动物福利与政策风险指数（AWPRI）：构建并验证跨国治理风险测量指标，25个国家，2004–2022

Jason Hung

Futurekind AI 研究员，Electric Sheep

摘要

尽管动物福利治理持续受到技术进步和自动化的影响，但目前缺乏一种纵向、跨国的定量指数，能够同时体现治理基线、政策变化方向，以及采用农业人工智能（*AI*）所带来的累积风险。本文提出动物福利与政策风险指数（*AWPRI*），这是一项综合风险指数，涵盖*2004–2022*年间的*25*个国家（$N = 475$ 个国家—年份观测值）。*AWPRI*基于*15*个变量构建，这些变量分布在三个权重相等的概念层：当前福利状况（*L1*）、政策轨迹（*L2*）和人工智能放大风险（*L3*）。变量通过最小-最大标准化归一化为 $[0, 1]$，数值越高表示政策风险越大。我们通过*K*均值聚类分析（$k = 4$；轮廓系数 $= 0.447$）、对*15*变量截面的主成分分析（*PCA*），以及在 ± 10个百分点层级权重扰动下进行的敏感性分析（斯皮尔曼相关系数均值 $\rho = 0.993$，最低值*0.979*；调整兰德指数（*ARI*）均值 $= 0.684$，范围为*0.477–1.000*）对该指数进行了验证。豪斯曼设定检验支持采用随机效应（*RE*）面板估计（$H = 2.55$，$p = 0.467$）。我们采用双重差分（*DiD*）研究设计，利用*2019*年人工智能治理风险分类差异进行分析，发现被认定为人工智能治理高风险的国家，其*AWPRI*得分比低风险国家高*0.080*分；在控制国家和年份固定效应后，结果依然成立（$\beta = 0.080$，标准误 $= 0.005$，$p < 0.001$）。在*2022*年横截面中，*L3*层的平均得分最高（*0.552*，标准差 $= 0.175$），显著高于*L1*层（威尔科克森 $W = 102,651$，$p < 0.001$）和*L2*层（$W = 99{,}295$，$p < 0.001$）。*2022*年，中国（*0.802*）、越南（*0.612*）和泰国（*0.586*）的综合风险得分最高；英国（*0.308*）最低。基于自回归积分滑动平均（*ARIMA*）的预测表明，到*2030*年，泰国、巴西和阿根廷的*AWPRI*风险将恶化。*AWPRI*及其交互式可视化可通过*https://awpri-dashboard.streamlit.app*公开访问。

关键词：动物福利政策；人工智能；精准畜牧业；综合指数；治理差距；双重差分；面板数据

1. 引言

全球粮食系统每年屠宰约800亿只陆生动物 [1]。这一规模意味着，动物福利治理方面的制度性投入不足在实证层面具有重要意义，也与政策密切相关。比较政治学和公共政策领域的研究在发展跨国动物福利治理评估的定量框架方面进展缓慢。学术界对动物福利的讨论，主要由规范性或法律术语 [2, 3], 所主导，或局限于对特定监管制度 [4]的案例研究。目前缺乏一种纵向、跨国的定量工具，能够追踪动物福利治理随时间的表现、判断其变化轨迹是在改善还是恶化，并评估新兴技术力量是否会加剧既有的治理差距。

人工智能（AI）在畜牧生产中的快速商业化，使得讨论技术赋能的动物福利监管日益具有时效性和现实意义。用于自动化跛行检测的计算机视觉系统、人工智能驱动的饲料优化以及疾病预测建模，如今已在主要畜牧业经济体中实现商业化应用[7, 8]。精准畜牧业（PLF）领域的市场预测规模到2032 [9]年将达到198.7亿美元。相关文献认为，人工智能能够更早发现动物福利问题，并减少对侵入性干预的依赖 [10, 11]。另有文献提出了实质性担忧：精准畜牧业的动物福利改善主张在商业规模上仍未得到证实；对于监管框架并非为应对算法问责而设计的司法辖区而言，人工智能驱动的集约化还会对动物福利构成系统性威胁[12, 13]。

现有的动物福利治理综合指标，包括世界动物保护协会的动物保护指数[5] 和Hårstad的范围综述[3], , 均仅考察某一时间点的立法文本。这两种工具都未追踪法律执行动态、政策改革轨迹，也未考察技术应用对治理差距产生的叠加效应。本文通过提出并分析动物福利与政策风险指数（AWPRI），回应了上述局限。

1.1 研究问题与贡献

本文探讨三个研究问题。第一，如何将动物福利政策风险转化为可衡量、可跨国比较的综合指数，并使其能够反映农业中的人工智能应用所带来的治理影响？第二，2004年至2022年间，25个国家的风险分布、聚类和时间变化呈现出哪些模式？第三，农业中的人工智能应用如何与既有治理条件及变化轨迹相互作用？到2030年，预计会形成怎样的国家风险概况？

本文作出四项贡献。

1. 本文介绍 AWPRI：首个用于动物福利治理的纵向跨国人工智能敏感型综合风险指数，涵盖 25 个国家、19 年的数据。

2. 本文通过k均值聚类分析、主成分分析（PCA）、Hausman 设定检验，以及层权重扰动下的敏感性分析，对该指数进行验证。3. 本文采用双重差分（DiD）研究设计，估计人工智能治理风险分类差异对 AWPRI 变化轨迹的影响，提供首个将人工智能治理状态与动物福利政策风险联系起来的准实验性证据。4. 本文基于自回归积分滑动平均（ARIMA），对全部 25 个国家截至 2030年 的情况进行预测，并提供 95%置信区间，从而指出在缺乏政策干预的情况下，哪些国家风险概况预计会恶化。

2. 相关研究

2.1 动物福利治理与综合指数

综合指数是用于跨国家治理比较的成熟工具。人类发展指数 [15], 、环境绩效指数 [16], 和全球和平指数 [17] 表明，可以将多维治理状况转化为可测量的分数，同时保留其政策可解释性。在动物福利领域，Browning [18] 明确指出，多维福利衡量框架有助于开展政策分析。然而，迄今为止，尚无综合指数将此类框架应用于动物福利治理与人工智能应用的交叉领域。

世界动物保护协会的动物保护指数 [5] 在单一时间点对50个国家的立法能力进行评级。Hårstad 关于农场动物福利治理的范围综述 [3] 同样将重点放在立法文本和政治驱动因素上。他发现，政策变化既非线性的，也难以预测。这两种工具都未考虑执法动态、时间轨迹，或人工智能驱动的农业集约化所带来的风险。动物法律基金会 [6] 记录显示，2024年英格兰接受检查的农场不足2.5%，其中19%的受检农场被发现违反福利法律，而导致起诉的违规行为不足1%。这一执法缺口凸显了静态立法指数未能揭示的维度。

