使用多源数据估计共识理想点*

Mellissa Meisels† Melody Huang‡ Tiffany M. Tang§

arXiv:2601.05213v1 [stat.AP] 8 Jan 2026

Abstract

随着大数据和机器学习的兴起，研究人员如今可以获得大量国会议员候选人理想点估计，用于理论检验。薄弱的关联引发了这样的问题：这些估计在多大程度上捕捉的是一种共享的量，而非特异的、领域特定的因素——然而，在大多数实质性分析中，不同的测量指标却被交替使用。此外，美国政治研究中的核心问题涉及候选人理想点与源自相同数据源的其他变量之间的关系，从而引入了内生性。我们提出了一种方法，即共识多维尺度分析（CoMDS），它更符合应用研究者在实践中使用理想点的方式。CoMDS 捕捉一组潜在理想点估计之间共享的稳定关联，并可将其解释为这些估计的共同空间表示。我们展示了该方法在评估现有测量指标各领域内部关系方面的效用，并提供一套诊断工具，以帮助实际应用。

*作者感谢 Scott Abramson、Josh Clinton、Josh Kalla，以及 PolMeth 2025 的与会者提出的反馈和意见。

†耶鲁大学政治学系助理教授，电子邮件：mellissa.meisels@yale.edu，网站：http://www.mellissameisels.com

‡耶鲁大学政治学与统计学及数据科学系助理教授，电子邮件：melody.huang@yale.edu，网站：http://www.melodyyhuang.com§圣母大学应用与计算数学及统计学系 Clare Boothe Luce 助理教授，电子邮件：ttang4@nd.edu，网站：http://tiffanymtang.github.io

1 引言

候选人职位的测量指标是检验与国会极化、问责和代表性相关理论的基本构成要素（Canes-Wrone 等人 2002；Clinton2006；Hall 2015；McCarty 等人 2006）。也许最普遍且历史最悠久的是 NOMINATE，这是一种基于唱名表决的在任立法者理想点估计（Poole 等人 2011）。大数据和机器学习的兴起为政治学中构建理想点带来了新方法。近期提出的方法包括交易层面的竞选财务收据（例如，Bonica 2014、2018年、2024年）、竞选网站政纲（Meisels 2025a）、推文（例如，Barber´a2015；Cowburn 和 S¨altzer2025）、Facebook 帖子（例如，Bond 和 Messing 2015）、立法演讲（例如，Lauderdale 和 Herzog 2016），以及最近的大语言模型生成的嵌入（Burnham2024）。

不同的理想点估计不仅取决于研究者所采用的具体数据源，也取决于他们从基础数据中构建潜因子模型时所用的行为假设和估计方法。各种理想点估计彼此之间的关联程度，无论在实质层面还是方法论层面，都是一个尚未解决的问题：近期证据表明，同一政党内部的各项测量指标之间关联极弱（Barber 2022；Meisels2025a；Tausanovitch 和 Warshaw 2017）。尽管所有这些指标都旨在捕捉候选人在自由派—保守派光谱上的理想点这一共同概念，但实际上，每项指标的测量很可能也具有相当程度的领域特异性。因此，估计所得的理想点将是一个无法识别的混合体，既包含真实的理想点[1]，也包含具有领域和情境特异性的特异性成分。

在实践中，应用研究者通常关注“意识形态”或“政治定位”这一更为一般的潜在概念，而不会拘泥于具体的估计结果（以及其中所使用的数据和方法）。相反，他们提出的问题往往是：候选人是否仍会回应

[1]我们将一种最大限度通用且不预设立场的“真实”理想点概念定义为：无论处于何种特定制度背景，它都始终存在。对于这类理想点究竟代表候选人根深蒂固的意识形态、策略性立场，还是党派实力，我们不作预设。

其选区，极端主义如何影响候选人的选举表现和筹款表现，以及不同的提名机构如何影响候选人群体的构成——这些问题都涉及对候选人“意识形态”的相对一般化概念化。尽管上述研究提出了不同测量指标是否捕捉到某个共同潜在概念的问题，并且呼吁根据具体应用调整测量指标（例如，Caughey and Schick- ler 2016年），从事实质性理论检验的学者仍继续或多或少地将这类理想点估计互换使用，而忽视了情境差异。

在本文中，我们提出了一种基于共识的方法，它更接近于理想点估计在实践中的实际使用方式。该方法，即共识多维尺度分析（CoMDS），汇总来自不同数据源和估计方法的一组理想点估计，以构建共识理想点估计。该估计捕捉了不同来源理想点估计之间共享的稳定关联，并可将其解释为这些估计的共同空间表示。为帮助研究人员识别有关美国国会政治和选举的不同实质性结论在多大程度上可能是特定数据源中特异性特征的结果，我们进一步引入了一种基于投影的方法，将每个来源理想点估计分解为两个正交成分：（1）由共识理想点估计所捕捉的共享成分；（2）未被共识理想点估计捕捉的剩余特异性成分。

与现有使用不同数据源估计理想点的方法（例如 En-amorado et al. 2021）不同，我们提出的方法不依赖于来源理想点估计所依据的行为模型和数据生成假设，因此研究人员可以为每个来源理想点估计纳入领域特定的实质性先验。此外，与主成分分析（PCA）等其他聚合方法不同，CoMDS 不受来源理想点估计中的旋转、重新缩放和平移影响，并且能够适用于不同数据源的缺失情况各异的情形，从而使方法实施具有很大的灵活性。

我们通过将 CoMDS 应用于国会议员候选人理想点，阐明了其效用。除了前文提到的现有测量指标之间关联较弱这一问题，另一个问题是，许多研究问题涉及候选人理想点以及等式另一侧的一个关键变量，而这两者都来自同一数据源。我们考察了各来源测量指标领域内具有实质意义的关系，首先表明，依赖领域特定理想点可能会导致结论被夸大（至少如此），甚至得出方向相反的错误结论（至坏如此）。此外，我们还表明，若不采用我们的共识方法，评估不同现有测量指标所得关系的稳健性，会得出不仅在效应大小上、甚至有时在方向上相互矛盾的结果。相比之下，CoMDS 使研究人员能够对共同存在于各项现有测量指标中的理想点成分与感兴趣变量之间的关系得出有意义的结论。

本文结构如下。第2节概述政治学中的理想点估计，并回顾研究国会议员候选人定位时常用的几种方法。第3节介绍所提出的方法——共识多维尺度分析，并提供一套可解释性和稳定性工具，以帮助实际应用。第 4 节展示候选人的理想点共识估计值，将其与原始来源测量指标进行比较，并重新评估现有测量指标各领域内具有实质意义的关系。第5节总结全文。

2 政治学中的理想点估计

理想点估计将给定的一组观测数据点视为由一个底层行为模型生成，而该模型是潜在理想点的函数。例如，NOMINATE 假设，立法者投赞成票而非反对票的概率，取决于其理想点与两个备选政策之间的距离，而每种投票选项分别代表其中一项政策。研究者随后推断出使观察到的唱名表决矩阵的似然最大化的理想点。

形式上，对于给定的数据来源 $Y^{(s)}$，理想点估计 $\mathbf{Z}^{(s)} \in \mathbb{R}^{n_s \times r_s}$ 是通过假设一个底层生成模型得出的：

$$Y^{(s)} = g_s(\mathbf{Z}^{(s)}) + \varepsilon^{(s)}, \tag{1}$$

其中，对底层数据生成过程的不同假设会对应于 $g_s(\cdot)$ 的不同函数形式。例如，在唱名表决的情境中，$g_s(\cdot)$ 是一个逻辑函数，它映射到立法者的效用，并决定他们投赞成票还是反对票。

值得注意的是，源数据的选择和估计假设可能导致理想点估计截然不同。例如，可以比较基于唱名表决的 NOMINATE 与根据竞选纲领文本估计的理想点（例如 Meisels 2025a）。立法唱名表决是在对公众而言相对不透明的制度环境中进行的。相比之下，同一批立法者的竞选纲领则明确面向公众，服务于竞选活动。就议程控制而言，候选人在竞选纲领中阐述议题和立场几乎不受限制；而他们只能就提交国会全院审议的议题进行投票，并对所提政策表示支持或反对。即使是两种基于竞选活动的数据源——竞选纲领与竞选捐款（例如 Bonica 2014）——在关键方面也有所不同：相关活动究竟由竞选团队本身实施，还是体现为另一行动者可观察到的行为。

因此，在缺乏严格假设的情况下，我们通常不会认为基于一种数据来源估计出的理想点，与基于另一种不同数据来源估计出的理想点等同（即 $\mathbf{Z}^{(s)} \neq \mathbf{Z}^{(s')}$）。然而，即使测量模型中不纳入任何协变量，不同的候选人职位测量指标也始终能将民主党人与共和党人区分开来。因此，尽管党内相关性相对较弱，不同理想点估计之间的合并相关性仍然异常强（Barber 2022；Meisels 2025a；Tausanovitch and Warshaw 2017）。这表明，不同的测量指标确实捕捉到了一些共同变异。换言之，估计得到的理想点 $\mathbf{Z}^{(s)}$ 包含

关于潜在理想点 $\mathbf{Z}^*$ 的信息，以及源数据和函数形式选择中的特异性方面。

为使模型形式化，我们将方程（1）改写为：

$$Y^{(s)} = g_s(\mathbf{Z}^* + \nu^{(s)}) + \varepsilon^{(s)}, \tag{2}$$

这里，我们将理想点估计$\mathbf{Z}^{(s)}$ 分解为：（1）$\mathbf{Z}^*$，代表某个假设的真实理想点；（2） $\nu^{(s)}$，代表来源理想点估计所属领域特有的个体差异方面。

委婉地说，要协调理想点评估的不同方法和途径颇具挑战。已有研究提出，汇集来自不同来源的结果数据，以拟合联合理想点评估模型（例如，Treier and Jackman 2008；Murray等人 2013；Quinn 2004）。遗憾的是，当两个数据集的观测值数量和信息量不同时，朴素合并会导致有偏估计（例如，Jessee 2016）。当目标总体不同时，这个问题尤为突出（例如，Lewisand Tausanovitch 2015；Tausanovitch and Warshaw 2013；Shor a nd McCarty 2011）。

其他方法引入了依据数据调整权重的方式，以重新分配不同数据源的权重。然而，这些方法依赖于对观测结果数据的强参数假设。例如，Enamorado等人(2021年) 隐含地假设不同结果服从正态分布，并且可以线性分解为共享的理想点估计和特异项。在方程 (2) 的语境下，这意味着所有数据源的每个函数 $g_s(\cdot)$ 本质上都是线性的。实际上，研究人员通常不会认为生成观测数据的不同��为模型具有相同的函数形式（也不会认为它们相对于理想点估计必然是线性的）。此外，实际研究中常用的数据是二元数据（即唱名表决票）或类别数据（即词频统计），这两者都不服从正态分布。我们将进一步讨论现有方法与我们提出的方法之间的关系

附录中的方法A.1。

在下一节中，我们将介绍一种方法——共识多维尺度分析(CoMDS) (An 和 Tang（2025）)——用于估计一组来源理想点估计中的共享成分，我们将其称为共识理想点。与现有方法不同，CoMDS 接收来源特定的理想点估计$\mathbf{Z}^{(s)}$，以构建共识理想点估计。由于 CoMDS 是一种无监督方法，它不依赖于对所有不同观测结果进行联合建模，因此即使无法获取底层结果数据，也可以使用该方法。这有几个优点。首先，研究人员可以保留针对每个数据源的不同情境特定基本假设，即各行为模型的假设。因此，各数据源的结果$Y^{(s)}$仍可映射到各自独特的行为模型$g_s(\cdot)$。其次，该方法的计算效率更高，研究人员可以直接利用已有的来源理想点来估计共识理想点。在第 4 节中，我们将 CoMDS 应用于国会议员候选人，并展示共识理想点如何在关注变量源自与现有来源测量指标相同的数据时，助力稳健地考察实质性关系。

3 使用 CoMDS 进行共识理想点估计

在下一节中，我们将介绍所提出的方法——共识多维尺度分析（CoMDS）。在第3.1节中，我们将形式化 CoMDS 背后的优化问题，并阐释共识理想点估计的直观含义。在第3.2节中，我们提出一种基于投影的方法，帮助研究者将来源理想点估计分解为共识理想点估计和一个特异性因子。最后，第3.3节提供两种诊断工具，以便在实践中解读和使用 CoMDS：（1）一种相对误差度量，用于估计每个来源理想点估计对共识理想点估计的单独贡献；（2）一种稳定性分析，用于评估

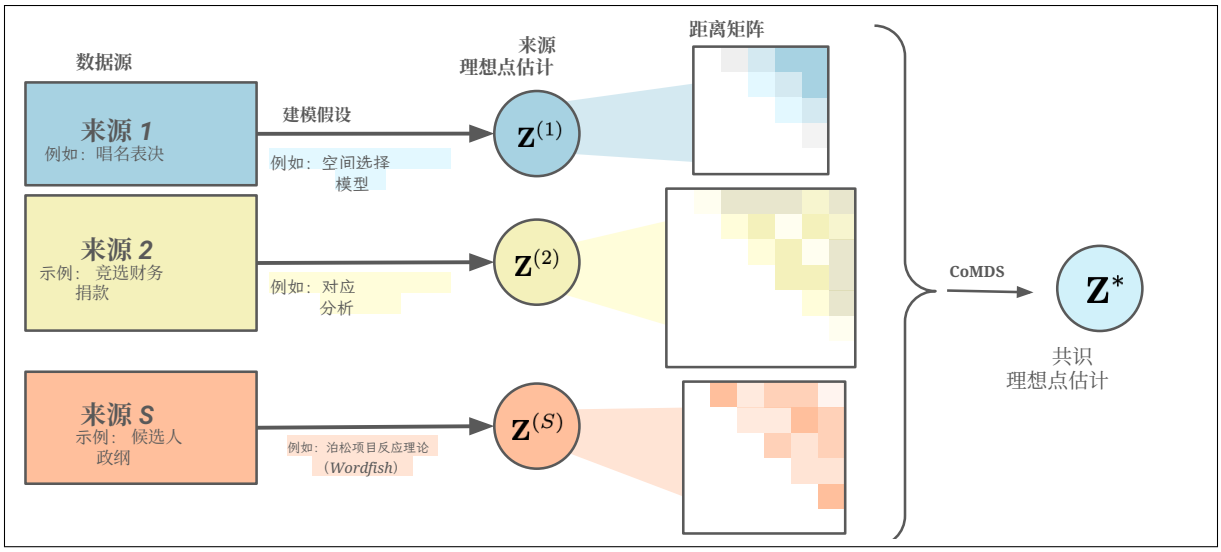

图 1： 共识理想点估计流程概述

共识理想点估计对纳入不同来源理想点估计的敏感程度。

3.1 共识多维尺度分析（CoMDS）

从高层次来看，共识多维尺度分析（CoMDS）将不同来源的理想点估计$\mathbf{Z}^{(s)}$ 作为输入，通过为每个来源计算成对距离矩阵来评估每一对观测值之间的（不）相似性$\mathbf{Z}^{(s)}$，并输出一个能够最佳保留来源理想点估计中所观测成对距离的共识^理想点估计$\mathbf{Z}^*$ （An 和 Tang（2025））。换言之，我们可以将 CoMDS 得到的共识理想点估计视为对底层来源理想点估计的共享空间表示的最佳近似。图1 展示了共识理想点估计流程。

更正式地说，假设我们正在研究 n 个候选人和 S 种来源理想点估计方法。对于每个 $s \in \{1, ..., S\}$，令 $\mathbf{Z}^{(s)} \in \mathbb{R}^{n \times r_s}$ 表示通过第 s^{th} 种理想点估计方法得到的来源理想点估计值。请注意，每个来源理想点估计 $\mathbf{Z}^{(s)}$ 的维度数量 r_s 可以不同，并且可能存在缺失值。不失一般性地，假设每个来源中的候选人均已对齐

因此，来源 s 中的第 i^{th} 个候选人（记为 $\mathbf{z}_i^{(s)}$）对应于来源 s' 中的第 i^{th} 个候选人（记为 $\mathbf{z}^{(s')}{}_i$）。定义缺失指示变量 $\alpha_i^{(s)}$：当候选人 i 的第 s^{th} 个来源理想点估计缺失时为 $\alpha_i^{(s)} = 0$，否则为 1。此外，令 Diag(r) 表示大小为 $r \times r$ 的对角矩阵集合。利用来源理想点 $\mathbf{Z}^{(1)}, \ldots, \mathbf{Z}^{(S)}$，CoMDS 通过以下两步程序估计共识理想点 $\mathbf{Z}^*$。

步骤 1：计算每个来源中理想点之间的不相似度。对于每个来源 $s = 1, \ldots, S$ 以及每一对候选人 $i, j = 1, \ldots, n$，计算 s^{th} 来源空间中理想点之间的成对距离（或不相似度）：$D_{ij}^{(s)} := d_{ij}(\mathbf{z}_i^{(s)}, \mathbf{z}_j^{(s)})$，其中$d(\mathbf{x}, \mathbf{y})$表示任意距离度量。本文始终采用欧几里得距离度量（即 $d(\mathbf{x}, \mathbf{y}) = \|\mathbf{x} - \mathbf{y}\|_2$）。

