间歇性参与下的预测合成：来自通胀密度调查的证据

Matthew C. Johnson*、Matteo Luciani†、
Minzhengxiong Zhang‡ 和 Kenichiro McAlinn§

arXiv:2602.05226v1 [stat.AP] 5 Feb 2026

摘要

中央银行依赖专业人士调查中的密度预测来评估通胀风险并传达不确定性。使用此类调查面临的一项核心挑战是参与不规律：预测者会加入或退出、跳过某些轮次，也会在长时间缺席后重新出现。在欧洲中央银行的专业预测者调查中，人员更替和缺失情况随时间显著变化，导致提交预测的人员名单每季度都在变动。标准聚合规则——例如等权合并、剔除缺席预测者后重新归一化，或临时插补——可能会导致组合预测出现人为跳变，其驱动因素是面板构成而非经济信息，从而增加实时解读的难度，并掩盖预测者表现。我们针对间歇性参与下的预测组合，提出了连贯的贝叶斯更新规则；即使无法观测到某位预测者的预测，该规则仍会为其维持定义明确的潜在预测状态。组合预测分布并非通过重新归一化或插补来更新，而是依据面板隐含的条件结构进行更新。这种方法能够区分真实的表现差异与机械性的参与效应，并呈现出可解读的预测者影响力动态。在欧洲中央银行的调查中，与等权基准相比，该方法提高了预测准确度，并生成了更平滑、校准更佳的通胀密度预测，尤其是在人员更替率较高的时期。

关键词：贝叶斯预测综合、时间序列、缺失数据、预测组合、调查面板

*亚马逊。 邮箱：jnmmatt@amazon.com

†美国联邦储备系统理事会。邮箱：matteo.luciani@frb.gov

‡统计科学系，天普大学福克斯商学院，宾夕法尼亚州费城 19122。邮箱：tuj77601@temple.edu §统计科学系，天普大学福克斯商学院，宾夕法尼亚州费城 19122。邮箱：kenichiro.mcalinn@temple.edu

免责声明 # 1：本文所表达的观点仅代表作者本人，并不一定反映美国联邦储备系统理事会或美国联邦储备系统的观点和政策。免责声明 # 2：本出版物与亚马逊无关，也不代表该公司及其子公司的立场。本文内容属于持续合作的一部分，基于作者加入亚马逊之前完成的工作。

1 引言

通胀预期调查在通胀预测和评估价格稳定风险方面发挥着核心作用，并受到政策制定者和市场参与者的密切关注。美联储等主要中央银行（Yellen，2015年）和欧洲中央银行（Eser 等人，2020年）定期将基于调查的通胀预期纳入其预测框架。除了点预测（例如，在预期扩展型菲利普斯曲线模型中使用的中位数）之外，这些机构还依靠调查答复的完整分布来评估通胀风险，例如费城联邦储备银行的专业预测者调查（SPF）和欧洲中央银行的 SPF。鉴于这些调查在机构通胀预测中发挥着核心作用，估计的通胀预期分布变化应反映真实的经济信息，而非预测汇总造成的机械性假象。

许多专业预测调查有一个看似基本、却影响深远的特点：参与极不规律。以欧洲中央银行的 SPF 为例，预测者经常跳过某些轮次、进入或退出面板，参与间隔也往往长短不一。当参与断断续续时，标准汇总方法可能会使组合密度预测出现人为波动，从而扭曲人们对不确定性变化和尾部风险的判断。现有的预测组合方法，对于如何在参与不规律时组合基于调查的密度预测，所提供的指导有限。本文在概率框架内将这一问题形式化，并提出一种理论基础扎实、计算简单且实用有效的协调一致的解决方案。

参与断断续续时，标准的实际操作汇总方式——剔除缺席的预测者并重新归一化权重，将当前可用的密度合并；或通过末次观测值结转法等简单插补填补缺口——可能会造成组合不确定性和尾部风险</style)的虚假变动。这些假象源于合并对象会随着贡献者集合的变化而改变：即使经济环境本身未变，仅仅因为高方差或离群预测者进入或退出，合并后的离散度也可能不同。这正是本文要解决的实际问题：将不确定性的真实变化与进入、退出及间歇性参与造成的假象区分开来，从而使离散度和尾部风险信号在实时监测中仍具有可解释性。

我们在欧洲央行专业预测者调查（ECB SPF）关于欧元区未来一年通胀的调查中记录了这些问题，该调查中的参与极不均衡。超过半数的预测者并不定期参与，长时间缺席的情况很常见，而且进入与退出模式随时间大幅变化。这些特征在宏观经济压力时期尤为显著，此时预测分散度与面板不稳定性会同时加剧。在此类时期，要将组合预测不确定性的机械性变化与对通胀风险认知的真实变化区分开来尤其困难。

偶发参与　　参与并非欧洲央行 SPF 的特例。许多机构预测

系统——包括费城联储 SPF 和众多私营部门共识平台——都会汇总来自各类面板的预测，而这些面板存在持续的进入、退出和间歇性参与模式，且这些模式往往会在不确定性加剧时期变得更为明显。在这些环境中，平衡面板在操作上难以实现，因此聚合规则必须能够在参与不规则的情况下保持可靠，而不能依赖临时的重新归一化或长期预测插补。我们的目标明确是在实际报告的信息基础上进行实时聚合，同时避免将报告中的行政性变动误读为不确定性的变化。

为应对这些挑战，我们提出一种有原则的、对更替敏感的预测合成方法：即使预测暂时缺失，也能为每位预测者维持连续的潜在评估。我们的方法既不剔除缺失的预测者（这会引人不连续），也不冻结其最近一次提交的密度（这会忽略新信息），而是通过面板所隐含的条件结构更新每位预测者的潜在预测状态。由此可将真实的表现差异与参与效应区分开来，并确保聚合密度随经济消息平稳演化，而非随行政性更替而变化。贝叶斯相干性要求给出明确的局部进入与退出调整规则，从而保留综合权重的学习动态，并避免预测均值与方差中的人为不连续。

我们利用近25年的通胀密度预测，在实时预测实验中评估所提出的方法。相对于等权合并——这一在实践中往往难以超越的基准——相干合成方法提高了点预测准确度，并给出校准明显更好的密度预测。这些改进在高波动率与预测者更替加剧的时期最为显著。从经济角度看，校准的改善意味着预测分散度与尾部风险的变动更能反映不确定性的真实变化，而非面板构成的变化；这一区分对中央银行实时评估通胀风险尤为重要。

本文有三项贡献。第一，本文针对预测分布中的预测者更替与缺失，对预测组合进行了形式化，并通过实证表明，在一项重要的机构调查中，常见的临时应对方法可能会显著扭曲合成后的不确定性，并混淆评估结果。第二，本文在动态贝叶斯预测综合框架内，提出基于相干性的进入与退出调整，从而在任意参与模式下实现一种有原则且可操作的聚合规则。第三，本文通过应用驱动的实证评估表明，基于相干性的调整能够提高预测准确度，并增强对实时不确定性与尾部风险动态的经济学可解释性。

本文其余部分安排如下。第2节介绍 SPF 的背景设定，以及参与不规律时标准合并方法所产生的实际问题。第3节阐述推动我们采用该方法的一致性概率表述。第4节在动态 BPS 框架下提出基于一致性的进入与退出算子。第5节介绍预测设计、基准和实证结果。第6节讨论实际影响

与扩展，第7节作总结。补充材料包含计算细节，以及针对设定、预测者集合规模和数据集（失业率）的稳健性分析。

相关文献

预测组合文献可追溯至 Bates 和 Granger（1969年），此后发展出线性池化、收缩权重、贝叶斯模型平均，以及基于损失的准则下的最优组合（例如，Clemen，1989年；Timmermann，2004年；Jore 等人，2010年；Geweke 和 Amisano，2011年）。具体而言，在密度预测方面，已有多种方法用于组合预测密度（例如，Hall 和 Mitchell，2007年；Amisano 和 Giacomini，2007年；Geweke 和 Amisano，2011年；Billio 等人，2012年；Aastveit 等人，2014年；Pettenuzzo 和 Ravazzolo，2016年；Del Negro 等人，2016年；Aastveit 等人，2018年）。这些方法通常将预测者视为固定且完全可观测的，因此，当贡献者集合随时间变化时，这些方法几乎无法提供指导。

贝叶斯预测综合（BPS）通过引入潜在的特定预测者预测状态和合成函数，提供了一个用于组合预测密度的一致框架（McAlinn 和 West，2019）。BPS 已应用于多变量宏观预测（McAlinn 等人，2020）、混频即时预测（McAlinn，2021）、结果依赖型池化（Johnson 和 West，2025），以及用于货币政策的决策综合（Tallman 和 West，2024；Chernis 等人，2024；Adrian 等人，2025）。在可用预测的集合不可预测地变化的调查环境中，BPS 为维持概率一致性提供了一条自然途径。

少量研究考察了存在缺失数据的预测面板（例如 Genre 等人，2013年；Dovern，2015年），但重点在于对个体预测进行建模或填补缺失响应值，而非进行一致的组合。标准处理方法依赖临时填补、EM 风格的平滑或整行删除——当观测集合随时间变化时，这些方法都无法保留一致的贝叶斯规则所蕴含的条件结构。机构预测文献主要集中于评估调查中的偏差或分歧（例如 Clements，2010年；Dovern 和 Weisser，2011年；Boero 等人，2015年），而非研究在间歇性参与下进行一致组合。

2 使用专业预测者调查进行预测

本文旨在解决机构预测系统中的一个实际问题：当贡献预测者集合不稳定时，如何构建单一的实时预测分布。此类系统依赖专业预测者调查。在我们的应用中，目标是结合欧洲中央银行专业预测者调查（SPF）中各预测者的预测分布，生成季度通胀密度预测。该调查被广泛用于通胀监测与沟通。这一环境的显著特点是参与并不均衡：预测者会随时间加入或退出、跳过调查轮次，之后又重新出现

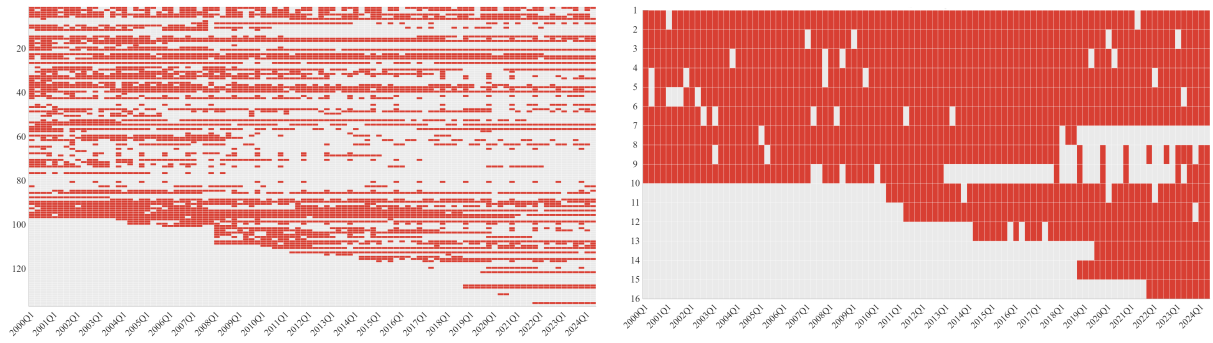

所有预测者　　应用中使用的预测者

图1：专家预测者随时间的参与情况。左图：完整面板的参与情况。右图：用于分析的子面板的参与情况。浅灰色表示不活跃，红色表示积极贡献。

即使间隔很长时间后也会重新出现，因此可用密度预测的面板每个季度都在变化（图 1）。这就是本文要解决的应用问题。 标准汇聚规则通常假定贡献者集合固定；若将其机械地应用于不断变化的面板，合成预测矩就可能出现人为波动，而这些波动是由条件集变化而非新信息所驱动的。

