

中国短期就业形势预测

——基于大型贝叶斯向量自回归模型

赵文¹,肖双双²

(1.中国社会科学院人口与劳动经济研究所,北京 100028;

2.北京师范大学统计学院,北京 100875)

摘要:在短期就业形势预测中,外部冲击往往伴随大量宏观变量的同步变化,传统低维预测模型难以及时吸收相关信息。基于中国月度宏观经济数据,构建包含 158 个变量的大型贝叶斯向量自回归(LBVAR)模型,通过引入明尼苏达先验与贝叶斯收缩缓解高维参数估计中的过拟合问题,并以采购经理指数(PMI)从业人员指数为核心指标开展短期预测分析。研究结果表明,与包含 3、14 和 22 个变量的模型相比,158 变量 LBVAR 模型在对 PMI 从业人员指数、居民消费价格指数以及银行间同业拆借 1 天加权平均利率等核心指标进行月度短期预测时,整体相对均方误差更小,预测精度更高。进一步结合 PMI 从业人员指数与城镇调查失业率之间的变化关系,对失业率进行转化预测,预测误差基本维持在 0~0.3 个百分点。因此,在外部冲击显著、经济运行不确定性上升的背景下,包含更多“及时”宏观变量的 LBVAR 模型可为精准预判就业形势动态演变、科学制定就业相关政策提供更具参考价值的决策支撑。

关键词:从业人员指数;向量自回归模型;贝叶斯收缩;相对均方误差

中图分类号:F24;F201

文献标识码:A

文章编号:2095-929X(2026)02-0034-12

一、引言

近年来,贸易摩擦、新冠肺炎疫情等事件对中国就业市场的冲击频发,而做好就业工作需要及时准确地预测月度就业形势。对此,中国劳动和社会保障科学研究院曾建立中国失业预警系统^[1]。近期的研究中,李宏等^[2]使用广东省的社会经济调查数据对五种回归方法预测失业率的可行性进行了验证。陈恺等^[3]使用时间序列方法分析了调查失业率与奥肯定律之间关系,认为奥肯定律在我国成立,并据此计算了自然失业率。葛明和高远东^[4]使用投入产出方法分析了价值链分工、需求结构与就业波动的关系,认为降低失业率需要统筹考虑价值链分工网络与国内外需求结构调整的贡献率、关键路径及部门差异性。贾海彦等^[5]发现数字经济有利于促进中老年人的劳动参与、提高就业质量。王佳慧等^[6]发现研究生扩招难以改善青年失业情况。

虽然预测大部分宏观经济指标已经在方法和基础数据上具备条件,但对失业率的预测仍存在困难:城镇调查失业率数据的时序较短,且相关模型中与就业密切相关的指标较少^[7],统计指标的内涵时有变化。孙婧

基金项目:中国社会科学院创新工程项目“法人单位间工资差距整体分布研究”。

作者简介:赵文(1982—),男,山东青岛人,博士,中国社会科学院人口与劳动经济研究所研究员,研究方向:宏观经济、收入分配。

芳等^[8]发现,在新冠肺炎疫情冲击后,疫情严重地区的农村劳动力非农就业率显著下降,农民工失去非农就业机会之后并未转向农业就业,而是选择了失业,对此,刘学良和宋炳妮^[9]认为,新冠肺炎疫情期间的失业率统计严重低估了失业的真实程度。本文认为,如果采用城镇调查失业率数据对失业率进行预测,则难以检验预测结果与真实情况之间的差异。因此,目前阶段,失业率难以准确预测。在中国,采购经理指数(PMI)中的从业人员指数更接近实际情况,且时序较长,作为一个先行指数,能够为预判宏观经济运行的方向提供重要的参考信息,因此近年来愈加受到重视。本文选取 PMI 中的从业人员指数作为核心指标进行失业率预测,观察期间设定在 2020 年 1 月到 2020 年 9 月。这一时期 PMI 中的从业人员指数变化幅度加大,能够更好地检验预测效果。

方法上,使用大型贝叶斯向量自回归模型。自从 Sims^[10-11]将向量自回归(VAR)方法应用于宏观经济分析以来,基于多元时间序列的模型在经济预测中被普遍使用。在近期具体应用上,向量自回归模型呈现出以下特点^[12-13]:第一,从传统的线性 VAR 模型向更复杂的非线性和时变模型发展;第二,越来越多地使用贝叶斯方法处理参数不确定性;第三,注重整合高频数据和实时数据;第四,强调模型的政策分析功能而非单纯的预测功能。

贝叶斯方法在失业率预测研究中占据重要地位,这种方法的优势在于能够有效处理小样本问题,通过先验分布引入经济理论约束,提高估计的稳定性和预测精度。使用该方法预测失业率的具体案例包括美国费城联储的 Stark^[14]开发的小型贝叶斯 VAR 模型以及美联储的 Stella 和 Stock^[15]开发的一个简约的通货膨胀和失业双变量模型被广泛用于美国产出、通货膨胀和失业率的短期预测。

对于短期预测来说,变量较少的小模型未必对短期变化足够敏感,预测效果可能不够好。例如,在新冠肺炎疫情期间的 2020 年 1 月,只有 PMI、金融市场数据和交通运输数据表现出了及时的反应,其他变量由于统计滞后的原因无法反映当月情况的快速变化。这就需要扩大模型的变量个数,引入这些“及时”变化的变量。在使用 VAR 模型进行预测时,虽然减少变量个数能够有效地避免因参数过多带来的过度拟合问题,但是失去“资格”的变量往往包含着重要的信息。传统无约束 VAR 的参数数量随变量增加而急剧膨胀,导致过拟合风险高。如何在增加变量个数的同时有效估计参数是一个难题。对此,De Mol 等^[16]和 Bańbura 等^[17]证明了贝叶斯收缩技术能使贝叶斯向量自回归(BVAR)模型扩展到 131 个变量,同时保持预测准确性和结构分析能力。