步骤 2：估计不同来源之间的共识结构。利用这些成对距离$D_{ij}^{(s)}$，CoMDS 借助多维尺度分析的一种推广方法（更多讨论请参见附录 A.2），以估计共识理想点$\mathbf{Z}^*$，该方法最初由心理计量学文献提出（Car-ˆroll and Chang 1970），具体方法为

$$\hat{\mathbf{Z}}^*, \hat{\mathbf{W}}^{(1)}, \ldots, \hat{\mathbf{W}}^{(S)} = \underset{\substack{\mathbf{Z} \in \mathbb{R}^{n \times r} \\ \mathbf{W}^{(s)} \in \text{Diag}(r)}}{\text{最小化}} \sum_{s=1}^{S} \sum_{i<j} \underbrace{\alpha_i^{(s)} \alpha_j^{(s)}}_{\substack{\text{缺失情况} \\ \text{指示变量}}} \left\{ \underbrace{D_{ij}^{(s)}}_{\substack{\text{来源空间中的距离} \\ \text{来源空间}}} - \underbrace{d(\mathbf{W}^{(s)}\mathbf{z}_i, \mathbf{W}^{(s)}\mathbf{z}_j)}_{\substack{\text{共识空间中的距离} \\ \text{共识空间}}} \right\}^2, \tag{3}$$

其中，r 是预先指定的共识输出维度数（通常为 $r = 1$ 或 2），$\hat{\mathbf{W}}^{(1)}, \ldots, \hat{\mathbf{W}}^{(S)}$ 是作为来源特定权重的 $r \times r$ 对角矩阵，而 $\alpha_i^{(s)} \alpha_j^{(s)}$ 是缺失指示变量：如果 s^{th} 候选人 i 和 j 的来源理想点均存在，则取值为 1；如果任一缺失，则取值为 0。

直观地说，CoMDS 确保原始源理想点空间中两名候选人之间的成对距离，与新学习得到的 CoMDS 理想点空间中这两名候选人之间的成对距离相近。这意味着，CoMDS 得出的共识理想点将涵盖来源理想点的变异，从而作为

不同来源理想点测量之间共享关联的测量指标。

为求解方程（3）给出的 CoMDS 优化问题，我们采用 SMACOF（De Leeuw 和 Mair，2009年），该方法利用带有闭式约束更新的迭代主化—最小化优化方案，来最小化方程（3）中的目标函数。已知该优化问题会线性收敛（De Leeuw，1988）。[2]

与其他聚合方法相比，CoMDS 具有若干优势。首先，与 MD2S（Enamorado 等，2021）和 PCA（Bonica（2024））等其他方法不同，CoMDS 不会明确作出任何线性假设。其次，由于 CoMDS 基于来源理想点估计之间的成对距离进行运算，并允许使用来源特定的权重矩阵$\mathbf{W}^{(s)}$，因此对于来源理想点估计中的底层旋转、重新缩放和平移具有不变性。重要的是，这类变换不会从根本上改变来源理想点估计的解释，因此也不应改变共识理想点估计。然而，像 PCA 这样直接对来源理想点估计进行运算的方法 $[\mathbf{Z}^{(1)}$、……、$\mathbf{Z}^{(S)}]$，会导致聚合结果对某个来源理想点估计的底层潜在空间中的重新缩放或旋转十分敏感。此外，PCA 等方法不会明确利用分组特征结构（即每个来源 s 对应一组特征$\mathbf{Z}^{(s)}$，其维度可能各不相同）。因此，当理想点估计的维度不同时，这类方法会隐式构造共识理想点估计，而给予维度较多的来源过高权重，无论该来源的质量如何。相比之下，CoMDS 在目标函数（3）中对每个来源赋予相同权重，专门用于学习所有输入来源之间的共识或共享结构。附录 B.1-B.3）中提供了展示这些差异的模拟结果。

最后，我们强调，CoMDS 能够自然地处理底层数据中程度不一的缺失情况。这使研究人员能够输入覆盖不同目标总体（即立法者、候选人等）的不同理想点估计，并构建

[2]作为参考，对于包含 2000 名候选人和 3 个来源的秩为 1 的问题，使用配备 Apple M3 Pro 芯片的 MacBook Pro，CoMDS 在容差为 1E-6 的情况下大约需要 2 分钟才能收敛。

共识理想点估计，即使存在不可忽略缺失数据也是如此。CoMDS 会将含有缺失数据的观测值与完整案例观测值一同嵌入同一空间。参见附录B.4，其中有更深入的讨论。

3.2 估计特异性理想点分量

共识理想点使研究人员能够探究候选人的领域无关理想点与感兴趣变量之间的实质性关系；与此同时，研究人员也可能关注有关问责、代表性和极化的不同结论如何特定于某些候选人行为（例如，Meisels 2025a）。估计原始来源理想点的特异性分量，有助于揭示这些潜在的领域间差异。我们提出一种基于投影的方法，将来源理想点估计 $\mathbf{Z}^{(s)}$ 分解为两部分：（1）由共识理想点估计 $\hat{\mathbf{Z}}^{*}$所代表的部分；（2）一个特异性因子 $\hat{\nu}^{(s)}$。

为此，定义共识投影矩阵 $\hat{\mathbf{P}}^{*} := \hat{\mathbf{Z}}^{*}(\hat{\mathbf{Z}}^{*\top}\hat{\mathbf{Z}}^{*})^{-1}\hat{\mathbf{Z}}^{*\top}$。利用 $\hat{\mathbf{P}}^{*}$，我们可以通过 $\hat{\mathbf{P}}^{*}\mathbf{Z}^{(s)}$ 将原始来源理想点估计 $\mathbf{Z}^{(s)}$ 投影到共识空间。直观地说，$\hat{\mathbf{P}}^{*}\mathbf{Z}^{(s)}$ 表示来源理想点估计中由共识理想点估计所代表的部分。接下来，我们将来源理想点 s 的特异性因子（即 $\hat{\nu}^{(s)}$）估计为残差项：

$$\hat{\nu}^{(s)} := \mathbf{Z}^{(s)} - \hat{\mathbf{P}}^{*}\mathbf{Z}^{(s)} = \left(\mathbf{I} - \hat{\mathbf{P}}^{*}\right)\mathbf{Z}^{(s)},$$

其中$\mathbf{I}$ 是一个 $n \times n$ 单位矩阵。根据构造，估计得到的特异性因子$\hat{\nu}^{(s)}$将与共识理想点估计$\hat{\mathbf{Z}}^{*}$正交。研究者也可以将$\hat{\nu}^{(s)}$ 解释为来源理想点估计中无法由共识理想点估计$\hat{\mathbf{Z}}^{*}$解释的残差部分。

$\hat{\nu}^{(s)}$ 的大小应根据原始来源理想点估计的尺度来解读。例如，NOMINATE的取值范围是 -1 到1，其中接近1的值

被解读为非常保守，而接近 -1 的值则被认为非常自由。在这种情况下，当特异性因子$\hat{}$ $\nu^{(s)} > 0$时，这意味着相对于共识理想点估计，NOMINATE高估了某个人的保守程度。相反，$\hat{}\nu^{(s)} < 0$ 意味着相对于该个人的共识理想点估计，NOMINATE高估了其自由主义程度。

3.3 CoMDS 的诊断指标

在接下来的小节中，我们将介绍两种诊断指标，以便更好地了解每种来源理想点度量对共识理想点估计的贡献。第一种是相对误差度量，可作为一种标准化的近似指标，衡量来源理想点与共识理想点的相似程度。第二种是留一稳定性分析，用于评估省略不同来源理想点后，共识理想点估计会发生怎样的变化。

相对误差度量。 首先，我们提出一种相对误差度量，用于评估每个来源理想点对共识理想点估计的独立贡献。这有助于了解现有候选理想点度量在多大程度上具有独特性，尤其是原始来源测量指标中有多少未能由各来源测量指标共有的部分解释。具体而言，相对误差诊断指标可以揭示候选人活动某一特定领域中的模式是否与不同情境下候选人活动的共同模式大致正交。

形式上，我们将来源理想点估计 $\hat{}\mathbf{Z}^{(s)}$ 的相对误差定义为： s^{th} 来源理想点估计与共识理想点估计之间成对距离的平方差，相对于所有 S 来源

理想点：

$$\text{RelError}(\mathbf{Z}^{(s)}) = \frac{\overbrace{\frac{1}{A^{(s)}}\sum_{i<j}\alpha_i^{(s)}\alpha_j^{(s)}\{d(\mathbf{z}_i^{(s)},\mathbf{z}_j^{(s)}) - d(\hat{\mathbf{W}}^{(s)}\hat{\mathbf{z}}_i^*,\hat{\mathbf{W}}^{(s)}\hat{\mathbf{z}}_j^*)\}^2}^{\text{error between } s^{th} \text{ source ideal points and consensus ideal points}}}{\underbrace{\sum_{s=1}^{S}\frac{1}{A^{(s)}}\sum_{i<j}\alpha_i^{(s)}\alpha_j^{(s)}\{d(\mathbf{z}_i^{(s)},\mathbf{z}_j^{(s)}) - d(\hat{\mathbf{W}}^{(s)}\hat{\mathbf{z}}_i^*,\hat{\mathbf{W}}^{(k)}\hat{\mathbf{z}}_j^*)\}^2}_{\text{total error, summed across all sources}}},$$

其中 $A^{(s)} = \sum_{i<j}\alpha_i^{(s)}\alpha_j^{(s)}$ 。这一来源特定量始终介于 0 和 1 之间。相对误差接近 0，表示来源理想点估计与共识理想点估计非常相似；相对误差接近 1，则表示两者差异很大。所有 S 个来源的相对误差之和等于 1。考虑一种极端情况：来源 s 的相对误差恰好等于 1。这意味着其他来源的相对误差必定为 0。从实质上说，这表示来源 s 与其他所有来源理想点估计正交（也就是说，没有 共享信息），而其他所有来源彼此相同（仅尺度不同），且也与共识理想点估计相同。另一方面，如果每个来源的相对误差都约为 $\frac{1}{S}$，则意味着 CoMDS 得出的共识理想点估计与各个来源的相似程度相同。

–

在实践中，学者很少拥有个体理想点的“真实值”测量指标。因此，较大的相对误差并不一定意味着某个来源理想点必然比其他来源的“正确性”更低。然而，较大的相对误差确实意味着某个来源理想点与共识理想点估计的偏离程度更大，并且该来源理想点中存在相当大的变异，而其他来源理想点估计并未共享这种变异。关于这一相对误差诊断的进一步直观解释，请参阅附录C中的说明性模拟研究。

留一稳定性分析。 研究人员评估每个来源理想点对共识理想点贡献的另一种方法，是进行留一分析

。为了评估纳入或排除不同来源理想点对共识理想点估计稳定性的影响，我们建议研究人员省略一个数据源，并重新估计 CoMDS，以观察估计结果是否发生较大变化。然后，我们可以评估原始共识理想点估计$\mathbf{Z}^*$ 与重新估计的共识理想点估计之间的相似性。

估计一维（$r = 1$）共识理想点时，一种常用的相似性度量是皮尔逊相关系数的绝对值：

$$\rho(s) = |\text{cor}(\hat{\mathbf{Z}}^*_{-(s)}, \hat{\mathbf{Z}}^*)|,$$

其中，$\mathbf{Z}^*_{-(s)}$ 表示使用 CoMDS 估计的共识理想点，但未纳入 s^{th} 来源理想点估计。估计多维（$r > 1$）共识理想点时，研究人员也可以通过计算原始共识理想点子空间与排除 s^{th} 来源后重新估计的共识理想点子空间之间的子空间相关性，来测量相似性。子空间相关性的常用测量指标是两个子空间交叉乘积矩阵的奇异值平方的平均值（Bj¨orck 和 Golub, 1973）：

$$\rho(s) = \frac{1}{r}\sum_{i=1}^{r} d_i^2,$$

其中，d_i是 ortho(ˆ**Z***)$^\top$ortho(ˆ$\mathbf{Z}^*_{-(s)}$) 的第 i^{th} 个奇异值，ortho(**A**) 表示张成与矩阵 **A** 相同子空间的一个正交基。

ˆ ˆ 总体而言， $\rho(s)$ 测量的是$\mathbf{Z}^*$ 与$\mathbf{Z}^*_{-(s)}$之间的一致程度，其中较大的、接近 1 的值意味着$\mathbf{Z}^*$ 与$\mathbf{Z}^*_{-(s)}$ 高度相似，而接近 0 的值则意味着$\mathbf{Z}^*$ 与$\mathbf{Z}^*_{-(s)}$ 正交。在删除单个来源理想点会导致共识理想点发生较大变化的情况下， $\rho(s)$ 将较低。这意味着删除 s^{th} 来源会导致最终的共识理想点估计发生较大变化。当被省略的来源理想点与其他来源理想点存在很大差异时，就会出现这种情况。

相反，如果 $\rho(s)$ 较高，则意味着 s^{th} 来源与其他输入相似。因此， s^{th} 来源不会对共识理想点估计产生很大影响。当多个来源理想点彼此相似时，可能会出现这种情况。

4 国会议员候选人理想点

在本节中，我们应用 CoMDS 来估计美国众议院候选人的理想点。首先，我们基于 NOMINATE、CF分数和竞选纲领立场估计共识理想点。尽管这三类测量指标之间的关系较弱，但我们的共识估计值仍然与每一类指标保持了实质性关系；其中，在某一来源测量指标与其他指标基本不相关的情况下，共识估计值仍能恢复党内相关性。随后，我们使用共识测量指标，评估来源测量指标各领域内具有实质意义的关系。具体而言，研究结果表明，如果所关注的变量与现有测量指标源自同一数据来源，依赖这些测量指标可能导致结论至多被夸大，最坏的情况下甚至会出现方向错误。此外，我们发现了许多案例：如果不采用共识方法，通常的“稳健性检验”——比较不同现有理想点之间的结果——无法令人满意地解释这些差异。这些分析凸显了共识理想点的广泛效用：当现有理想点存在显著分歧，而研究者原本会将它们视为可以互换时，共识理想点能够帮助恢复共同空间表示。

4.1 众议院候选人理想点的现有测量指标

虽然 CoMDS 几乎可以纳入任意数量的国会议员候选人理想点测量指标，但本文重点关注三类现有估计值。从概念上说，这些理想点可能代表真诚信奉的意识形态信念、策略性

政治定位、党派实力或两者的结合（例如 Lee 2009年；McCarty 2016年）。不过，在每种情况下，我们普遍关注的都是候选人在左—右连续谱上的位置。

第一种理想点测量方法 NOMINATE 基于唱名表决的空间选择模型，沿两个维度估计立法者的理想点（Lewis等人 2025年；Poole 和 Rosen- thal 1997年）。该方法假定，立法者在投票层面的决策完全取决于其理想点与赞成票和反对票所代表的备选政策之间的距离。由于 NOMINATE 基于立法行为，因此涵盖了所有立法者，但必然不包括未能当选进入国会的人。

其次，我们纳入三种竞选财务（CF）分数（Bonica 2014，2018年，2024年）。第一种变体将对应分析应用于竞选捐款矩阵，隐含地假设捐款是基于捐赠者与受赠者之间的相似性而提供的。经典 CF 分数是静态的，而第二种变体会随时间动态变化。第三种变体 DW-DIME 使用机器学习将捐款映射到 NOMINATE 空间，以便准确预测唱名表决行为。总体而言，CF 分数涵盖了获得捐款的候选人；这些候选人的捐款者人数达到最低门槛，且这些捐款者本人也向达到最低门槛的其他受赠者提供了捐款。

最后一种测量指标估算候选人竞选网站上所载政纲的立场（Meisels 2025a）。这一动态测量指标依赖于广泛使用的 `wordfish`文本尺度调整算法，该算法基于泊松项目反应理论模型，并假定词语使用能够反映潜在的单维理想点（Slapin and Proksch 2008）。政纲立场涵盖选择建立竞选网站且网站包含任何议题内容的候选人。

这些现有测量指标依据的是关于候选人活动的差异极大的数据来源，这些活动被分别假定由差异极大的过程生成，而且每种测量指标的估计都采用不同的统计方法。因此，过去的研究发现，同一政党内对候选人理想

图2： 来源理想点测量之间的关系

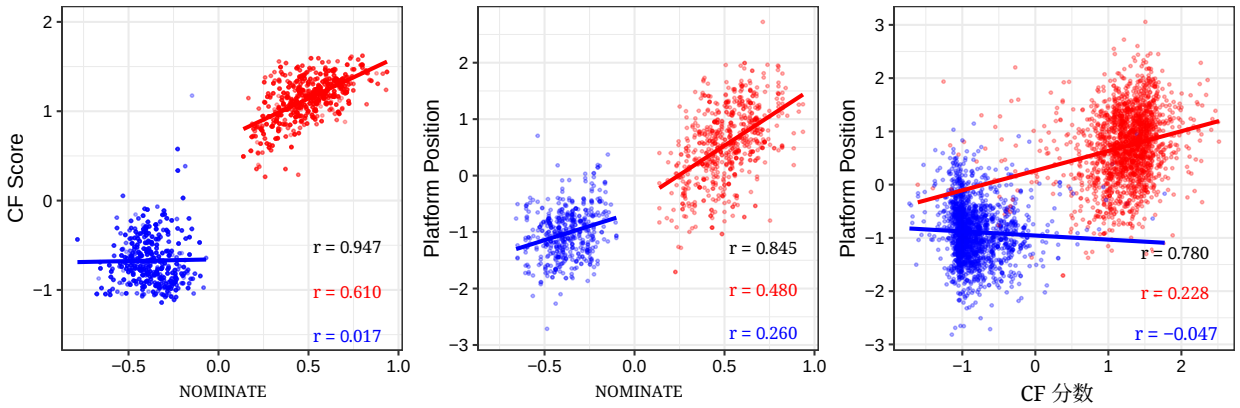

点的估计值之间的关联较弱（Barber 2022；Meisels 2025a；Tausanovitch 和 Warshaw 2017）。图2证实了这一点：三种主要测量指标之间的相关性总体较强，但在政党内部差异很大。尤其值得注意的是，民主党内 CF 分数与另外两种测量指标之间几乎不存在关联，这与Barber (2022）以及Meisels (2025a）[3]

