

基于 ARMA 模型和 VAR 模型的中国债券市场 信用价差预测比较研究

周荣喜 王先良 杜思楠 王永超
(北京化工大学 经济管理学院, 北京 100029)

摘要: 选取上海证券交易所企业债和国债月度数据,利用遗传算法对静态利率期限结构 NSM 参数模型进行求解,进而拟合较为精确的企业债和国债的利率期限结构,据此计算出企业债的信用价差。数据一部分作为样本内拟合区间,另外一部分作为样本外预测区间以检查模型的预测精度。通过建立自 ARMA 样本外预测模型和 VAR 样本外预测模型分别对我国债券市场信用价差进行预测,最后比较两种模型的预测精度。结果表明 VAR 模型对于信用价差短期预测较为准确,而 ARMA 模型对于较长期预测较为准确。

关键词: 信用价差预测; NSM 模型; ARMA 模型; VAR 模型

中图分类号: C934

引言

随着近些年国家对债券市场的重视,我国的债券市场得到了快速的发展,发行债券成为了国家和企业融资的重要渠道。但是企业债券相比较国债面临着更大的风险,其中最大的就是信用风险。信用价差作为衡量企业进行外部融资活动所产生的风险溢价的指标 (Moody and Taylor)^[1],在二级市场上反映着债券的信用风险大小,日益受到国内外学者的广泛关注。信用价差不仅能够反映当前货币政策和财政政策的实施效果,同时还能够成为未来宏观经济形势预测的重要指标,为资产定价、套期保值和规避风险提供科学参考。基于 NSM 模型相比较其他 NS 族模型在拟合我国债券市场债券上的精度和价格误差上的优势^[2],本文采用 NSM 模型并结合遗传算法求解得到国债和企业债的利率期限结构,进而得到信用价差。

Guhua 等^[3]经过实证研究表明,信用价差可以作为宏观经济的先行指标并且可以有效预测商业周期转折点。Vereda 等^[4]提出加入宏观经济变量的向量自回归模型 (VAR) 来拟合几个到期的国债收益率,并与其他单因素预测模型相比较,VAR 模型

预测效果更好。Jacobs 等^[5]建立针对企业债券的信用价差双因素仿射模型,不管是样本内预测还是样本外预测,双因素仿射模型的误差均方根显著降低。Krishnan 等^[6]通过实证表明信用价差历史数据可以用来预测未来信用价差期限结构,并且通过无风险利率曲线图可以提高预测准确性。杨文瀚等^[7]通过建立 GM(1,1)模型,首次对我国企业债券的信用价差进行预测,并得到了满足预测精度的结果。刘金全等^[8]利用 VAR 分析认为,利率期限结构、收益曲线特征和宏观经济冲击之间存在相互作用和影响关系。何志刚等^[9]基于无约束 VAR 模型对企业债信用价差期限结构与货币政策变量等宏观经济变量关系进行实证研究,研究结果表明信用价差期限结构能够有效预测未来实体经济增长。

鉴于时间序列模型在预测上取得了长足的进步,国内外学者很多采用 ARMA 和 VAR 模型预测相关宏观经济变量数据。与其他学者单独采用一种预测模型不同的是,本文将在相关研究的基础上,建立 ARMA 样本外预测模型和 VAR 样本外预测模型对我国债券市场信用价差进行预测,并且比较两种模型的预测精度,阐明每个模型在长期预测和短期预测上的各自优势。另外,在 VAR 模型内生变量的变量选取上,本文考虑了时间序列数据的滞后性,因而加入了信用价差本身前期值作为内生变量,同时还选取了影响我国债券市场的显著宏观经济因素,建立 VAR 模型并进行样本外预测。

收稿日期: 2013-05-22

基金项目: 国家自然科学基金(71171012)

第一作者: 男,1972年生,教授

E-mail: zrx103@126.com

1 模型和参数求解

1.1 NS 修正模型(NSM 模型)

在 NSM 模型中,假设远期利率为 f ,则它关于剩余期限 t 的函数

$$f(t) = \beta_0 + \beta_1 e^{-t/\tau_1} + \beta_2 \left(\frac{t}{\tau_1}\right) e^{-t/\tau_1} + \beta_3 \left(\frac{t}{\tau_1}\right)^2 e^{-t/\tau_1} + \beta_4 \left(\frac{t}{\tau_1}\right)^3 e^{-t/\tau_1} \quad (1)$$