为了弥补现有研究在就业形势预测方面的不足,基于 De Mol 等^[16]和 Bańbura 等^[17]提出的大型贝叶斯向量自回归模型(LBVAR)展开研究,通过将含有 158 个变量的模型与含有 3、14、22 个变量的模型进行比较分析,甄别多变量模型的可靠程度,使得预测结果更加严谨和科学。对时序较长且波动较大的 PMI 从业人员指数进行预测,观察 2020 年 1 月到 2020 年 9 月期间预测结果与实际情况的差异,用于验证方法的可行性,为未来观察短期就业形势的变化提供思路。

二、方法和数据

(一) 向量自回归模型

VAR 模型是宏观经济学的标准工具,不对参数施加过多限制,能够捕获复杂的数据关系,因而广泛用于结构分析和预测。VAR 模型的高度通用性也意味着,由于滞后期通常较长,即使是中等变量规模的系统也存在大量的参数需要估计,这就带来了过度参数化的风险。

通常的情况是,即使是只含有几个变量,随着变量滞后阶数的增加,待估参数的个数也会快速增加,这限制了模型引入变量的数量,而且,在宏观经济应用的典型样本规模下,能够可靠估计的无限制参数数量相当有

限。因此,上述因素促使向量自回归通常只能基于少量的变量进行回归。在实证应用中,向量自回归模型使用的变量通常是3~10个。但是这可能会产生遗漏变量偏差,对结构分析和预测都有不利影响。对于需要研究比关键宏观经济指标更多的应用场景来说,限制变量规模是有问题的。Christiano等^[18]认为,通胀对货币紧缩的反直觉增长,即所谓的价格悖论,是由于忽略了商品价格指数等前瞻性变量而造成的假象。在Stock和Watson^[21]的研究中,分析相对较大数据集的一个流行的解决方案是定义一组核心指标,并一次添加一个变量或一组变量。然而,采用这种方法在对不同模型的脉冲响应进行比较时就会出现这个问题。

为了规避这些问题,近期的研究提出了对协方差结构施加限制以减少需要估计的参数数量。例如,Forni等^[19]以及Stock和Watson^[20-21]提出的用于大型横截面的因子模型,其依据的假设是:大型数据集中大量的动态相互关系可以由少数共同因子来解释。这些模型已在预测领域成功应用。但是,Bañbura等^[17]认为这些限制是不必要的,只要在增加更多变量时提高先验的紧密度,那么收缩方法实际上是足以处理大型模型,贝叶斯向量自回归(BVAR)模型是分析大型动态系统的因子模型或面板VAR的有效替代。

(二)大型贝叶斯向量自回归模型

随着变量个数增多且滞后项阶数的增加,模型待估参数的个数也会增加,贝叶斯向量自回归模型通过使用贝叶斯统计方法来解决这一问题并提供较好的拟合效果。这是因为,在进行统计推断时贝叶斯方法将任意一个未知参数都可以看作是随机变量,并且都可以用一个先验概率分布去描述,通过将先验分布与样本似然函数相结合,依据贝叶斯定理,得到后验分布。与以往研究主要使用BVAR模型不同的是,本文基于Bañbura等^[17]提出的大型贝叶斯向量回归(LBVAR)模型进行分析,该模型通过使用贝叶斯收缩的方法对模型参数设定进行调整,在保留相关样本信息的同时减轻过度拟合问题,并进一步扩展了模型中所能容纳变量的数量,有利于将经济系统内更多的指标应用于宏观分析。

令 $Y_t = c + A_1 Y_{t-1} + \dots + A_p Y_{t-p} + u_t$, 其中, u_t 为 n 维高斯白噪声向量,其协方差矩阵满足 $E u_t u_t' = \psi$; $c = (c_1, c_2, \dots, c_n)'$ 为 n 维常数项向量; A_1, \dots, A_p 为 $n \times n$ 阶自回归系数矩阵。该方法通过在参数上施加先验分布,从而缓解“维度灾难”(curse of dimensionality)问题。同时,根据明尼苏达先验分布的设定,该分布假设

$$E[(A_k)_{ij}] = \begin{cases} \delta_i \dots j = i, k = 1 \\ 0, \text{其他情况} \end{cases}, V(A_k)_{ij} = \begin{cases} \frac{\lambda^2}{k^2} \dots j = i \\ \vartheta \frac{\lambda^2 \sigma_i^2}{k^2 \sigma_j^2} \dots \text{其他情况} \end{cases}, \text{系数矩阵 } A_1, \dots, A_p \text{ 被认为在先验上相互独立}$$

且服从正态分布,至于残差协方差矩阵,假定其为固定且已知的对角形式,即 $\psi = \sum$, 此时, $\sum = \text{diag}(\sigma_1^2, \dots, \sigma_n^2)$ 。

对于预期具有显著均值回归特征的变量,本文将其设定为白噪声过程的先验假设,即 $\delta_i = 0$ 。超参数 λ 控制先验分布围绕随机游走或白噪声过程的总体收缩程度(overall tightness),并决定先验信念相对于样本信息的权重。先验方差中的 $\frac{1}{k^2}$ 表示滞后阶数增加时方差递减的速度,而 $\frac{\sigma_i^2}{\sigma_j^2}$ 反映不同变量间的量纲和波动差异。参数 ϑ 控制变量滞后项相对自身滞后项的重要性衰减程度。在进行结构分析时,需要考虑不同变量残差之间可能存在的相关性,本文遵循Kadiyala和Karlsson^[23]以及Robertson和Tallman^[24]的做法,采用正态—逆威沙特先验(Normal-Inverse-Wishart prior),令 $\vartheta = 1$,从而放宽协方差矩阵的固定性。

进一步地,将VAR模型表示为多元回归系统 $Y = X B + U$, 其中, $Y = (Y_1, \dots, Y_T)'$, $X = (X_1, \dots, X_T)'$, $X_t = (Y'_{t-1}, \dots, Y'_{t-p}, 1)'$, $U = (u_1, \dots, u_T)'$, $B = (A_1, \dots, A_p, c)'$ 为 $k \times n$ 阶系数矩阵, $k = np + 1$ 。此时,正态—逆威沙特先验可以表示为 $\text{vec}(B) | \Psi \sim N(\text{vec}(B_0), \Psi \otimes \Omega_0)$, $\Psi \sim iw(S_0, \alpha_0)$ 。然后通过植入 T_d 虚拟观测值 Y_d 和 X_d ^①,使其参数的先验分布符合正态逆威沙特分布的形式。为了确保先验期望 ψ 存在,进一步