2.1 为什么更替和缺失是一阶特征

图 1 展示了预测者活动随时间变化的热力图。自调查启动以来，已有超过130名不同的预测者参与其中，形成了一个极为稀疏且不规则的面板（左图）。在实时评估中，我们聚焦于一个预先指定的 核心面板 ，该面板既提供了足够的历史记录来初始化预测规则并对其进行评分，同时仍保留了大量的进入/退出和间歇性参与现象（右图）。具体而言，我们选择在整个样本期间提交非缺失密度数据总数最多的预测者，但要求其在初始训练窗口中拥有足够的观测值以完成初始化。这样得到的核心面板包含 $J = 16$ 名预测者，其信息丰富程度足以支持稳定的实时基准评估，同时仍呈现出较长的参与间隔和显著的时变更替（图 1，右图）。补充材料的第S2.2节验证了，将面板扩展至 $J = 20$名预测者并不会改变主要发现。

图1的三个特征与实时聚合尤其相关。首先，进入与退出十分频繁：活跃集合 A_t 并非缓慢变化，也不存在稳定或稳态面板。其次，缺失具有持续性：许多预测者会连续较长时间缺席，而不是只缺失一轮。第三，参与会随时间变化，其变化方式很可能与宏观经济环境相关，因此，面板不稳定性往往恰恰在预测不确定性最为重要时最为显著。

这些特征并非无关紧要的记账问题。图2 显示，活跃专家人数随时间显著变化（面板 (a)），参与者的预测离散度显著（面板 (b)），且参与率（活跃季度占比）与

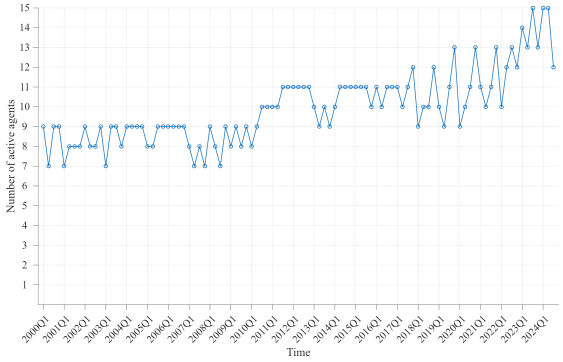

(a) 活跃专家人数随时间的变化。

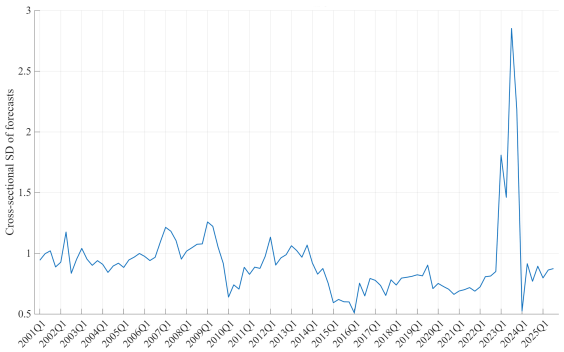

(b) 活跃专家之间的预测分散度。

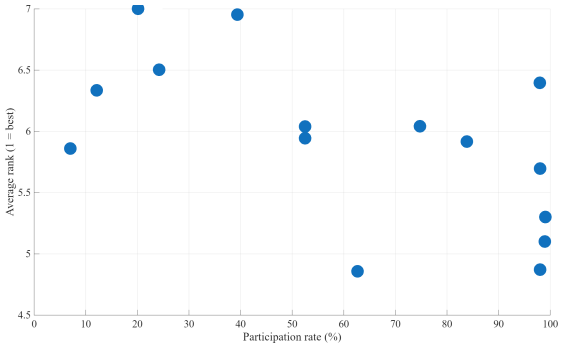

(c) 参与率的预测误差。

图2：央行预测小组的描述性特征。

预测误差呈负相关（面板 (c)），这表明参与并非随机。图3进一步显示，专家之间的预测误差存在很强的依赖关系，进一步说明预测多样性与相关性并存，汇总方法必须同时考虑能力异质性和横截面依赖。这一点也可以为我们的分析所用：如果两位预测者高度相关，其中一位退出，那么权重的变化理应反映这种高度相关性。

2.2 机构通常如何组合调查预测

在实践中，基于调查的预测通常采用的主流操作基准，是对截至时间 t 之前收到的所有提交结果取平均：等权（EW）组合规则。在我们的实证分析中，等权组合（EW）作为主要参考基准；众所周知，在许多预测情境下，很难胜过这一方法（例如，Genre 等人，2013年）。

相关方法通过在稳定性约束（如非负约束和单纯形约束）下，依据频率学派评分规则估计组合权重，从而有别于等权方法；这些方法适用于点预测和密度预测；参见 Conflitti 等人(2015年) 以及Diebold 和 Shin(2019年) 提出的正则化“部分平等主义” LASSO 方法。第二类务实的修正方法会在求平均之前插补缺失提交，例如采用末次观测值结转法或预测者特定均值插补。第三类方法根据历史预测误差估计权重，例如利用滚动窗口计算均方误差倒数权重。

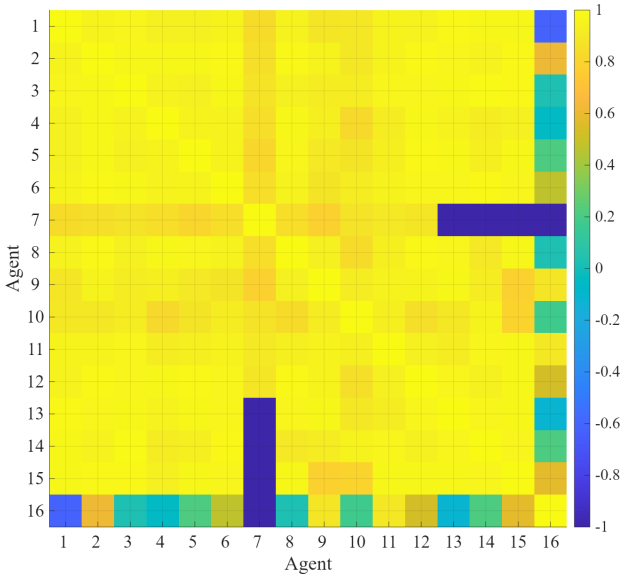

图3：专家预测误差的相关矩阵。

尽管这些策略各不相同，但它们都隐含地将预测者集合视为在估计窗口内基本固定，因此对 A_t 中的不稳定性十分敏感。我们关注的是与此互补（且在实证中至关重要）的问题：在许多调查中，预测者集合本身会随着新成员进入、成员退出以及间歇性参与而迅速变化，因此聚合规则必须适应不断变化的信息集，而非人为稳定的面板。

2.3 应用问题：为什么朴素修正会扭曲密度预测

更替和缺失造成了机构目标与朴素汇总结果之间的不匹配。机构的目标是得到一个单一的季度预测密度，其变化反映有关通货膨胀的新信息和预测者信念的变化，而不是因行政原因导致的应答者变化。然而，当活跃集合 A_t 发生变化时，常见的操作性修正会隐含地改变支撑汇总对象的条件集 。

密度预测中有两种机制尤其令人担忧。首先，插补缺失密度会引入合成信息，并实质性地改变支撑合并密度的联合预测结构，尤其是在缺席持续时间较长或属于永久缺席时。其次，剔除缺失的预测者并重新归一化权重，会在剩余预测者之间重新分配影响力；即使底层预测环境保持稳定，也可能导致组合预测均值和方差出现人为跳变。在密度预测情境下，这些人为因素影响重大：它们会改变感知风险水平、扭曲尾部概率，并混淆对校准和尖锐度的回测，因为预测变化可能由参与情况而非学习所驱动。

2.4 基于调查的密度组合要求

SPF 情境提出了对可用组合程序的具体要求：(i) 组合密度应通过对观测到的预测进行条件化来更新，而不是机械地重新归一化权重或插入临时填补；(ii) 合并后的离散度和尾部风险度量不应在进入与退出时点发生机械性跳变；(iii) 该方法不应要求为参与情况指定结构模型；(iv) 即使参与是间歇性的，该程序也应支持对预测者增值进行有意义的推断。这些要求直接源于面板数据的实证特征：频繁的进入与退出、持续性的缺失，以及时变的参与情况。

3 问题表述

现在，我们将第 2 节的实际要求纳入概率框架，形式化定义当只有部分预测者提交密度且活跃集合随时间变化时，组合预测分布的一致更新应满足的条件。

3.1 观测到的预测密度与时变活跃集合

令 y_t 表示在季度 t 测量的目标次年通胀率，并令 $h_{j,\,t}(\cdot)$ 表示预测者 j 在时间 t 之前提交的、针对 y_t 的密度预测。最多有 J 名潜在预测者组成的预测者池。在时间 t 之前，预测者 j 可以提供关于 y_t 的完整预测密度，

$$h_{j,t}(x) \;\equiv\; p_j(y_t = x_t | \mathcal{I}_{j,t})\,,$$

其中，$\mathcal{I}_{j,\,t}$ 表示预测者 j 关于时间 t 的信息集。令 $A_t \subseteq \{1,\ldots,J\}$ 表示时间 t 的活跃预测者集合，即提交密度预测的预测者集合。在全文中，形如 $H_{A_t,\,t}$ 的双下标表示将量 H 限制在时间 t 的预测者子集 A_t 上。我们观测到以下集合

$$H_{A_t,t} \;\equiv\; \{h_{j,t}(\cdot) : j \in A_t\},$$

而 $j \notin A_t$ 的密度则无法观测。

决策者（DM）寻求 y_t 的单一预测分布，该分布基于过去结果以及时间 t 之前观测到的密度（例如 $t-1$）。关键难点在于 A_t 随时间变化，因此一个连贯的模型必须规定：当仅观测到$H_{A_t,\,t}$ 时，DM的预测分布如何更新。

3.2 含潜在预测状态的预测综合

贝叶斯预测综合（BPS）将每位预测者的密度表示为关于潜在预测状态$x_{j,\ t}$ 的信息，并通过合成函数将这些状态加以综合。令 $\boldsymbol{x}_t$ =($x_{1,\ t}$，……，$x_{J,\ t}$)′ 汇集潜在状态，并令 $m_t(\boldsymbol{x}_t)$表示DM对 $\boldsymbol{x}_t$ 的联合预测先验（在观测时间 t之前各预测者的密度之前）。令 p_t (y_t)表示DM基于截至为时间t作出预测时所掌握的信息、对 y_t 的预测先验。DM指定一个合成函数 $\alpha_t(y_t|\boldsymbol{x}_t,\ \Phi_t)$，其参数为 Φ_t，该函数将潜在状态映射为 y_t的预测密度。在完全平衡面板下——即当全部 J 个密度均被观测到时——BPS后验预测具有如下形式

$$p(y_t|H_t, y_{1:t-1}) \ = \ \int \alpha_t(y_t|\boldsymbol{x}_t, \Phi_t) \prod_{j=1}^{J} h_{j,t}(x_{j,t})\, dx_t, \tag{1}$$

其中 $H_t = \{h_{1,t}, \ldots, h_{J,t}\}$。

3.3 一致性（一致）条件

式（1）只有在 DM 的先验预测分布p_t（y_t）通过综合函数与联合先验 m_t（$\boldsymbol{x}_t$）一致时，才是贝叶斯相干的:

$$p_t(y_t) \ = \ \int \alpha_t(y_t|\boldsymbol{x}_t, \Phi_t)\, m_t(\boldsymbol{x}_t)\, d\boldsymbol{x}_t. \tag{2}$$

方程（2）是一致性（或相符性）条件：DM 对 y_t 的先验必须等于联合模型所蕴含的边缘分布，即 （y_t，$\boldsymbol{x}_t$）。在固定且完全观测的面板中，这一要求通常无碍，因为可以直接选择满足条件的先验。然而，在更替和缺失的情况下，一致性至关重要，因为当仅观测到部分预测密度且活跃集合 A_t随时间变化时，该条件仍须成立。

3.4 部分观测：仅使用$H_{A_t,\ t}$进行相干更新

当仅观测到 $H_{A_t,\ t}$ 时，BPS 将缺席的预测者视为潜在预测状态中未被观测到的分量，而不是视为从模型中消失的贡献者。用 $\boldsymbol{x}_t = (x_{A_t,\ t},\ x_{A_t^c,\ t})$ 表示将潜在状态划分为活跃分量和非活跃分量。相干更新会用报告的密度替换观测分量的先验，同时让非活跃分量仍由其预测先验支配。