根据即期利率与远期利率关系,在连续复利的情况下,有

$$r(t) = \frac{1}{t} \int_0^t f(u) du, f(t) = \frac{dr(t)}{dt} t + r(t)$$

将式(1)代入上式可得

$$r(t) = \beta_0 + (\beta_1 + \beta_2 + 2\beta_3 + 6\beta_4) \left(\frac{1 - e^{-t/\tau_1}}{t/\tau_1}\right) - \left[(\beta_2 + 2\beta_3 + 6\beta_4) + (\beta_3 + 2\beta_4) \frac{t}{\tau_1} + \beta_4 \left(\frac{t}{\tau_1}\right)^2 \right] e^{-t/\tau_1} \quad (2)$$

式(2)中, β_0 代表曲线的长期水平; β_1 代表长期水平与剩余期限为 0 的起始值的偏差,反映了曲线的斜率; β_2 描述利率曲线的峰态大小与趋势,反映了利率曲线的曲度; β_3 和 β_4 反映了利率曲线峰态的大小与趋势的曲度进行微调; τ_1 决定了利率曲线峰的具体位置。

那么折现因子 $D(t)$ 就可以表示为 $D(t) = e^{-r(t)t}$,进而可得债券价格的理论值为

$$\hat{P}_j = \sum_{t=1}^{T_j} C_j(t) D_j(t), j=1, 2, \dots, n \quad (3)$$

式(3)中, T_j 表示第 j 支债券的剩余到期期限, $C_j(t)$ 表示第 j 支债券在 t 时刻的现金流, \hat{P}_j 表示第 j 支债券价格的理论值。在实证分析过程中,若令 P_j 表示第 j 支债券的实际价格,当满足所有样本国债的实际价格与理论价格偏差绝对值之和最小,即

$$\min \sum_{j=1}^n |\hat{P}_j - P_j|, j=1, 2, \dots, n \quad (4)$$

式(4)可得到折现函数 $D(t)$ 的系数向量的最优估计值,进而可拟合出国债和企业债的即期利率。模型(4)是一个非线性优化问题,由于遗传算法具有高效、实用、鲁棒性强等特点,本文使用遗传算法求解确定 $[\beta_0, \beta_1, \beta_2, \beta_3, \beta_4, \tau_1]$ 的值^[10]。得到样本内的每个月月末交易日企业债和国债的利率期限结构模型,再选取具有代表性的剩余到期期限分别为 1、3、5、7、10、15、20 年的国债即期利率和企业债即期

利率,二者之差为信用价差,分别用 CS1、CS3、CS5、CS7、CS10、CS15 和 CS20 表示。

1.2 ARMA 预测模型

ARMA 模型由于其简单性,可行性和灵活性,故为目前应用最广泛的时间序列预测模型之一。建模与预测包含 4 个步骤:(1)序列平稳化处理,如果序列是非平稳的,可以通过差分变化使其满足平稳性条件;(2)模型识别,主要通过自相关系数和偏自相关系数来确定模型的滞后阶数 p 和 q ;(3)参数估计和模型诊断,估计模型的参数,并检验(包括参数的显著性检验和残差的随机性检验),然后判断所建模型是否可取;(4)利用所选取合适参数的模型进行预测。

自回归移动平均模型 ARMA(p, q)。如果时间序列 $\{X_n\}$ 满足

$$X - \phi_1 X_{n-1} - \dots - \phi_p X_{n-p} = \varepsilon_n - \theta_1 \varepsilon_{n-1} - \dots - \theta_q \varepsilon_{n-q}$$

则称时间序列 $\{X_n\}$ 服从(p, q)阶自回归移动平均模型 ARMA(p, q); ϕ_1, \dots, ϕ_p 为自回归回归系数; $\theta_1, \dots, \theta_q$ 为移动平均系数。