4.2 构建共识理想点估计值

尽管有证据表明，这些测量指标的估计具有相当程度的领域特异性，但在绝大多数实质性应用中，人们仍将它们互换使用和解读。正如Tausanovitch and Warshaw明确指出的那样：“实证应用研究几乎一律将这些模型的估计值用作候选人意识形态的测量指标”（2017年，168）。研究极化、代表性或问责等议题的学者通常关心的是刻画候选人不受领域限制的整体极端主义与温和程度，或自由主义与保守主义，因此，测量指标之间的情境差异往往被淡化，通常被视为无关紧要的麻烦。[4]

[3]完整案例见附录 E，其中显示，CF分数与政纲立场之间的相关性略强。[4]需要明确的是，我们赞同学者应当仔细考虑其理论对不同领域的适用性。我们采用基于投影的方法来估计剩余的特异性成分

我们基于共识的方法，更接近于现有候选人理想点估计值在实际中的典型用法。我们使用上文讨论的基于唱名表决、捐款和政纲的测量指标，估计2016年至2024年众议院候选人的共识理想点。由于 CoMDS 无需依赖插补即可处理缺失数据，因此我们纳入至少被三种测量指标中的两种所涵盖的所有候选人。这样一来，我们便能够对同时拥有政纲立场和 CF 分数的非现任者，以及所有现任者进行尺度化，最终得到共计5,389个独特的候选人—年份观测值。[5]

图中共识理想点的分布3 呈现出预期中显著的党派双峰分布，绝大多数民主党人位于绝大多数共和党人的左侧。[6] 此外，图4 显示，共识理想点与各项主要来源测量指标之间保持着中等偏强的相关性。除了整体上普遍较高的相关性之外，正如图2所示，每项原始测量指标与共识测量指标的关联都强于其与其他测量指标的关联。例如，尽管民主党人的 CF 分数与其他来源测量指标基本不相关 —— 与政纲的相关性略为负值，与 NOMINATE 的相关系数为 0.017——但民主党人的 CF 分数与其共识理想点的相关系数接近 0.2。

4.3 评估现有测量指标领域内的实质性关系

如上所述，尽管有证据表明……，但在应用实证研究中，现有的候选人理想点估计值往往被交替使用和解读

现有测量指标尤其适用于未来研究不同背景下候选人理想点之间的实质性差异。[5]我们在附录D中对估计得到的共识理想点进行了稳定性分析，结果表明，这些估计值对其他分析选择具有稳健性，例如仅使用 NOMINATE 的第一维度，或仅使用完整数据。[6]在附录E中，我们报告并讨论了通过 CoMDS 估计的理想点与通过最相近的替代聚合方法（MD2S 和主成分分析）估计的理想点之间的关系。

图3： 按政党划分的候选人的共识理想点分布

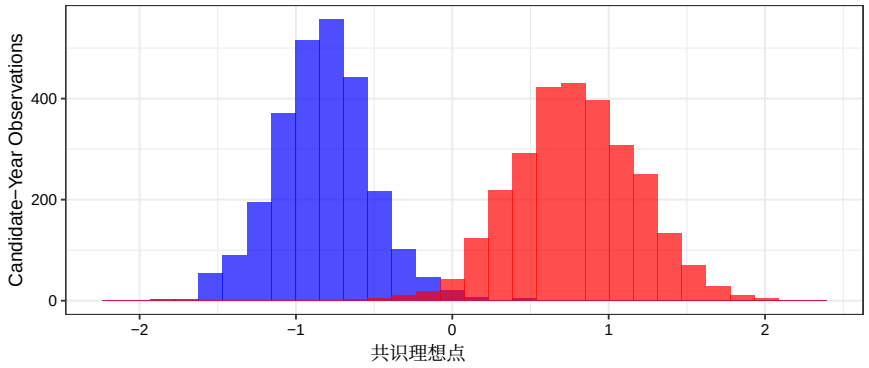

图4： 来源与共识理想点评估指标之间的关系

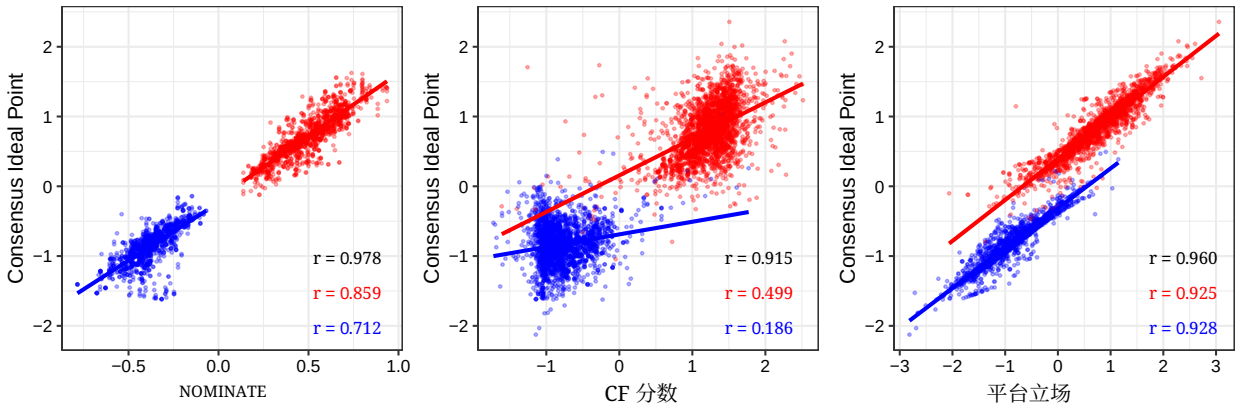

测量指标具有相当显著的领域特异性。许多关于选举、代表性、极化和问责的研究问题，都涉及一个与现有理想点源自同一数据来源的关注变量，这一事实使问题更加突出。例如，考虑极端主义对众议院选举筹款究竟有利还是有害这一问题。最简单而言，要对此进行研究，就需要对回归方程左侧的竞选捐款数据进行某种转换，并对右侧的候选人理想点进行某种转换——其中可能包括 CF 分数。

在缺乏共识方法的情况下，对于不同测量指标之间差异没有先验预期的研究者，必须转而比较使用不同领域特定测量指标（包括一种属于实质性变量所在领域的测量指标）所得结果的“稳健性”；而实质性变量

是研究者感兴趣的变量。如果发现同一领域内的理想点与感兴趣变量之间存在很强的关联，这种关联可能具有实质意义，也可能只是因为这些变量或多或少是联合测量的机械结果。因此，不同领域特定理想点在统计显著性或实质显著性上的任何分歧，都可能成为得出相关结论的重大障碍。通过识别不同测量指标之间共享的稳定关联，我们的共识方法使理想点摆脱对任何单一特定领域的依赖，从而更可靠地评估现有理想点所属领域内的变量与一个领域中立的理想点之间的关系。[7]

4.3.1 理想点与唱名表决中的党派不忠

国会议员的唱名表决理想点与唱名表决中的党派忠诚之间的联系早已确立：与温和派相比，极端派立法者更常与本党步调一致地投票（Carson 等（2010）；Minozzi 和 Volden（2013））。不过，这种联系可能部分源于对 NOMINATE 等唱名表决理想点的估计。由于模型会隐含地假定一同投票的议员具有更相似的理想点，因此，经常投票反对本党——很可能因此与对立党派站在一起——的议员，其唱名表决理想点会比从不违背党意的同党议员更接近对立党派。事实上，这正是 NOMINATE 的“AOC 问题”症结所在：NOMINATE 将众所周知的进步派稳稳地归入民主党党团的温和派阵营（Lewis Lewis）。此类模型未能考虑“以两端反对中间”的行为，即立场不同的议员出于相反理由反对某项立法（Duck-Mayr 和 Montgomery（2023））。[8]

[7]在附录E中，我们报告了仅基于完整案例（即拥有竞选网站政纲的立法者）或仅纳入 CoMDS 估计中的三个主要测量指标（即经典 CFscores、政纲立场和 NOMINATE 第一维度）所得的全部结果。我们还报告并讨论了采用现有共识理想点测量指标——Bonica Bonica (2024年) 的综合得分——得出的结果，不过这些得分是基于不同的来源测量指标和聚合方法估算的。[8]“小队”的典型案例包括：投票反对他们认为进步性不足的民主党立法案，同时与认为同一立法案保守性不足的共和党成员站在一起。

我们通过两组分析重新考察立法者的理想点与党派忠诚之间的关系。首先，我们比较基于共识理想点与 NOMINATE 得出的结果，以评估使用与因变量属于同一领域的理想点可能如何扭曲结论。其次，我们比较三种主要来源测量指标——NOMINATE、CF 分数和政纲立场——得出的结果。如果没有共识方法，研究者通常会进行这种“稳健性检验”，试图排除某项结果仅仅是自变量和因变量源自同一领域所造成的假象。为尽可能提高可比性，我们在样本内对所有理想点进行标准化，并且在每项分析中仅纳入相关测量指标所覆盖的观测值。因此，结果上的任何差异都将源于理想点估计的差异，而非样本覆盖范围的差异。

我们的因变量——唱名表决中的党派不忠——基于《国会季刊》（CQ）长期使用的党派团结测量指标。CQ 将党派团结唱名表决定义为：一个政党的多数成员投票反对另一政党多数成员的表决；立法者的党派团结得分，则是该立法者与本党立场一致的党派团结表决所占比例。不出所料，这些得分呈明显的左偏分布：只有少数成员在不到 90% 的党派团结表决中与本党立场一致。因此，我们通过对「1 减去党派团结得分」进行对数变换，计算党派不忠这一信息量更大的测量指标。[9]

表1前两列的估计结果表明，在立法者的温和程度与唱名表决中的党派不忠之间关系的方向上，不依赖领域的理想点与基于唱名表决的理想点达成一致。随着民主党人的共识理想点变得更保守／不那么自由，他们投票反对本党立场的频率显著上升；而随着共和党人的共识理想点变得更保守／不那么自由，他们投票反对本党立场的频率显著下降。然而，

[9]在附录 E 中绘制理想点与所有关注因变量的关系图，表明这些关系存在显著的非线性，因此我们也在所有报告的模型中控制相应理想点测量的二次设定。

表1： 理想点与唱名表决中的党派不忠诚之间的关系 y

	因变量：log(% 反对党派多数意见的票数)				
	共识与领域		比较来源测量指标		
	共识	NOMINATE	NOMINATE	CF 分数	政纲
*A*组. 民主党人					
理想点	0.673***	0.727***	0.729***	0.036	0.211***
	(0.035)	(0.027)	(0.043)	(0.073)	(0.062)
观测值	1,206	1,206	493	493	493
*B*面板：共和党人					
理想点	-0.504***	-0.651***	-0.628***	-0.352***	-0.291***
	(0.034)	(0.028)	(0.040)	(0.048)	(0.047)
观测值	1,340	1,340	660	660	660

注： 理想点随保守主义程度的提高而增大，并在样本内重新缩放，使均值为 0、标准差为 1。模型控制了二阶多项式。括号内为按立法者聚类的标准误。* $p < 0.05$，** $p < 0.01$，*** $p < 0.001$

与共识模型相比，NOMINATE模型的系数幅度被夸大了，这表明使用相同的唱名表决数据来测量自变量和因变量会放大关系的强度。

共识理想点使我们能够得出结论：总体而言，温和派立法者投票反对本党立场的频率远高于极端派立法者。然而，比较表1中不同来源测量指标的估计结果表明，若不采用我们的共识方法，在利用现有理想点进行稳健性检验时，很难确认这种关系。对于民主党人而言，CF 分数与党派不忠之间未检测到关联。根据政纲立场估算的关联程度不足 NOMINATE 所估结果的三分之一。共和党人的来源理想点与党派不忠之间的关联更为一致，但尽管模型仅纳入三种测量指标均覆盖的立法者，不同测量指标所估出的关联程度仍有很大差异。总的来说，这些结果阐明了，当组成测量得出不同估计结果时，共识方法如何帮助我们对立法者的温和程度与唱名表决中的党派不忠之间关系的强度和大小得出有意义的结论。

4.3.2 理想点与竞选捐款人

极端派在选举中是否具有财务优势，是近期有关国会极化的文献所探讨的核心问题。与包括选民在内的其他群体相比，个人捐赠者显然立场更为极端；大量研究表明，他们会基于立场相同这一原因向极端候选人捐款（Ansolabehere 等，2003；Barber，2016b；Kujala，2020）。然而，其他研究指出，个人捐赠者也会受到更具策略性的考量驱动，而这些考量也可能促使他们支持非极端派候选人（Gimpel 等，2008；Meisels 等，2024）。与个人捐赠者不同，有证据表明，政治组织——尤其是企业——往往支持温和派候选人（Barber，2016a；Meisels，2025b；Thieme，2020）。依赖基于捐款的理想点来考察候选人定位与筹款成功之间的关系，很可能会带来问题：知名度较高的候选人（如现任者）能够从全国性捐赠者那里筹款，而绝大多数知名度较低的候选人则必然只能依靠地方支持。

与上一节类似，我们开展两组分析，以重新考察候选人的理想点与财政支持基础之间的关系。第一组将基于共识理想点的结果与基于领域特定 CF 分数的结果进行比较；第二组则考察在不同现有理想点测量指标之间进行比较时，结果会表现得多么“稳健”。为操作化财政支持，我们对意识形态、金钱与选举数据库（Bonica（2024））所报告的候选人在其整个职业生涯中获得捐款的不同捐款人数进行对数转换。相较于捐款总额，关注捐款人数有助于避免捕捉支持不同理想点候选人的捐赠者财富差异，而是捕捉候选人支持基础总体规模的差异。此外，我们采取与之前相同的步骤，通过重新调整测量指标的尺度并将样本限定为共同观测值，最大限度地提高不同理想点模型之间的可比性。

估计结果　　表 2 的前两列表明，关于基本结论的】【。　　t

表 2： 理想点与筹款成功之间的关系

	因变量：竞选活动唯一捐赠者数量的对数				
	共识与领域		比较来源测量指标		
	共识	CF 分数	NOMINATE	CF 分数	政纲
*A*组。民主党人					
理想点	-0.373***	0.839***	0.221**	-0.811***	0.051
	(0.073)	(0.072)	(0.073)	(0.065)	(0.066)
观测值	2,629	2,629	516	516	516
*B*面板：共和党人					
理想点	-0.423***	-0.963***	-0.111*	0.350***	-0.120*
	(0.062)	(0.057)	(0.055)	(0.066)	(0.061)
观测值	2,760	2,760	678	678	678

注：理想点随保守主义程度的提高而增加，并在样本内重新缩放，使其均值为 0、标准差为 1。模型控制二阶多项式。括号内为候选人聚类标准误。* p <0.05，** p < 0.01，*** p < 0.001

在民主党人和共和党人中，随着共识理想点变得更保守，财务基础都会大幅下降。这实际上表明，总体极端主义在财政上有利于民主党人，而总体温和则在财政上有利于共和党人。相比之下，在两党候选人中，CF 分数的温和程度与财政支持之间存在正相关，而且 CF 分数模型中的系数大小是共识理想点模型中的两倍以上。因此，现有理想点测量指标中的共享成分——由共识理想点所体现——与候选人财政支持之间的关系，从实质效应大小乃至方向上，都与 CF 分数所体现的关系存在根本差异。

鉴于基于领域特定测量指标与领域无关测量指标得出的结果存在差异，如果在没有采用我们的共识方法时，通过比较不同现有理想点的结果进行“稳健性检验”却无法得出明确的实质性结论，或许并不令人意外。请注意，与共识模型相比，表 3 中 CF 分数模型的估计值符号与其他来源测量指标模型的估计值符号不同。

前者涵盖了所有由 CF分数以及 NOMINATE 或政纲立场所覆盖的候选人，而后者仅涵盖由这三项指标全部覆盖的候选人。正如Meisels (2025a)所指出的，非现任者（他们往往较不善于筹款）的 CF 分数比现任者极端得多，但其他测量指标并未显示出这种情况。即使只看由这三项测量指标全部覆盖的完整案例，各来源测量指标之间也存在明显分歧。CF 分数表明，极端主义与更雄厚的财务基础相关；而政纲立场和 NOMINATE 则表明，即便有所关联，温和程度也与更雄厚的财务基础相关。总之，对现有理想点结果的比较表明，若没有像我们这样的方法来达成共识，研究者就无法得出连贯的总体结论。

4.3.3 理想点与词汇多样性

尽管大量研究考察了演讲、新闻稿和政纲，但其重点一直集中于意识形态内容，复杂性也是政治文本的另一个重要维度。随着时间推移，政治修辞日益“浅薄化”的现象，尤其是就国情咨文演讲而言，既受到了公众关注，也得到了学术界的重视（Benoit等人 2019年）。相关研究考察了选民范围的扩大——这一过程通过选举轮次（Di Tella等人 2025年）或选举权扩大（Spirling 2016年）表现出来——与精英修辞语言复杂度之间的对应关系。另一类研究则评估候选人/政党的意识形态立场与语言复杂性之间的关系（例如 Schoonvelde等人 2019年；Tetlock 1983年），总体上发现，更强的保守主义倾向与较不复杂的语言相关。这些研究通常比较属于保守派和自由派政党的政治人物的修辞复杂度（例如美国的共和党人和民主党人）。

为评估保守主义与词汇多样性之间是否存在政党内部关系，我们再次开展分析，将基于共识理想点的结果与基于领域特定理想点的结果进行比较，同时比较三种现有理想点测量指标的结果。为捕捉词汇多样性，我们依赖竞选网站