定义 res　　通过对非活跃状态进行边缘化而获得的受限合成函数，使用

动态模型的条件先验分布：

$$\alpha_{A_t,t}(y_t|x_{A_t,t},\Phi_t) \;=\; \int \alpha_t\big(y_t|x_{A_t,t},x_{A_t^c,t},\Phi_t\big)\; m_t(x_{A_t^c,t}|x_{A_t,t})\,dx_{A_t^c,t}. \tag{3}$$

仅给定活动集密度时，相干的后验预测分布为

$$p(y_t|H_{A_t,t},y_{1:t-1}) \;=\; \int \alpha_{A_t,t}(y_t|x_{A_t,t},\Phi_t)\prod_{j\in A_t} h_{j,t}(x_{j,t})\,dx_{A_t,t}. \tag{4}$$

方程（3）–（4）阐明了在相干的概率框架中应如何处理缺失的预测者：将其视为对未观测潜在状态进行边缘化，而非改变模型维度或重新归一化权重。这一概率对象将在下一节中用于推导动态 BPS 模型中的显式进入与退出算子，从而确保后验学习和预测不确定性随 A_t 随时间平滑演变。

4 进入与退出下的相干更新

本节将第 3 节提出的相容性原则应用于 McAlinn 和 West (2019年) 的动态贝叶斯预测综合模型，并推导显式的进入与退出算子。其核心思想是，潜在预测状态和合成系数在各时点均保持固定维度 J，而进入与退出仅改变潜在状态中哪些分量可被观测（因而会进入似然），直至时点 t。

4.1 时变专家集合下的联合高斯更新

令 $\boldsymbol{\theta}_t = (\theta_{0,t}, \theta_{1,t}, \ldots, \theta_{J,t})'$ 表示时间 t 的合成系数，并令 $\boldsymbol{x}_t = (x_{1,t}, \ldots, x_{J,t})'$ 表示潜在专家特定预测状态。在 McAlinn 和 West（2019）的动态贝叶斯预测综合模型下，给定 $(\boldsymbol{\theta}_t, \boldsymbol{x}_t)$，合成函数是高斯且线性的：

$$y_t \;=\; \theta_{0,t} + \theta'_{1:J,t}\boldsymbol{x}_t + \nu_t, \qquad \nu_t \sim N(0, v_t). \tag{5}$$

给定过去数据和过去的预测信息，$(\boldsymbol{\theta}_t,\ \boldsymbol{x}_t)$ 具有预测先验（在状态演化和高斯预测状态设定下为高斯分布）。通过确保仅观测到部分专家时，对该子集进行相容贝叶斯条件化以获得 y_t 的预测分布，即可处理进入与退出——而无需改变 $(\boldsymbol{\theta}_t,\ \boldsymbol{x}_t)$ 的维度。

令 $A_t \subseteq \{1, \ldots, J\}$ 表示时间 t的活动专家集，并令 A_t^c表示其补集。记作 $\boldsymbol{x}_t = (x_{A_t,\ t},\ x_{A_t^c,\ t})$，类似地，记作 $\boldsymbol{\theta}_t = (\theta_{A_t,\ t},\ \theta_{A_t^c,\ t})$。时间 t 之前观测到的预测密度为 $\{h_{j,t} : j \in A_t\}$；非活跃专家对应的是预测状态中未观测到的分量，而不是从模型中消失的参数。

4.2 退出即边缘化

假设某些专家在 $t-1$ 时活跃，但在 t时不活跃，即 $j \in A_{t-1} \setminus A_t$。由于时间 t的似然仅取决于 $x_{A_t,\ t}$ （通过观测到的预测信息）以及活跃系数，相干更新会将 $(x_{A_t^c,\ t},\ \theta_{A_t^c,\ t})$ 视为由其预测先验支配的潜在分量。等价地，合成函数通过在决策者的先验条件分布下对非活跃状态进行边缘化来更新：

$$p_t(y_t|H_{A_t,t}) = \int \alpha_{A_t,t}(y_t|x_{A_t,t}) \prod_{j\in A_t} h_{j,t}(x_{j,t})\, dx_{A_t,t}, \tag{6}$$

$$\alpha_{A_t,t}(y_t|x_{A_t,t}) = \int \alpha_t(y_t|x_{A_t,t}, x_{A_t^c,t})\, m_t(x_{A_t^c,t}|x_{A_t,t})\, dx_{A_t^c,t}. \tag{7}$$

这正是一致性所蕴含的“移除一个专家”操作：它是对未观测潜在状态的贝叶斯边缘化，而不是模型维度的改变，也不是重新归一化规则。

闭式高斯推论。 假设（i）活跃集预测状态服从高斯分布，且

$$x_{A_t,t}|H_{A_t,t} \sim N(h_{A_t,t}, H_{A_t,t}),$$

（其中 $H_{A_t,t}$ 在活跃专家之间的独立预测状态抽样下为对角阵），且（ii）完整潜在状态的预测先验为联合高斯分布：

$$\begin{pmatrix} x_{A_t,t} \\ x_{A_t^c,t} \end{pmatrix} \sim N\left(\begin{pmatrix} m_{A_t,t} \\ m_{A_t^c,t} \end{pmatrix}, \begin{pmatrix} M_{A_t,t} & M_{A_t,A_t^c,t} \\ M_{A_t^c,A_t,t} & M_{A_t^c,t} \end{pmatrix} \right).$$

Let

$$B_t \ = \ M_{A_t,A_t^c,t}\, M_{A_t,t}^{-1}.$$

于是，对非活跃状态进行边缘化会为 $y_t|H_{A_t,t}$诱导出一个经调整的线性高斯合成，其中

$$_t\tilde{h}_{A_t,t,} \qquad \tilde{}\mathbb{E}[y_t|H_{A_t,t}] = \theta_{0,t} + \theta'_{A_t} \tag{8}$$

$$\mathrm{Var}(y_t|H_{A_t,t}) = v_t + \theta'_{A_t,t} H_{A_t,t}\theta_{A_t,t} + \theta'_{A_t^c,t} M_{A_t^c,t}\theta_{A_t^c,t} + \theta'_{A_t^c,t}(B'_t(H_{A_t,t} - M_{A_t,t})B_t)\,\theta_{A_t^c,t}, \tag{9}$$

其中，有效（由一致性决定的）系数调整为

$$\tilde{\theta}_{0,t} = \theta_{0,t} + \theta'_{A_t^c,t}\left(m_{A_t^c,t} - B'_t h_{A_t,t}\right), \tag{10}$$

$$\tilde{\theta}_{A_t,t} = \theta_{A_t,t} + B_t\,\theta_{A_t^c,t}. \tag{11}$$

方程（10）–（11）清楚地揭示了这一机制：退出会通过先验交叉协方差（经由 B_t）重新分配离开的专家的影响力，并根据实际活跃集均值 $h_{A_t,\ t}$ 与非活跃状态的先验隐含均值之间的差异调整截距。

其直观含义如下。当一位预测者退出时，其对组合预测的影响并不会就此消失；相反，这种影响会按剩余预测者的潜在状态对该退出预测者状态的预测能力，重新分配给剩余预测者。矩阵 B_t 通过先验交叉协方差，准确刻画了这种预测关系。如果退出的预测者与某位存续预测者高度相关，那么退出预测者的大部分综合权重会转移给该存续预测者（通过方程（11））。如果退出的预测者在很大程度上具有特质性，其权重则会被吸收到截距中（通过方程（10））。这种结构确保退出不会造成任何人为不连续：组合预测会平滑变化，因为此前由退出预测者提供的信息，现在可根据剩余面板推断得出，只是相应的不确定性更大。

实现方式（传输视角）。在 MCMC/滤波实现中，退出通过从 $\boldsymbol{\theta}_t$ 的完整预测高斯分布中抽样来实现，随后应用一个线性（高斯）传输映射，使其隐含的后验矩与相干边缘分布相匹配；该边缘分布是在时间 t之前从观测似然中移除退出的专家后得到的。退出的专家仍保留在状态向量中；通过在活跃子空间中进行边缘化和保矩调整来确保一致性。

4.3 作为条件投影的进入

现在假设专家在时点 t 之前进入，因此 $j \in A_t \setminus A_{t-1}$。进入是一个逆向问题：时点 t 的扩展模型在将新进入专家边缘化后，必须还原为先前的预测分布。形式上，令 A_{t-1} 表示持续参与的专家，A_{t-1}^c 表示新进入专家（因此 $A_t = A_{t-1} \cup A_{t-1}^c$），一致性要求通过边缘化还原进入前预测：

$$p_t(y_t) = \int \alpha_{A_{t-1},t}(y_t|x_{A_{t-1},t})\, m_t(x_{A_{t-1},t})\, dx_{A_{t-1},t} \tag{12}$$

$$= \iint \alpha_t(y_t|x_{A_{t-1},t}, x_{A_{t-1}^c,t})\, m_t(x_{A_{t-1},t}, x_{A_{t-1}^c,t})\, dx_{A_{t-1},t}\, dx_{A_{t-1}^c,t}. \tag{13}$$

与退出不同，仅凭（12）–（13）无法唯一确定进入：添加新的系数和状态会引入自由度。因此，我们采用一种务实的保相干构造：为进入系数设定先验，并通过条件投影扩展合成函数。

假设与上文相同的高斯设定，划分为 $(A_{t-1},\ A_{t-1}^c)$，并定义

$$B_t \ = \ M_{A_{t-1},A_{t-1}^c,t}\, M_{A_{t-1},t}^{-1}, \qquad M_{A_{t-1}^c|A_{t-1},t} \ = \ M_{A_{t-1}^c,t} - M_{A_{t-1}^c,A_{t-1},t} M_{A_{t-1},t}^{-1} M_{A_{t-1},A_{t-1}^c,t}.$$

$\tilde{\quad}$ $\tilde{\quad}$令 $(\theta_{0,\,t},\ \theta_{A_{t-1},\,t},\ \tilde{v}_t)$ 表示进入前综合的已知 参数（即由持续参与的专家所隐含的模型）。给定进入系数 $\theta_{A_{t-1}^c,\,t}$（从其先验中抽取）的一个样本值，通过求解其余参数，使进入状态边缘化后恢复进入前预测，从而确保一致性：

$$\theta_{0,t} = \tilde{\theta}_{0,t} - \theta'_{A_{t-1}^c,t}\left(m_{A_{t-1}^c,t} - B_t' m_{A_{t-1},t}\right), \tag{14}$$

$$\theta_{A_{t-1},t} = \tilde{\theta}_{A_{t-1},t} - B_t\,\theta_{A_{t-1}^c,t}, \tag{15}$$

$$v_t = \tilde{v}_t - \theta'_{A_{t-1}^c,t}\,M_{A_{t-1}^c|A_{t-1},t}\,\theta_{A_{t-1}^c,t}. \tag{16}$$

换言之，进入会激活新的系数，同时调整截距、持续存在的系数和残差方差，使扩展后的合成函数成为进入前模型的相干扩展。

实现。 在采样器中，进入通过以下方式实现：(i) 为进入系数指定先验均值/方差$\theta_{A_{t-1}^c,\,t}$（可选地利用经验超参数提供信息），(ii) 从完整的预测高斯分布中抽样，以及 (iii) 应用线性变换，强制满足由（14）–（16）所蕴含的条件均值和协方差。这样，新系数便能平滑激活，且预测分布在进入事件前后保持连续。

4.4 总结

退出对应于相干边缘化：非活跃专家保留在状态向量中，并依据其预测先验演化；与此同时，通过对其未观测状态积分，更新合成函数。进入对应于相干条件投影：加入新专家，使得将其边缘化后能够恢复进入前的预测分布。这些显式算子是通过高斯抽样后再应用保矩线性映射，对这些变换进行的有限样本实现。因此，$(\boldsymbol{\theta}_t,\ \boldsymbol{x}_t)$ 的后验分布保持固定维度，即使面板人员更替显著，预测分布也能平滑演化。