2.2 人工智能与精准畜牧业

Tuyttens 等人 [12] 指出，精准畜牧业（PLF）的应用会带来 12 种特定的动物福利威胁，包括算法取代人工观察、自动化监测促使牲畜饲养集约化，以及为实现生产力最大化而非改善动物福利，使用人工智能的商业激励。在基础福利立法薄弱的司法管辖区，这些问题会更加突出；在这些地区，人工智能应用可能加速生产集约化，却不会引发相应的监管响应 [14]。Elliott 和 Werkheiser [13] 认为，现有的精准畜牧业透明度框架在概念上仍不成熟，而且大多数人工智能农业系统都缺乏特定于动物福利的问责机制。AWPRI 的 L3 层专门用于量化这种治理与技术不对称所带来的累积风险。

2.3 治理测量的面板数据方法

固定效应（FE）和随机效应（RE）面板回归是利用治理指数跨国纵向差异的标准方法。Hausman [19] 设定检验是模型选择的传统判据。Hausman 统计量显著，表明国家特定效应与回归变量相关，因此应优先采用固定效应估计量；若结果不显著，则随机效应估计量有效且效率更高。双重差分设计已应用于治理研究，以识别政策干预的因果效应 [20]。我们的统计分析为动物福利治理文献提供了首项准实验性证据。

3. 方法

3.1 国家与时间范围

AWPRI面板数据集涵盖六大19=全球区域的25个国家，时间跨度为19年（2004–2022），共计（25x19=）475个国家—年份观测值。国家的选择旨在最大限度地体现区域多样性、数据可获得性以及福利立法能力的变化，同时纳入全球最大的畜牧业生产国、福利立法最先进的国家，以及农业人工智能应用迅速发展的主要新兴经济体。本研究涵盖的25个国家是：阿根廷、澳大利亚、巴西、加拿大、中国、丹麦、法国、德国、印度、意大利、日本、肯尼亚、墨西哥、荷兰、新西兰、尼日利亚、波兰、南非、韩国、西班牙、瑞典、泰国、英国、美国和越南。完整数据集可访问：https://awpri-dashboard.streamlit.app。本文报告的所有分析均使用面板_*awpri_normalized.csv*数据集；该数据集与AWPRI交互式仪表板用于数据可视化的数据源完全相同。

3.2 变量选择与操作化

15个变量分配在三个等权重的概念层中，每层包含5个变量。第1层（L1：当前福利状况）衡量治理基线，包括：（1）动物权利立法框架；（2）法治指数（风险编码）；（3）人均养殖动物；（4）水产养殖产量占比；以及（5）人均肉类消费量。第2层（L2：政策轨迹）体现治理变化的方向和速度，包括：（6）动物权利趋势得分（立法年度变化）；（7）植物蛋白风险；（8）公民空间风险；（9）公民自由风险；以及（10）公众关切代理指标。第3层（L3：人工智能放大风险）量化农业中的人工智能应用所产生的叠加效应，包括：（11）人工智能治理风险；（12）人工智能福利研究一致性；（13）人工智能感知能力研究风险；（14）人工智能系统中的物种歧视偏见比率；以及（15）畜牧业人工智能专利强度。所有15个变量均采用一致的编码方式，数值越高代表政策风险越大。数据来自世界动物保护协会的动物保护指数 [5], 联合国粮农组织 FAOSTAT[1], V-Dem民主指数 [22], Oxford Insights政府人工智能准备度指数 [23], 斯坦福人工智能指数 [24], 以及通过OpenAlex获取的专利数据库。缺失值（约占观测值的7.3%）采用国家时间序列内的线性插值法进行填补。

3.3 AWPRI 构建

所有 15 个变量均基于完整的 2004–2022 面板数据进行极差标准化，从而能够进行有效的跨国和跨时间比较。每个层得分均为其五个构成变量的非加权平均值：

$$L_{1it} = (1/5) \sum\{k \in \mathcal{K}_1\} v_{kit}$$

$$L_{2it} = (1/5) \sum\{k \in \mathcal{K}_2\} v_{kit}$$

$$L_{3it} = (1/5) \sum\{k \in \mathcal{K}_3\} v_{kit}$$

其中，$\mathcal{K}1$, $\mathcal{K}2$, $\mathcal{K}3$分别表示第1层、第2层和第3层的五变量指标集，具体定义见表 A1（附录）；v_{kit} 表示国家k 在年份i的变量t的标准化值。

AWPRI 综合得分是三个层得分的未加权平均值：

$$AWPRI_{it} = (L_{1it} + L_{2it} + L_{3it} / 3$$

根据经济合作与发展组织（OECD）和联合研究中心（JRC）关于综合指标的建议，当没有充分的先验证据支持对不同维度采用差异化权重时，采用等权重 [21]。第 3.7 节所述的敏感性分析将用于评估这一决策的稳健性。

3.4 聚类分析与验证

根据得分阈值划分四级风险类型：危急（≥ 0.55）、高（0.45–0.55）、中等（0.35–0.45）和低（< 0.35）。这些界限通过对2022年横截面的综合得分和层得分进行 k 均值聚类分析来验证，并通过肘部法和轮廓系数分析确定最优 k 值。聚类稳健性通过三项互补指标进行评估，即（1）轮廓系数、（2）Calinski–Harabasz 指数和（3）Davies–Bouldin 指数。

3.5 预测

使用针对各国分别估计的ARIMA模型，将国家层面的AWPRI 变化轨迹预测至2030年；模型阶数通过最小化赤池信息准则（AIC）来选择。预测的不确定性以95%置信区间表示。所有模型均使用Python和statsmodels库实现。

3.6 统计分析

共进行了七项互补性推断分析。

首先，使用 Wilcoxon符号秩检验评估 L3 得分是否系统性地高于 L1 和 L2，分别针对完整面板（$N = 475$）和 2022年横截面（$n = 25$）进行检验。鉴于标准化层得分的分布有界且不符合正态分布，因此采用符号秩检验，而非参数 t 检验。

其次，针对 2022年横截面中的 15 个构成变量计算斯皮尔曼等级相关矩阵，以评估构念效度并检测指数结构中潜在的多重共线性。

第三，采用克鲁斯卡尔–沃利斯检验，并进一步进行带 Bonferroni 校正的两两 Mann–Whitney U 检验，以检验不同风险等级之间的 AWPRI 得分是否存在显著差异。

第四，进行 Hausma n 设定检验，以在固定效应和随机效应面板估计量之间作出选择。

检验统计量为：

$$H = (\beta^{FE} - \beta^{RE})^T \, [Var(\beta^{FE}) - Var(\beta^{RE})]^{-1} \, (\beta^{FE} - \beta^{RE}) \sim \chi^2(K)$$

其中，β^{FE} 和 β^{RE} 分别表示固定效应和随机效应系数向量，K为时变回归变量的数量。若统计量显著（$p < 0.05$），则表明估计量之间存在系统性差异，应优先采用固定效应。