ARMA 模型的预测公式

$$\hat{X}(l) = \begin{cases} \hat{X}_k(l) & l \geq 1 \\ X_{k+l}(l) & l \leq 0 \end{cases}$$

$$V[ek(l)] = (1 + G_1^2 + \dots + G_{l-1}^2) \sigma_\varepsilon^2$$

其中, V 为预测方差, GREEN 函数为

$$G_0 = 1, G_l = \sum_{j=1}^l \phi_j^* G_{l-j} - \theta_l^* \quad l=1, 2, \dots, q$$

$$\theta_l^* = \begin{cases} 0 & j > p \\ \phi_j^* & j \leq p \end{cases}, \theta_j^* = \begin{cases} 0 & j > p \\ \theta_j & j=1, \dots, q \end{cases}$$

预测向量 $\hat{X}_k = (\hat{X}_k(1), \hat{X}_k(2), \dots, \hat{X}_k(l))^T, l=1, 2, \dots, q$ 的递推公式

$$\hat{X}_{k+1} = \begin{pmatrix} -G_1 & 1 & 0 & \dots & 0 \\ -G_2 & 0 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ -G_{q-1} & 0 & 0 & \dots & 1 \\ -G_q + \phi_q^* & \phi_{q-1}^* & \phi_{q-2}^* & \dots & \phi_1^* \end{pmatrix} \hat{X}_k + \begin{pmatrix} G_1 \\ G_2 \\ \vdots \\ G_{q-1} \\ G_q \end{pmatrix} x_{k+1} + \begin{pmatrix} 0 \\ 0 \\ \vdots \\ 0 \\ \sum_{j=q+1}^p \phi_j^* x_{k+q-j+1} \end{pmatrix} \quad (5)$$

当 $\hat{X}_{k+1} = \phi_1 \hat{X}_{k+1}(l-1) + \dots + \phi_p \hat{X}_{k+1}(l-p)$ ($l > p$) $p \leq q$ 时, 式(5)的最后一项为 0; 若 $l \leq 0$ 时, 则 $\hat{X}_{k+1}(l) = x_{k+1+l}$ 。

1.3 VAR 预测模型

VAR 是多维时间序列模型的最核心的内容之一, 通常用来预测相互联系的时间系统以及分析随机扰动项对变量系统的动态影响。与此同时, 在 VAR 模型时不必对变量的内生性或外生性进行设定, 因为所有的变量都是内生变量, 故选择了 VAR 模型作为我国债券市场信用价差预测模型。

一般的 VAR(p) 模型的数学表达式是

$$y_t = A_1 y_{t-1} + \dots + A_p y_{t-p} + Hx_t + u_t, t = 1, 2, \dots, T$$

其中, y_t 和 x_t 是 k 维内生变量列向量, p 是滞后阶数, T 是样本数, $k \times k$ 维矩阵 $A_1 \dots A_p$ 和矩阵 H 是待估系数矩阵, u_t 是 k 维扰动列向量, 它们相互之间可以同期相关, 但不与自己的滞后值相关, 且不与等式右边的变量相关。

VAR 预测模型如下

$$X(t+h) | t = \alpha_0 + \gamma_1 X(t) + \gamma_2 M(t) + \varepsilon(t+h);$$

$$M = (CPI, IG, ER, M2)^T, X = CS(i)^T, i = 1, 2, \dots, 7$$

h 为步长, $\varepsilon(t+h)$ 为随机扰动项, $X(t)$ 、 α_0 、 $\varepsilon(t+h)$ 为 7×1 维向量, $M(t)$ 为 4×1 维向量, γ_1 为 7×7 阶矩阵, γ_2 为 4×4 阶矩阵。

本文采用误差均方根 V_{RMSE} 作为样本外预测的结果评估, V_{RMSE} 是通过若干个预测值对预测效果进行综合评价, 表示为

$$V_{RMSE} = \sqrt{\frac{1}{n} \sum_{t=T+1}^{T+n} (\hat{y}^t - y^t)^2}$$

其中, T 表示样本容量, n 表示样本外预测期数, \hat{y}^t 表示预测值, y^t 是真实值。

2 实证分析

本文针对我国债券市场, 选取 2006 年 1 月至 2012 年 12 月上海证券交易所均 AAA 级的企业债和国债月度数据, 共 84 组数据, 利用遗传算法对静态利率期限结构 NSM 参数模型求解, 进而拟合较为精确的企业债和国债的利率期限结构, 据此计算出企业债的信用价差。时间序列数据首先经过平稳性检验, 否则会出现“虚假回归”现象^[11], 对于各期限信用价差进行单位根检验如表 1, 经过 ADF 检验表明, 各期限信用价差原序列是不平稳的, 经过一阶差分处理后序列是平稳的, 即表明所有期限信用价差均服从一阶单整。如果没有明确