5 实证结果：基于央行专家面板的预测

我们使用欧洲中央银行专业预测者调查中的通货膨胀密度预测，评估所提出的一致性贝叶斯综合模型。如第2节所述，调查参与者的更替十分显著：只有少数专家出现在超过一半的样本中，有些专家仅间歇性地参与，还有许多专家长时间完全不再参与。这一实证背景直接检验了一致性更新相较于标准合并和基于插补的基准方法，能否提升预测表现与稳定性。为展示模型的稳健性，我们在补充材料S3中

使用同一 SPF 调查中的失业率密度预测，复现本节所述的分析。

5.1 数据结构与实验设置

该数据集包含 $T = 99$个季度的一年期通胀预测，来自 $J = 16$ 名预测者（当我们改变预测者数量时，结果仍保持一致，参见补充材料 S2.2）。在每个季度 t，只有部分 $A_t \subseteq \{1, \ldots, J\}$ 预测者提交密度预测。面板数据完全按观测结果处理：如果预测者 j 在时点t未进行报告，则 $j \notin A_t$ 该来源在该日期没有可用预测。

在每个季度，我们以信息集 $D_t = \{y_{1:t-1}, \boldsymbol{x}_{1:t}\}$ 为条件，其中 y_t 表示实际通胀， $\boldsymbol{x}_t$ 汇集了当前活跃面板所隐含的潜在专家信号。模型采用递归方式估计，仅使用预测发布时可获得的信息，并针对 $t = 1$、.....、 $T - 1$生成预测分布 $p(y_{t+4}|D_t)$。

在初始化时，我们使用最初的42个季度（2000年第一季度至2010年第二季度）。仅在这一初始期间，我们对缺失的专家预测进行线性插值，以便为所有方法提供共同的起始值。这样可以确保每种方法——包括基准方法——都从相同的信息状态开始评估期，使累积绩效指标从零开始，之后的差异仅反映样本外表现。重要的是，所有方法均采用相同的插值方式，且插值仅应用于评估前的训练窗口；在57个季度的评估期内，不进行任何形式的插补，进入与退出则完全按照观测到的情况处理。这一设计可防止训练集中的插补伪影传递到评估指标中，避免造成难以诊断或归因的问题。

5.2 基准方法

本研究的实证目标是评估：相较于常用的聚合方案，对预测者进入、退出和间歇性参与进行连贯处理，是否能够提升预测表现。我们将所提出的模型与以下基准方法进行比较：

1. **等权组合（EW）**。在每个 t ，预测值是所有当前可用专家预测的简单平均值，$y^{\mathrm{EW}}_{t|t-1} = |\mathcal{A}_t|^{-1} \sum_{j \in A_t} f^{(j)}_{t|t-1}$。该方法在机构环境中得到广泛应用，并作为我们进行预测评估的基准模型。EW 在实践中很难被超越，因此提供了一个要求很高的基准。

2. **基于插补的等权方法**。我们还考虑对缺失预测先采用简单规则进行插补，再对面板进行等权组合，包括末次观测值结转法（LOCF）和基于个体均值的插补法（ASMI）。这些方法在汇总前构建平衡面板，但不确保最终预测分布的一致性。

3. **逆均方误差**。 作为基于性能的加权方法的一个例子，我们考虑线性组合，其权重与滚动窗口均方预测误差的倒数成正比。

$\widehat{\quad}^{-1}$具体而言，权重满足 $w_{t,j} \propto$ 均方误差$_{t,j}$。这种方法将专家集合视为在估计窗口内固定不变，因此对面板不稳定性较为敏感。

一个自然的问题是，为什么没有将标准 BPS（不含进入与退出算子）纳入基准。答案是，标准 BPS 与大多数先进的预测组合方法一样，要求预测者组成固定面板，因此无法应用于贡献者集合随时间变化的情形。由于样本中没有任何预测者参与了每个季度，运行标准 BPS 就需要在整个评估期内进行大量插补，从而混淆任何比较。上述基准代表了参与具有间歇性时实际可行的方案：汇总所有观测到的数据、插补后再汇总，或根据可用历史数据估计权重。

5.3 BPS 的估计细节

相干 BPS 模型使用补充材料第S1节所述的马尔可夫链蒙特卡罗算法进行估计。对于每种设定，采样器先运行 3,000 次预热迭代，随后保留 5,000 个抽样。每次迭代都会对潜在专家信号进行抽样，而第4 节所述的进入与退出算子可确保在活跃集合的时变构成下，后验推断仍保持相干 A_t。

先验设定遵循贝叶斯预测合成文献中的标准选择（例如，McAlinn 和 West（2019）；McAlinn，2021年）。具体而言，给定观测方差 v_0，初始合成系数满足 $\boldsymbol{\theta}_0|v_0 \sim N(\boldsymbol{m}_0, (v_0/s_0)\boldsymbol{C}_0)$，其中 $\mathbf{m}_0 = (1/J)\mathbf{1}'$且 $\mathbf{C}_0 = 10^{-4}\, I$。观测方差先验为 $1/v_0 \sim G(n_0/2, n_0 s_0/2)$，其中 $n_0 = 5, s_0 = 0.01$。折扣因子设为 $(d, \beta) = (0.99, 0.9)$，其中 d用于折扣状态演化，β用于折扣随机波动率。先验和折扣因子设定均遵循 McAlinn 和 West（2019）。

我们将 M_c 中的潜在相关参数设为 $M_{\text{corr}} = 0.99$，并将进入/退出专家的方差设为1。对于进入 $\theta_{A_{t-1}^c}$，我们假设其服从均值位于 $\{0, 1/J\}$（或者，对于重新进入的情形，均值为最后一个可用参数）、方差为1的正态分布，这与初始专家的先验一致。这些选择涵盖了悲观、中性和保留信息的进入情景。我们通过从一年期超前预测分布中抽样，并应用相应的未来进入/退出算子来计算预测。补充材料S2.1 报告了潜在相关设置 $\rho \in \{0, 0.5, 0.9, 0.99\}$完整网格下的结果；定性结论不受这一选择影响。

表1：评估期内的全样本预测表现。均方根误差衡量相对于等权的一年期点预测准确性；对数预测密度比是相对于等权基准的对数预测密度比（正值更优）。潜在相关性设定为0.99

	EW	EW LOCF	EW ASMI	逆-MSE	$\theta^* = 0$	$\theta^* = 1/J$	$\theta^* = prev$
RMSE	1.00	1.03	1.05	1.13	0.92	0.92	0.93
LPDR	0.00	-8.45	2.18	-0.86	33.07	32.81	31.94

5.4 评估指标

我们评估点预测和密度预测的表现。点预测准确性采用均方根预测误差（RMSE）衡量，

$$\text{RMSE} = \sqrt{\frac{1}{T}\sum_{t=1}^{T}(y_t - \hat{y}_t)^2}.$$

为便于解释，均方根误差值相对于等权基准报告，因此小于1的数值表明相对于等权有所改进。

密度预测准确性使用相对于等权基准的对数预测密度比进行评估，

$$\text{LPDR} = \sum_{t=1}^{T}\Big[\log p(y_t|D_t) - \log p_{\text{EW}}(y_t|D_t)\Big],$$

其中 D_t 表示在时间 t可获得的信息集。正的对数预测密度比值表明所考虑的方法优于等权。所有结果均基于下一季度的一年期通胀预测，其中预测以递归方式构建，以模拟实时实施。

5.5 总体预测表现

表 1 和图 4总结了整个评估期内的一年期超前（四季度超前）预测表现。由此可以得出两点结论。首先，相干BPS的密度预测表现远胜其他方法，其累积对数预测密度比增益远高于相等权重。其次，在样本的大部分时期，点预测准确性的差异相对较小，但在高波动时期，这些差异会产生显著的经济影响——恰恰是在这些时期，面板最不规则，预测者更替也最为频繁。替代先验设定下的结果见补充材料 S2。

点预测准确性（均方根误差）。图4 的面板(a)显示，在长时间平静时期，所有方法的走势都十分接近；但当信息集变得稀疏或突然变化时，各方法之间便出现分化。潜在相关性较高的相干BPS设定（例如$\rho = 0.99$）在全样本中的累积均方根误差最低或接近最低，而

累积均方根预测误差（RMSE）。累积对数预测密度比（LPDR）。

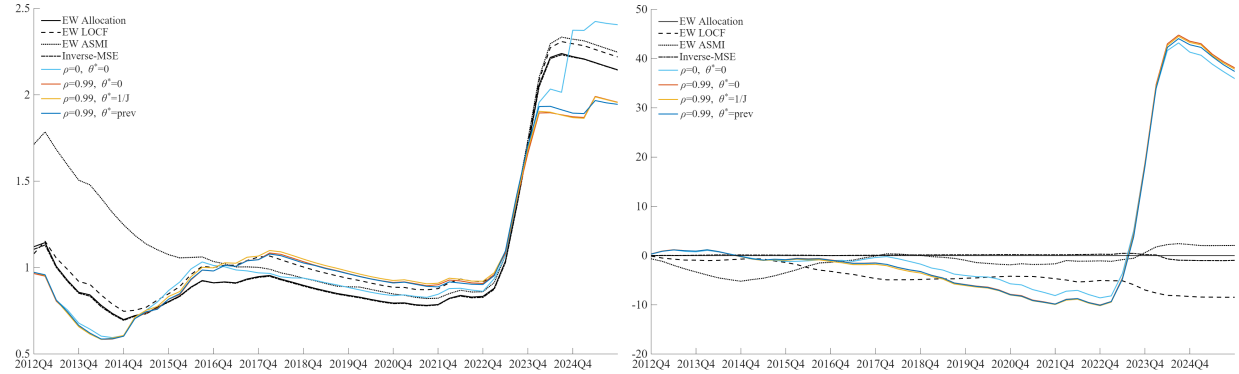

图4：所提出的相干贝叶斯方法与等权方法的一年期预测准确度。面板(a)追踪 RMSE 随时间的变化，面板(b)报告相对于等权基准的累积 LPDR。

这一优势主要来自波动最剧烈的子时期。在相干变体中，θ^* =0和 $\theta^* = 1/J$ 的均方根误差几乎没有差别，而 $\theta^* =$ prev的表现略差，这与在参与间隔较长时沿用过时的系数信息相一致。

基于插补的竞争方法（末次观测值结转法和 ASMI）并未提高点预测准确性，表现甚至可能不如简单的等权方法，这反映了一个根本性的不匹配：此处的缺失主要是结构性 的（进入/退出和零星报告），而非短暂的测量损失。逆均方误差加权在较平稳时期可以与相等权重相当，但仍对活跃集合的突然变化较为敏感，在更替频繁时表现不够稳定。

密度准确度（LPDR）。图4 的面板(b)是最清晰的区分指标。与相等权重相比，相干BPS产生了极大的正累积 LPDR，表明其预测分布的校准效果显著更好，并且系统性地为实现结果分配了更高的概率质量。相比之下，末次观测值结转法的 LPDR 显著为负，而逆均方误差加权的 LPDR 接近于零或为负，反映出在预测者集合变化时存在过度自信和不佳的不确定性传播。ASMI 的表现可能略为正面，但相较于相干BPS，其收益很小。

一个显著特点是，密度预测收益并非随时间均匀分布：相干BPS 在样本中段可能表现落后（累积对数预测密度比回撤），但在通胀飙升期间会显著占优；此时，实现结果进入了线性池和收缩启发式方法系统性低估的区域。这正是基于一致性的调整最为重要的情形：模型会根据参与情况的变化和离散度的上升来扩大并重新分配不确定性，而不是默认将面板视为稳定不变。

时间特征与状态依赖性。 表现差异集中在特定时间段。评估窗口初期，各方法总体相近。在样本中期，参与尤为不均衡，相干BPS更加保守，因此在累积指标上可能暂时落后。在COVID-19时期及通胀飙升期间，排名发生了明显逆转：相干BPS在均方根误差和对数预测密度比两项指标上都取得了最大幅度的改善，而这些改善