第五，双重差分设计利用了根据 2019年 Oxford Insights政府人工智能准备度指数所呈现的国家层面人工智能治理风险分类差异。国家被划分为处理组（人工智能_治理_风险 $= 1.0$ in 2019, n $= 14$）和对照组（人工智能_治理_风险 $= 0.0$, n $= 11$）。处理前时期为 2004–2016年；处理后时期指 2019–2022年，排除 2017—2018年过渡期。估计方程为：

$$AWPRI_{it} = \alpha + \beta (Post_t \times Treat_i) + \gamma_i + \delta_t + \varepsilon_{it}$$

其中，处理后$_t$ 表示处理后时期的指示变量，处理组$_i$ 表示处理指标，γ_i 和δ_t 分别表示国家和年份固定效应，β 表示处理组平均处理效应（ATT）的双重差分估计量。标准误按国家聚类。通过在处理前时期将年份趋势与处理指标进行交互，检验平行前趋势假设。

第六，敏感性分析评估在进行 ± 10 个百分点层级权重扰动时AWPRI得分排名的稳定性。对于每种扰动后的权重组合，计算其与基准AWPRI 排名的斯皮尔曼秩相关，以及用于评估聚类分配稳定性的调整兰德指数（ARI）。

第七，对标准化15变量横截面进行主成分分析，以识别该指数的潜在维度结构，并确定治理差距是普遍存在于各领域，还是具有主题结构。

3.7 敏感性分析

通过系统的扰动分析评估等权方案的稳健性。层权重在基准等额分配（$w1 = w2 = w3 = 1/3$）的基础上变动 ± 10 个百分点，同时要求所有权重均严格大于零且总和为一。在此容差范围内，以五个百分点为间隔枚举所有可行的权重组合，从而构建一组替代性综合指标设定。针对每一种

替代设定，评估两项稳健性标准，即：（1）扰动后的 AWPRI 排名与基线排名之间的斯皮尔曼秩相关；（2）根据扰动得分得出的聚类分配与根据基线得分得出的聚类分配之间的调整兰德指数。斯皮尔曼标准用于检验在合理的重新加权下，国家排名顺序是否稳定；调整兰德指数标准用于检验在不同权重假设下，国家是否会被划分到不同的风险等级。将斯皮尔曼均值 ρ 高于 0.95 作为排名顺序稳健性可接受的主要阈值；同时按照综合指标稳定性评估的惯例，将调整兰德指数作为聚类分配稳定性的补充指标予以报告 [21]。

4. 结果

4.1 描述性统计

表1列出了完整面板（N = 475）中 AWPRI 综合得分及其三个组成层得分的汇总统计量。AWPRI 的完整面板均值为 0.472（SD = 0.086），呈正偏态（偏度 = 0.97）。偏度值表明，高风险国家集中在分布的上尾部。L3 的完整面板均值最高（0.550，SD = 0.125），L1 最低（0.421，SD = 0.085）。与 L2（0.073）和 L3（0.051）相比，L1 的国家内标准差较窄（0.008），这表明，2004 至 2022 年间，动物福利立法的结构稳定性高于波动性更大的政策轨迹和人工智能治理组成部分。

表1. 汇总　　计统计量：AWPRI 与层得分（完整面板，N = 475，2004–2022　　）

变量	N	Mean	SD	Min	中位数	Max	偏度
AWPRI得分	475	0.472	0.086	0.284	0.454	0.802	0.97
L1 — 当前福利状况	475	0.421	0.085	0.245	0.413	0.627	0.17
L2 — 政策轨迹	475	0.445	0.131	0.121	0.431	0.895	0.92
L3 — 人工智能放大风险	475	0.550	0.125	0.217	0.552	0.884	−0.09

注：完整面板（*20　04–2022*年）统计数据。数值越高表示政策风　　险越大。

在2022年横截面（n = 25）中，样本均值 AWPRI 为 0.461（标准差 = 0.111）。L3 的均值最高，为 0.552（标准差 = 0.175），高于 L2（均值 = 0.410，标准差 = 0.138）和 L1（均值 = 0.422，标准差 = 0.094）。L3 得分最高的是中国（0.884），最低的是美国（0.218）。Wilcoxon符号秩检验显示，在完整面板中，L3 得分显著高于 L1（W = 102,651，$p < 0.001$）和 L2（W = 99,295，$p < 0.001$）。在2022年横截面中，L3 得分也高于 L1（W = 271，$p = 0.001$）和 L2（W = 302，$p < 0.001$）。无论采用完整面板还是2022年横截面，这些统计结果都相互吻合。