假设 $\psi \sim |\psi|^{-\frac{n+3}{2}}$ 。通过将虚拟观测值与原始模型相结合,可以得到具有解析形式的后验分布。与此同时,模型变为 $Y_* = X_* B + U_*$, $T_* = T + T_d$, $Y_* = (Y', Y'_d)'$, $X_* = (X', X'_d)$, $U_* = (U', U'_d)'$, 进而得到后验分布的表达式为: $vec(B) | \Psi, Y \sim N(vec(\tilde{B}), \Psi \otimes (X_*' X_*)^{-1})$, $\Psi | Y \sim iW(\tilde{\Sigma}, T_d + 2 + T - k)$ 。其中, $\tilde{B} = (X_*' X_*)^{-1} X_*' Y_*$, $\tilde{\Sigma} = (Y_* - X_* \tilde{B})^{-1} (Y_* - X_* \tilde{B})$ 。值得注意的是,系数的后验期望将与 Y_* 与将进行最小二乘回归所得估计一致,同时与明尼苏达先验下的后验均值完全相同。

(三) 最优模型选择

由于变量数量的增加容易导致过度拟合,传统上对中国宏观经济系统的研究多基于 VAR 或 BVAR 模型,变量规模通常控制在 20 个以内。然而,这样的中小型模型难以全面刻画宏观系统的多部门特征。Bańbura 等^[12]比较了不同规模的 VAR 模型——从包含就业、通货膨胀与利率的 3 变量 VAR,到 Christiano 等^[18]的 7 变量和 20 变量模型,再到包含 131 个宏观与金融部门指标的大型 VAR。结果表明,大型模型在预测精度上优于小型模型,并产生更可信的脉冲响应。

为了得出适用于中国经济系统的预测模型,本文参考周建和况明^[25]所选取的变量,根据所获取的经济指标分别构建了含有 3、14、22 和 158 个变量的 LVBAR 模型^②,其中 3 变量模型的 3 个变量分别为 PMI 从业人员指数、居民消费价格指数和银行间同业拆借 1 天加权平均利率;14 变量模型在此基础上增加了发电量、社会消费品零售总额、货币和准货币(M2)供应量、出口总值、进口总值、金融机构人民币信贷收支各项贷款、房地产新开工施工面积、国内生产总值、商品零售价格指数、全国房地产开发景气指数、工业增加值;22 变量模型则在 14 变量模型的基础上进一步添加了货运量、总资产、铁路货运量、特别提款权兑人民币汇率、城镇居民人均收入、城镇居民人均支出、农村居民人均收入、农村居民人均支出。本文主要分析这 4 个模型的预测效果。

(四) 相对均方误差与总体紧度

短期预测中,采用相对均方误差(RMSE)评价各模型的预测精度,可以根据 $RMSE = \sum \frac{mfse_{i,h}^{(\lambda,m)}}{mfse_{i,h}^{(0)}}$ 计算相对均方误差。其中, $mfse_{i,h}^{(\lambda,m)}$ 指的当预测阶数为 h 时总体紧度为 λ 时变量 i 的绝对均方误差,其测算方法为: $mfse_{i,h}^{(\lambda,m)} = \frac{1}{T_1 - T_0 - H + 1} \sum_{T=T_0+H-h}^{T_1-h} (y_{i,T+h}^{(\lambda,m)} - y_{i,T+h})^2$, 假设 T_0 为检验区间的起点, T_1 为检验区间的终点,在整个预测阶段,设定进入递归预测的检验区间为 $T_0 + H - h, \dots, T_1 - h$ 。 $y_{i,T+h}^{(\lambda,m)}$ 为变量 i 的 h 阶预测值, $y_{i,T+h}$ 为观测值。取最长超前预测阶数 H 为 12,意味着对于不同的超前预测阶数,每一次的检验区间也不同。 $mfse_{i,h}^{(0)}$ 是基于随机游走模型的 i 变量绝对均方误差。因此,以随机游走模型为基准,若相对均方误差大于 1,则预测精度低于基准;若其小于或等于 1,则预测效果优于或相当于基准。

$$① Y_d = \begin{pmatrix} diag(\delta_1 \sigma_1, \dots, \delta_n \sigma_n) \\ \lambda \\ 0_{n(p-1) \times n} \\ diag(\sigma_1, \dots, \sigma_n) \\ 0_{1 \times n} \end{pmatrix}, X_d = \begin{pmatrix} J_p \otimes diag(\sigma_1, \dots, \sigma_n) & 0_{np \times 1} \\ \lambda & \\ 0_{n \times np} & 0_{n \times 1} \\ 0_{1 \times np} & \varepsilon \end{pmatrix}, J_p = dig(1, \dots, p)。$$

② 因文章篇幅限制,留存备案。

另外,最优 λ 值则是根据 $\lambda_{fit} = \arg \min_{\lambda} |fit - \frac{1}{3} \sum \frac{msfe_{i,h}^{(\lambda,m)}}{msfe_{i,h}^{(0)}}|$ 计算,即该值能使 3 个核心变量在样本外预测区间内的平均相对均方误差具有最小值,此时模型预测效果更好。由于变量数量多,采用经济系统内的 3 个核心变量,即 PMI 从业人员指数、居民消费价格指数和银行间同业拆借 1 天加权平均利率,来选择模型的最优 λ 值。同时基于 3 个变量的相对均方误差对 4 个模型的预测效果进行比较,模型中 3 个核心指标的整体相对均方误差越小,说明模型的预测精度越高。