主导全样本总量。

解释。 在稀疏面板中，核心难点不仅在于选择权重，还在于如何将不断变化且仅部分可观测的个体预测集合，以一致的方式映射为目标变量的预测分布。通过填补缺失预测或机械地重新分配权重的方法，在平稳时期可能表现得颇具竞争力，但当面板构成发生变化时，它们无法正确传递不确定性。在参与不规则的高波动状态下，相干BPS的改善幅度最大；此时，相干调整既能防止潜在状态出现虚假的跳变，又能在面板的信号内容发生变化时，使模型迅速适应。

密度预测收益为何超过点预测收益。密度预测改进（对数预测密度比）与点预测改进（均方根误差）之间的巨大差距，反映了相干更新所纠正问题中的一种根本不对称性。点预测主要取决于合成系数 θ_t，当参与程度仅存在轻微不规则时，所有方法都能较好地估计这些系数。然而，密度预测则关键取决于预测方差，而预测方差又取决于预测者集合发生变化时不确定性如何传递。当某位预测者退出时，朴素方法要么完全舍弃该预测者的贡献——导致方差损失——要么填补一个过时密度——根据过时信息产生人为方差。这两种做法都无法正确量化信息来源丢失所带来的额外不确定性。相比之下，相干退出算子通过公式（9）中的边缘化，明确增大预测方差：额外项之所以增加方差，正是因为退出预测者的潜在状态如今已不可观测。相应地，随着新信息到来，相干进入会调低方差。这种方差核算在点预测指标中不可见，却对密度校准至关重要，这解释了为什么对数预测密度比的收益比均方根误差的收益高出一个数量级，也解释了为什么这些收益集中在方差调整最为活跃的高更替时期。

5.6 综合权重的动态变化

图 5 展示了具有代表性的设定下后验合成系数的演变。面板(a)展示截距路径，它反映了潜在通胀成分的低频变动；面板(b)–(c)则展示了不同潜在相关性设定下若干预测者的系数路径。

有两点值得注意。首先，不同的潜在依赖设定（例如， $\rho = 0.99$ 与 $\rho = 0.5$）不会显著改变系数动态；平滑性和可解释性保持稳定。截距和持续参与的预测者的系数在常规进入/退出事件中平滑演变，持续参与的专家不会出现虚假的结构突变。其次，截距在宏观压力时期的响应最为强烈。在通胀飙升期间，模型大幅将权重转向截距，这与图4中较大的对数预测密度比增益一致。信息量更丰富的进入

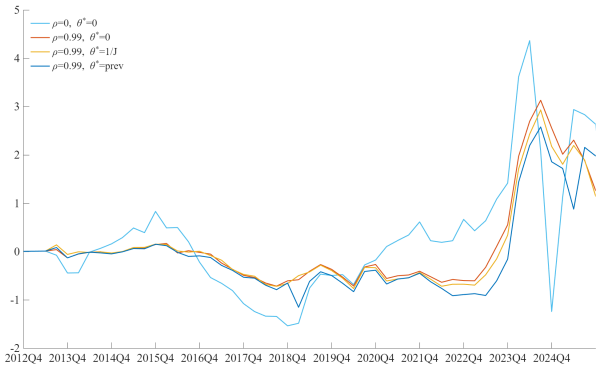

(a) BPS 的截距路径。

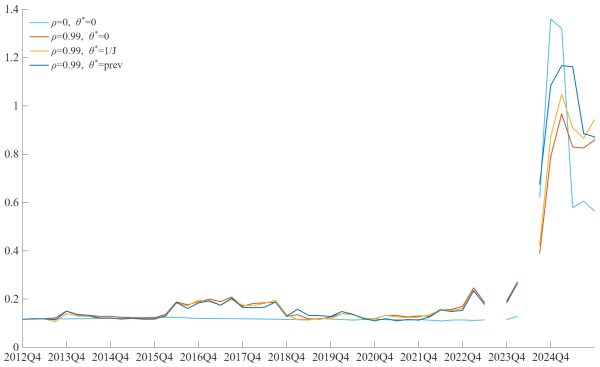

(b) 选定的系数路径， $\rho = 0.99$。

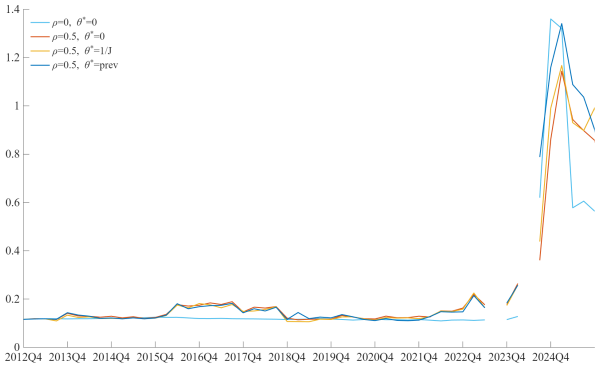

(c) 选定的系数路径， $\rho = 0.5$。

图 5：不同相关性和先验设定下后验系数的演变。即使频繁发生进入与退出，相干 BPS 模型仍能生成平滑且易于解释的路径。

先验分布会减少分配给截距的权重，这一点体现在面板 (b)–(c) 中。

持续活跃的专家的权重平滑演变，反映了对相对预测表现的逐步学习。重要的是，进入和退出事件不会导致截距或持续参与预测者的系数发生人为跳变，因为基于相干性的调整算子确保即使 A_t 的构成发生变化，全局状态仍保持稳定。

5.7 单独分析：进入与退出的影响

图 6 通过聚焦专家集合发生单次变动前后的短时间窗口，对进入和退出机制进行了直观展示。我们考察一个精简面板，其中包含两位持续活跃的专家（红线和黄线），以及一位进入或退出的专家（深蓝线），从而能够单独考察调整机制。

在专家进入时，相干 BPS 更新会使截距及相关系数平滑地向与扩展面板相一致的取值移动，而不会产生虚假的尖峰。同样，在专家退出时，离开的专家的贡献会逐渐淡出，而不会导致其余系数出现不连续。若采用简单删除缺失预测者或将其系数重置为零的朴素替代方法，这些变化路径就会出现明显断点。

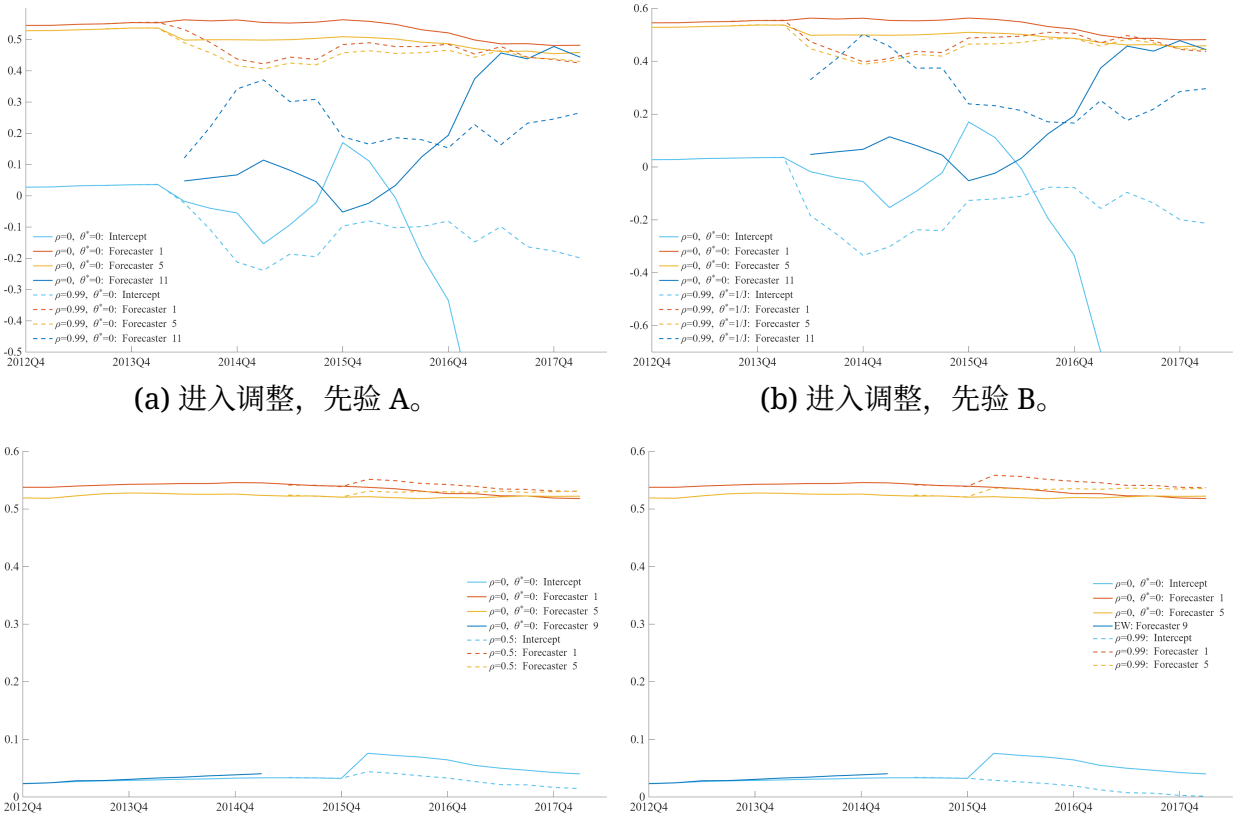

(a) 进入调整，先验 A。

(b) 进入调整，先验 B。

(c) 退出调整，先验 A。

(d) 退出调整，先验 B。

图 6：进入和退出事件期间后验系数一致调整的示意图。

6 讨论

实证结果表明，当预测调查面板不稳定时，处理专家进入、退出和缺失提交的机制，会显著影响实时预测不确定性和回顾性评估。删除后重新归一化，或填补缺失提交的做法，会以隐含方式改变条件信息集，从而可能导致合成预测矩出现人为波动。本文提出的基于相干性的更新，通过将缺失预测视为未观测到的潜在预测状态，而非将其作为贡献者删除，解决了这一问题，使预测能够随着面板构成的变化而平滑演进。

其主要实用优势有三点。第一，最终得到的预测分布对哪些报告者恰好参与报告所引起的行政性变动不那么敏感；变化主要由报告的信息和后验学习驱动。第二，由于进入和退出是通过边缘化和条件投影处理，而非通过临时重新分配权重来处理，因此合成系数的变化可解释为预测价值相对大小的真实转变。第三，该方法可在标准滤波流程中实现，且无需指定结构性参与模型。当面板不稳定性较轻时，简单合并可能就已足够；当进入、退出和长期参与间断很常见时，相干更新规则可防止

合并后的预测分布在不确定性量化最为重要的时刻恰好出现机械性不连续。

该方法并不试图建模预测者为何会缺席某些轮次。相反，它聚焦于一个范围更窄但在实践中至关重要的目标：给定时间t观测到的密度子集，以与单一贝叶斯联合模型一致的方式更新组合预测分布。当目标是构建可部署的聚合规则、避免产生伪影，而非对参与行为本身作因果解释时，这种优先考虑一致性的做法是合适的。该方法继承了底层动态综合框架的局限：对于具有强烈非高斯特征的预测状态，高斯设定可能过于受限；而进入事件则需要为进入系数设定先验。实践中，这些先验带来的敏感性通常局限于进入事件前后的短暂窗口。

可以直接进行若干扩展：多元和多时域预测、针对分组预测者的层级先验、其他（非高斯）综合族，以及将该方法应用于企业规划、能源负荷预测和流行病学预测中心的其他非连续面板。经验教训是，不规则参与是一项一阶特征，设计组合规则时应明确将其纳入考量。

7 结论

专业预测者调查是通胀监测和政策沟通的重要依据，但其面板本质上具有间歇性。预测者的进入、退出和间歇性参与意味着可用的密度预测会随时间变化，因此，标准的汇聚规则可能会将对经济信念的真实变化与面板构成的机械变化混为一谈。本文针对这类情形提出一种连贯的贝叶斯预测综合方法：为每位预测者关联一个潜在预测状态，无论是否观测到预测，该状态始终存在；并在部分观测条件下，通过贝叶斯条件化更新组合预测分布。