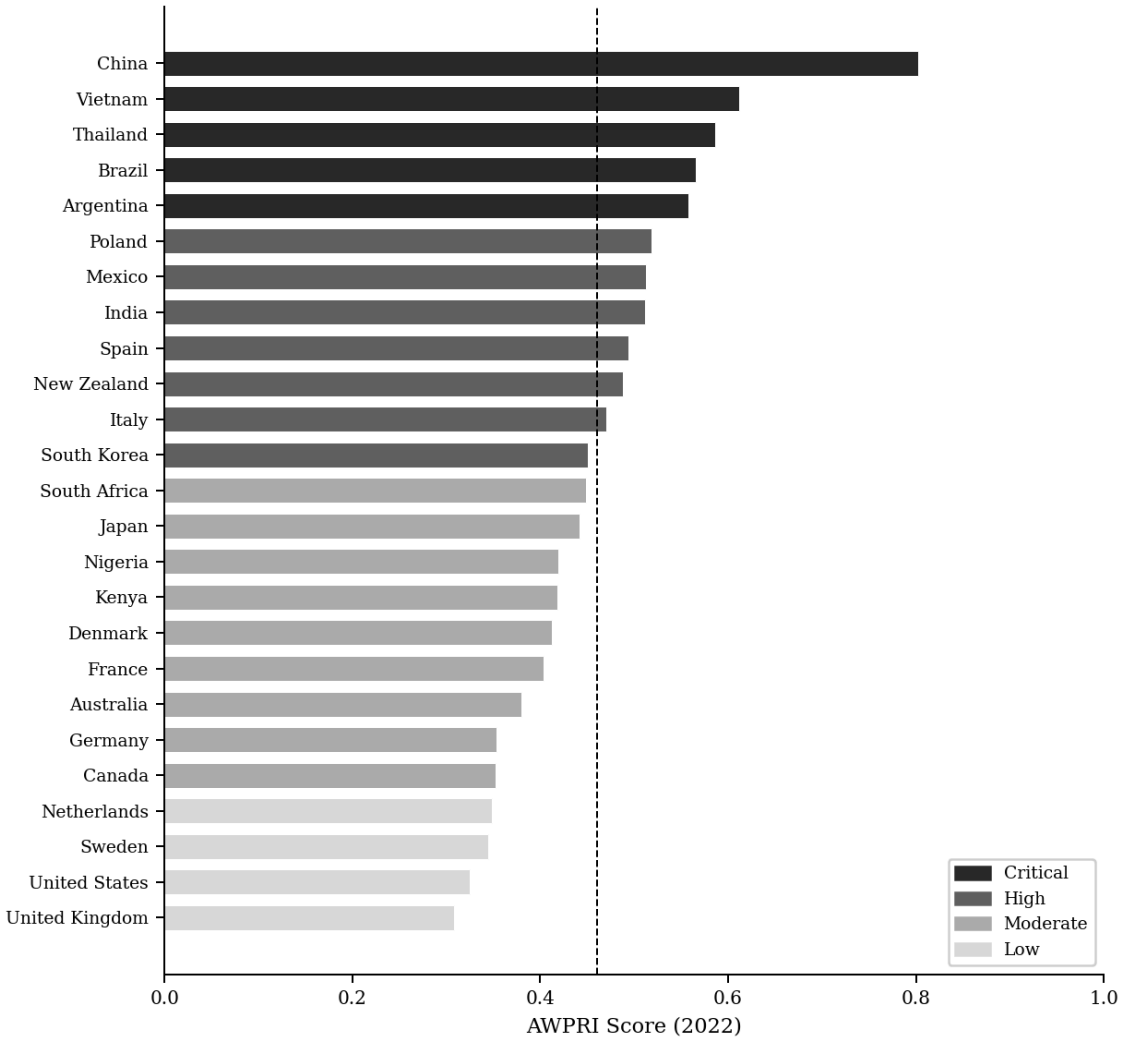

图 1：2022年各国家 AWPRI 排名。国家按 AWPRI 得分升序排列。虚线 = 样本均值（0.461）。阴影表示风险等级。

4.2 斯皮尔曼相关结构

图2展示了2022年横截面中15个构成变量之间若干选定的斯皮尔曼秩相关。图2中可见几组较高的相关性，其中最明显的是 ai_aw_research_risk 与 ai_sentience_risk 之间（$\rho = 0.97$），以及 rule_of_law_risk 与 civil_liberties_risk 之间（$\rho = 0.93$）。这些较高的层内相关性表明构念在理论上具有一致性（即（1）治理质量指标和（2）人工智能知识指标）。这两组近乎冗余的变量对（即（ $\rho =$ ）ai aw 0 97 2 $\rho = 0\ 93$ research risk 与 ai sentience risk（ . ），以及（）rule of law risk 与 civil liberties risk（ . ））基于理论理由予以保留。此处，ai_aw_research_risk 衡量人工智能福利研究与商业激励相一致的程度，而 ai_sentience_risk 则体现研究人员对人工智能的道德考量持怀疑态度，代表不同的作用机制。此外，rule_of_law_risk 体现了对任意国家行为的正式制度约束，而 civil_liberties_risk 则体现个人自由在实践中的行使，代表治理环境中可区分的维度。可以看到，跨层相关性略低，其中最大的跨层变量对