表 3：理想点与词汇多样性之间的关系

	因变量：竞选纲领校正词型-词次比（CTTR）				
	共识与领域		比较来源测量指标		
	共识	政纲	NOMINATE	CF 分数	政纲
*A*组。民主党人					
理想点	0.376***	0.471***	0.156	-0.344	0.287
	(0.090)	(0.080)	(0.193)	(0.203)	(0.178)
观测值	1,836	1,836	516	516	516
*B*面板：共和党人					
理想点	-0.542***	-0.729***	-0.064	0.057	-0.633***
	(0.064)	(0.064)	(0.122)	(0.144)	(0.129)
观测值	1,994	1,994	678	678	678

注：理想点随保守主义程度的提高而增大，并在样本内重新缩放，使均值为 0、标准差为 1。模型控制了二阶多项式。括号内为候选人聚类标准误。* p <0.05，** p < 0.01，*** p < 0.001

政纲——这是覆盖大量非现任者的仅有的长篇语料库之一（Meisels 2025a）。[10] 上述关于语言复杂度的研究采用了多种多样的测量指标，这些指标考察词语、句子以及文档整体的长度与复杂度等特征。与此类研究所关注的更为正式的文本不同，竞选政纲经常包含项目符号列表和许多并非完整句子的 小标题。由于该语料库的句法并不适合依赖自然句子句法特征的指标，我们采用一种简单的词汇多样性测量指标，即Carroll校正型符比（CTTR）（Carroll 1964）。该测量指标通过文档中独特词语数与词语总数之比来代理文本的概念复杂度，随后用总词数两倍的平方根替换分母中的词语总数，以进行校正并应对该比值对文档长度的敏感性。

表 3 中使用共识理想点和领域特定理想点得出的结果表明，党内温和化——而非以往研究所称的自由主义——与更高的修辞复杂度相关。然而，在民主党人和共和党人中，基于共识的——

[10]相比之下，可用于研究在任立法者词汇多样性的数据来源有很多，例如新闻稿或国会演讲。

估计结果都比基于政纲的估计更为温和。不过，比较不同来源测量指标的系数后可以发现，如果没有我们的共识方法，在进行稳健性检验时，这种关系将无法被检测到。与不完整案例相比，在完整案例中，基于政纲的估计值较小（对民主党人而言，在传统显著性水平下甚至不具统计显著性），而另外两种理想点测量指标在符号和大小上则不一致。若没有基于共识理想点的估计结果，我们就无法判断，仅在基于政纲理想点的分析中出现的强关系，是否只是因为其使用了与因变量相同的数据来源进行测量。

5 结论

在政治学的各个子领域中，许多持续进行的辩论都需要估算政治行为者的理想点。例如，美国政治前沿尚未解决的研究问题，就需要估算国会议员候选人的职位。现有研究记载了基于不同数据来源和测量方法所得估算结果之间薄弱的党内关系，这表明每种测量指标都可能是两部分的混合：一是各种测量指标共同反映的、较少依赖具体领域的理想点，二是领域特定且个别化的成分（Barber 2022；Meisels 2025a；Tausanovitch 和 Warshaw 2017）。然而，在大多数应用研究中，研究者关注的是候选人“政治定位”或“意识形态”这一更一般的概念，因此往往将不同的测量指标视为大致可以互换。

我们提出共识多维尺度分析（CoMDS）作为一种估计方法，它更符合理想点在实际应用中的使用方式。人们通常会评估不同测量指标所得结果的稳健性，以确保研究发现并非由某一种理想点测量指标所驱动；然而，我们已经表明，现有测量指标不仅可能对当前争论焦点中基本关系的实质大小存在分歧，

还可能对其方向存在分歧。因此，若缺乏像我们提出的这类共识方法，研究者将无法对所关注的关系得出有意义的结论。相比之下，共识理想点有助于考察不同理想点测量指标之间共同 的组成部分与相关变量之间的关系。

除了利用国会议员候选人的共识理想点来考察其他感兴趣的关系之外，本文提出的方法还有许多方面为未来研究开辟了新的方向。CoMDS 无需研究者对不同数据源的结果进行联合建模，因此能够对不同情境下不同的底层行为模型进行编码。该方法还能够灵活处理不同来源测量指标中缺失情况的差异；此外，最终得到的共识理想点也不受来源测量指标重新缩放或旋转的影响。

CoMDS 的可定制性使其非常适合估计其他行为主体的理想点，也便于纳入不断涌现的其他来源测量指标。虽然本文聚焦于现有国会议员候选人理想点的三大类估计值，但也可以轻松地将大语言模型或社交媒体场合产生的新估计值与其他来源测量指标一并纳入。这使未来研究能够考察纳入较新的估计值后，共识理想点是否会发生变化，以及如何变化。除了本文应用所聚焦的特定情境外，在其他存在多个相似概念测量指标、且这些指标在实际应用中差异显著的场景里，CoMDS 也可能发挥作用。由于潜在理想点几乎按定义而言很少存在“真实值”，对于不关注相似概念的不同测量指标之间情境差异的研究者，我们提出的共识方法提供了一种以数据为依据、旨在调和差异的方法。

与识别其共享成分相辅相成的是，我们提出的基于投影的方法有助于进一步考察来源测量指标之间的差异。尽管已有明确证据表明，国会议员候选人理想点的估计值之间关系相对较弱，但要精确找出它们为何不同，一直更加困难

。通过将每项测量指标分解为与其他测量指标共享的成分，以及剩余的特异性正交成分，未来的研究可以更轻松地分析领域特异性因素与感兴趣的外部变量之间的关系。进而，这有望开辟新的研究方向，探究候选人在不同场合和活动中的策略行为差异。

参考文献

An, B. 和 T. M. Tang（2025）。通过多视图学习实现共识降维。*arXiv* 预印本 *arXiv:2512.15802*。Ansolabehere, S.、J. M. de Figueiredo 和 J. M. Snyder（2003）。为什么美国政治中的资金如此之少？《经济学展望杂志》*17*(1)，105–130。Barber, M.（2022）。比较竞选财务与基于投票的意识形态测量。《政治学杂志》*84*(1)，613–619。Barber, M. J.（2016a）。意识形态捐助者、捐款上限与美国立法机构的极化。《政治学杂志》*78*(1)，296–310。Barber, M. J.（2016b）。代表美国参议院中捐助者、党派成员和选民的偏好。《公众舆论季刊》*80*(S1)，225–249。出版方：Oxford Academic。Barber´a, P.（2015）。物以类聚，人以群分：使用 Twitter 数据进行贝叶斯理想点估计。《政治分析》*23*(1)，76–91。Benoit, K.、K. Munger 和 A. Spirling（2019）。通过文本复杂度测量并解释政治素养。《美国政治学杂志》*63*(2)，491–508。电子版：https://onlinelibrary.wiley.com/doi/pdf/10.1111/ajps.12423。Bj¨orck, A. 和 G. H. Golub（1973）。计算线性子空间间夹角的数值方法。《计算数学》*27*(123)，579–594。Bond, R. 和 S. Messing（2015）。量化社交媒体的政治空间：根据 Facebook 上公开表达的偏好估计意识形态。《美国政治学评论》*109*(1)，62–78。Bonica, A.（2014）。描绘意识形态市场。《美国政治学杂志》*58*(2)，367–386。Bonica, A.（2018）。使用监督式机器学习，根据竞选捐款推断唱名表决得分。《美国政治学杂志》*62*(4)，830–848。出版方： [中西部政治学会，Wiley]。Bonica, A.（2024）。意识形态、政治资金与选举数据库：公开版本 4。0 [计算机文件]。加利福尼亚州斯坦福：斯坦福大学图书馆。https://data.stanford.edu/dime。Burnham, M.（2024）。语义缩放：使用大语言模型进行贝叶斯理想点估计。*arXiv* 预印本 *arXiv:2405.02472*。Canes-Wrone, B.、D. W. Brady 和 J. F. Cogan（2002）。步调不合，乌纱不保：选举问责与众议院议员投票。《美国政治学评论》*96*(1)，127–140。

Carroll, J. B.（1964）。《语言与思维》。Prentice-Hall。Google 图书 ID：JKk0AAAAMAAJ。Carroll, J. D. 和 J.-J. Chang（1970）。通过对“Eckart–Young”分解进行 n 向推广，分析多维尺度分析中的个体差异。*Psychometrika 35*(3)，283–319。Carson, J. L.、G. Koger、M. J. Lebo 和 E. Young（2010）。国会中党派忠诚的选举代价：选举代价。《美国政治学杂志》*54*(3)，598–616。Caughey, D. 和 E. Schickler（2016）。国会意识形态的实质与变化：NOMINATE 及其替代方案。《美国政治发展研究》*30*(2)，128–146。Clinton, J. D.（2006）。国会中的代表性：第106届众议院中的选民与唱名表决。《政治学杂志》*68*(2)，397–409。Cowburn, M. 和 M. S¨altzer（2025）。两阶段选举中的党派传播：初选对国会选举竞选期间立场变化的影响。《政治学研究与方法》*13*(2)，392–411。De Leeuw, J.（1988）。多维尺度分析中主化方法的收敛性。《分类学杂志》*5*，163–180。De Leeuw, J. 和 P. Mair（2009）。使用主化方法进行多维尺度分析：R 中的 SMACOF。《统计软件杂志》*31*，1–30。Di Tella, R.、R. Kotti、C. Le Pennec 和 V. Pons（2025）。让敌人离你更近：美国和法国选举中的策略性政纲调整。《美国经济评论》*115*(8)，2488–2528。Duck-Mayr, J. 和 J. Montgomery（2023）。反对中间派：当人们因截然相反的原因作出相同反应时，如何测量潜在特质。《政治分析》*31*(4)，606–625。Enamorado, T.、G. L´opez-Moctezuma 和 M. Ratkovic（2021）。对多个来源的数据进行尺度调整。《政治分析》*29*(2)，212–235。出版方：剑桥大学出版社。Gimpel, J. G.、F. E. Lee 和 S. Pearson-Merkowitz（2008）。支票正在邮寄途中：国会选举中的选区间资金流动。《美国政治学杂志》*52*(2)，373–394。电子版：https://onlinelibrary.wiley.com/doi/pdf/10.1111/j.1540-5907.2008.00318.x。Hall, A. B.（2015）。极端派赢得初选会怎样？《美国政治学评论》*109*(1)，18–42。Honaker, J.、G. King 和 M. Blackwell（2011）。Amelia II：一款处理缺失数据的程序。《统计软件杂志》*45*，1–47。

Jessee, S. (2016).（如何）才能在同一尺度上估计公民和政治精英的意识形态？《美国政治学杂志》*60*(4), 1108–1124. Kujala, J. (2020). 美国的捐赠者、初选与极化。《美国政治学杂志》*64*(3), 587–602. 电子版：https://onlinelibrary.wiley.com/doi/pdf/10.1111/ajps.12477. Lauderdale, B. E. and A. Herzog (2016). 从立法演讲中测量政治立场。《政治分析》*24*(3), 374–394. Lee, F. E. (2009). 超越意识形态：美国参议院的政治、原则与党派倾向. 芝加哥大学出版社。Lewis, J. B. Voteview |为什么 NOMINATE 会将 Ocasio-Cortez、Omar、Pressley 和 Talib 估计为温和派？Lewis, J. B., K. Poole, H. Rosenthal, A. Rudkin, A. Boche, and L. Sonnet (2025). Voteview：国会唱名表决数据库。Lewis, J. B. and C. Tausanovitch (2015). 联合标度何时能够直接比较偏好？载于理想点模型会议，第1卷。Lock, E. F., K. A. Hoadley, J. S. Marron, and A. B. Nobel (2013). 用于多种数据类型综合分析的联合与个体变异解释（JIVE）。《应用统计年鉴》*7*(1), 523. McCarty, N. (2016). 为 DW-NOMINATE 辩护。《美国政治发展研究》*30*(2), 172–184. McCarty, N., K. Poole, and H. Rosenthal (2006). 极化的美国：意识形态与不平等财富之舞. 麻省理工学院出版社。Meisels, M. (2025a). 候选人立场、响应性与极端主义回报。《政治学杂志》, 000–000. 出版方：芝加哥大学出版社。Meisels, M. (2025b). 凡事适度？极端派候选人提名对个人及企业政治行动委员会筹款的影响。《政治学研究与方法》, 1–17. Meisels, M., J. D. Clinton, and G. A. Huber (2024). 捐给极端派？关于捐赠者对候选人与选区特征反应的实验性证据。《英国政治学杂志》*54*(3), 851–873. Minozzi, W. and C. Volden (2013). 国会中谁会响应政党的号召？《政治学杂志》*75*(3), 787–802. 出版方：芝加哥大学出版社。Murray, J. S., D. B. Dunson, L. Carin, and J. E. Lucas (2013). 面向混合数据的贝叶斯高斯 Copula 因子模型。《美国统计学会杂志》*108*(502), 656–665.

Poole, K., J. B. Lewis, J. Lo, and R. Carroll (2011). 使用 wnominate 在 R 中对唱名表决进行尺度调整。《统计软件杂志》*42*(1), 1–21. Poole, K. T. and H. Rosenthal (1997). 《国会：点名投票的政治经济史》. 牛津大学出版社。Quinn, K. M. (2004). 混合序数与连续响应的贝叶斯因子分析。《政治分析》*12*(4), 338–353. Schoonvelde, M., A. Brosius, G. Schumacher, and B. N. Bakker (2019). 自由派说教，保守派沟通：对381,609篇政治演讲中的复杂性与意识形态进行分析。*PLOS ONE 14*(2), e0208450. 出版方：公共科学图书馆。Shor, B. and N. McCarty (2011). 美国立法机构的意识形态映射。《美国政治学评论》*105*(3), 530–551. Slapin, J. B. and S.-O. Proksch (2008). 从文本估计时间序列政党立场的尺度化模型。《美国政治学杂志》*52*(3), 705–722. 电子版：https://onlinelibrary.wiley.com/doi/pdf/10.1111/j.1540-5907.2008.00338.x. Spirling, A. (2016). 民主化与语言复杂性：1832—1915年选举权扩大对议会话语的影响。《政治学杂志》*78*(1), 120–136. 出版方：芝加哥大学出版社。Stekhoven, D. J. and P. B¨uhlmann (2012). Missforest——一种用于混合类型数据的非参数缺失值插补方法。《生物信息学》*28*(1), 112–118. Tausanovitch, C. and C. Warshaw (2013). 测量国会、州立法机构和城市中的选民政策偏好。《政治学杂志》*75*(2), 330–342. Tausanovitch, C. and C. Warshaw (2017). 在两极分化的国会中估计候选人的政治倾向。《政治分析》*25*(2), 167–187. Tenenbaum, J. B., V. d. Silva, and J. C. Langford (2000). 非线性降维的全局几何框架。《科学》*290*(5500), 2319–2323. Tetlock, P. E. (1983). 认知风格与政治意识形态。《人格与社会心理学杂志》*45*(1), 118–126. 出版地：美国；出版方：美国心理学会。Thieme, S. (2020). 温和还是策略？企业与行业团体的政治捐赠。《政治学杂志》*82*(3), 1171–1175. 出版方：芝加哥大学出版社。Torgerson, W. S. (1952). 多维尺度分析：I. 理论与方法。《心理计量学》*17*(4), 401–419. Treier, S. and S. Jackman (2008). 民主作为潜变量。《美国政治学杂志》*52*(1), 201–217.