(五)数据来源

观察期设定在 2020 年 1 月到 2020 年 9 月,这一时期就业市场波动较大,制造业 PMI 从业人员指数在 31.8 到 50.9 之间波动,非制造业 PMI 从业人员指数在 37.9 到 49.1 之间波动。月度城镇新增就业在 39 万到 125 万之间波动。而其他时期的指标变化程度没有这么大。因此,2020 年 1 月到 2020 年 9 月是观察模型预测准确程度的适合时期。原始数据期间为 2005 年 1 月至 2020 年 9 月,除布伦特原油价差、采购经理指数、汇率、银行间同业拆借利率、质押 7 天加权平均利率外,各个变量都转化成同比增长率,布伦特原油价差指的是当月最高价格与最低价格的差。反映就业市场的 PMI 从业人员指数(EI)是根据制造业采购经理指数和非制造业采购经理指数中的从业人员指数加权平均得出,参考赵文^[26]分别使用权重 0.25 与 0.75。在使用同比数据的情况下,用来分析的数据预测区间相应地变为 2006 年 1 月至 2020 年 9 月。经济系统中大部分变量是以月度频率发布,部分变量以季度公布,由于失业率是月度指标,同时模型要求所有变量为同频状态,将包括季度指标内的所有变量转化为月度同频模式。中国一些宏观指标在每年一二月份会有较大的波动,还有一些指标在一月份不发布。对此,通常的方法是删除这些波动大的数据,这能够减少状态空间模型的结果的波动,但对于预测失业率不合适。根据经验,失业率在年前和年后会出现高峰值,失业率的预警也主要着眼于短期。删除波动大的数据对长期预测有价值,但违背了短期预测的初衷。这些波动较大的数据在年度间比较也有规律,并不特殊。为了尽可能地将经济指标数据纳入模型中分析,将季度数据平滑并采取线性插值的方式得到月度数据^①。表 1 的变量统计表记录了分析的 158 个变量的主要数据来源和分类,除此之外,失业率数据来源于国家统计局。

表 1 变量数据来源及统计

数据来源	指标分类	变量数量	数据来源	指标分类	变量数量
《中国统计年鉴》	国民经济核算	22	《中国统计年鉴》	财政	2
	价格指数季度	1		能源	9
	建筑业	3		房地产	4
	人民生活	4	中国人民银行	货币统计概览	11
	工业	2		金融机构信贷收支统计	6
	价格指数月度	34		金融市场统计	9
	国内贸易	1		企业商品价格	4
	对外经济	2		固定资产投资	1
	交通运输	22	国泰安(CSMAR)数据库	存款性公司	2
	邮电通信	8		国房景气指数	1
	采购经理指数	9	万得(Wind)数据库	布伦特原油价差	1
	国民经济核算	22			

由于 VAR 模型是基于历史数据对未来的趋势进行预测,所以在利用时间序列进行分析时需要保持变量特征的稳定性,ADF 检验常常被应用于检验变量的平稳性。检验结果表明,部分变量为白噪声时间序列,剩

①线性插值和二项式插值等方法对预测结果差别很小,本文选择了线性插值方法。

下一部分变量满足随机游走,全部 158 个变量在 1%的水平下服从 1 阶单整,全部变量满足建模的基本要求。

三、主要结果

(一) 递归公式

在预测过程中,主要通过超前递归的方式获取 h 阶月度的预测值, h 阶预测的表达式为:

$$Y_{t+h|t}^{(\lambda,m)} = (Y_{i,t+h|t}^{(\lambda,m)}, \dots, Y_{n,t+h|t}^{(\lambda,m)})' \quad (1)$$

那么,带有参数的矩阵形式的预测表达式变为:

$$\hat{Y}_{t+h|t}^{(\lambda,m)} = \hat{C}^{(\lambda,m)} + \hat{A}_1^{(\lambda,m)} Y_t + \dots + \hat{A}_p^{(\lambda,m)} Y_{t-p+1} \quad (2)$$

(二) 预测过程

基于短期政策分析时,主要考虑 1 阶递归形式来获取下一月的预测的效果。根据递归公式, h 阶超前预测的 y 为 $y|t+h$,假设 $h=1$,此时为 1 阶超前预测,参考 Bańbura 等^[17]选择滞后项的阶数 p 为 13,那么第一次预测的终点就发生在 $t=13$ 时,第一个预测值的产生时点即为 $y|t+1=y|14$,因为数据区间为 2016 年 1 月到 2020 年 9 月,与 $p=13$ 和初始月度数据 2006 年 1 月相对应的样本外观测区间的第一次预测值的产生月度为 2007 年 3 月,以此类推。在 4 个模型中, λ 的先验设定值主要通过样本外 2006 年 1 月到 2015 年 12 月这 10 年递归预测的效果得出,然后基于具体值对检验区间的预测效果进行判别。结合以上分析,一般情况下 3 变量模型的 λ 为无穷大,此时变量个数较少不需要进行参数收缩,通过数据模拟后,可以直接得出其他三个模型的 λ 。预测结果表明,14 变量、22 变量和 158 变量模型的 λ 分别为 0.156、0.07 和 0.011,相比之下,模型中所涉及的变量指标的个数越多,超参数 λ 就越小。为了检验模型对 2 月冲击的预测能力,通过在模型中直接设定上述步骤获得 λ ,考虑在 2017 年 1 月到 2020 年 2 月期间内 3 个主要宏观变量的预测效果。

令 T_0 为 2016 年 1 月, T_1 为 2020 年 2 月,那么当 $h=1$ 时,相应的检验区间的起点为 2016 年 12 月,终点为 2020 年 1 月。若开始 2017 年 1 月第一次预测,第一次预测的终点为 2016 年 12 月,与 $p=13$ 时相对应的月度数据预测区间为 2015 年 11 月到 2016 年 12 月;最后一次预测发生在 2020 年 2 月,此时月度数据预测的终点为 2020 年 1 月,月度数据预测区间变为 2018 年 12 月到 2020 年 1 月。特别地,当 $h=H=12$ 时,若开始第一次预测,预测起点为 2017 年 1 月,与 $p=13$ 时相对应的用来进行预测的数据区间即为 2014 年 12 月到 2016 年 1 月;若开始终点 2020 年 2 月的预测,数据区间相应地变为 2018 年 1 月到 2019 年 2 月。此时模型进行第一次预测的时间点在 2017 年 1 月,对应这月预测数据所使用的区间的终点即 T_1 为 2016 年 1 月;模型进行最后一次预测时间为 2020 年 2 月,对应这月预测数据所使用的区间的终点即 T_1 为 2019 年 2 月。