肉类消费_量_千克和植物_蛋白质_风险（$\rho = 0.80$）。图2展示了完整的15×15 斯皮尔曼相关性热图。

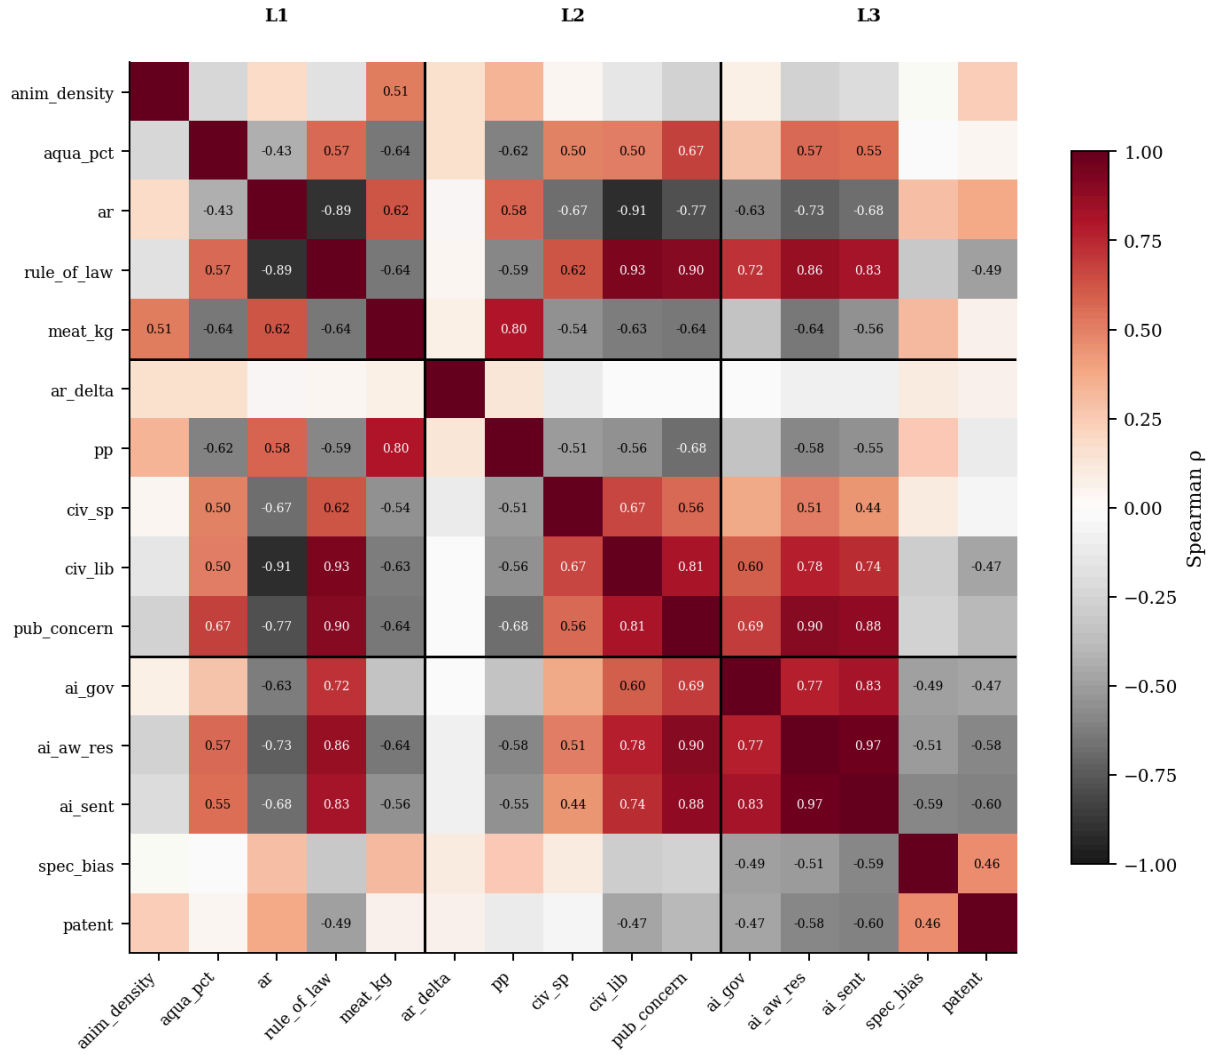

图2：斯皮尔曼等级相关矩阵，15个构成变量，2022年截面数据。粗体横线和竖线标示L1、L2和L3的边界。仅显示$|\rho| > 0.40$的数值。

4.3 跨国 *AWPRI* 得分，*2022*年

表2列出了截至2022年全部25个国家的AWPRI综合得分及层级分解。2022年，中国的AWPRI得分最高（0.802），这主要归因于其L2得分为样本最高（0.895）。这表明其动物福利立法改革轨迹正在恶化（如L2得分所示），同时治理基线也令人担忧（如L1得分所示）。越南（0.612）和泰国（0.586）的综合得分分别位居第二和第三；越南的L3得分为0.680，泰国为0.768，二者均显著高于样本均值（0.552）。得分较低的国家中，英国的AWPRI得分最低（0.308），其次是美国（0.325）和瑞典（0.345）。

图3展示了全部25个国家的层级得分分解。一个显著的模式是，在大多数样本中，L3 得分通常高于对应的 L1 和 L2 得分，其中包括

治理基线相对较强的国家，例如德国（L3 = 0.352）、瑞典（L3 = 0.388）和英国（L3 = 0.260）。这些发现初步表明，更完善的动物福利立法和更有利的政策变化轨迹并不会系统性地降低人工智能放大风险；这一发现将在第4.5节中进行检验。

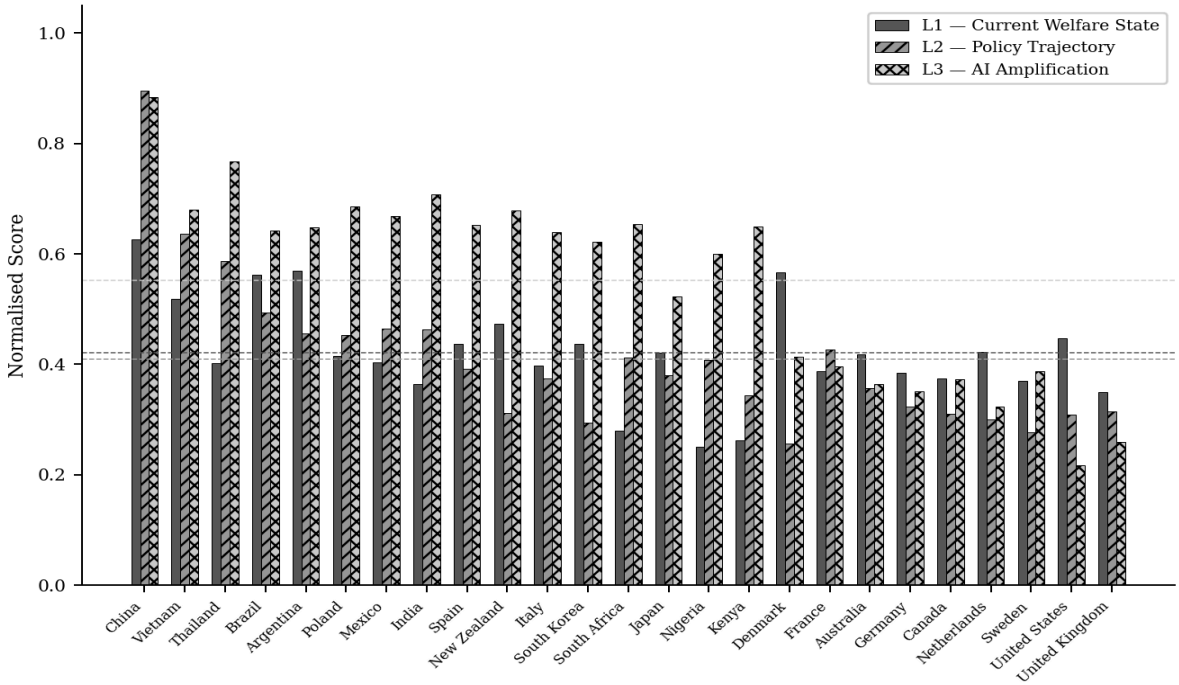

图3：各国分层得分分解，2022年。国家按 AWPRI 得分降序排列。虚线表示各层的样本均值。

表2：各国AWPRI得分及分层分解，2022年

国家	AWPRI	L1	L2	L3	风险等级	趋势
中国	0.802	0.627	0.895	0.884	危急	↑
越南	0.612	0.519	0.637	0.680	危急	↑ ns
泰国	0.586	0.403	0.587	0.768	危急	↑***
巴西	0.566	0.562	0.494	0.642	危急	↑**
阿根廷	0.558	0.569	0.455	0.648	危急	↑*
波兰	0.518	0.415	0.453	0.687	High	↑ ns
墨西哥	0.513	0.404	0.465	0.669	High	↑ ns
印度	0.512	0.364	0.464	0.708	High	↑ ns
西班牙	0.494	0.437	0.392	0.653	High	↑ ns
新西兰	0.488	0.473	0.312	0.679	High	↑ ns
意大利	0.471	0.398	0.375	0.640	High	↑ ns
韩国	0.451	0.437	0.294	0.622	High	↓ ns
南非	0.449	0.279	0.412	0.654	中等	↑*
日本	0.442	0.421	0.381	0.523	中等	↓**

尼日利亚	0.420	0.251	0.407	0.600	中等	↑ ns
肯尼亚	0.418	0.262	0.343	0.650	中等	↓ ns
丹麦	0.412	0.567	0.256	0.414	中等	↓*
法国	0.404	0.388	0.427	0.396	中等	↓**
澳大利亚	0.380	0.418	0.357	0.364	中等	↓*
德国	0.353	0.385	0.323	0.352	中等	↓**
加拿大	0.353	0.375	0.311	0.373	中等	↓***
荷兰	0.349	0.422	0.300	0.323	Low	↓**
瑞典	0.345	0.370	0.277	0.388	Low	↓**
美国	0.325	0.447	0.309	0.218	Low	↓*
英国	0.308	0.350	0.315	0.260	Low	↓**

注。趋势列报告普通最小二乘法（OLS）趋势斜率的方向与显著性（AWPRI ~ 年份，2004–2022）。* $p < 0.05$；** $p < 0.01$；*** $p < 0.001$；ns = 不显著。