说明, 以下分析的信用价差序列均是一阶差分处理后的序列。

表 1 各信用价差序列单位根检验结果

Table 1 Unit root test results of the credit spreads

CS	信用价差序列		一阶差分序列	
	t 值	p 值	t 值	p 值
CS1	-2.405742	0.1439	-11.544403	0.0001
CS3	-2.203477	0.2069	-9.604508	0.0000
CS5	-2.282045	0.1805	-10.02634	0.0001
CS7	-2.388264	0.1486	-10.18891	0.0001
CS9	-2.668087	0.0847	-10.02948	0.0001
CS15	-3.028929	0.0370	-9.300556	0.0000
CS20	-3.766961	0.0050	-6.963337	0.0000

本文确定各期限信用价差序列的自回归系数和移动平均系数是根据自相关图和偏相关图来判断, 根据各期限信用价差序列自回归和移动平均系数建立 ARMA 模型, 系数估计值如表 2。

从表 2 的估计结果来看, 各期限信用价差的 ARMA 模型拟合度较为显著, 均达到了 0.74 以上, 且 ARMA 模型对短期信用价差序列的拟合程度要好于中长期的信用价差序列; 各期限信用价差平稳序列均呈现不同的自回归和移动平均的特征; 除了 CS15 中 AR(2) 项和 CS20 中 AR(1) 项, 各模型的自回归和移动平均项的系数全部通过置信度为 95% 的 t 检验; 各模型的 D-W 统计量表明模型的残差不存在一阶序列相关。

基于信用价差在时间序列上变化主要是受宏观经济因素的影响, 本文选取包括居民消费价格指数 CPI、工业增加值增长率 IG、汇率 ER 和货币供应量 M2, 这 4 个变量涵盖了经济增长因素、通货膨胀因素、国际经济影响因素和流动性因素, 因此, 具有较高的概括性和较强的说服力。宏观经济变量时间序列数据和上面的各期限信用价差一样, 首先需要经过单位根检验以判断序列是否平稳, 经过 ADF 检验后, 原序列是不平稳的, 经过一阶差分处理后序列成为平稳序列, 即表明所有宏观经济变量序列服从一阶单整。针对不同期限信用价差所建立的 VAR 模型估计结果见表 3。

VAR 模型的估计是要经过单位根检验以判断模型是否平稳, 结果表明所有模型的特征方程根的倒数值均是小于 1 的, 证明模型是平稳的; 同时也表明不同的序列之间不存在协积关系, 因此模型是

表 2 各期限信用价差序列 ARMA 模型估计表格
Table 2 The estimated ARMA model of the credit spread time series

CS	CS1	CS3	CS5	CS7	CS10	CS15	CS20
常数项	3.865914 [4.843948]	2.818666 [3.786482]	2.238143 [3.519326]	1.864812 [3.48483]	1.467453 [4.064062]	1.203244 [6.865252]	1.062039 [3.95473]
AR(1)	0.936633 [35.05769]	0.927178 [25.21892]	0.918639 [21.56730]	0.910029 [19.6460]	0.860389 [16.44282]	1.356178 [4.676998]	-0.040170 [-0.29697]
AR(2)	—	—	0.927095 [12.72390]	—	—	-0.468548 [-1.898316]	0.668840 [5.51371]
MA(1)	-0.363190 [-3.081484]	-0.165217 [-2.304039]	-0.187353 [-2.453666]	-0.193911 [-2.486307]	—	-0.736813 [-2.493296]	0.918539 [6.347858]
拟合度	0.892846	0.879573	0.839770	0.814113	0.796680	0.796132	0.747624
调整拟合度	0.889695	0.876031	0.835057	0.808646	0.793733	0.783586	0.732093
D-W 统计量	1.993619	1.978667	1.995062	1.999970	2.286206	1.881375	2.297016

方括号 [] 里的数字为 t 检验值

有效的;模型的拟合度均达到了较高的水平。从表 3 的 VAR 模型的估计结果可以看出,对短期债券企业债信用价差序列之间的动态关系拟合程度相对于中长期债券信用价差序列较好,并且随着到期期限

