's road transport: current status, future trends, and policy implications [J]. Energy Policy, 2005, 33(12): 1499-1507.
- [3] 岳超, 王少鹏, 朱江玲, 等. 2050 年中国碳排放量的情景预测-碳排放与社会发展 IV [J]. 北京大学学报: 自然科学版, 2010, 46(4): 517-524.
YUE Chao, WANG Shao-peng, ZHU Jiang-ling, et al. 2050 Carbon emissions projection for China-carbon emissions and social development, IV [J]. Acta Scientiarum Naturalium Universitatis Pekinensis, 2010, 46 (4): 517-524. (in Chinese)
- [4] Marcotullio P J, Marshall J D, et al. Potential futures for road transportation CO₂ emissions in the Asia Pacific [J]. Asia Pacific Viewpoint, 2007, 48 (3): 355-377.
- [5] 刘建翠. 中国交通运输部门节能潜力和碳排放预测 [J]. 资源科学, 2011, 33(4): 640-646.
LIU Jian-cui. Energy saving potential and carbon emissions prediction for the transportation sector in China [J]. Resources Science, 2011, 33 (4): 640-646. (in Chinese)
- [6] 赵爱文, 李东. 中国碳排放灰色预测 [J]. 数学的实践与认识, 2012, 42(4): 61-69.
ZHAO Ai-wen, LI Dong. Grey forecast of China's carbon dioxide emissions [J]. Mathematicis in Practice and Theory, 2012, 42(4): 61-69. (in Chinese)
- [7] 卢奇, 顾培亮, 邱世明. 组合预测模型在我国能源消费系统中的建构及应用 [J]. 系统工程理论与实践, 2003(3): 24-30.
LU Qi, GU Pei-liang, QIU Shi-ming. The construction and application of combination forecasting model in Chinese energy consumption system [J]. Systems Engineering-Theory & Practice, 2003 (3): 24-30. (in Chinese)
- [8] IEA. Technology roadmap: biofuels for transport [M]. Paris: International Energy Agency, 2011.