Van Buuren, S. 和 K. Groothuis-Oudshoorn（2011年）。mice：R 中的链式方程多重插补。《统计软件杂志》第 *45* 卷，1–67。

Yu, B. 和 K. Kumbier（2020年）。可验证数据科学。美国国家科学院院刊 *117*（8），3920–3929。

附录

目录

A 附加讨论 2A.1 与 MD2S（Enamorado 等，2021）的关系 .2A.2 将 CoMDS 解读为受约束的多维尺度分析问题 .2

B 示例模拟 **模拟** **3**
B.1 非线性数据生成模拟 .3B.2 旋转不变性模拟 .4B.3 不平衡且相关的来源模拟 .5B.4 缺失数据 .8

C CoMDS 诊断指标的补充讨论 11

D 候选人定位应用的诊断与稳定性分析 12

E 补充候选人定位分析 **17**
E.1 与替代方法的比较.17E.2 仅纳入完整案例时的稳健性 .18E.3 对三项主要测量指标进行尺度调整时的稳健性 .20E.4 补充分析 .22

A 补充讨论

A.1 与 MD2S（Enamorado 等人，2021）的关系

与我们的方法最为接近的是 Enamorado等人（2021）提出的一种称为 MD2S 的方法。Enamorado等人（2021）关注这样一种情形：研究人员拥有两个数据源，并且能够获取这两个数据源中的结果： $Y_{(1)}Y_{(2)} \in \mathbb{R}^{n\times p}$。然后，他们假设以下线性数据生成过程：

$$\begin{cases} Y^{(1)} &= \mathbf{Z}^*\mathbf{\Gamma}^{(1)} + \nu^{(1)} + \varepsilon^{(1)} \\ Y^{(2)} &= \mathbf{Z}^*\mathbf{\Gamma}^{(2)} + \nu^{(2)} + \varepsilon^{(2)} \end{cases}, \tag{4}$$

为了估计模型，他们进一步对 $\nu^{(s)}$施加低秩假设，对 $\mathbf{\Gamma}^{(s)}$ 和 $\nu^{(s)}$施加正交约束，并对 $\varepsilon^{(s)}$施加正态性假设。随后，所提出的算法通过联合建模 $Y_{(1)}$ 和 $Y_{(2)}$，估计 $\{\mathbf{Z}^*,\ \mathbf{\Gamma}^{(1)},\ \mathbf{\Gamma}^{(2)},\ \nu^{(1)},\ \nu^{(2)}\}$。

比较方程（4）中假设的数据生成过程与方程（1）中 CoMDS 假设的数据生成过程，有助于凸显这些方法之间的差异。回顾一下，在方程（1）中，我们假设结果可以写作 $Y^{(s)} = g^{(s)}\left(\mathbf{Z}^* + \nu^{(s)}\right) + \varepsilon^{(s)}$。然而，我们并未对 $g^{(s)}$ 的函数形式或误差项 $\varepsilon^{(s)}$施加任何限制。因此，我们可以将方程（4）中的数据生成过程视为方程（1）的一个特例，其中函数 $g^{(s)}$ 对于所有数据源而言，都是一个线性映射。假设所有结果都必须与真实理想点$\mathbf{Z}^*$ 呈线性关系，这一假设可能相当严格，也无法对应许多现有数据源所假定的底层行为模型。例如，NOMINATE 通常假设赞成／反对票服从由底层理想点决定的逻辑函数。

A.2 将 CoMDS 理解为受约束的多维尺度分析问题

理解 CoMDS 的另一种方式，是考察它与受约束多维尺度分析问题的等价性。具体而言，定义分块对角矩阵 $\mathbf{D} = diag(\mathbf{D}^{(1)}, \ldots, \mathbf{D}^{(S)}) \in \mathbb{R}^{Sn\times Sn}$，并假设我们对 Torgerson 1952) $\mathbf{D}$ 应用普通多维尺度分析（MDS），并施加一个特定约束——具体来说，

$$\hat{\mathbf{Z}}^*_{MDS} = \underset{\tilde{\mathbf{Z}}\in\mathbb{R}^{Sn\times r}}{\arg\min} \sum_{i<j} \left(\mathbf{D}_{ij} - d(\tilde{\mathbf{z}}_i, \tilde{\mathbf{z}}_j)\right)^2, \tag{5}$$

满足以下约束条件：

$$(i)\ \ \tilde{\mathbf{Z}} = \begin{bmatrix} \mathbf{Z}\mathbf{W}^{(1)} \\ \vdots \\ \mathbf{Z}\mathbf{W}^{(S)} \end{bmatrix},\ (ii)\ \mathbf{W}^{(1)}, \ldots, \mathbf{W}^{(S)} \text{ are } r \times r \text{ diagonal matrices, and } (iii)\ \mathbf{Z} \in \mathbb{R}^{n\times r}.$$

那么，约束多维尺度分析解（5）满足

$$\hat{\mathbf{Z}}^*_{MDS} = \begin{bmatrix} \hat{\mathbf{Z}}^*\hat{\mathbf{W}}^{(1)} \\ \vdots \\ \hat{\mathbf{Z}}^*\hat{\mathbf{W}}^{(S)} \end{bmatrix}, \tag{6}$$

where $\hat{}\mathbf{Z}^*$ 和 $\hat{}\mathbf{W}^{(1)}$，……，$\hat{}\mathbf{W}^{(S)}$ 是式（3）中 CoMDS 问题的解).

B 示例模拟

本节通过一系列示例模拟，帮助读者直观理解 CoMDS，并突出 CoMDS 相较于现有方法的主要优势。具体而言，我们将 CoMDS 与直接对拼接后的来源理想点[$\mathbf{Z}^{(1)}$、……、$\mathbf{Z}^{(S)}$]进行比较，从而具体展示 CoMDS 的四项重要优势——（i）能够灵活处理非线性数据生成过程，见第B.1节；（ii）对来源理想点中的任意平移、重新缩放和旋转具有不变性，见第B.2节；（iii）即使在不平衡且相关的情形下，也能识别共识模式，见第B.3节；以及（iv）能够天然地处理缺失数据。

B.1 非线性数据生成模拟

首先，回顾第 2 节中提出的理想点模型（1），其中我们假设数据源 $Y^{(s)}$ 由理想点估计 $g_s(\cdot)$ 的某个函数生成，其中理想点估计为 $\mathbf{Z}^{(s)}$，并可能包含噪声 $\epsilon^{(s)}$:

$$Y^{(s)} = g_s(\mathbf{Z}^{(s)}) + \epsilon^{(s)}.$$

以往的方法，如 PCA（Bonica（2024））和 MD2S（Enamorado 等，2021）[11] 假设 $g_s(\cdot)$ 具有线性函数的形式。这种线性假设往往限制性较强，在实践中可能并不成立。另一方面，CoMDS 不假设$g_s(\cdot)$ 具有线性形式，而是旨在保留源理想点空间与共识理想点空间中样本之间的成对距离。这种保持距离的性质使 CoMDS 更灵活，能够捕捉 $g_s(\cdot)$ 中可能存在的非线性关系。

为了说明这种处理非线性的能力，我们使用同一组底层二维理想点估计 $\mathbf{Z}^*$，模拟两个数据源 $Y^{(1)}$ and$Y^{(2)}$：一个采用线性 $g_s(\cdot)$，另一个采用非线性 $g_s(\cdot)$。具体而言，我们从二维均匀分布中抽取 $n = 500$ 个样本，模拟真实的共识理想点估计 $\mathbf{Z}^*$。随后，我们令第一个数据源 $Y^{(1)} = \mathbf{Z}^* \in \mathbf{R}^{500\times 2}$（即 $g_s(\cdot)$是恒等函数），并令第二个数据源 $Y^{(2)} \in \mathbf{R}^{500\times 3}$ 为 $\mathbf{Z}^*$经非线性“瑞士卷”变换后的结果（Tenenbaum 等，2000）[12]。这两个模拟数据源如图 B1A-B 所示。

[11]MD2S 的矩阵分解模型与 JIVE（Locket al. 2013）的模型等价。JIVE 是一种在生物医学文献中广受欢迎的数据整合方法。MD2S 仅被用于整合两个数据集，而 JIVE 则提供了通用的公式和软件，可用于整合任意数量的数据集。因此，在本文所有实证比较中，我们都使用 JIVE 软件实现。[12]瑞士卷是一种常见的非线性变换示例，其中一个二维平面被“卷起”

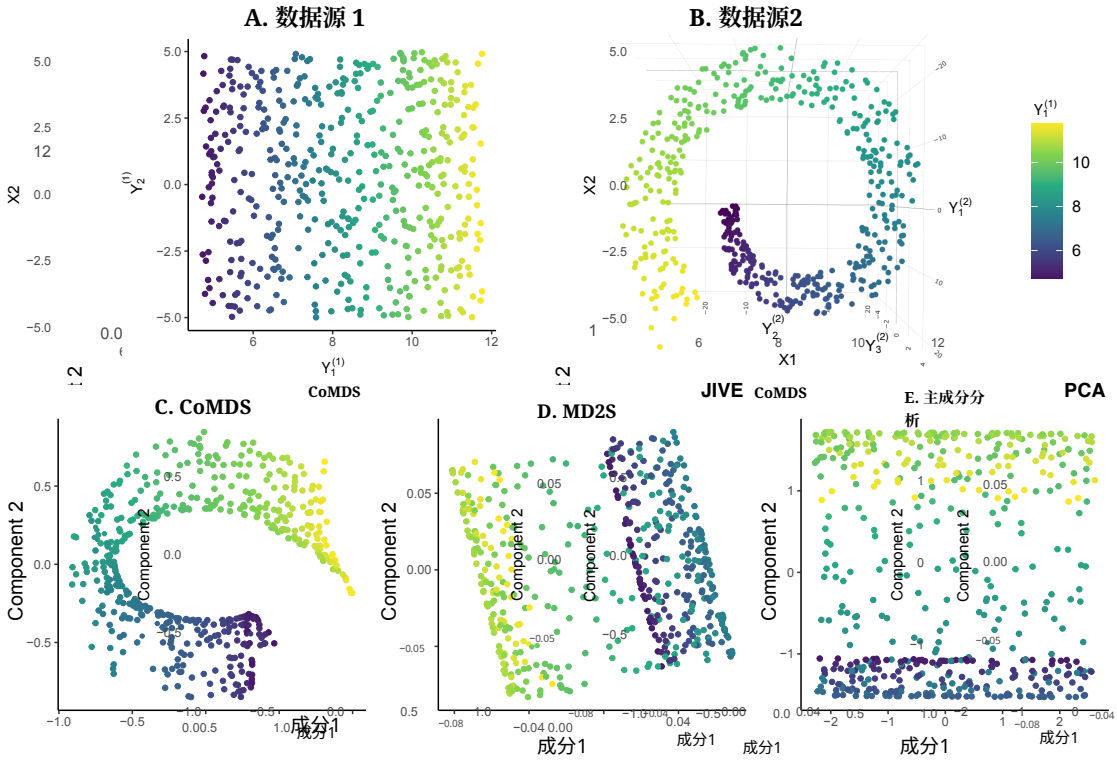

图 B1：(A) 我们从均匀分布中模拟得到一个数据源 $Y^{(1)} \in \mathbb{R}^{500\times 2}$。(B) 随后，我们对 $Y_{(1)}$ 应用非线性瑞士卷变换，得到第二个数据源 $Y^{(2)} \in \mathbb{R}^{500\times 3}$。(C-E) 分别对 $Y_{(1)}$ 和 $Y^{(2)}$ 应用 CoMDS、MD2S 和主成分分析后得到的共识图如下所示。基于线性的方法（如 MD2S 和主成分分析）会将瑞士卷结构“压平”，从而丢失理想点原有的排序。相比之下，CoMDS 会将瑞士卷“展开”，更准确地保留理想点的原始结构。

由于两个数据源 $Y^{(1)}$ 和 $Y_{(2)}$ 都是 $\mathbf{Z}^*$的直接（无噪声）函数，我们预计估计得到的共识理想点 $\mathbf{Z}^*$ 会与 $\mathbf{Z}^*$ 相似（这等同于$Y^{(1)}$ 图 B1A 中所示的结果）。然而，如图 B1D-E 所示，采用基于线性的方法（如 MD2S 和 PCA）无法保留理想点原有的顺序（从黄色到深紫色）。MD2S 和 PCA 都旨在对数据源进行线性投影，因此必须将瑞士卷结构“压平”，导致卷曲外缘（即亮黄色和深紫色区域）被压向共识空间的中心，而不是保留为瑞士卷的外缘。相比之下，CoMDS 不假设线性，而是着重保留成对距离。因此，图 B1C 所示的 CoMDS 共识图估计结果保留了从黄色到深紫色的优美渐变。

B.2 旋转不变性模拟

CoMDS 的另一项重要优势是其稳健性：对于来源理想点的平移、重新缩放和旋转，它具有不变性。由于理想点的数值在

在三维空间中卷曲成瑞士卷糕点的形状。

本质上是任意的，只有理想点之间的相对距离才容易解释，因此，对此类平移、重新缩放和旋转保持不变是一项理想的特性。换言之，如果来源理想点以任意方式进行平移、重新缩放或旋转，估计出的共识理想点不应发生变化。[13] 然而，像主成分分析（PCA）这类直接处理来源理想点原始数值的方法，对此类变换十分敏感，可能会因输入嵌入的方向或尺度调整不同而得出不同结果。

为了说明 CoMDS 的不变性，我们将重点探讨旋转不变性，并构建一个玩具模拟：首先，我们模拟真实底层共识理想点 $\mathbf{Z}^* \in \mathbb{R}^{100\times 2}$ ，其各个元素独立同分布，来自标准正态分布。接着，我们考虑以下两种假设情景：

1. 原始情景： 对两个未旋转的数据源 $Y^{(1)} = \mathbf{Z}^*$ 和 $Y_{(2)} = \mathbf{Z}^*$应用 CoMDS 或 PCA，估计共识理想点；

2. 旋转情景： 将其中一个数据源旋转 60 度后，对这两个数据源应用 CoMDS 或 PCA，估计共识理想点： $Y_{(1)} = \mathbf{Z}^*$ 和 $Y^{(2)} = \mathbf{Z}^*\mathbf{R}$，其中$\mathbf{R}$ 是一个二维旋转矩阵，可将理想点旋转 60 度。

由于$\mathbf{Z}^*\mathbf{R}$ 的实质含义和解释与未经旋转的 $\hat{}\mathbf{Z}^*$相同，因此我们希望从这两种假设情景中估计出的共识理想点$\mathbf{Z}^*$ 彼此等价。

在图 B2A 中，我们展示了估计得到的 CoMDS 共识理想点 $\mathbf{Z}^*$ 的第一和第二维度在原始（未旋转）情景与旋转情景之间保持不变（如完全相关所示）。这是预期结果，因为 CoMDS 优化问题（3）仅基于理想点之间的成对距离，而成对距离不会因原始理想点取值的平移和旋转而改变。如果进行了额外的重新缩放（尽管本次模拟中并未进行），来源特定权重 $\hat{}\mathbf{W}^{(1)}, \ldots, \hat{}\mathbf{W}^{(S)}$ 在（3）中将确保 CoMDS 对原始理想点取值的此类重新缩放保持不变。

相比之下，图B2B 显示，PCA 得到的前两个主成分（PC）会因来源理想点是否经过旋转而发生显著变化。这一点可从原始（未旋转）情景与旋转情景中主成分 1（或主成分 2）得分之间的低相关性看出。在这里，缺乏不变性从解释角度带来了一个难题——尽管两个假设情景中的输入源数据在实质上等价，但由此得到的共识主成分却不同，因此引发了疑问：哪一组共识主成分“更好”，以及哪一组应当用于进一步分析或解释。

B.3 不平衡且相关的来源模拟

按设计，CoMDS 专门用于识别所有来源理想点估计中共有的模式。这一设计与估计能够协调多个来源的共识理想点这一目标十分契合。通用降维

[13]重要的是，这些变换不会改变来源理想点的含义。

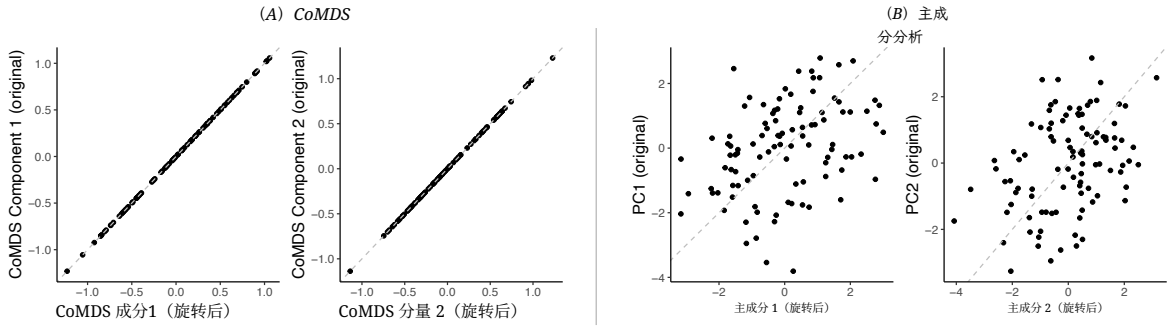

图 B2：旋转不变性模拟结果。(A) 散点图比较了原始（未旋转）情景（y 轴）与旋转情景（x 轴）下估计的 CoMDS 共识理想点。完全相关表明，CoMDS 不受来源理想点旋转的影响。(B) 散点图比较了原始（未旋转）情景（y 轴）与旋转情景（x 轴）下 PCA 得到的前两个主成分（PCs）。低相关性表明，PCA 对来源理想点的旋转较为敏感。

方法（如 PCA）则不一定旨在寻找此类共识结构。事实上，PCA 旨在找出使数据变异量最大化的模式。这些方差最大化模式往往具有特殊性（即特定于某个来源），并非存在于所有输入数据源中。

在实践中，方差最大化模式可能具有特异性且仅存在于单一数据源中的两种常见情形是：(i) 某个数据源拥有大量特征（或成分）；或 (ii) 某个数据源的特征（或成分）之间具有很高的相关性。在通过模拟说明这些情形之前，我们要强调，它们在理想点估计中具有实际意义。例如，在维度不平衡的情形下，研究者可能希望找出传统理想点估计（例如 NOMINATE 和 CF分数，维度为 1 或 2）与较新的嵌入（例如由大语言模型生成的嵌入，这类模型可以轻松输出包含数百个维度的潜在嵌入）之间的共识。此外，研究者可能希望纳入某种理想点估计方法的多个变体（例如纳入不同版本的 CF分数（Bonica 2014、2018年、2024年）），因为这些变体彼此之间已知具有很高的相关性。

维度不平衡模拟。 为了说明维度不平衡情形下主成分分析的局限性，我们模拟两个低维数据源 $Y_{(1)}Y_{(2)} \in \mathbb{R}^{300\times 2}$和一个高维数据源 $Y^{(3)} \in \mathbb{R}^{300\times p}$，如下所示：

$$
\begin{aligned}
Y^{(1)} &= \mathbf{Z}^{*}\mathbf{D}^{(1)} + \varepsilon^{(1)} \\
Y^{(2)} &= \mathbf{Z}^{*}\mathbf{D}^{(2)} + \varepsilon^{(2)} \\
Y^{(3)} &= [\mathbf{Z}^{*}, \mathbf{Z}^{(3)}]\mathbf{D}^{(3)} + \varepsilon^{(3)},
\end{aligned}
$$

其中$\mathbf{Z}^{*} \in \mathbb{R}^{300\times 2}$ 是一个标准正态矩阵，用于编码真实的共识结构；$\mathbf{Z}^{(3)} \in \mathbb{R}^{300\times_{(p-2)}}$ 是一个标准正态矩阵，用于捕捉第三个