的增加,模型的拟合度逐渐减少,且信用价差序列本身的滞后项对于信用价差的影响比其他宏观经济因素更为显著,这说明我国债券市场仍然是一个不成熟的市場。

表 3 信用价差 VAR 模型估计结果
Table 3 The estimated VAR model of the credit spread time series

CS	CS1	CS3	CS5	CS7	CS10	CS15	CS20
CS1(-1)	0.610810 [6.65320]	0.698428 [7.87819]	0.664160 [7.04116]	0.639122 [6.54404]	0.630127 [6.45193]	0.694553 [8.17768]	0.702571 [8.52393]
CPI(-1)	-0.202250 [-3.15969]	-0.168631 [-2.72409]	-0.171734 [-2.77859]	-0.159465 [-2.78862]	-0.117432 [-2.51040]	-0.035472 [-1.07705]	0.015587 [0.40849]
ER(-1)	-0.028979 [-3.48141]	-0.022861 [-3.04852]	-0.022877 [-3.09280]	-0.021040 [-3.08397]	-0.001232 [-2.66478]	-0.004652 [-1.14176]	0.002306 [0.47943]
IG(-1)	0.076286 [2.18110]	0.056748 [2.84756]	0.052735 [1.73632]	0.045559 [1.60833]	-0.019671 [-1.00721]	0.004902 [0.24895]	-0.008954 [-0.36299]
M2(-1)	-0.026273 [-2.72179]	-0.025213 [-2.81148]	-0.026694 [-2.91154]	-0.024870 [-2.89257]	-0.017335 [-2.44299]	-0.002585 [-0.47658]	0.008288 [1.19509]
常数项	1.488316 [3.26102]	1.273607 [2.91809]	1.307504 [2.98174]	1.214097 [2.98591]	0.881488 [2.65613]	0.233925 [0.99479]	-0.193261 [-0.6902]
拟合度	0.901644	0.893456	0.858014	0.835335	0.822546	0.821125	0.770091
调整拟合度	0.894078	0.885260	0.847092	0.822669	0.808895	0.807366	0.752406

方括号 [] 里的数字为系数的 t 检验值

通过以上建立的 ARMA 样本外预测模型和 VAR 样本外预测模型,得到各期限信用价差样本外预测步长最大值为 12 的预测值,见表 4。从表 4 中可以看出,VAR 模型和 ARMA 模型都能够较好的对我国债券市场信用价差进行样本外预测。相比较而言,VAR 模型对于短期债券信用价差预测更为准确,而 ARMA 模型对于较长期债券信用价差预测更为准确,误差比较小。从 V_{RMSSE} 值大小比较两种模型

的样本外预测精度,结果表明对于短期债券信用价差样本外预测而言,VAR 模型具有较大的优势,而对于长期债券信用价差样本外预测而言,ARMA 模型具有较大的优势,这与两种模型的真实值与预测值之间的误差比所得出的结论是一致的。

3 结束语

ARMA 与 VAR 在时间序列上的预测上具有自

表 4 各期限信用价差的 ARMA 和 VAR 样本外真实值与预测值比较
Table 4 Comparison between the real and predicted values based on the ARMA and VAR models