若 $h>1$,假设为 2 或者 3,由于在 $y|t+h-1 \sim y|t+h-n (h=n+1, n \geq 1)$ 区间内没有实际观测值,通过将预测值进行迭代的方式,参考 1 阶预测的模式来进行下一步的预测。以此类推,分别进行 1、2、3、6、12 阶超前预测。

表 2 显示各变量区间内预测的相对均方误差(RMSE)。就 1 阶 PMI 从业人员指数(EI)预测的 RMSE 来看,158 变量 LBVAR 模型对 EI 进行预测时的 RMSE 与 3、14、22 变量模型 RMSE 的区别并不明显,但就居民消费价格指数(CPI)和银行间同业拆借 1 天加权平均利率(ILOWAIR)的预测效果看,158 变量 LBVAR 模型预测的 RMSE 相对较小。根据上述结果,在进行短期 1 阶预测时,通过将 158 变量 LBVAR 模型与其他 3 个模型进行比较,发现在对核心宏观指标进行预测时,158 变量 LBVAR 模型的效果更好,预测精确度更高。而 2 阶、3 阶短期超前预测与 1 阶预测的结论一致,相较之下 158 变量 LBVAR 模型的预测精度更高。但在 6 阶、12 阶的中期预测中,就整体表现而言,14、22 变量模型的效果较好。综上所述,158 变量 LBVAR 模型在即期预测中的预测效果更好,较适用于短期预测的政策研究。

表2 区间内预测的相对均方误差

变量	1阶				2阶				3阶				6阶				12阶			
	3	14	22	158	3	14	22	158	3	14	22	158	3	14	22	158	3	14	22	158
EI	0.30	0.27	0.25	0.25	0.57	0.52	0.54	0.56	0.76	0.73	0.77	0.79	0.92	0.90	0.94	0.92	1.03	1.04	1.04	1.12
CPI	0.33	0.45	0.64	0.30	0.56	0.57	0.88	0.54	0.42	0.71	0.74	0.38	1.00	1.29	1.38	1.05	1.59	1.76	1.51	1.27
ILOWAIR	0.70	0.51	0.58	0.57	1.06	0.80	0.80	0.65	0.56	0.83	0.88	0.54	1.80	0.75	0.86	0.79	2.46	1.01	0.96	2.13

(三) 稳健性检验

基于表2的预测精度值,在1阶预测中3变量模型3个指标EI、CPI和ILOWAIR的RMSE分别为0.30、0.33、0.70,大部分高于其他3个模型,尤其是158变量模型中同变量的RMSE;在2、3、6、12阶预测中也有相同的结论,这表明3变量模型的预测效果在任何阶数都相对较差,图1对4个模型的EI预测值与EI实际值进行比较,发现3变量模型的预测值与实际值的偏离程度最大,预测效果最差。进一步地,本文对14变量、22变量、158变量的LBVAR模型的预测精度进行讨论。




图1 4个模型的EI预测值与EI实际值

为了得出外生冲击下(受疫情影响的月份)3个模型的短期预测效果,主要对2020年2月到9月这一期间的预测效果进行分析。然而,受疫情冲击影响,2020年3月与4月期间3个核心指标的数据波动幅度也比较大。基于数据平稳性这一要求,如果将这两个月的数据纳入检验区间内,可能会在衡量模型对数据预测的整体效果上产生影响。而且,从模型自身的角度出发,2020年3月到2020年4月分别作为2020年2月的后一期和后二期,在进行向量自回归时三者之间的相关系数会较高,但是实际上系统会进行缓冲和自动稳定,所产生的影响会比模型预测的略低。从图1可知,EI实际值在2月达到最低值后逐步上升,受模型反应滞后影响,4个模型EI实际值都表现为在3月达到最低值后开始增加,而且4月的预测值与实际值的拟合效果也不理想。直至5月,预测值与实际值才表现为较高的重合度。综上所述,不再对3月、4月进行进一步讨论,选择2020年5月到9月的预测值进行稳健性检验。

表3反映了2020年5月到9月期间模型的预测效果。在此期间,14变量、22变量和158变量LBVAR模型对CPI预测的RMSE分别为0.49、0.56和0.58,就CPI的预测效果看,3个模型的RMSE相差不大并且都小于1,说明3个模型的预测效果都好于随机游走预测。但对于EI的预测效果,14变量、22变量和158变量LBVAR模型对EI的RMSE分别为1.53、1.12和0.91,158变量LBVAR模型的RMSE相比14变量、22变量模型的1.53、1.12较小,且小于1,显然其预测效果更好且好于随机游走模型。在对ILOWAIR的预测效果上,14变量和22变量LBVAR模型对ILOWAIR的RMSE都小于1,分别为0.71和0.63,但是158变量LBVAR模型

预测的 $RMSE$ 更小,只有 0.23。结合 3 个核心变量的整体预测效果来看,使用 158 变量 LBVAR 模型进行预测的精确度更高,更具有预测价值,因此主要参考在 158 变量的 LBVAR 模型中所得到的 EI 预测值来对失业率进行分析。

表 3 三模型的变量预测结果和实际值

(单位:%)

年/月	EI				CPI				$ILOWAIR$			
	实际值	预测值			实际值	预测值			实际值	预测值		
		14	22	158		14	22	158		14	22	158
2020/05	48.70	51.13	49.71	49.99	2.40	2.91	2.95	3.39	1.19	2.32	1.81	1.66
2020/06	48.80	47.99	49.32	49.74	2.50	1.90	2.11	2.68	1.79	1.64	1.67	1.69
2020/07	48.40	47.64	49.21	49.19	2.70	2.42	2.27	2.64	1.83	2.43	2.16	1.92
2020/08	48.60	47.24	47.19	48.23	2.40	2.66	2.90	2.73	1.98	2.53	2.71	1.87
2020/09	49.20	47.51	47.65	48.24	1.70	2.36	2.55	2.47	1.70	2.48	2.70	1.80