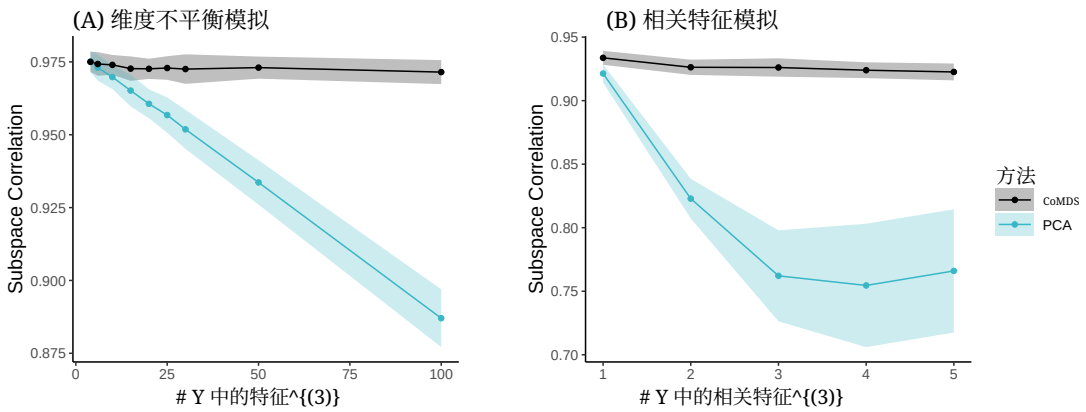

图 B3： 真实共识理想点 $\mathbf{Z}^*$ 与估计得到的共识理想点 $\mathbf{Z}^*$ （通过 CoMDS 或 PCA 得到）之间的子空间相关性度量，分别展示了（A）维度不平衡和（B）相关特征模拟中的结果。相关性越高，表示性能越好。在这些模拟设置下，CoMDS 能准确估计共识理想点；而随着维度不平衡程度加剧，或特异性数据源内部的相关性增强，PCA 的性能会下降。线条表示对 100 次模拟重复的测量子空间相关性取平均后的结果，阴影区域表示 $\pm 1SE$。

数据源中的特异性； $\varepsilon_{ij}^{(s)} \overset{iid}{\sim} N(0, \sigma^2)$ 是加性噪声项，其中 σ 取为$\mathbf{Z}^*$标准差的一半；而$\mathbf{D}^{(1)}$、$\mathbf{D}^{(2)}$和$\mathbf{D}^{(3)}$ 是对角矩阵，用于控制每个数据源中共识成分和特异性成分的强度。具体而言，我们设定$\mathbf{D}^{(1)} = \mathbf{D}^{(2)} = \text{diag}\{4, 2\} \in \mathbb{R}^{2\times 2}$ 和$\mathbf{D}^{(3)} = \text{diag}\{1.5, 1.5, 4, 2, 1, ..., 1\} \in \mathbb{R}^{p\times p}$，使得第三个（高维）数据源中的特异性信号占主导地位。为评估维度不平衡的影响，我们将第三个数据源中的维度数 p 从 $p = 4$ 变化到 100，并对每种模拟重复进行 100 次实验。

在图 B3中，我们绘制了真实共识理想点所诱导的子空间与估计得到的共识理想点 $\mathbf{Z}^*$ 所诱导的子空间之间的相关性 $\mathbf{Z}^*$ （通过 CoMDS 或 PCA 得到）；相关性越高，表示性能越好。更具体地说，我们将子空间相关性定义为真实共识子空间与估计共识子空间之间交叉乘积矩阵的奇异值平方的平均值（Bj¨orck 和 Golub 1973）。直观而言，如果真实共识子空间与估计共识子空间对齐良好，那么子空间相关性将接近 1。如图 B3A 所示，随着维度数量 p 增加，PCA 的性能会下降，而 CoMDS 能避免这一问题，并准确估计共识理想点 $\mathbf{Z}^*$，即使维度不平衡程度不断加剧。

相关特征模拟。 为说明在相关特征设定下主成分分析的缺陷，我们模拟两个具有独立特征的数据源 $Y_{(1)}Y_{(2)} \in \mathbb{R}^{300\times p}$

以及一个具有相关特征的数据源 $Y^{(3)} \in \mathbb{R}^{300\times p}$，如下所示：

$$
\begin{aligned}
Y^{(1)} &= [\mathbf{Z}^*, \mathbf{Z}^{(1)}]\mathbf{D}^{(1)} + \varepsilon^{(1)} \\
Y^{(2)} &= [\mathbf{Z}^*, \mathbf{Z}^{(2)}]\mathbf{D}^{(2)} + \varepsilon^{(2)} \\
Y^{(3)} &= (\sqrt{1-\omega}\,\mathbf{Z}^* + \sqrt{\omega}\,\mathbf{Z}^{(3)})\mathbf{1}_p^\top \mathbf{D}^{(3)} + \varepsilon^{(3)},
\end{aligned}
$$

其中，$\mathbf{Z}^* \in \mathbf{R}^{300\times 1}$ 是一个标准正态矩阵，用于编码真实的共识结构；$\mathbf{Z}^{(1)}$、$^{(2)} \in \mathbf{R}^{300\times(p-1)}$ 和 $\mathbf{Z}^{(3)} \in \mathbf{R}^{300\times 1}$ 是标准正态矩阵，用于捕捉各数据源中的特异性成分；$\mathbf{D}^{(1)} = \mathbf{D}^{(2)} = \text{diag}\{1, \frac{0.2}{p-1}, \ldots, \frac{0.2}{p-1}\} \in \mathbf{R}^{p\times p}$是对角矩阵，用于控制第一和第二个数据源中共识成分与特异性成分的强度；$\mathbf{D}^{(3)} = \text{diag}\{\frac{1.2}{p}, \ldots, \frac{1.2}{p}\} \in \mathbf{R}^{p\times p}$，使得 Y(3)中的信噪比与 $Y^{(1)}$ 和 Y(2)中的信噪比相近； ω 控制第三个数据源中特异性成分的权重；而 $\varepsilon_{ij}^{(s)} \overset{iid}{\sim} N(0, \sigma^2)$是加性噪声项，其中$\sigma$ 取为$\mathbf{Z}^*$的标准差的一半。为评估相关特征的影响，我们设定 $\omega = 0.9$，通过将p 从 $p = 1$、.....变化至5来改变第三个数据源中的相关程度，并对每次模拟进行100次重复实验。

如图 B3B 所示，随着第三个数据源中的相关性增强，PCA 估计共识理想点的表现会 $\mathbf{Z}^*$ 逐渐变差。这是因为 PCA 旨在找出数据中方差最大的模式，而在这种情况下，这些模式主要由第三个数据源中特有或个体化的相关特征所主导。相比之下，即使第三个数据源中的相关性增强，CoMDS 仍能有效地学习潜在的共识理想点$\mathbf{Z}^*$ 。

B.4 缺失数据

CoMDS 最后一项重要的实际优势是，即使某些来源理想点缺失，它仍然可以应用。此外，应用 CoMDS 时无需选择、使用和执行缺失数据插补方法。相反，在存在缺失值的情况下，CoMDS 优化问题（3）中涉及缺失来源理想点的项会被赋予零权重（通过缺失权重 $\alpha_i^{(s)}$ ），因此在估计过程中实际上会被忽略。为了更好地了解存在缺失数据时 CoMDS 估计值的变化，我们提供了一个示例：我们取第4节中使用的 NOMINATE、CF 和竞选纲领理想点数据，仅保留来自全部三个数据源的观测值，并比较使用完整（无缺失）数据与随机缺失一定比例（即 1、5、10、20%）理想点数据时估计得到的 CoMDS 共识理想点。

图 B4 显示，使用完整数据估计的 CoMDS 共识理想点（y 轴）与假设来源理想点中随机有一定比例缺失时估计的 CoMDS 共识理想点（x 轴）高度相关。仅考察数据完整的样本时，这种相关性几乎完美，而且 > 0.98 仅考察存在缺失值的样本时也是如此。这种高度一致性表明，无论我们观测到的是完整数据，还是部分来源理想点随机缺失，CoMDS 共识理想点都相似（或稳定）。

不过，估计的共识理想点仍然存在一些变化，尽管总体而言变化幅度较小

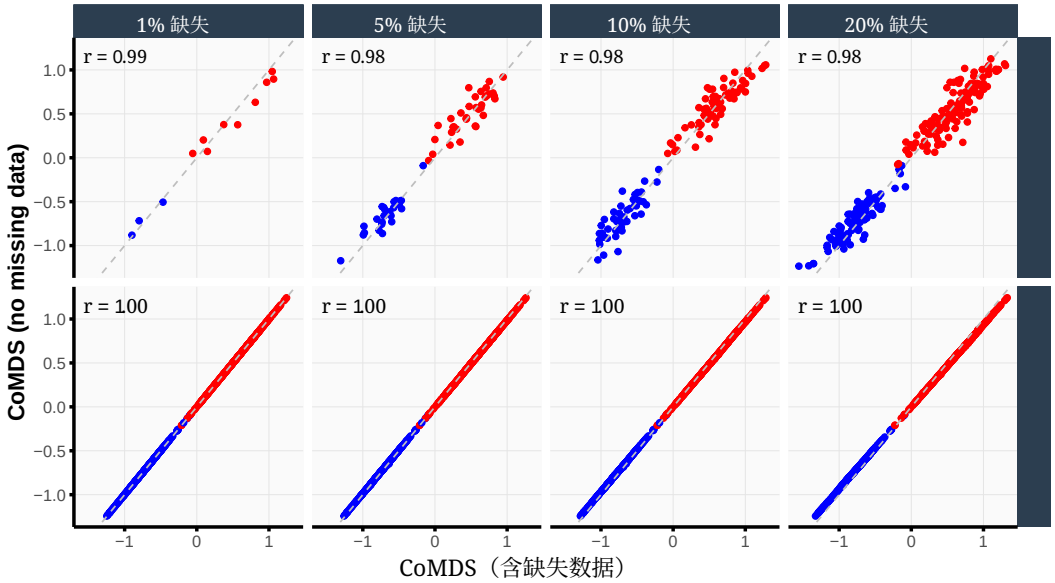

图B4： 比较CoMDS使用完整（无缺失）数据（纵轴）与使用随机缺失一定比例理想点的数据（横轴）所得到的共识理想点估计。含缺失值的样本显示在第一行，而完全观测到数据的样本显示在第二行；每一列展示不同缺失比例下的结果。较高的相关性表明，无论我们观测到的是完整数据，还是部分来源理想点随机缺失，CoMDS都能给出相似的共识理想点估计。

当样本存在缺失来源值时。为了直观了解缺失数据如何改变估计的共识理想点，我们进一步考察了图B5 和表B1中 10% 缺失情况下存在缺失值的候选人。首先从图B5开始，横轴表示候选人的共识理想点估计值排名的变化，即存在缺失情况时候选人的共识理想点估计值排名减去使用完整数据时候选人的共识理想点估计值排名，其中排名 1 表示最自由派的候选人，而排名 N 表示最保守的候选人。该横轴实质上反映了：当缺失该候选人的一个理想点来源时，其共识理想点是变得更加自由派（负值），还是更加保守（正值）。纵轴表示候选人的缺失理想点值与其所属政党的平均理想点值之间的差异。该纵轴反映了候选人的缺失理想点相较于其政党中的典型候选人是更加自由派（负值），还是更加保守（正值）。图B5 的关键结论是：通常情况下，当缺失的理想点值相较于平均值显得更加保守（或自由派）时，排除这一理想点将导致候选人的共识理想点估计值变得更加自由派（或保守）。反之，当缺失的理想点值相较于平均值显得更加保守（或自由派）时，通常将这一理想点纳入 CoMDS 估计会使候选人的共识理想点估计值向更加保守（或自由派）的方向移动，这正如预期。

此外，在表格B1中，我们从图B5中突出显示了几位具有代表性的候选人

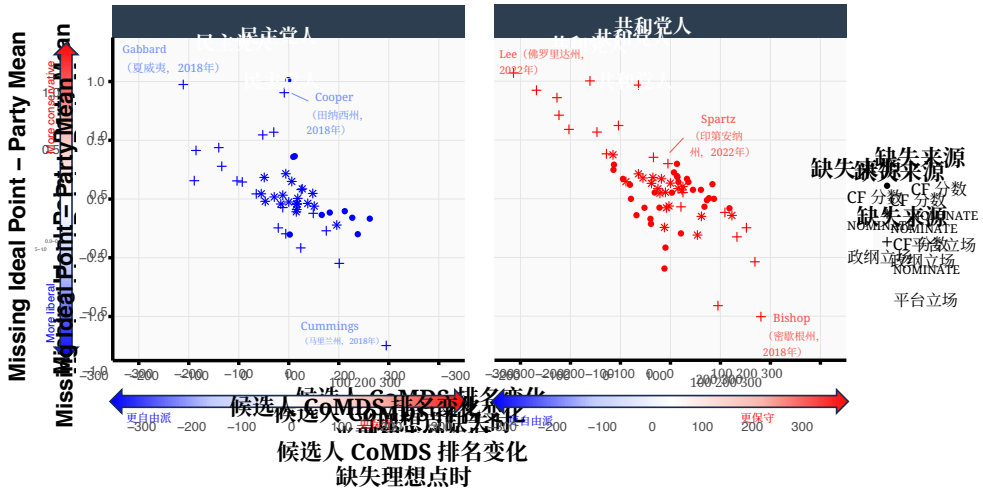

图 B5：缺失数据插补的稳定性

候选人	NOMINATE 百分位数	CF 分数 百分位数	政纲 百分位数	当缺失 政纲立场时，候选人的理想点看起来……
Gabbard（民主党，夏威夷，2018年）	79	63	98	更自由派
Cooper（民主党，田纳西州，2018年）	97	95	97	没有变化
Cummings（D，马里兰州，2020年）	28	65	1	更保守
Lee（R，佛罗里达州，2022年）	25	32	97	更自由派
Spartz（R，印第安纳州，2022年）	44	89	67	无变化
Bishop（共和党，密歇根州，2018年）	37	31	8	更保守

表B1

并列出他们的 NOMINATE、CF 和政纲理想点的百分位排名。百分位排名越高，表示理想点倾向于越保守；百分位排名越低，则表示理想点倾向于越自由派。所列出的每位候选人都缺少政纲理想点，而这也正如人们直觉上所料：

- 政纲理想点比其观测到的 NOMINATE 和 CF 分数更保守的候选人（如 Gabbard 和 Lee），在缺失政纲理想点时，其理想点显得更加自由派。

- 政纲理想点与其观测到的 NOMINATE 和 CF 分数相似或居中的候选人（如 Cooper 和 Spartz），在缺失政纲理想点时，其理想点仍保持相似。

- 对于其政纲理想点看起来比其观测到的 NOMINATE 和 CF 分数更自由的候选人（例如 Cummings 和 Bishop），当其政纲理想点缺失时，其理想点看起来反而更保守。

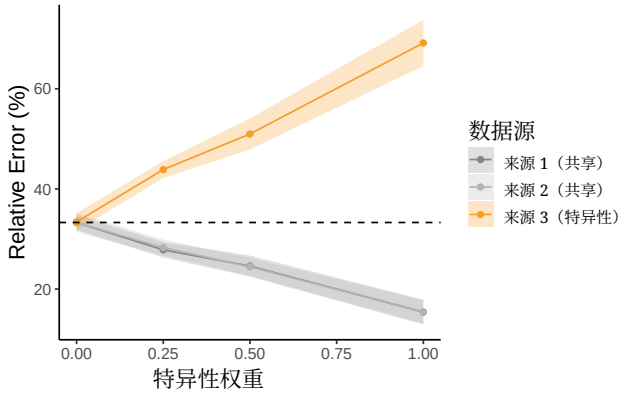

图 C1： 随着第三个数据源中的特异性强度 ω 变化，各数据源的相对误差 $Y^{(3)}$。不存在特异性时，每个数据源对总平方误差损失的贡献相同，且相对误差也相同。随着特异性强度增加，第三个数据源的相对误差增大，而前两个数据源的相对误差减小。

C 关于 CoMDS 诊断的补充讨论

如第 3.3 节所述，对于给定的来源 s，相对误差诊断测量 s^{th} 源理想点空间中的成对距离与估计的共识理想点空间中的成对距离之间的平方误差，并将其置于所有 S 来源的总平方误差之中。一般而言，该诊断测量来源理想点估计与共识理想点估计的相似程度，相对误差越大，表示不相似度越高。具体而言，20%的相对误差表示，所有来源的总平方误差损失中，有20%归因于该 s^{th} 来源。

为了进一步直观地说明如何解读相对误差诊断指标，我们进行了一项简短的模拟研究，展示随着来源理想点中特异性信号强度的变化，相对误差诊断指标会如何变化。具体而言，我们通过以下方式模拟三个数据源 $Y_{(1)}Y_{(2)}\,Y_{(3)} \in \mathbb{R}^{300\times 2}$：

$$
\begin{aligned}
Y^{(1)} &= \mathbf{Z}^* + \varepsilon^{(1)} \\
Y^{(2)} &= \mathbf{Z}^* + \varepsilon^{(2)} \\
Y^{(3)} &= \sqrt{1-\omega}\;\mathbf{Z}^* + \sqrt{\omega}\mathbf{Z}^{(3)} + \varepsilon^{(3)},
\end{aligned}
$$

其中，$\mathbf{Z}^* \in \mathbb{R}^{300\times 2}$ 是一个经过正交化（采用 Gram-Schmidt 过程）的标准正态矩阵，用于编码真实的共识结构；$\mathbf{Z}^{(3)} \in \mathbb{R}^{300\times 2}$ 是一个经过正交化的标准正态矩阵，用于编码第三个数据源中的特异性成分；$\varepsilon_{ij}^{(s)} \overset{iid}{\sim} N(0, \sigma^2)$ 是加性噪声项，其中 σ 取为$\mathbf{Z}^*$标准差的一半；ω 则控制第三个数据源中特异性信号的强度。从宏观上看，前两个数据源 $Y^{(1)}$ 和 $Y_{(2)}$ 仅包含共识信息，不含特异性成分；而第三个数据源 $Y^{(3)}$ 则是共识成分与特异性成分的加权组合。