4.4 风险聚类类型学与验证

表3呈现了我们根据基于阈值的评分分类设计的风险聚类类型学。危急风险层级（n = 5）包括中国、越南、泰国、巴西和阿根廷。这五个国家的三个层得分均接近或超过样本均值（L1 $\geq$ 0.422；L2 $\geq$ 0.410；L3 $\geq$ 0.552），但泰国的 L1 得分（0.403）略低于 L1 均值。这表明，(1)薄弱的立法框架、(2)不断恶化的改革轨迹以及(3)快速的人工智能应用正共同累积影响。高风险层级（n = 7）的主要风险来自 L3；其成员国具有可识别的立法框架和中等程度的改革活动，但人工智能采用轨迹快于监管能力。中等风险层级（n = 9）的风险在各层之间分布不均，L1 得分相对高于 L2 或 L3，这表明主要问题并非缺少立法，而是改革步伐以及新出现的人工智能治理缺口。低风险层级（n = 4）包括荷兰、瑞典、美国和英国，这些国家的治理基线最强，且样本中的 L3 得分最低。

表3. AWPRI风险聚类类型学，2022年（k = 4）

风险等级	国家	平均AWPRI	平均L3	n
危急	中国、越南、泰国、巴西、阿根廷	0.625	0.724	5
High	波兰、墨西哥、印度、西班牙、新西兰、意大利、韩国	0.492	0.665	7
中等	南非、日本、尼日利亚、肯尼亚、丹麦、法国、澳大利亚、德国，加拿大	0.403	0.481	9
Low	荷兰、瑞典、美国、英国	0.332	0.297	4

注：聚类边界：危急 $\geq$ 0.55；高 = 0.45–0.55；中等 = 0.35–0.45；低 < 0.35。

图4呈现了聚类验证结果。基于簇内平方和的肘部法确定，$k = 4$ 是收益递减的拐点，超过该点后，增加聚类数量只能带来微乎其微的改进。$k = 4$ 时的轮廓系数为0.447（Calinski–Harabasz 指数为= 35.56；Davies–Bouldin 指数为= 0.659），表明该聚类方案达到尚可至良好的水平。

值得注意的是，$k = 3$ 得到的轮廓系数略高（0.492），这表明在$k = 4$时，经验聚类将中国划分为单独一类。这一发现意义重大，因为在不受约束的情况下，k-均值算法将中国识别为一个偏离程度足够大的异常值，足以单独构成一个聚类。基于理论考量，本文保留四级类型划分，因为阈值边界具有重要的政策解读价值。

Kruskal–Wallis 检验显示，四个风险等级的 AWPRI 得分存在显著差异（H = 20.77，$p < 0.001$）。采用 Bonferroni 校正的两两 Mann–Whitney U 检验表明，所有相邻风险等级之间的比较均具有统计显著性（例如，高风险与中等风险（$p = 0.009$）、高风险与低风险（$p = 0.017$），以及中等风险与低风险（$p = 0.001$））。收入组比较显示，按世界银行分类，AWPRI 得分存在显著差异（ 2022 = ）（Kruskal–Wallis H . p . ），这主要是因为与高收入国家相比，中高收入和中低收入国家的 L（H . p . ）和 L（H .$p = 0.008$）得分较高。 12 130, = 0 002 2 = 14 602, = 0 001 3 = 9 74,

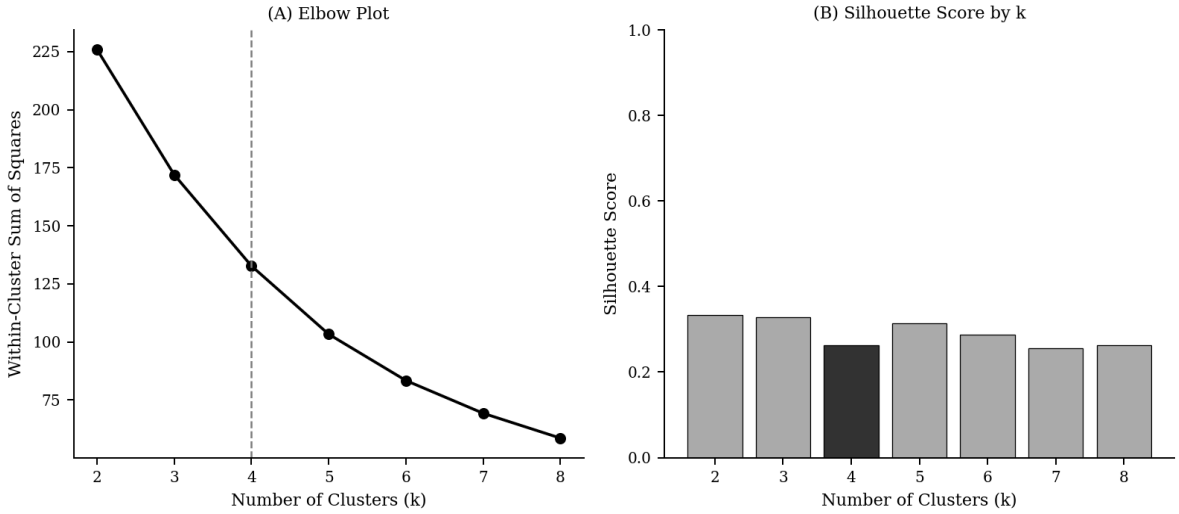

图4：聚类验证。(A) 不同 k 值对应的簇内平方和肘部图。(B) 不同 k 值对应的轮廓系数。k = 4 处的虚线表示所选方案。

4.5 时间动态，*2004–2022*

图5展示了部分国家的 AWPRI 时间轨迹。表2中的趋势列报告了全部25个国家的 OLS 趋势斜率方向及显著性水平。在2004–2022年期间，25个国家中有15个呈现统计显著的趋势（$p < 0.05$），其中5个恶化，10个改善。在恶化轨迹中，泰国的斜率最大（每年 $\beta = 0.005$，$p < 0.001$），其次是巴西（$\beta = 0.0035$，$p = 0.003$）和南非（$\beta = 0.003$，$p = 0.010$）。在改善轨迹中，加拿大改善幅度最大（每年 $\beta = -0.005$，$p < 0.001$），其次是荷兰（$\beta = -0.004$，$p = 0.002$）。全样本平均 AWPRI 从2004年的0.490降至2022年的0.461，净改善主要由中风险聚类和低风险聚类推动。然而，危急风险群组在2004年至2022年间总体呈恶化趋势。