将所提出的方法应用于专业预测者调查中的通胀密度预测，与常用的实际基准方法相比，该方法提升了预测表现和可解释性。在面板不稳定性加剧的时期，这种提升尤为显著——而恰恰是在这些时期，可靠且稳定的不确定性度量对政策分析最为重要。更广泛地说，结果凸显了一个普遍观点：当目标是构建可实际部署的组合预测分布时，处理预测者更替和缺失并非次要的数据问题，而是统计问题不可或缺的一部分。确保一致性为临时采用重新归一化或插补提供了一种有原则且实用的替代方案，从而构建出在现实预测面板所具有的间歇性参与模式下，依然稳定、易于解释且信息丰富的预测组合系统。

参考文献

Aastveit, K. A., K. R. Gerdrup, A. S. Jore, and L. A. Thorsrud（2014）。实时国内生产总值即时预测：一种密度组合方法。《商业与经济统计期刊》*32*，48–68。Aastveit, K. A., J. Mitchell, F. Ravazzolo, and H. K. van Dijk（2018）。经济学中预测密度组合的发展。技术报告，廷伯根研究所讨论论文。Adrian, M. T., D. Giannone, M. Luciani, and M. West（2025）。情景综合与宏观经济风险。国际货币基金组织。Amisano, G. G. and R. Giacomini（2007）。通过加权似然比检验比较密度预测。《商业与经济统计期刊》*25*，177–190。Bates, J. M. and C. W. J. Granger（1969年）。预测的组合。《运筹学季刊》*20*，451–468。Billio, M., R. Casarin, F. Ravazzolo, and H. K. van Dijk（2012）。拐点预测的组合方案。《金融与经济季刊评论》*52*，402–412。Boero, G., J. Smith, and K. F. Wallis（2015）。专业预测者不确定性的测量与特征。《应用计量经济学杂志》*30*(7)，1029–1046。Chernis, T., G. Koop, E. Tallman, and M. West（2024年）。货币政策中的决策综合。*arXiv* 预印本 *arXiv:2406.03321*。Clemen, R. T.（1989年）。预测组合：综述与注释书目。《国际预测学杂志》*5*，559–583。Clements, M. P.（2010年）。对调查受访者预测不一致性的解释。《欧洲经济评论》*54*(4)，536–549。Conflitti, C., C. De Mol, and D. Giannone（2015年）。调查预测的最优组合。《国际预测学杂志》*31*(4)，1096–1103。Del Negro, M., R. B. Hasegawa, and F. Schorfheide（2016年）。动态预测池：对金融摩擦与预测表现的考察。《计量经济学杂志》*192(2)*，391–405。Diebold, F. X. and M. Shin（2019年）。用于正则化调查预测组合的机器学习：部分平等套索及其衍生方法。《国际预测学杂志》*35*(4)，1679–1691。Dovern, J.（2015年）。预测分歧的多变量分析：以调查数据检验分歧模型。《欧洲经济评论》*80*，16–35。Dovern, J. and J. Weisser（2011年）。专业宏观经济预测的准确性、无偏性和效率：七国集团的实证比较。《国际预测学杂志》*27*(2)，452–465。Eser, F., P. Karadi, P. R. Lane, L. Moretti, and C. Osbat（2020年）。欧洲中央银行的菲利普斯曲线。《曼彻斯特学派》*88*(S1)，50–85。

Genre, V., G. Kenny, A. Meyler, and A. Timmermann（2013）。《结合专家预测：简单平均是否能被超越？》《国际预测学杂志》*29*，108–121。Geweke, J. F. and G. G. Amisano（2011）。最优预测池。《计量经济学杂志》*164*，130–141。Hall, S. G. and J. Mitchell（2007）。结合预测密度。《国际预测学杂志》*23*，1–13。Johnson, M. C. and M. West（2025）。采用结果依赖型池的贝叶斯预测综合。《统计科学》*40*，109–127。arXiv:1803.01984。Jore, A. S., J. Mitchell, and S. P. Vahey（2010）。结合具有不确定不稳定性的向量自回归模型的预测密度。《应用计量经济学杂志》*25*(4)，621–634。McAlinn, K.（2021）。用于经济即时预测的混频贝叶斯预测综合。《英国皇家统计学会会志》*C*辑：应用统计*70*(5)，1143–1163。McAlinn, K., K. A. Aastveit, J. Nakajima, and M. West（2020）。宏观经济预测中的多元贝叶斯预测综合。《美国统计学会杂志》*115*(531)，1092–1110。McAlinn, K. and M. West（2019）。时间序列预测中的动态贝叶斯预测综合。《计量经济学杂志》*210*(1)，155–169。Pettenuzzo, D. and F. Ravazzolo（2016）。基于决策的模型组合下的最优投资组合选择。《应用计量经济学杂志》*31*(7)，1312–1332。Tallman, E. and M. West（2024）。贝叶斯预测决策综合。《英国皇家统计学会会志》*B*辑：统计方法*86*(2)，340–363。Timmermann, A.（2004）。预测组合。载于 G. Elliott, C. W. J. Granger, and A. Timmermann（编），《经济预测手册》，第1卷，第4章，第135–196页。北荷兰出版社。Yellen, J. L.（2015）。通胀动态与货币政策。于马萨诸塞州阿默斯特的马萨诸塞大学阿默斯特分校 Philip Gamble 纪念讲座上的演讲，2015年9月24日。

《间歇性参与下的预测合成：来自通胀密度调查的证据》的补充材料

S1 后验计算与滤波算法

本补充材料介绍了我们实证分析中所使用的确切后验模拟方案。

S1.1 计算中使用的模型组成部分

在每个季度 $t = 1{:}T$，给定潜在专家状态 $\boldsymbol{x}_t = (x_{1,\,t},\ \ldots\ldots,\ x_{J,\,t})'$ 和合成系数 $\boldsymbol{\theta}_t = (\theta_{0,\,t},\ \theta_{1,\,t},\ \ldots\ldots,\ \theta_{J,\,t})'$，综合似然为高斯动态线性模型

$$y_t = F_t'\boldsymbol{\theta}_t + \nu_t, \qquad F_t = (1, x_{1,t}, \ldots, x_{J,t})', \qquad \nu_t \sim N(0, v_t),$$

其中，非活跃专家对应的系数确定性地设为零。

我们将每个报告的专家密度 $h_{j,\,t}$ 表示为一个 Student-t 形式，其参数为（均值$a_{j,\,t}$、方差 $A_{j,\,t}$、自由度 $n_{j,\,t}$），并使用标准正态—伽马混合：

$$x_{j,t}|\phi_{j,t} \sim N\big(a_{j,t},\, \phi_{j,t}A_{j,t}\big), \qquad \phi_{j,t} \sim \text{Gamma-mix}(n_{j,t}),$$

其中 $\phi_{j,\,t}$ 通过下文第21 步中的共轭更新进行抽样。

令 $A_t \subseteq \{1, \ldots, J\}$ 为时间 t 的活跃集合（指示向量 idx(t, ·）。定义 $t-1$ 与 t 之间的进入/退出集合：

$$\mathcal{X}_t = \{j : \text{idx}_{t-1,j} = 1,\ \text{idx}_{t,j} = 0\}, \qquad \mathcal{E}_t = \{j : \text{idx}_{t-1,j} = 0,\ \text{idx}_{t,j} = 1\}.$$

S1.2 折扣状态前向滤波

在给定 $\boldsymbol{x}_t$ 的固定抽样值（在一次 MCMC 迭代中）的条件下， $\boldsymbol{\theta}_t$ 的状态演化通过折扣处理。若 $(m_t,\ C_t)$ 表示在观测 y_{t-1}之后 且处理时间 t 之前的滤波均值/协方差，则时间 t 的先验为

$$a_t = m_t, \qquad R_t = C_t/d,$$

其中， $d \in (0,1]$ 为状态折扣因子。波动率采用标准的折扣随机波动率递推进行更新（通过（$n_t,\ s_t$）实现）：

$$n_{t+1} = \beta n_t + 1, \qquad s_{t+1} = s_t \cdot \frac{\beta n_t + e_t^2/q_t}{n_{t+1}},$$

其中， $\beta \in (0,1]$ 为波动率折扣因子， $e_t = y_t - f_t$， q_t 为下文定义的单步预测方差。

给定（$a_t,\ R_t,\ s_t,\ n_t$），通常的单步预测和更新为

$$f_t = F_t' a_t, \qquad q_t = F_t' R_t F_t + s_t, \qquad A_t = R_t F_t / q_t,$$

$$m_{t+1} = a_t + A_t(y_t - f_t), \qquad C_{t+1} = r_t\big(R_t - q_t A_t A_t'\big), \qquad r_t = \frac{\beta n_t + e_t^2/q_t}{n_{t+1}}.$$

S1.3 退出与进入的相干先验调整

当活跃集合在 $t-1$ 和 t之间变化时，一致性要求对观测子集进行条件化，而不进行重新归一化或删除。在计算中，我们通过˜将高斯先验 $N(a_t,\ R_t)$迁移为调整后的先验 $N(\tilde{a}_t,\ R_t)$ 来实现这一点，该先验对应于 ˜ 一致性所蕴含的边缘分布 / 扩展，然后使用 $(\tilde{a}_t,\ R_t)$计算 $f_t,\ q_t$并用y_t进行更新。

算子所用的潜在状态协方差。为构造将进入/退出的专家与持续参与的专家联系起来的回归算子，我们使用 $\boldsymbol{x}_t$的工作联合协方差：

$$\Sigma_t = D_t M_c D_t, \qquad D_t = \operatorname{diag}\big(\sqrt{\phi_{1,t}A_{1,t}}, \ldots, \sqrt{\phi_{J,t}A_{J,t}}\big),$$

其中， M_c 是一个相关矩阵，其非对角元素均设为标量 M_{corr} （对角元素为 1）。当需要为某次算子调用中未使用的专家指定某些$A_{j,\ t}$ 时（例如，为退出/进入集合定义 Σ_t ），我们遵循代码中的经验默认做法：将缺失值或零值替换为时间 t上非零方差的均值。

蒙特卡洛传输。 退出算子和进入算子均通过以下方式实现：(i) 抽取 S个样本 $\theta^{(s)} \sim N$（a_t， R_t），并将其限制在相关活跃集合内；(ii) 应用线性映射 $\theta^{(s)} \mapsto \theta^{(s)*}$；(iii) 将（$\tilde{a}_t$, $\tilde{R}_t$）设为 $\{\theta^{(s)*}\}$的样本均值/协方差，并强制应用当前活动掩码（非活跃系数设为零）。在我们的实现中 $S = 1000$。

S1.3.1 退出算子

若 $\mathcal{X}_t \neq \emptyset$，令 $\mathcal{C}_t = \{1, \ldots, J\} \setminus \mathcal{X}_t$ 表示未退出的索引。定义回归矩阵

$$B_t^{\text{exit}} = \Sigma_{\mathcal{X}_t,\mathcal{C}_t,t}\, \Sigma_{\mathcal{C}_t,\mathcal{C}_t,t}^{-1},$$

并令 $\mu_t = (a_{1,\ t},\ \ldots\ldots,\ a_{J,\ t})'$ 为时点 t 专家预测均值构成的向量。对于每次先验抽样 $\boldsymbol{\theta}^{(s)} = (\theta_0^{(s)},\ \theta_1^{(s)},\ \ldots\ldots,\ \theta_J^{(s)})'$，定义退出传输（以与代码相匹配的分块形式表示）：

$$\theta_0^{(s)*} = \theta_0^{(s)} + \theta_{\mathcal{X}_t}^{(s)\prime}\Big(\mu_{\mathcal{X}_t,t} - B_t^{\text{exit}}\,\mu_{\mathcal{C}_t,t}\Big),$$

$$\theta_{1:J}^{(s)*} = \theta_{1:J}^{(s)} + \theta_{\mathcal{X}_t}^{(s)\prime}\ \bar{B}_t^{\text{exit}},$$