在图 C1 中，我们总结了随着 ω 变化时各来源的相对误差，即 $Y^{(3)}$ 中特异性成分的强度。不出所料，当 $Y_{(3)}$ 中不存在特异性信号时（即 $\omega = 0$），所有

三个数据源都只包含共识信息，因此三个来源的相对误差相等。换言之，每个来源对平方误差损失总量的贡献相等（即 $1/3 = 33.3\%$），而共识理想点估计与各来源的理想点估计完全一致，或与它们的相似程度相同。

随着 $Y^{(3)}$ 中由 ω 控制的特异性信号增强，第三个来源 $Y_{(3)}$ 的相对误差增加，而前两个来源 $Y^{(1)}$ 和 $Y_{(2)}$的相对误差则降低。也就是说，随着 ω 增大，估计得到的 CoMDS 共识理想点与第三个来源 $Y^{(3)}$ 的差异越来越大。这是符合直觉的，因为更大的 ω 意味着 $Y^{(3)}$ 中的特异性信号更强，因此其与真实底层共识理想点$\mathbf{Z}^*$ 的相似度更低。

D 候选人定位应用的诊断与稳定性分析

为补充第 4 节中的候选人位置研究，我们报告建议采用的 CoMDS 诊断指标（见第 3.3 节），并进行全面的稳定性分析（Yu 和 Kumbier（2020）），以确保所呈现的发现稳定，并且能够经受其他同样合理的分析选择。候选人定位分析中的关键选择包括：(i) 在 CoMDS 估计中纳入哪些主要数据源；(ii) 仅纳入 NOMINATE 的第一维，还是纳入其两个维度；(iii) 使用经典 CF 分数，还是更复杂的 CF 分数变体；以及 (iv) 是否排除缺失来源理想点估计的候选人。下文将评估这些选择如何影响 CoMDS 估计得到的共识理想点，并最终证明第 4 节所示的共识理想点估计在这些不同的建模选择下稳定且稳健。重要的是，这种稳定性的证明有助于提高实质性发现的可靠性和有效性。

CoMDS 诊断。 如第3.3节所建议的，我们进行留一分析，并评估在每次依次留出一个数据源时，估计的共识理想点（基于无缺失情况的候选人拟合）的稳定性。图 D1 比较了包含三类输入来源（即 NOMINATE、三个 CF 分数和政纲立场）的 CoMDS 共识理想点（纵轴）与每次留出一种来源类型后重新估计的 CoMDS 共识理想点（横轴）。我们观察到，与留出 NOMINATE 或三个 CF 分数相比，留出政纲立场时，原始共识理想点与重新估计的共识理想点之间的相关性略低（尽管仍然非常高）。这表明，政纲立场提供了一些独特信息，而仅考虑 NOMINATE 和 CF 分数时可能会忽略这些信息。

与此同时，图D2 中的相对误差诊断表明，通过 CoMDS 同时分析政纲立场、NOMINATE 和 CF 分数时，在三种数据源理想点类型中，政纲立场的相对误差最低。这表明，所有来源测量指标中的共享信息与政纲立场的相似程度高于与 NOMINATE 或 CF 分数的相似程度；反过来说，与共享成分正交的剩余特异性变异，在政纲立场中的量

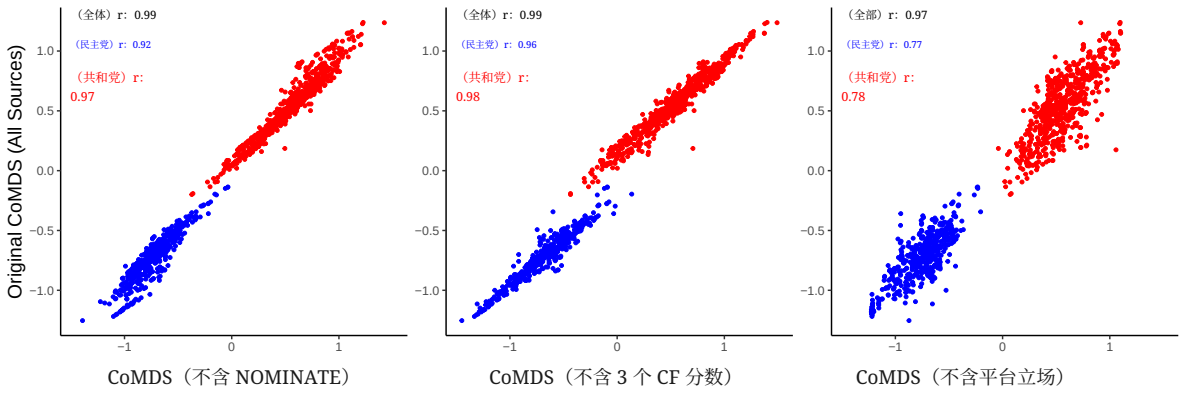

图 D1：留一稳定性分析。我们比较原始 CoMDS 共识理想点（纵轴）与逐一排除各来源类型后重新估计的 CoMDS 共识理想点（横轴）。较高的相关性表明，估计得到的共识理想点稳定可靠，不受排除任何单一来源类型的影响。

相较于 CF 分数和 NOMINATE，政纲立场中的特异性变异更少。综合来看，这些诊断表明，尽管政纲立场提供了 NOMINATE 或 CF 分数未能完全捕捉的独特信息，但它们与共识理想点所捕捉的共享成分密切一致。

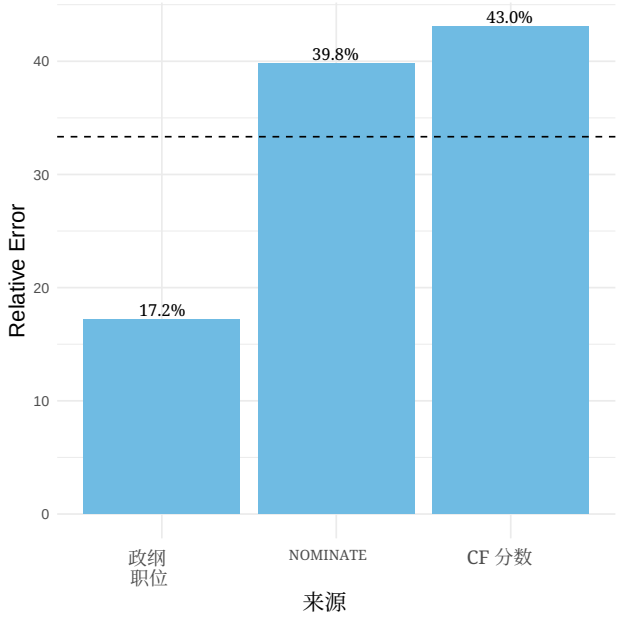

图 D2：相对误差诊断

其他建模选择的稳定性。除了输入来源的选择之外，我们还进一步评估了 CoMDS 共识理想点估计在其他建模选择下的稳定性。具体而言，虽然我们在最初的 CoMDS 分析中选择同时使用 NOMINATE 的两个成分和三种 CF 分数变体

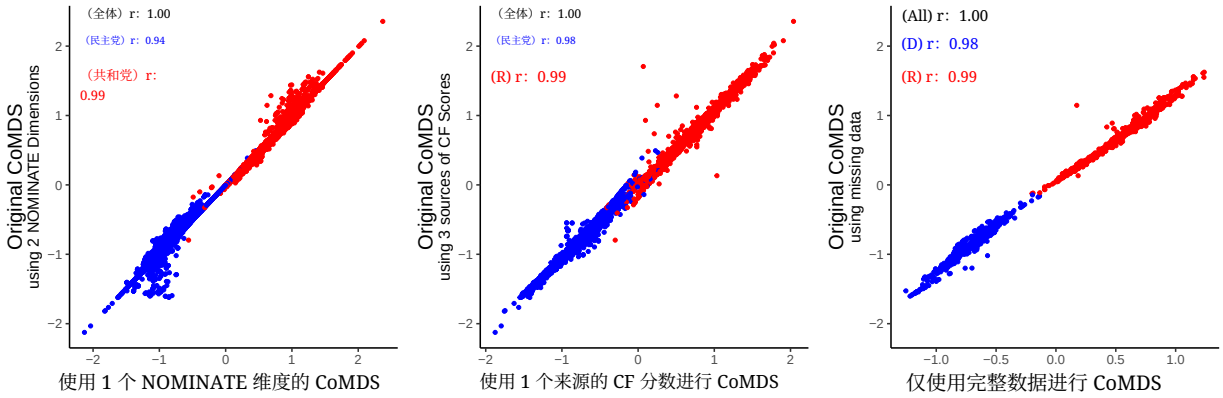

图 D3：不同建模选择下的稳定性。我们比较原始 CoMDS 共识理想点（纵轴）与重新估计的 CoMDS 共识理想点，后者分别仅使用第一个 NOMINATE 成分（左）、一种来源的 CF 分数（中），以及仅纳入所有来源数据均完整的候选人（右）。较高的相关性表明，估计得到的共识理想点具有稳定性，不易受这些不同建模选择的影响。

的[14]（即经典 CF 分数、动态变体和 DW-DIME（Bonica 2014、2018年、2024年）），我们本可以只使用 NOMINATE 的第一个成分，或仅纳入经典版 CF 分数。图 D3 左侧两个面板显示，这些替代建模选择得出的共识理想点估计非常相似，这一点可由较高的相关性看出。图 D3最右侧的面板比较了两种情况下的共识理想点估计：一种是 CoMDS 仅使用拥有完整数据（即没有缺失来源理想点）的候选人子集进行估计；另一种是使用至少拥有三种来源中的两种数据的更大候选人集合进行估计（正如主要分析所采用的做法）。与前面的结果类似，这一比较显示相关性很高，表明这一选择不会显著改变估计出的共识理想点。

不同缺失数据插补选择下的稳定性。回顾一下，在纳入可能缺失来源理想点的候选人的分析中，我们应用了 CoMDS，但没有对缺失值进行插补，因为 CoMDS 可以通过将其缺失权重设置为 $\alpha_i^{(s)}$ 零来D4自然处理缺失数据。在图D4中，我们将这些 CoMDS 共识理想点估计与以下结果进行比较：先使用各种数据插补方法对缺失的来源理想点进行插补，再将 CoMDS 应用于该插补后的数据集。由于不同的插补方法通常会对数据生成过程和缺失机制施加不同的假设，我们考察了实践中广泛使用的三种插补方法：使用 `missForest` (Stekhoven 和 B¨uhlmann 2012年) 的基于随机森林的插补、链式方程多重插补（MICE）（Van Buuren 和 Groothuis-Oudshoorn 2011年）以及 Amelia（Honaker 等，2011年）。从图D4可以看出，无论选择哪种插补方法，CoMDS（不进行插补）得到的共识理想点估计都与对缺失值进行插补后得到的 CoMDS 估计高度相关，不过与基于随机森林的插补结果之间的相关性最高。

[14]每种来源的 CF 分数均赋予 $\frac{1}{3}$ 权重，以免相较于 NOMINATE 和政纲立场过度强调 CF 分数。

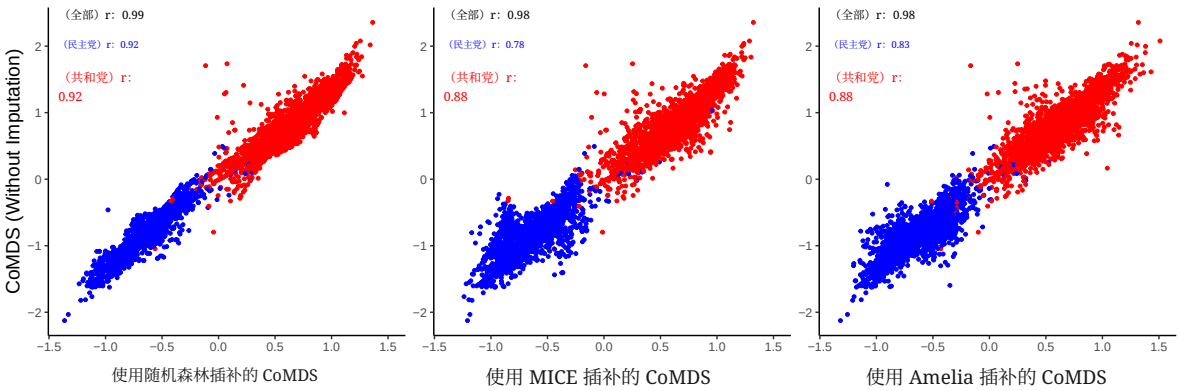

图 D4： 未进行插补的原始 CoMDS 共识理想点（纵轴）与采用基于随机森林的插补方法「MissForest」（左）、MICE 插补（中）和 Amelia 插补（右）进行缺失数据插补后的 CoMDS 估计值（横轴）之间的稳定性。相关性较高表明，估计得到的共识理想点对于缺失数据的处理方式具有稳定性和稳健性。

我们还在图D5中展示了使用不同数据插补方法，或使用同一数据插补方法的不同运行结果时，CoMDS 共识理想点估计之间的相关性。有趣的是，使用同一插补方法但进行不同随机抽样时观察到的 CoMDS 估计之间的相关性（图D5）往往低于未进行插补的 CoMDS 与采用不同插补方法的 CoMDS 之间的相关性（图D4）。这说明数据插补方法往往会给分析引入更多不稳定性，从而使实质性解释变得复杂。此外，这也凸显了 CoMDS 能够自然处理缺失值的优势，无需在数据预处理过程中增加插补步骤。

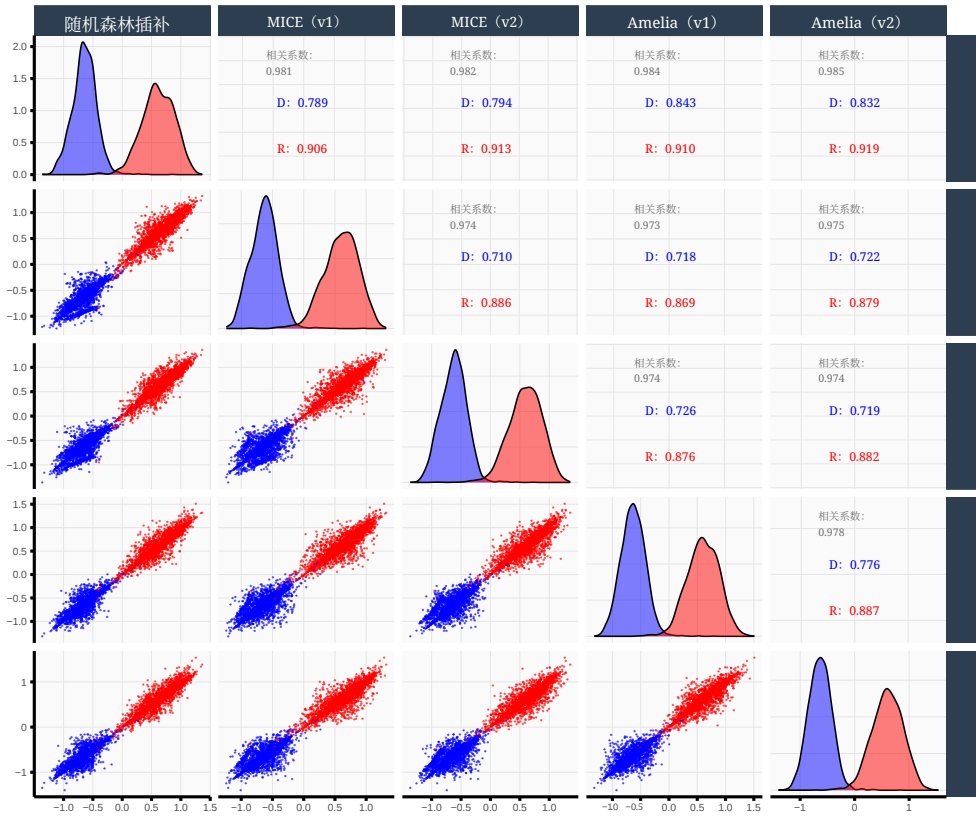

图 D5：使用不同缺失数据插补方法时 CoMDS 理想点估计的稳定性：基于随机森林的插补方法 'MissForest'，从 MICE 插补中随机抽取的两个样本（标记为 v1 和 v2），以及从 Amelia 插补中随机抽取的两个样本（标记为 v1 和 v2）。

E 候选人政治定位的补充分析

为补充论文中报告的实质性结果，我们在此呈现其他分析。这些分析可能会因其他可能的样本选取、聚合方法或建模选择而值得关注。具体而言，我们将 CoMDS 对众议院候选人理想点的估计，与采用替代聚合方法得到的估计进行比较；将样本限制为完整案例（即来源测量指标均无缺失）；并评估仅基于三种主要来源测量指标变体（即 NOMINATE 第一维度、经典 CF 分数和竞选纲领立场）得到的 CoMDS 估计。

E.1 与替代方法的比较

如附录A.1 和B所述，与 CoMDS 最密切相关的聚合方法是 MD2S 和主成分分析（PCA），不过在我们的具体应用中，这三种方法之间的关键差异都非常重要。为了评估这些方法在实际应用于我们的实质性研究情境时有何不同，我们使用相同的数据来源重新缩放候选人的聚合理想点，唯一的区别是采用 MD2S 或 PCA，而非 CoMDS。图E.1 绘制了基于 CoMDS 的理想点与替代理想点之间的关系。与 CoMDS 不同，MD2S 和 PCA 无法直接处理缺失情况，因此我们分别采用随机森林插补[15] 和贝叶斯主成分分析；同时也展示完整案例之间的关系，因为在完整案例中，处理缺失情况的差异对相关性降低的影响应该较小。