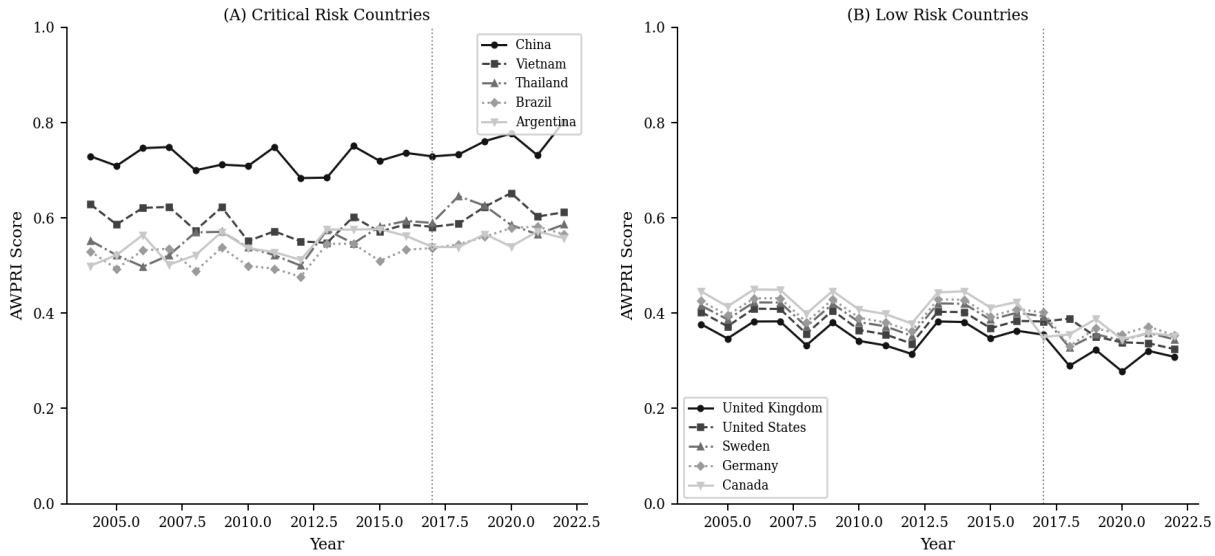

图5：AWPRI 时间轨迹，2004–2022。（A）危急风险国家。（B）低风险及部分中等风险国家。2017年处的垂直虚线表示人工智能治理风险差异化的开始。

图6展示了全部25个国家的 OLS 趋势斜率系数及其95%置信区间。呈现统计显著恶化轨迹（斜率为正，$p < 0.05$）的国家集中在危急风险层级，而呈现统计显著改善轨迹（斜率为负，$p < 0.05$）的国家则主要分布在低风险和中等风险集群。AWPRI框架预测，已面临较高基线动物福利风险的国家，其政策状况也正经历最快速的恶化；这一预测与图6的发现一致，恶化轨迹集中于危急风险层级。

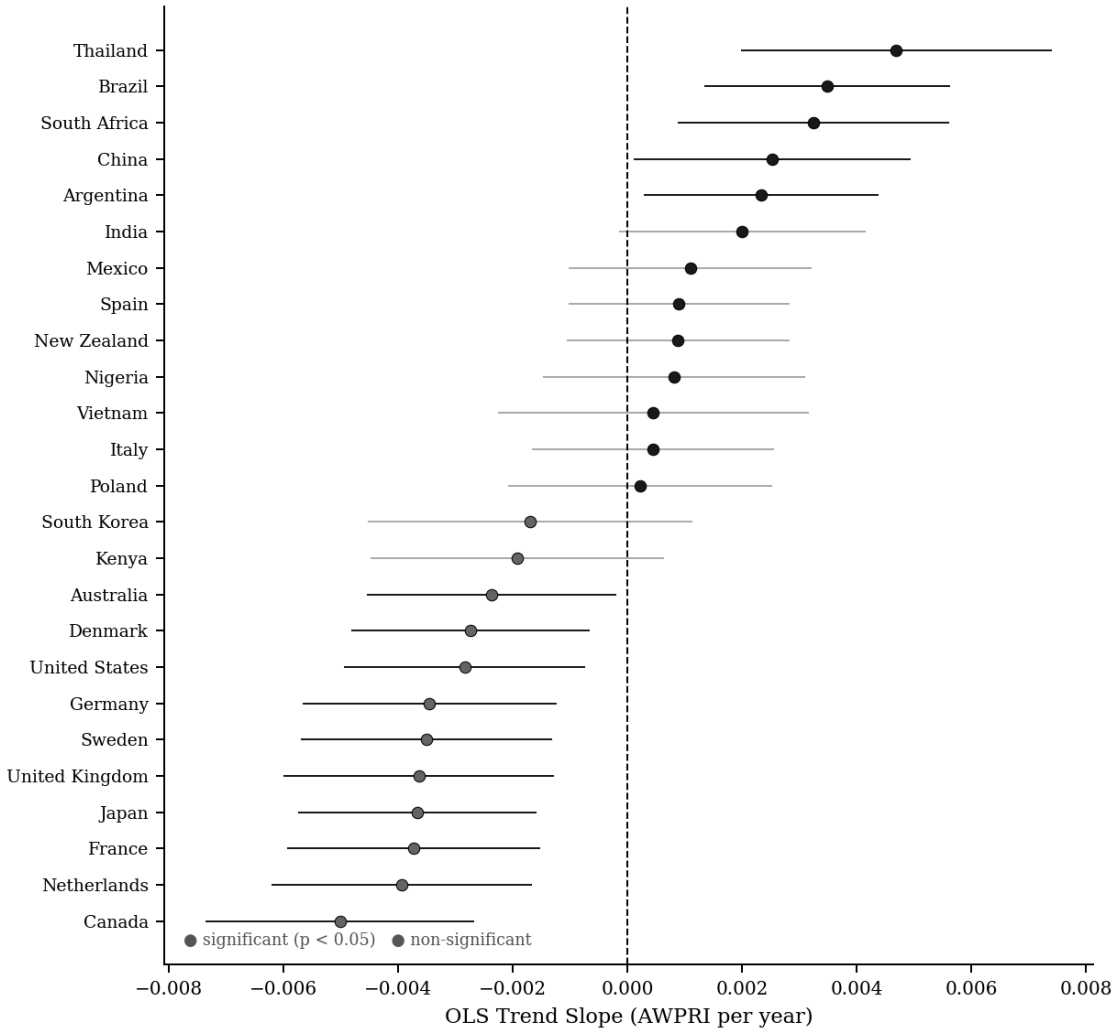

图6：2004–2022年各国 OLS 趋势斜率系数。柱形表示各国层面以年份为自变量、AWPRI 为因变量进行 OLS 回归所得的 β 系数。误差线表示 95%置信区间。柱形按风险等级着色。各国按斜率大小排序。* p < 0.05；** p < 0.01；*** p < 0.001。

4.6 双重差分分析

图7展示了双重差分分析。处理组由 14 个被 2019年牛津洞察评估列为高人工智能治理风险的国家组成（阿根廷、巴西、中国、印度、意大利、肯尼亚、墨西哥、新西兰、尼日利亚、波兰、南非、西班牙、泰国、越南）；对照组由 11 个人工智能治理风险较低的国家组成（澳大利亚、加拿大、丹麦、法国、德国、日本、荷兰、韩国、瑞典、英国、美国）。表4展示了处理前趋势检验结果。可以看到，处理前时期的年份趋势与处理指标之间的交互项在统计上并不显著（$\beta = 0.000$，$p = 0.673$）。这意味着我们无法在统计上确信，2017年之前处理组和对照组国家的 AWPRI 变化轨迹存在差异。