步长		CS1	CS3	CS5	CS7	CS10	CS15	CS20
1	真实值	0.04253	0.02854	0.02245	0.01895	0.01584	0.01584	0.01754
	预测值 1	0.03821 (-0.1552)	0.02703 (-0.0529)	0.02146 (-0.0441)	0.01787 (-0.0569)	0.01467 (-0.0738)	0.01203 (-0.2405)	0.01066 (-0.3922)
	预测值 2	0.04341 (-0.08448)	0.02980 (0.04415)	0.02299 (0.0241)	0.01906 (0.0058)	0.01644 (0.0378)	0.01641 (0.0359)	0.01831 (0.0438)
3	真实值	0.04354	0.02865	0.02165	0.01854	0.01589	0.01741	0.01751
	预测值 1	0.03827 (-0.0121)	0.02704 (-0.0562)	0.02146 (-0.0087)	0.01787 (-0.0361)	0.01467 (-0.0767)	0.01203 (-0.3090)	0.01066 (-0.3912)
	预测值 2	0.04406 (0.0119)	0.02989 (0.0433)	0.02298 (0.0614)	0.01906 (0.0280)	0.01655 (0.0415)	0.01673 (-0.0392)	0.01884 (0.0759)
5	真实值	0.0425	0.02953	0.02276	0.01841	0.01547	0.01652	0.01851
	预测值 1	0.03831 (-0.0986)	0.02705 (-0.0839)	0.02146 (-0.0571)	0.01787 (-0.0293)	0.01467 (-0.0517)	0.01203 (-0.2717)	0.01066 (-0.4241)
	预测值 2	0.04474 (0.0527)	0.03001 (0.0163)	0.02300 (0.0105)	0.01910 (0.0374)	0.01667 (0.0775)	0.017051 (0.0321)	0.01936 (0.0459)
7	真实值	0.04176	0.02852	0.02287	0.01904	0.01582	0.01623	0.01354
	预测值 1	0.03836 (-0.08142)	0.02705 (-0.0515)	0.02146 (-0.0616)	0.01789 (-0.0603)	0.01467 (-0.0726)	0.01203 (-0.2587)	0.01066 (-0.2127)
	预测值 2	0.04544 (0.0811)	0.03017 (0.0578)	0.02306 (0.0083)	0.01915 (0.0057)	0.01682 (0.0632)	0.01737 (0.07024)	0.01588 (0.1728)
9	真实值	0.04258	0.028652	0.02292	0.01801	0.01542	0.01684	0.01482
	预测值 1	0.03839 (0.0984)	0.027059 (-0.0555)	0.02146 (-0.0636)	0.01787 (-0.0077)	0.01467 (-0.0486)	0.01403 (-0.2856)	0.01066 (-0.2807)
	预测值 2	0.04617 (0.0843)	0.03035 (0.0592)	0.02314 (0.00959)	0.01923 (0.0677)	0.01697 (0.1005)	0.01771 (0.1704)	0.02040 (0.3765)
10	真实值	0.04253	0.02863	0.02127	0.01804	0.01581	0.01402	0.01385
	预测值 1	0.03841 (-0.0969)	0.02706 (-0.0548)	0.02146 (0.0089)	0.01787 (-0.00943)	0.01467 (-0.0721)	0.01203 (-0.1419)	0.01066 (-0.2303)
	预测值 2	0.04654 (0.0943)	0.03045 (0.063569)	0.02318 (0.08979)	0.01928 (0.0687)	0.01706 (0.0790)	0.01787 (0.2746)	0.02066 (0.3034)
12	真实值	0.04163	0.02883	0.02254	0.01794	0.01542	0.01437	0.01357
	预测值 1	0.03844 (-0.0718)	0.02706 (-0.0613)	0.02146 (-0.04791)	0.01788 (-0.0033)	0.01467 (-0.0486)	0.01203 (-0.1628)	0.01066 (-0.2144)
	预测值 2	0.04229 (0.0159)	0.03066 (0.06347)	0.02329 (0.07763)	0.01938 (0.0802)	0.01723 (0.1173)	0.01821 (0.2672)	0.02118 (0.5607)
	V_{RMSE1}	5.011×10^{-6}	8.883×10^{-7}	3.345×10^{-7}	2.446×10^{-7}	3.018×10^{-7}	1.953×10^{-6}	5.999×10^{-6}
	V_{RMSE2}	2.042×10^{-6}	6.509×10^{-7}	2.672×10^{-7}	1.367×10^{-7}	4.365×10^{-7}	4.108×10^{-6}	8.338×10^{-6}

预测值 1 和 2 分别为 ARMA 和 VAR 样本外预测模型的预测值,括号内数字为相对预测百分比误差, V_{RMSE1} 和 V_{RMSE2} 分别为 ARMA 模型和 VAR 模型的样本外预测的误差均方根值。

己独特的优势: ARMA 通过捕捉数据中的线性特征来进行预测,而 VAR 则是通过时间序列的过去值对变量的动态影响,并在此基础上对变量进行预测。本文实证结果表明,VAR 模型和 ARMA 模型都能够很好的对我国债券市场信用价差进行样本外预测,相比较而言,VAR 模型在预测短期债券信用价差的