其中， $\bar{B}_t^{\text{exit}}$是 B_t^{exit}的填充版本，在对应于 $\mathcal{X}_t$ 的列中填入零，并将B_t^{exit}放入 $\mathcal{C}_t$对应的列中。最后，在时间 t 强制应用当前活动掩码，将所有 $j \notin A_t$设为$\boldsymbol{\theta}_j^{(s)*} = 0$ 。调整后的先验矩（$\tilde{a}_t$， $\tilde{R}_t$）是以下内容的样本均值/协方差

$\boldsymbol{\theta}^{(s)*}$。

S1.3.2 进入算子

如果 $\mathcal{E}_t \neq \emptyset$，令 $\mathcal{C}_t = \{1, \ldots, J\} \setminus \mathcal{E}_t$ 表示非进入索引。定义

$$B_t^{\text{ent}} = \Sigma_{\mathcal{E}_t,\mathcal{C}_t,t}\, \Sigma_{\mathcal{C}_t,\mathcal{C}_t,t}^{-1}.$$

进入操作需要为新的系数指定先验。在实现中，具体做法是：(i) 将所有涉及进入系数的协方差重置为零，(ii) 将其边缘方差设为一个基准值，以及 (iii) 指定进入系数的先验均值。将由此得到的"重置"先验记为 $N(a_t^{(0)},\ R_t^{(0)})$。

然后抽取 $\boldsymbol{\theta}^{(s)} \sim N(a_t^{(0)},\ R_t^{(0)})$（限制在当前活跃集合内），并应用进入传输

$$\theta_0^{(s)*} = \theta_0^{(s)} - \theta_{\mathcal{E}_t}^{(s)\prime}\Big(\mu_{\mathcal{E}_t,t} - B_t^{\text{ent}}\,\mu_{\mathcal{C}_t,t}\Big),$$

$$\theta_{\mathcal{C}_t}^{(s)*} = \theta_{\mathcal{C}_t}^{(s)} - \theta_{\mathcal{E}_t}^{(s)\prime}\, B_t^{\text{ent}}, \qquad \theta_{\mathcal{E}_t}^{(s)*} = \theta_{\mathcal{E}_t}^{(s)}.$$

~与退出操作相同，我们在时间 t 强制应用活动掩码，并将 $(\tilde{a}_t,\ R_t)$ 设为 $\boldsymbol{\theta}^{(s)*}$ 的样本均值/协方差。

排序。 当退出和进入在同一 t 发生时，我们先执行退出，再执行进入，且两者都作用于时间-t 先验，然后才计算 $f_t,\ q_t$ 并使用 y_t 进行更新。

S1.4 完整 *MCMC* 算法

算法1概述了完整的 Gibbs/FFBS 方案。滤波时基于先前的潜在状态抽样 $\boldsymbol{x}^{(i-1)}$ 进行 $\boldsymbol{\theta}$，然后基于新的 $\boldsymbol{\theta}^{(i)}$ 进行抽样 $\boldsymbol{x}^{(i)}$。

S2 稳健性分析

本附录报告了主要实证结果的稳健性检验和扩展分析。我们记录了在敏感性分析中所考虑的完整一致性和进入先验设定网格下的预测表现，以及在扩展后的预测者集合下的预测表现。这些额外分析确认，本文的定性结论对于替代性设定和面板定义具有稳健性。

S2.1 不同模型设定

表 S1 报告了稳健性网格中考虑的全部设定。每一行对应以下两项的一个组合：（i）决定潜在预测状态先验中不同预测者之间依赖关系的相关性设定（参数化为 ρ），以及（ii）针对新近活跃预测者的进入先验选项（例如，均值初始化选择）。对于每种设定，我们都会重新进行完整的实时预测评估，并在相同的信息集上重新计算所有基准，因此，任何差异都仅反映所变更的建模选择，而非数据可用性或评估设计的变化。

总体而言，结果与第 5.5节的结果一致：在点预测方面，均方根误差与等权基准相当或更优；在密度预测方面，对数预测密度比始终显著高于等权基准。此外，稳健性网格呈现出一种系统性规律：新进入者先验均值的信息性越弱的设定，表现往往越好。这表明，积极纳入新进入预测者的信息平均而言可能适得其反，而不带倾向的先验在进入时能发挥有益的正则化作用。

S2.2 扩大预测者集合

本附录评估扩大个体密度预测者面板后结果的稳健性。正文聚焦于一个精选子集，该子集旨在体现清晰的进入与退出以及间歇性参与，同时保留用于训练的稳定核心。在此，我们将纳入的预测者人数从 $J = 16$ 增加到 $J = 20$，并重新进行完整的预测组合实验，

表 S1：评估期内的全样本预测表现。RMSE 衡量一年期超前点预测准确性；LPDR 表示相对于等权基准的对数预测密度比（正值更优）。目标变量：通胀率。 $J = 16$

	EW	等权末次观测值结转	等权 ASMI	逆均方误差
RMSE	2.0690	2.1410	2.1672	2.0676
LPDR	-	-8.44	2.18	-0.85

	$\theta^* = 0$			
	$\rho = 0$	$\rho = 0.5$	$\rho = 0.9$	$\rho = 0.99$
RMSE	2.3901	1.9304	1.9171	1.9276
LPDR	30.09	32.04	32.23	31.94

.

	$\theta^* = 1/J$			
	$\rho = 0$	$\rho = 0.5$	$\rho = 0.9$	$\rho = 0.99$
RMSE	2.4016	1.9084	1.9094	1.9078
LPDR	30.17	32.81	32.91	32.82

	$\theta^* = prev$			
	$\rho = 0$	$\rho = 0.5$	$\rho = 0.9$	$\rho = 0.99$
RMSE	2.3414	1.9097	1.9047	1.9073
LPDR	30.70	32.82	33.17	33.07

同时保持目标对齐（一年期超前滚动月份）、密度到正态分布的矩匹配、训练/评估划分、BPS先验设定，以及覆盖（ρ，θ^*）的超参数网格不变。

表 S2 显示，扩大面板范围并未改变主要结论。就点预测而言，合成方法的相对 RMSE 表现与基准 $J = 16$ 设定下的表现仍然相当，在与等权基准比较时亦是如此。就密度预测而言，在不同设定下，合成方法持续取得显著高于等权合并的 LPDR，表明随着预测者集合扩大，其在概率校准方面的优势依然存在。

S3 补充应用：一年期超前失业率密度预测

本附录复现了欧洲中央银行专业预测者调查（SPF）失业率密度预测的主要通胀分析。目的并非引入新方法，而是验证从通胀研究中获得的定性见解是否适用

表S2：评估期内的全样本预测表现。RMSE 衡量一年期前向点预测精度；LPDR 是相对于等权基准的对数预测密度比（正值表示表现更好）。目标变量：通胀率。 $J = 20$

	EW	等权末次观测值结转	等权 ASMI	逆均方误差
RMSE	2.0777	2.1410	2.1672	2.0676
LPDR	-	-8.44	2.18	-0.85

	$\theta^* = 0$			
	$\rho = 0$	$\rho = 0.5$	$\rho = 0.9$	$\rho = 0.99$
RMSE	2.2566	1.9976	1.9171	1.9988
LPDR	27.17	31.19	31.14	31.10

.

	$\theta^* = 1/J$			
	$\rho = 0$	$\rho = 0.5$	$\rho = 0.9$	$\rho = 0.99$
RMSE	2.2916	2.0070	2.0258	2.0166
LPDR	27.10	30.99	30.82	31.03

	$\theta^* = prev$			
	$\rho = 0$	$\rho = 0.5$	$\rho = 0.9$	$\rho = 0.99$
RMSE	2.3076	2.0401	2.0496	2.0451
LPDR	26.41	30.23	30.31	30.36

当我们将该方法用于具有不同时间序列特性的另一种宏观经济变量时。

S3.1 预测对象与目标对齐

SPF 中的失业率预测以各预测者针对预先指定区间提供的单独密度直方图形式呈现。我们将每位预测者的直方图与正态分布$\mathcal{N}(m_{t,j}, s_{t,j})$进行矩匹配：使用区间中点计算均值，并加入区间内方差（区间内均匀分布）以得到$s_{t,j}$；这样既保留了引导得到的密度所含的信息，又能在不同时间和预测者之间形成可比的参数化表示。与正文一样，我们记录可用性指标$i_{t,j} \in \{0, 1\}$，以表示预测者 j 是否在时间 t提交了密度预测。

与通货膨胀不同（在SPF应用中，通货膨胀按季度预测期限处理），失业率练习采用SPF滚动预测期限约定："一年期超前"目标是一个特定的日历月份（例如2026May），其定义取决于调查时最新可得的失业率观测值。因此，对于每个调查季度 t，我们提取与SPF一年期超前滚动目标期间月份相对应的行，并

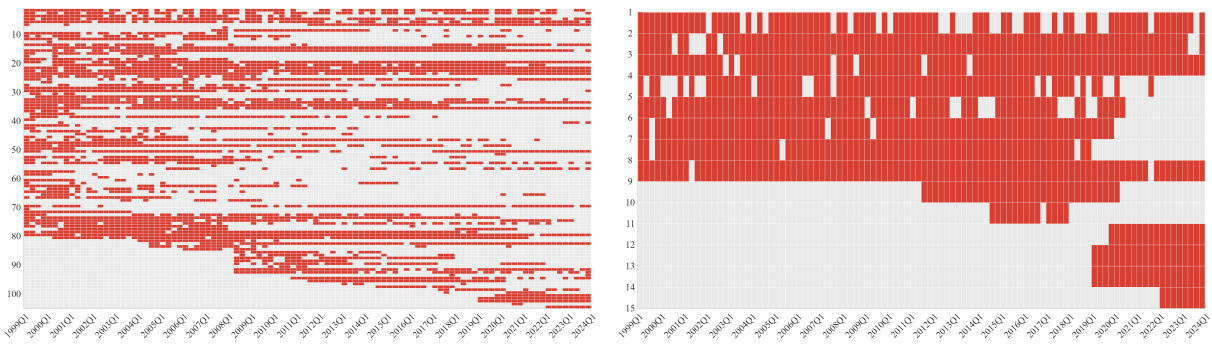

所有预测者　　应用中使用的预测者

图7：失业率：专家预测者随时间的参与情况。左面板：完整面板的参与情况。右面板：用于分析的子面板的参与情况。浅灰色表示不活跃，红色表示活跃贡献。

将已实现的失业率与该月份对齐。预测练习在一年期超前期限内进行：点预测准确性使用预测均值，密度准确度使用完整的预测分布。

S3.2 预测者参与与间歇性

图 7 总结了失业率密度中的参与情况。参与具有很强的间歇性：其中有一批长期存在的稳定核心预测者，但该面板也表现出较长时间的空缺、短暂的活跃期以及明显的进入/退出阶段。尤其是，样本后期出现了大量人员更替：有几位预测者直到样本中期之后才进入，而另一些预测者则在样本结束前退出。这一模式在定性上与通胀预测者组相似，但情况更为严重，因为（i）对于某些预测者而言，失业率存在更大块的缺失；（ii）2019年之后的时期显示出更为明显的进入浪潮。这些特征使失业率分析成为检验促成综合框架的缺失机制的有用压力测试。

S3.3 竞争性组合规则

我们采用与通胀分析相同的基准方法和综合变体进行比较。操作性基准是对可用密度进行等权（EW）混合。两种常见的“修复”规则会在合并前处理缺失问题：
EW-LOCF 用末次观测值结转法填补缺失提交；EW-ASMI 则采用特定预测者均值插补。我们还

表 S3：评估期内的全样本预测表现。RMSE 衡量一年期前向点预测精度；LPDR 是相对于等权基准的对数预测密度比（正值表示表现更好）。目标变量：失业率。 $J = 16$

	EW	等权末次观测值结转	等权 ASMI	逆均方误差
RMSE	1.7896	1.8702	2.4231	1.7844
LPDR	-	-3.19	7.64	1.65

	$\theta^* = 0$			
	$\rho = 0$	$\rho = 0.5$	$\rho = 0.9$	$\rho = 0.99$
RMSE	1.1034	1.6549	1.7027	1.7025
LPDR	12.93	7.47	6.098	5.99

.