(四) 失业率的预测结果

城镇调查失业率和 EI 往往会根据经济发展的方向发生变化。检验 2006 年 1 月到 2020 年 1 月期间失业率和 EI 这两个指标的平稳性,ADF 单位根检验结果表明,两变量均为 0 阶单整序列,说明其时间序列是平稳的。在此基础上,进一步分析城镇调查失业率与 EI 之间的关系。为了进一步探究两者之间具体转化形式,参考赵文^[26]的研究,假设转化失业率=上一年同期实际失业率 $\times(1-EI$ 的同比变化率)。2019 年 1 月到 12 月的实际失业率与转化失业率情况如表 4 所示。将表 4 中 2019 年实际失业率和基于 2018 年实际 EI 所得出的 2019 年转化失业率的值进行比较,发现两者转化偏差保持在 0~0.3 个百分点,由此可见,根据上述公式进行转化的可信度较高,城镇调查失业率和 EI 基本上呈反向变动。

表 4 实际失业率与转化失业率

(单位:%)

年/月	EI	实际失业率	转化失业率
2019/01	48.40	5.10	5.10
2019/02	48.33	5.30	5.10
2019/03	48.43	5.20	5.20
2019/04	48.33	5.00	5.00
2019/05	47.98	5.00	4.90
2019/06	47.88	5.10	4.90
2019/07	48.30	5.30	5.30
2019/08	48.40	5.20	5.20
2019/09	47.90	5.20	5.00
2019/10	47.98	5.10	5.00
2019/11	48.58	5.10	4.80
2019/12	48.05	5.20	4.90

从 2020 年 2 月开始,为了反映出冲击传导的效果,基于简单一次移动平均法,即式(3),来对预测值 $EI'_{i,t}$ 进行修正,同时,在数据平稳性的准则下,使用修正值 $EI^*_{i,t-1}$ 、 $EI^*_{i,t-2}$ 来替代实际值 $EI_{i,t-1}$ 、 $EI_{i,t-2}$ (具体替换公式如式(4)所示),并将修正后的数值代入式(3)中。特别地,2019 年 12 月的 $EI_{2019,12}$ 和 2020 年 1 月的 $EI_{2020,01}$ 不做修正,依旧为原始值,此时修正值 $EI^*_{i,t}$ 主要意义在于数据修正,同时也用来进行预测对比。

$$EI_{i,t}^{(1)} = \begin{cases} EI_{i,t} & i = 2020, t = 1 \\ \frac{1}{3}(EI'_{i,t} + EI^*_{i,t-1} + EI^*_{i-1,12}) & i = 2020, t = 2 \\ \frac{1}{3}(EI'_{i,t} + EI^*_{i,t-1} + EI^*_{i,t-2}) & i = 2020, t = 3, 4, \dots, 9 \end{cases} \quad (3)$$

$$EI_{i,t}^* = \begin{cases} EI_{i,t} & i = 2019, t = 12; i = 2020, t = 1 \\ EI_{i-1,t} \times \left(1 - \frac{u_{i,t}^* - u_{i-1,t}^-}{u_{i-1,t}^-}\right) & i = 2020, t = 2 \\ EI_{i,t-1} \times \left(1 - \frac{u_{i,t}^* - u_{i,t-1}^-}{u_{i,t-1}^-}\right) & i = 2020, t = 3, 4, \dots, 9 \end{cases} \quad (4)$$

在2020年2月,一次移动平均EI的预测值 $EI_{i,t}^{(1)}$ 为2月预测 $EI'_{2019,12}$ 、 $EI'_{2020,01}$ 和 $EI'_{2020,02}$ 三者的平均值,从3月开始,1次移动平均EI的预测值 $EI_{i,t}^{(1)}$ 为当月t预测 $EI'_{i,t}$ 、同年t-1期修正 $EI^*_{i,t-1}$ 和同年t-2期修正 $EI^*_{i,t-2}$ 三者的平均值。根据式(4),2月份的修正值 $EI^*_{2020,02}$ 是根据2019年2月实际EI值 $EI_{2019,02} \times (1 - 2020年2月失业率的同比变化率)$ 得出。从2020年3月开始,为了反映出传导效应,修正值 $EI_{i,t}^*$ 根据同年上一期修正值 $EI^*_{i,t-1} \times (1 - 月度失业率的环比变化率)$ 得出。

$EI_{i,t}^{(1)}$ 通过式(5)可得转化失业率 $UNER_{i,t}^{(1)}$ 。

$$UNER_{i,t}^{(1)} = UNER_{i,t-1}^{(1)} \times \left(1 - \frac{EI_{i,t}^{(1)} - EI_{i,t-1}^{(1)}}{EI_{i,t-1}^{(1)}}\right) \dots, i = 2020, t = 2, 3, \dots, 9 \quad (5)$$

根据上述失业率与从业人员的转化关系来获取中国失业率预测值 $UNER_{i,t}^{(1)}$,观察表5中各类EI值和失业率值可知,由于冲击发生在2020年2月份,并带有系统外因素的偶然性,基于历史先验信息的预测不足以全面地表现出EI的具体信息,2月失业率的实际值为6.2%,而预测值 $UNER_{i,t}^{(1)}$ 仅为5.4%。在2020年3月,使用一次移动平均对EI进行转化后的预测失业率值 $UNER_{i,t}^{(1)}$ 为5.9%,3月的实际值也为5.9%,完全符合实际。2020年4月在对 $EI'_{i,t}$ 进行移动平均后所预测到失业率值 $UNER_{i,t}^{(1)}$ 为5.8%,与实际值6%相差0.2个百分点,在合理预测偏差内。2020年5月 $UNER_{i,t}^{(1)}$ 为5.6%,与实际值5.9%分别相差0.3个百分点,在预测偏差0~0.3个百分点内。2020年6月 $UNER_{i,t}^{(1)}$ 为5.6%,和实际失业率5.7%相差0.1个百分点,预测偏差更小。7月 $UNER_{i,t}^{(1)}$ 为5.5%与实际值5.7%相差0.2个百分点,具有较小的偏差。8月为5.4%与实际值5.6%相差0.2个百分点,在偏差范围内。9月, $UNER_{i,t}^{(1)}$ 为5.4%与实际失业率5.4%完全符合。上述结果表明,转化失业率与实际失业率在2020年3到9月具有较高的拟合程度,且都表现出逐步下降的趋势。