时候更具有优势,误差较小,而 ARMA 在预测长期债券信用价差的时候更具有优势,误差较小,从判断样本外预测精度 V_{RMSE} 来看,结论也是一致的。本文对于企业债的投资者具有很好的指导意义。本文还可以扩大样本区间,从而更好的判断两种模型对于我国债券市场信用价差预测的优劣。

参考文献:

- [1] Mody A, Taylor M P. Financial predictors of real activity and the financial accelerator [J]. *Economic Letters*, 2004, 82: 167-172.
- [2] 周子康, 王宁, 杨衡. 中国国债利率期限结构模型研究与实证分析[J]. *金融研究*, 2008(3): 131-150.
Zhou Z K, Wang N, Yang H. Empirical research of debt term structure of interest rates in our country [J]. *Finance Research*, 2008(3): 131-150. (in Chinese)
- [3] Guhaa D, Hiris L. The aggregate credit spread and the business cycle[J]. *International Review of Financial Analysis*, 2002, 11: 219-227.
- [4] Vereda L, Lopes H, Fukuda R. Estimating VAR models for the term structure of interest rates[J]. *Mathematics and Economics*, 2008, 42: 548-559.
- [5] Jacobs K, Li X F. Modeling the dynamics of credit spreads with stochastic volatility [J]. *Management Science*, 2008, 54(6): 1176-1188.
- [6] Krishnan C N V, Ritchken P H, Thomson J B. Predicting credit spreads[J]. *Journal of Financial Intermediation*, 2009, 22(12): 32-67.
- [7] 杨文瀚, 刘思峰, 王燕. 中国企业债券信用价差的灰色预测及实证研究[J]. *中国管理科学*, 2008, 13(10): 169-171.
Yang W H, Liu S F, Wang Y. Grey prediction of Chinese corporation bond's credit spread and its empirical analysis [J]. *Chinese Journal of Management Science*, 2008, 13(10): 169-171. (in Chinese)
- [8] 刘金全, 王勇, 张鹤. 利率期限结构与宏观经济因素的动态相依性—基于 VAR 模型的经验研究[J]. *财经研究*, 2007, 33(5): 126-143.
Liu J Q, Wang Y, Zhang H. Dynamic dependence of term structure of interest rates and macroeconomic factors: empirical studies based on VAR models [J]. *Journal of Finance and Economics*, 2007, 33(5): 126-143. (in Chinese)
- [9] 何志刚, 牛伟杰. 我国企业债信用价差期限结构中的货币政策含义[J]. *上海金融*, 2012(7): 53-58.
He Z G, Niu W J. Policy implications of term structure of credit spreads on corporate bonds in our country [J]. *Shanghai Finance*, 2012(7): 53-58. (in Chinese)
- [10] 周荣喜, 牛伟宁. 基于 SV 模型的中国债券市场信用价差影响因素研究[J]. *统计与信息论坛*, 2011, 26(12): 80-88.
Zhou R X, Niu W N. Research on the factors affecting credit spreads of China's bonds based on SV model [J]. *Statistics & Information Forum*, 2011, 26(12): 80-88. (in Chinese)
- [11] Sims C A, Stock J H, Watson M W. Inference in linear time series models with some unit roots [J]. *Econometrica*, 1990, 58(1): 113-144.

Comparison of credit spread forecasting based on ARMA and VAR models

ZHOU RongXi WANG XianLiang DU SiNan WANG YongChao

(School of Economics and Management, Beijing University of Chemical Technology, Beijing 100029, China)

Abstract: In order to study China's bond market, this paper selects the monthly transaction data of the Shanghai Stock Exchange and by using the NSM model, combined with a genetic algorithm, the interest rate term structures of government bonds and corporate bonds are obtained along with the credit spread which is the difference between the two interest rate term structures. Part of the data was taken as the fitting sample, and the remaining part of the data was taken as an out-forecasting sample to check the accuracy of predictions made using the model. The ARMA and VAR out-forecasting models have been established in order to forecast China's bond market credit spreads, and the precisions of the two models have been compared. The results show that the VAR model is more accurate for short-term forecasts, and the ARMA model is more accurate for longer-term forecasts.

Key words: credit spread forecast; NSM model; ARMA model; VAR model