	$\theta^* = 1/J$			
	$\rho = 0$	$\rho = 0.5$	$\rho = 0.9$	$\rho = 0.99$
RMSE	1.1622	1.7052	1.7564	1.7451
LPDR	13.28	7.95	6.64	6.50

	$\theta^* = prev$			
	$\rho = 0$	$\rho = 0.5$	$\rho = 0.9$	$\rho = 0.99$
RMSE	1.2446	1.7460	1.8081	1.9073
LPDR	12.84	6.92	5.57	5.44

纳入一种逆均方误差方案，该方案根据过去的点预测误差学习组合权重。所提出的方法对个体标准化密度 $\{\mathcal{N}(m_{t,\,j},\ s_{t,\,j})\}$ 应用 BPS 式综合，并结合可用性指标 $\{i_{t,j}\}$；超参数网格和 θ^* 选项与正文相同： $\theta^* = 0$（无平等化拉力）、 $\theta^* = 1/J$（向相等权重进行弱收缩），以及 $\theta^* = \text{prev}$（通过向前一期权重收缩实现时间稳定化）。持久性参数 ρ控制折扣与适应的程度。

S3.4 全样本表现

表S3报告了评估期内的全样本结果。主要发现是，对于失业率这一变量，相较于实际操作中的基准方法，综合方法在点预测和密度表现方面均带来了显著提升。

首先，考察点预测准确性。等权基准的均方根误差为 1.7896，而逆均方误差的表现基本无异（1.7844）。相比之下，表现最佳的综合配置大幅降低了均方根误差，最低可达 1.1034（对应 $\theta^* = 0$ 和 $\rho = 0$），且在整个网格范围内都显著优于基准方法。这一改进幅度远大于

稳定面板中的典型水平，这表明失业率密度包含持续存在的、因预测者而异的信号，而这种信号在进入/退出情况下被简单合并所稀释。

其次，密度表现与点预测结果一致。EW-LOCF 的对数预测密度比（-3.19）受到严重惩罚，这与潜在状态发生变化时末次观测值结转法众所周知的脆弱性相符。
EW-ASMI 在密度方面优于等权（对数预测密度比为 7.64），但均方根误差表现较差，凸显了在分布空间中“修正”缺失可能会扭曲隐含均值这一事实。相比之下，综合方法取得了较大的正对数预测密度比（约为 5–13，具体取决于 ρ 和 θ^*），意味着相较于等权方法，累计预测似然增益显著。

敏感性模式同样值得关注。在预测失业率时，较低的 ρ对应最佳结果：对于所有 θ^* 选项，无论是均方根误差还是对数预测密度比，$\rho = 0$ 在各种持续性设定中均占优。这表明，失业率的预测关系具有足够强的时变性，因此激进折扣（快速适应）有益。相比之下，正文中的通胀分析表现出较弱的敏感性，且稳定化作用更为突出（较大的 ρ 和/或 $\theta^* = \text{prev}$）。简言之，失业率预测更能受益于快速适应，而通货膨胀预测则更能受益于稳定化。

S3.5 时间路径诊断：优势为何产生

图 8–9 分别绘制了累积 LPDR 和滚动均方根误差的时间路径。两个特征尤为突出。

(i) 综合方法的优势具有持续性，而非偶发性。BPS变体的累积 LPDR 曲线在较长时期内始终显著高于基准方法，这表明改进并非仅由危机季度或一次性事件所驱动。
</output>

（ii）末次观测值结转法恰恰在适应发挥作用时失效。在趋势变化和水平变动期间，末次观测值结转法曲线的表现明显较差，这与插补滞后密度的情况一致。这与通胀分析中所强调的同一种失效模式相同，但在这里更为明显，因为失业率更加平滑，因此从似然层面更容易诊断出“滞后”的插补值。

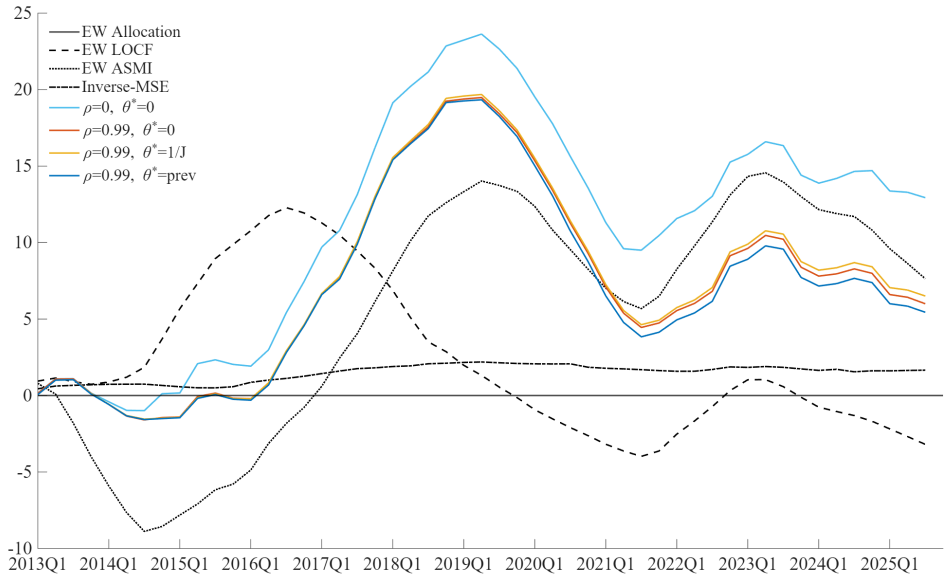

图 8：失业率一年期预测密度相对于等权的累积 LPDR。

S3.6 与通胀分析的对比

相较于主要的通胀应用，失业率的结果更为有力，也更加明确。

• **综合带来的收益更大**。 在失业率分析中，综合将均方根误差从大约 1。8（等权）降至最佳设定下约 1。1，并带来了两位数的对数预测密度比提升。通胀分析同样显示出改善，但通常幅度较小，这与通胀更难预测、且对影响所有主体的共同冲击更为敏感相一致。

• **最优适应性不同**。 失业率偏好较低的 ρ （快速适应），而通胀往往更多受益于持久结构（更高的 ρ 和/或 θ^* =prev）。这种差异是合理的：失业率变化更加平滑，但其预测映射可能随机制/政策而变化；通胀则会出现更剧烈的冲击，此时稳定化机制可以防止对短暂的预测异常反应过度。

• **插补情况下，基准方法的表现有所不同**。在失业率分析中，等权 ASMI 的 LPDR 显著提高，但均方根误差（RMSE）却变大，体现出分布空间插补与均值准确度之间的脱节。在通胀分析中，同一组基准方法通常

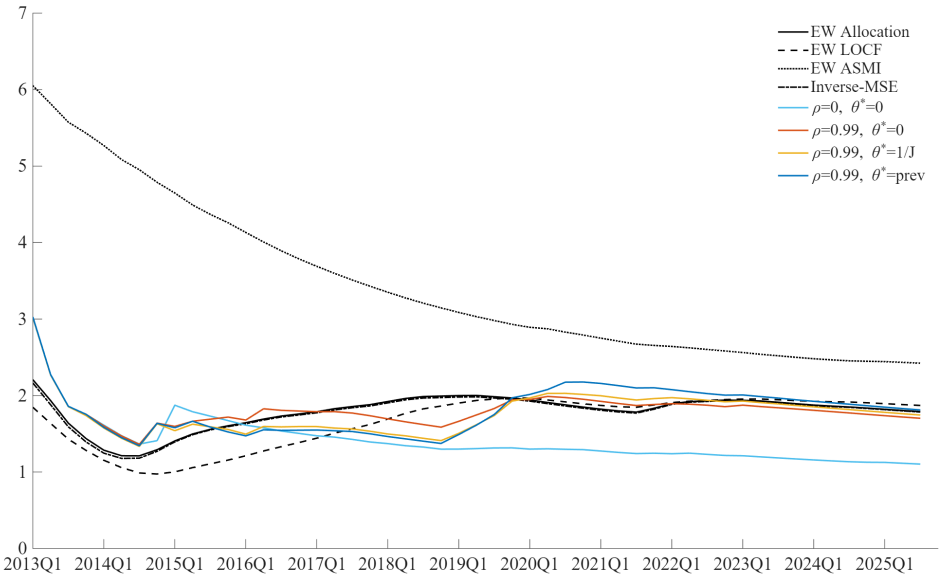

图9：失业率一年期超前预测的滚动均方根误差（点预测 =预测均值）。

更加一致，这表明失业率密度的均值/形状权衡更为显著（可能是由于其分箱结构更紧凑、内在波动性更小）。

总体而言，失业率练习强化了这一主要信息：当预测者参与具有间歇性且面板呈现进入/退出时，明确考虑缺失并学习时变组合结构的综合方法，能够胜过运营中的等权合并以及常见的插补后取平均的启发式方法。

算法 1 采用相干先验调整的间歇性 BPS 马尔可夫链蒙特卡洛

1：输入：$\{y_t\}_{t=1}^{T}$；专家参数 $\{a_{j,t}, A_{j,t}, n_{j,t}\}$；活动指示变量 {idx$_t$、$_j$}；折扣因子（$d$、$\beta$）；先验分布（$m_0$、$C_0$、$n_0$、$s_0$）；超参数（$M_{\text{corr}}$、$\theta_m$、$\theta_C$）。2：从 idx 预先计算进入/退出指示变量 $\mathcal{E}_t$、$\mathcal{X}_t$。3：通过从专家混合表示中抽样来初始化 $\{\boldsymbol{x}_t^{(0)}, \phi_t^{(0)}\}$。4：对于 $i = 1$，...，I，执行 5：（可选）通过在候选网格上最大化一步超前对数预测似然来选择（d、β）（在我们的实证运行中为单元素网格）。6：初始化（m_1、C_1、n_1、s_1）=（m_0、C_0、n_0、s_0）。7：对于 $t = 1$，...，T，执行 8：构造 F_t =（1、$x_{1\,t}^{(i-1)}$、...、$x_{J\,t}^{(i-1)}$）′，并应用活动掩码（将非活跃系数固定为 0）。9：根据（m_t、C_t）计算折扣先验（a_t、R_t）。10：相干先验调整：11：如果 $\mathcal{X}_t \neq \emptyset$，则通过蒙特卡洛传输对（$a_t$、$R_t$）应用退出算子，以获得˜（$\tilde{a}_t$、$R_t$）。~12：否则，将（$\tilde{a}_t$、$R_t$）=（$a_t$、$R_t$）。13：结束 if~14：如果 $\mathcal{E}_t \neq \emptyset$，则通过重置+传输步骤对（$\tilde{a}_t$、$R_t$）应用进入算子，以获得最终先验矩（$\tilde{a}_t$、$R_t$）。15：结束 if~16：使用（$\tilde{a}_t$、$R_t$）计算 f_t、q_t，并利用 y_t更新（m_{t+1}、C_{t+1}、n_{t+1}、s_{t+1}）。17：结束 for 18：后向抽样（FFBS）：从由折扣动态线性模型所隐含的平滑分布中抽取 $v_{1\,T}^{(i)}$：和 $\theta_{1\,T}^{(i)}$，并在每个 t处强制应用活动掩码。19：对于 $t = 1$，...，T，执行 20：从给定（$\boldsymbol{\theta}_t^{(i)}$、$v_t^{(i)}$、$y_t$）的条件高斯后验中抽取 $\boldsymbol{x}_t^{(i)}$（共轭更新）。21：从给定 $\boldsymbol{x}_t^{(i)}$ 的条件伽马混合更新中抽取 $\phi_t^{(i)}$（Student-t混合表示）。22：结束 for 23：结束 for 24：输出：预热期后的后验抽样；根据最终滤波状态计算的一步超前预测参数（a_{T+1}、R_{T+1}、v_{T+1}、n_{T+1}），并对 $T+1$ 活跃集合应用相同的退出/进入逻辑。