表5 各类EI指数和失业率

(单位:%)

年/月	EI	UNER	$EI'_{i,t}$	$EI_{i,t}^{(1)}$	$EI_{i,t}^*$	$UNER_{i,t}^{(1)}$
2019/12	48.1	5.2	—	48.1	48.1	—
2020/01	48.3	5.3	47.9	48.3	48.3	—
2020/02	36.4	6.2	46.4	47.6	40.1	5.4
2020/03	48.5	5.9	37.0	41.8	42.1	5.9
2020/04	49.0	6.0	45.4	42.5	41.4	5.8
2020/05	48.7	5.9	50.0	44.0	42.0	5.6
2020/06	48.8	5.7	49.7	44.4	43.5	5.6
2020/07	48.4	5.7	49.2	44.9	43.5	5.5
2020/08	48.6	5.6	48.2	46.0	44.2	5.4
2020/09	49.2	5.4	48.2	46.1	45.8	5.4

综合以上分析,通过使用递归预测的方式能够得出四个模型在不同预测阶数下的结果,并且通过分析 4 个模型的相对均方误差对模型的预测精度进行比较,发现含有 158 个变量的 LBVAR 模型的预测效果较好,同时对冲击后 2020 年 5 月到 9 月的预测数据进行稳健性检验后发现,相较之下,此模型在中国疫情冲击后经济的传导预测上更具说服力。最后,通过对 EI 进行移动平均和公式转化后得出失业率的预测值,发现冲击后几个月的预测偏差都保持在 0~0.3 个百分点。以上综合分析表明,含有 158 个变量的 LBVAR 模型在核心经济指标波动性和稳定性特征上具有较好的预测能力。

四、结论和讨论

就业形势的预测对于推动高质量就业工作具有重要的意义。较大的外部冲击通常会导致系统外的重要变化,增加预测模型中变量个数就成为实现更加准确预测的首要方法,因此,短期的预测必须加入更多“及时”的变量,才能得到较为准确的结果。传统无约束 VAR 模型的参数数量随变量增加而急剧膨胀,导致过拟合风险高。如何在增加变量数量的同时有效估计参数是一个难题。

本文基于中国宏观经济的 158 个月度指标构建了一个大型贝叶斯自回归模型,探讨了此模型在宏观指标中的预测作用,尤其在对 PMI 中的从业人员指数进行短期预测方面。结果显示,大型贝叶斯自回归模型更适合大样本数据。在目前的统计环境下,估计含有 100 多个变量的贝叶斯 VAR 模型不仅是可行的,而且它比文献中所考虑的典型的含有 30 个变量以内的 VAR 模型预测结果更好,加入更多变量的 LBVAR 模型对从业人员指数具有更精准的预测效果。由于选取变量通常带有一定主观性,受到变量个数限制的 VAR 模型难以全面吸收宏观经济指标的有效信息,而 LBVAR 模型通过囊括更多指标至模型中,能够更全面地利用经济指标信息,实现对冲击反应的更高敏感性,从而使得从业人员指数的预测结果更加符合就业形势的变化。总的来说,在经济结构转型、外部环境复杂多变的背景下,就业市场的不确定性显著提升,LBVAR 模型的短期预测优势能够为政策预留更充足的调整窗口,增强就业政策的前瞻性与灵活性,从而为宏观经济调控中就业政策的制定与优化提供更具针对性的决策支撑。

当然,通过预测从业人员指数,在宏观经济指标和就业市场形势之间建立起联动的观察机制只是初步的工作。要更全面地衡量就业市场和经济运行之间的关系还有很多工作要做。比如,对不同群体、不同行业的从业人员指数进行细致预测,可以增强积极就业政策的针对性。过去,城镇登记失业率与经济形势联系不紧密,所以使用城镇调查失业率来观察就业形势。但是近年来城镇调查失业率也出现了类似的情况。这意味着就业市场统计体系有待进一步完善,以便为就业形势的科学研判和政策调控提供有力支撑。

参考文献:

- [1] 劳动和社会保障部劳动科学研究所课题组.我国失业预警系统与就业对策研究[J].经济研究参考,2002(34):11-26.
- [2] 李宏,李建武,莫荣,等.基于回归分析的失业预警建模实证研究[J].中国软科学,2012(5):138-147.
- [3] 陈恺,申广军,谭韦珊.调查失业率与奥肯定律再检验——兼谈自然失业率与青年失业问题[J].经济学报,2025,12(1):19-37.
- [4] 葛明,高远东.价值链分工、需求结构与就业波动[J].经济学动态,2025(9):135-152.
- [5] 贾海彦,王进明,赛晓好.数字经济对中老年就业的影响研究[J].山东财经大学学报,2024,36(6):108-122.
- [6] 王佳慧,刘金东,褚洪良.研究生扩招有助于缓解青年失业吗——来自 OECD 国家的证据[J].山东财经大学学报,2025,37(2):33-48.
- [7] 都阳,张翕.中国自然失业率及其在调控政策中的应用[J].数量经济技术经济研究,2022,39(12):26-45.
- [8] 孙婧芳,蔚金霞,杜凤莲.新冠疫情冲击下农业对非农失业的缓冲作用:农业劳动力蓄水池功能的再思考[J].中国农村经济,2024(11):42-60.