图 E.1 显示，CoMDS 得出的估计值与替代聚合方法得出的估计值之间存在较强但并不完美的相关性。即使在政党内部，大多数相关性仍远高于 0.5。结果表明，至少在我们的应用和样本中，贝叶斯主成分分析得出的估计值比 MD2S 得出的估计值更接近 CoMDS。估计值之间的相关性并不完美，部分原因可能是替代方法隐含地对相关的来源测量指标赋予了过高权重；此外，这些方法的插补方式也会影响底层空间，而原本在该空间中进行缩放的完整案例子集也会受此影响。

尽管这些结果展示了在底层数据来源保持不变的情况下，采用不同方法得出的众议院候选人理想点估计之间的关系，但我们也发现了一种现成的综合测量指标，对于应用研究者而言，它是一个颇具吸引力的替代方案：Bonica (2024年)。这种方法对多种唱名表决和捐款类指标进行 Amelia 插补和主成分分析（PCA），因此，这类估计在源数据和方法两个维度上都与 CoMDS 得出的估计有所不同。鉴于综合得分所采用的源数据，表 E1 显示，在唱名表决和竞选捐款这两个领域的实质性分析中使用这些得分，所得结果分别与主要结果中报告的领域特定 NOMINATE 和 CF 分数高度相似，这并不令人意外。相反，综合得分与词汇多样性之间几乎没有关联，这与 DW-NOMINATE 和 CF 分数同词汇多样性之间缺乏显著关联的情况一致。

[15]为尽可能提高与 CoMDS 的相似度，我们选择了随机森林插补；图 D4 显示，这是使估计值最接近我们未进行插补的 CoMDS 方法所得结果的插补方法。

图 E1： CoMDS 与其他聚合方法估计的理想点之间的关系

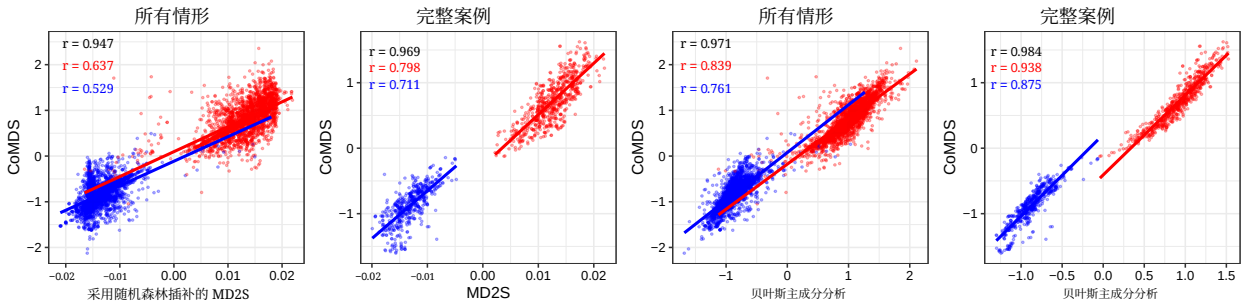

表 E1： Bonica 综合得分的主要结果

	唱名表决不忠		# 竞选捐赠者		词汇多样性	
	Dems	Reps	Dems	Reps	Dems	Reps
综合得分	0.793***	−0.737***	0.682***	−0.757***	−0.191	0.103
	(0.045)	(0.055)	(0.094)	(0.073)	(0.106)	(0.075)
观测值	1.208	1.345	2.628	2.759	1.835	1.993

* p < 0.05, ** p < 0.01, *** p < 0.001

E.2 仅纳入完整案例的稳健性

鉴于 CoMDS 能够直接处理缺失数据，基于共识理想点的主要分析纳入了候选人在三项主要来源测量指标中有两项非缺失估计值的案例。然而，如附录 B所详述，缺失情况会影响估计，影响程度取决于候选人缺失的来源估计与其非缺失来源估计之间的差异。此外，由于我们纳入的来源测量指标具有各自的特点，其目标总体存在系统性差异，因此每项指标的缺失情况都高度非随机。例如，NOMINATE 依赖国会唱名表决记录，因此排除了所有未能当选国会议员的候选人，而这些人与当选者存在系统性差异。在这里，我们针对完整案例子集重新进行所有分析，以评估共识理想点；该子集包括拥有竞选网站政纲的立法者。

图E2 显示，在这些完整案例中，来源测量估计值之间的相关性略高于主要分析所纳入的所有情形。相关性增幅最大的是 CF 分数与政纲立场之间的相关性；这并不太令人意外，因为这两种测量指标涵盖了大量非现任候选人，而这些候选人都因缺少 NOMINATE 分数而被排除在完整案例分析之外。完整案例（即拥有竞选纲领的候选人）中，NOMINATE 分数与 CF 分数之间的相关性仅略有上升；NOMINATE 分数与政纲立场之间的相关性则保持不变，因为所有同时拥有这两项数据的候选人也都有 CF 分数。此外，图E3 显示，完整案例中的共识理想点分布与主要样本所有情形中的分布相当相似，不过政党之间的重叠略少。

图 E2： 完整案例中各来源测量指标之间的相关性

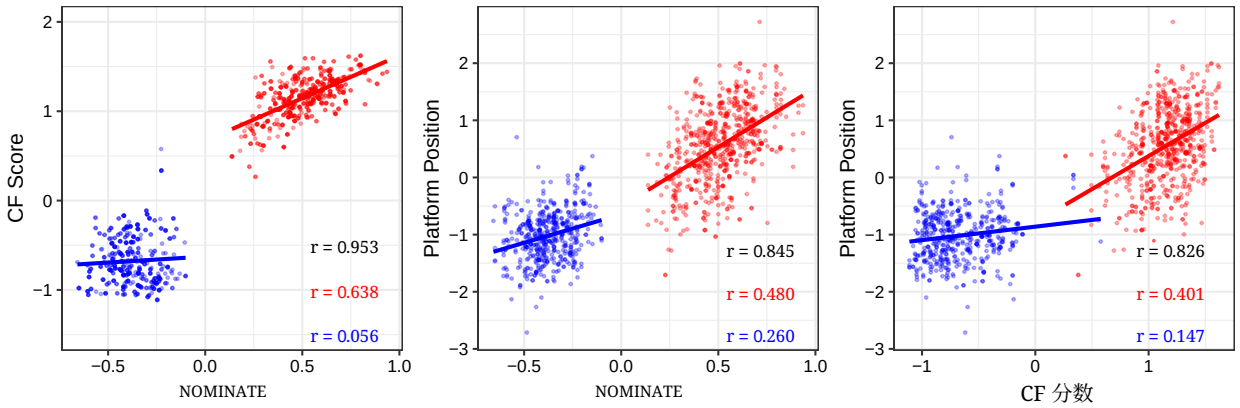

图 E3： 完整案例中的共识理想点分布

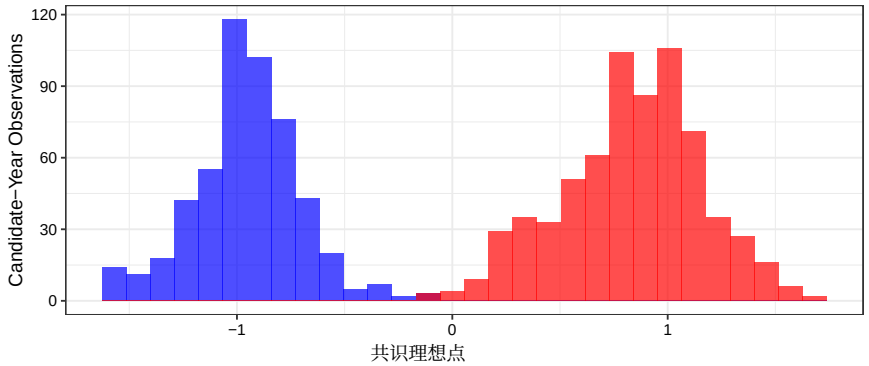

此外，图E4 显示，筛选出完整案例后，共识理想点与 CF 分数之间的相关性略有增强，而共识理想点与 NOMINATE 分数及政纲立场之间的相关性略有减弱。然而，在完整案例中，共识理想点与 NOMINATE 分数及政纲立场之间的关系仍强于其与 CF 分数之间的关系。这表明，与存在缺失情况的案例总体相比，完整案例总体中的共识理想点与其 CF 分数的关联更强；但无论在完整案例还是不完整案例中，共识理想点与另外两种测量指标的关联仍然更强。

表 E2 仅基于完整案例重新估计了共识理想点的主要实质性结果。对于民主党人和共和党人，完整案例中的唱名表决不忠估计在定性上相似，但数值较小，这表明在此情境下，领域特定测量指标可能被高估得更多。竞选捐赠者的结果表明，在完整案例中，共识理想点与财务基础之间几乎没有实质性关联。这与表 2 中基于来源测量指标报告的完整案例结果高度混杂的情况一致。最后，基于共识理想点的词汇多样性结果在完整案例中数值更小。总体而言，将实质性结果限定在完整案例中，表明领域特定估计如果说有变化的话，相较于共识理想点，

图 E4： 完整案例中来源与共识测量指标之间的关系 s

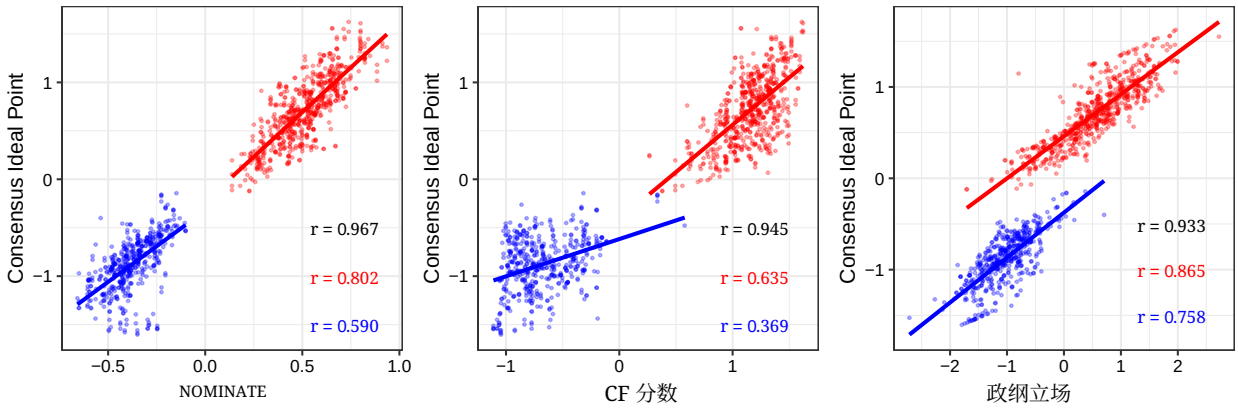

表 E2： 完整案例中的共识理想点结果

	唱名表决不忠		# 竞选捐助者		词汇多样性	
	Dems	Reps	Dems	Reps	Dems	Reps
共识	0。574***	−0.437***	0.002	−0.088	−0.023	−0.301*
	(0.050)	(0.044)	(0.080)	(0.056)	(0.208)	(0.141)
观测值	493	660	516	678	516	678

* p $<$ 0.05, ** p $<$ 0.01, *** p $<$ 0.001

则显得更加夸大。

E.3 对三项主要测量指标进行尺度调整的稳健性

在使用 CoMDS 对众议院候选人的立场进行尺度调整时，除了单维度的政纲立场外，我们还采用了 NOMINATE 的两个维度，以及 CF 分数的经典、动态和以 NOMINATE 为目标的变体。不过，学者通常关注 NOMINATE 的第一维度以及经典 CF 分数。在此，我们仅使用这三项主要测量指标重新估计候选人的理想点，并使用基于这三项测量指标的估计值复现所有实质性结果。图 E5 表明，基于三项主要测量指标得到的共识理想点分布，与基于原始测量指标集合得到的分布相对相似；不同之处在于，民主党人的共识理想点分布略显集中。同样，图E6确认，无论使用三项主要来源测量指标还是原始来源测量指标集合，各项来源测量指标与共识理想点之间的关系看起来都相对相似。最后，表 E3 报告了使用三项主要来源测量指标估计的共识理想点所得出的实质性结果。总体而言，结论在定性上仍与包含其他来源测量指标变体的共识理想点所得出的结论相似；民主党人的词汇多样性结果除外，其结果基本上等同于最初使用政纲立场得到的结果。

图 E5：基于三项主要测量指标缩放的共识理想点分布

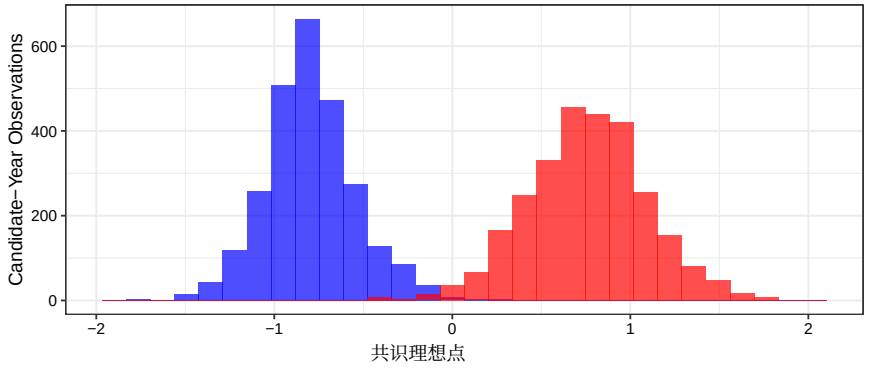

图E6：基于三项主要测量指标的来源与共识测量指标之间的关系

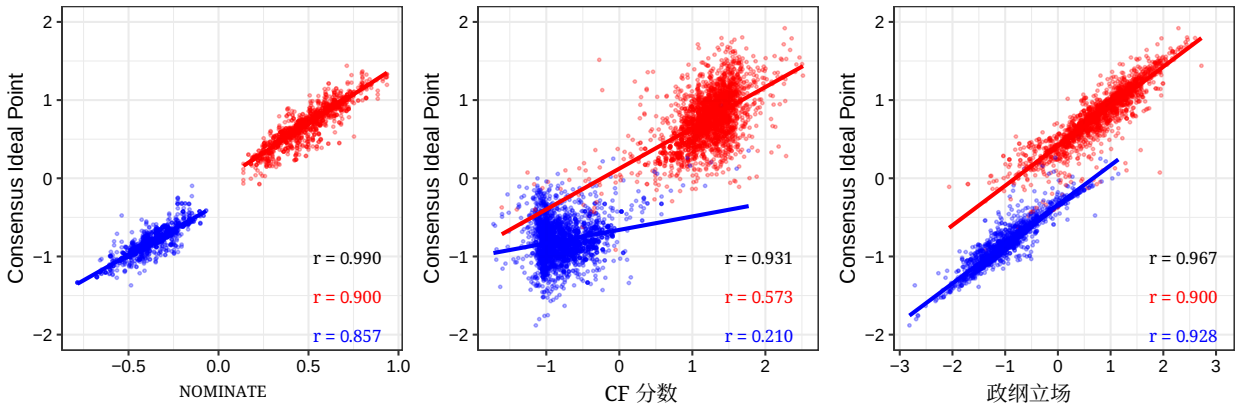

表 E3： 基于三项主要测量指标的共识理想点与实质性变量之间的关系

	党派不忠		# 竞选捐赠者		词汇多样性	
	Dems	Reps	Dems	Reps	Dems	Reps
共识	0。631***	−0.556***	−0.260***	−0.475***	0.478***	−0.538***
	(0。034)	(0.032)	(0.059)	(0.057)	(0。080)	(0。063)
观测值	1.206	1.340	2.629	2.760	1.836	1.994

* p < 0.05, ** p < 0.01, *** p < 0.001

E.4 补充分析

图 E7、E8和E9 展示了实质性分析所捕捉到的基本双变量关系的散点图，并按政党拟合了局部加权回归曲线。在所有情形中，似乎都存在明显的二次项。因此，在主分析和补充分析所报告的所有实质性回归中，我们都控制了相应理想点测量的平方项。

图 E7： 理想点与唱名表决中的党派不忠

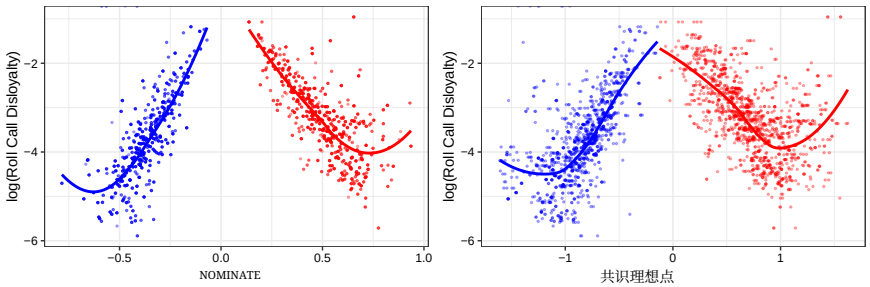

图 E8： 理想点与筹款成功

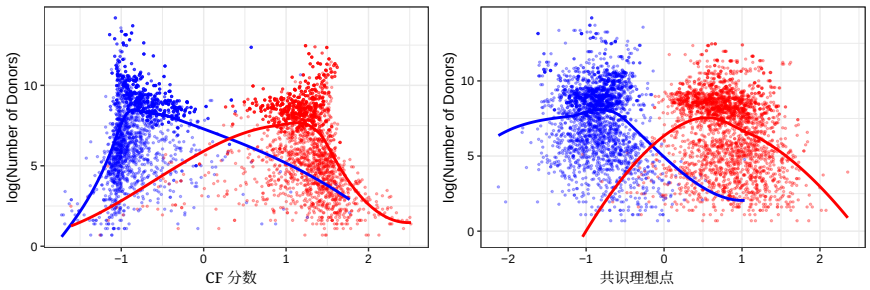

图 E9： 理想点与词汇多样性