- [9]刘学良,宋炳妮.新冠肺炎疫情下的失业情况、失业率修正及就业保障[J].中国劳动关系学院学报,2021,35(4):87-96.
- [10]SIMS C A.Macroeconomics and reality[J].Econometrica,1980,48(1):1-48.
- [11]SIMS C A.Are forecasting models usable for policy analysis? [J].Quarterly Review,1986(10):2-16.
- [12]DE LUNA X,GENTON M G.Spatio-temporal autoregressive models for US unemployment rate[J].Advances in Econometrics,2004(18):279-294.
- [13]GRODZICKI T,JANKIEWICZ M.Forecasting the level of unemployment, inflation and wages; the case of Sweden[J].European Research Studies Journal,2020(2):400-409.
- [14]STARK T.A Bayesian vector error corrections model of the U.S. economy [R].Federal Reserve Bank of Philadelphia, Working Paper,1998.
- [15]STELLA A,STOCK J H.A state-dependent model for inflation forecasting[R].Board of Governors of the Federal Reserve System (U.S.),International Finance Discussion Papers 1062.
- [16]DE MOL C,GIANNONE D,REICHLIN L.Forecasting using a large number of predictors; is Bayesian shrinkage a valid alternative to principal components? [J].Journal of Econometrics,2008,146(2):318-328.
- [17]BANBURA M,GIANNONE D,REICHLIN L.Large Bayesian vector auto regressions[J].Journal of Applied Econometrics,2010,25(1):71-92.
- [18]CHRISTIANO L J,EICHENBAUM M,EVANS C L.Monetary policy shocks; what have we learned and to what end? [R].NBER working papers,1998,No.6400.
- [19]FORNI M,HALLIN M,LIPPI M, et al.The generalized dynamic - factor model: identification and estimation [J].Review of Economics and Statistics,2000,82(4):540-554.
- [20]STOCK H J,WATSON W M.Macroeconomic forecasting using diffusion indexes[J].Journal of Business & Economic Statistics,2002,20(2):147-162.
- [21]STOCK J H,WATSON M W.Implications of dynamic factor models for VAR analysis[R].NBER Working paper,2005.No.11467.
- [22]LITTERMAN R.Forecasting with Bayesian vector autoregressions-five years of experience[J].Journal of Business & Economic Statistic,1986,4(1):25-38.
- [23]KADIYALA K R,KARLSSON S.Numerical methods for estimation and inference in Bayesian VAR-models[J].Journal of Applied Econometrics,1997,12(2):99-132.
- [24]ROBERTSON J C,TALLMAN E W.Vector autoregressions; forecasting and reality[J].Economic Review(Federal Reserve Bank of Atlanta),1999,84(Q1):4-18.
- [25]周建,况明.中国宏观经济动态传导、可靠性及货币政策机制[J].经济研究,2015,50(2):31-46.
- [26]赵文.短期失业率预测研究[J].财经智库,2021,6(3):105-117,144.

Forecasting China's Short-Term Employment Situation: Based on a Large Bayesian Vector Autoregressive Model

ZHAO Wen¹, XIAO Shuangshuang²

(1. *Institute of Population and Labor Economics, Chinese Academy of Social Sciences, Beijing 100028, China;*

2. *School of Statistics, Beijing Normal University, Beijing 100875, China)*

Summary: In recent years, such external shocks as trade frictions and COVID-19 have frequently superimposed, significantly exacerbating the short-term fluctuations in China's employment market, and the need for timely and precise prediction of employment situations has become increasingly prominent. Due to such factors as short time series and statistical caliber adjustment, the surveyed urban unemployment rate is difficult to directly meet the requirements of short-term prediction. In comparison, the practitioner index in the Purchasing Managers' Index (PMI) is characterized by high frequency of release, stable historical series and rapid response to shocks, making it a more suitable leading indicator for reflecting the changes in employment conditions. To enhance short-term forecasting capabilities, this study constructs a large Bayesian Vector Autoregressive (LBVAR) model encompassing 158 monthly macroeconomic indicators, and by employing the Minnesota priori and the normal-inverse Wishart priori, mitigates the "curse of dimensionality" through Bayesian shrinkage while maximizing the utilization of the information from a large data set. And based on this, this study selects the overall tightness hyperparameter with relative mean squared error as the criterion, tests the model's out-of-sample prediction performance in different forecast periods, and meanwhile, compares this large model with the three types of small and medium-sized LBVAR models that contain 3, 14, and 22 variables, and finally, converts the predicted value of the PMI practitioner index into the predicted value of the surveyed urban unemployment rate based on empirical formulas. The research results indicate that in the short-term (1-3 periods) forecasts of the PMI practitioner index, consumer price index, and 1-day weighted average inter-bank lending rate, the relative mean squared error of the 158-variable LBVAR model is the smallest overall, and its forecast accuracy is significantly better than that of small and medium-sized models. The further robustness tests conducted from May to September 2020 after the shock of the pandemic revealed that the large model exhibits the lowest prediction error for the PMI practitioner index with all the three core indicators significantly outperforming the random-walk benchmark model. The surveyed urban unemployment rate in 2020 calculated based on the PMI practitioner index forecast reveals that the forecast errors from March to September mostly remain between 0 and 0.3 percentage points, effectively capturing the dynamic trend of the declining unemployment rate. On the whole, under the premise of reasonably setting the Bayesian shrinkage intensity, the LBVAR model which incorporates more variables is technically feasible and significantly outperforms the traditional small VAR models in short-term forecasting of China's macroeconomic indicators. By incorporating a large number of macro and financial indicators with "timeliness", large-scale LBVAR models can more sensitively capture the transmission process of external shocks within the economic system, thereby significantly enhancing the predictive accuracy of employment-related indicators, and providing more solid technical support for the forward-looking, flexible and precise implementation of employment policies. In the future, the monitoring and early warning capabilities for employment risks are expected to continuously enhance by further integrating macro-financial data and perfecting the employment statistics system.

Key words: practitioner index; vector autoregressive model; Bayesian shrinkage; relative mean square error

JEL Classification: J21; C82

(责任编辑 张媛媛)