双重差分估计量显示，在控制国家和年份固定效应后，处理组国家在处理后时期的 AWPRI 得分比对照组国家高 0.080 分（表5）（$\beta = 0.080$，$p < 0.001$）。原始平均处理效应为 0.080，其中处理组的 AWPRI

在同一时期增加了 0.030（从 0.506 升至 0.536），而对照组的 AWPRI 则下降了 0.050（从 0.433 降至 0.383）。以 L3 为结果变量进行双重差分估计时，系数升至 0.200（$p < 0.001$）（表 5）。这一发现表明，这种差异主要是通过人工智能放大层（即 L3）产生的，而非通过治理基线（即 L1）或政策轨迹（即 L2）部分产生。

值得注意的是，处理变量（人工智能_治理_风险）是 L3 的五个构成变量之一，而 L3 本身占 AWPRI 复合结果的三分之一。这种构成结构带来了部分内生性。更重要的是，双重差分分析表明，2019年人工智能治理风险分类对 AWPRI 变化轨迹的预测作用超出了 L3 组成部分的范围（包括 L1 治理基线和 L2 政策轨迹）。

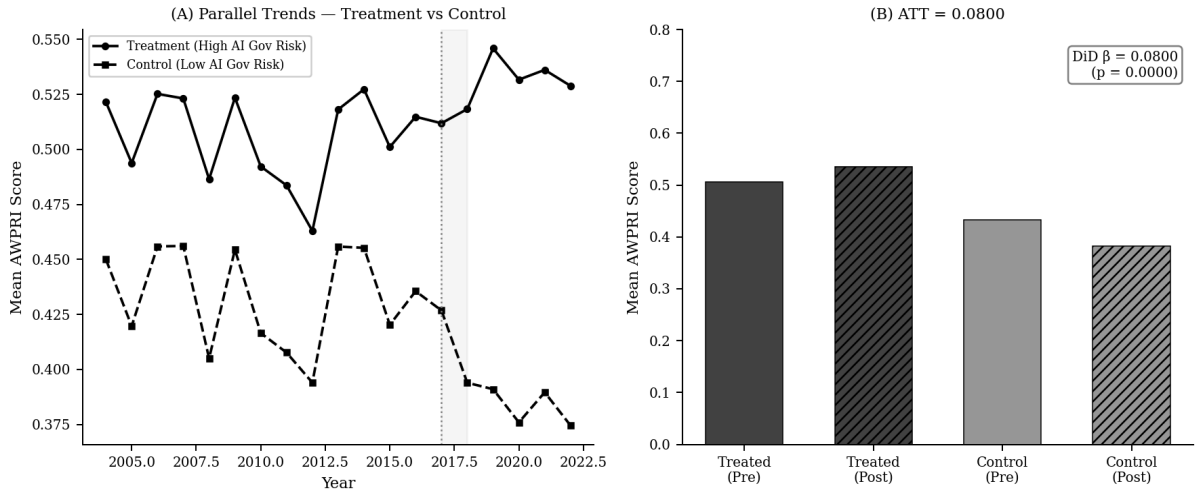

图7：双重差分。(A) 处理组与对照组的平行前趋势。2017年的垂直虚线表示处理开始；灰色区域表示从估计中排除的2017—2018年过渡期。(B) 各组处理前和处理后的平均AWPRI得分。双重差分 $\beta = 0.080$（$p < 0.001$）。

表4。处理前趋势检验：处理前时期（2004–2016年）AWPRI 对年份 × 处理交互项的普通最小二乘回归

Term	系数	标准误	*t*	*p*	N
年份趋势（中心化）	0.003	0.002	1.391	0.165	325
处理指标	—	—	—	—	
年份 × 处理（处理前时期）	0.000	0.001	0.423	0.673	
国家固定效应	Yes				

注。 因变量：AWPRI 综合得分。处理前时期定义为2004–2016年（处理开始前的年份）。处理组（n = 14）：根据2019年牛津洞察评估，被归类为高人工智能治理风险的国家。对照组（n = 11）：被归类为低人工智能治理风险的国家。年份趋势采用均值中心化处理。处理指标被国家固定效应吸收，因此未单独估计。年份 × 处理交互项不显著（$p = 0.673$），这表明处理组和对照组国家在处理前时期的 AWPRI 变化轨迹在统计上无显著差异，支持双重差分设计的有效性。标准误采用异方差稳健估计。

表5. 按结果变量划分的双重差分估计值（处理：高人工智能治理风险，2019年；N = 475）

结果变量	*β*（双重差分）	S.E.	*t*	*p*	95%置信区间
AWPRI（综合指标）	0.080***	0.005	16.878	<0.001	[0.071，0.089]

L3—人工智能放大风险	0.200***	0.000	2515.913	<0.001	[0.200, 0.200]
L2—政策轨迹	0.030**	0.010	2.920	0.004	[0.010, 0.050]
L1—当前福利状况	0.010	0.005	1.958	0.050	[0.000, 0.020]

设计	
处理组	14个国家（根据2019年Oxford Insights分类，属于高人工智能治理风险）
对照组	11个国家（人工智能治理风险较低）
处理开始	2017年；2017–2018年为过渡年份，不纳入估计
固定效应	国家和年份
标准误	按国家聚类
观测值	475

注。 β (双重差分)是采用普通最小二乘法并控制国家和年份固定效应后，交互项（事后 × 处理组）的系数。L3 的标准误接近于零，这是因为$ai_$治理_风险（处理变量）是 L3 的五个构成变量之一，造成了机械性重叠；解读 L3 的结果时应注意这一点。L1 的结果恰好达到但未低于传统的 $\alpha = 0.05$ 阈值，因此应谨慎解读。** $p < 0.01$；*** $p < 0.001$。

4.7 主成分分析

图 8 = 2 55 = 0 467

(A) 展示了碎石图。豪斯曼设定检验显示 H .（p .）。这意味着我们没有足够的统计把握拒绝“固定效应与随机效应估计量之间不存在系统性差异”这一零假设，表明后者对于描述 AWPRI 变化轨迹的面板建模而言有效且效率更高。PC1 解释了总方差的 51.6%，PC2 解释了 17.8%；如虚线所示，需要五个主成分才能达到 91.4% 的累积方差。研究结果表明，这 15 个指标无法简化为单一维度。图 8(B) 展示了 PC1–PC2双标图。载荷箭头表明，PC2 上载荷最高的变量总体指向相似方向，而国家得分在 y 轴或 x 轴上均未按风险等级清晰分离。危急风险国家（即标记颜色最深的国家）集中在 PC1 的正值区域，而低风险国家聚集在负值区域。然而，各风险等级之间并未完全清晰地分离。若干中等风险和高风险国家在 PC1 方向上高度重叠，这表明仅凭第一主成分无法可靠地区分不同风险等级。因此，我们对 AWPRI 采用的三层构成并未与单一主成分重复。该发现支持保留复合结构，而非将其压缩为单一指数维度。

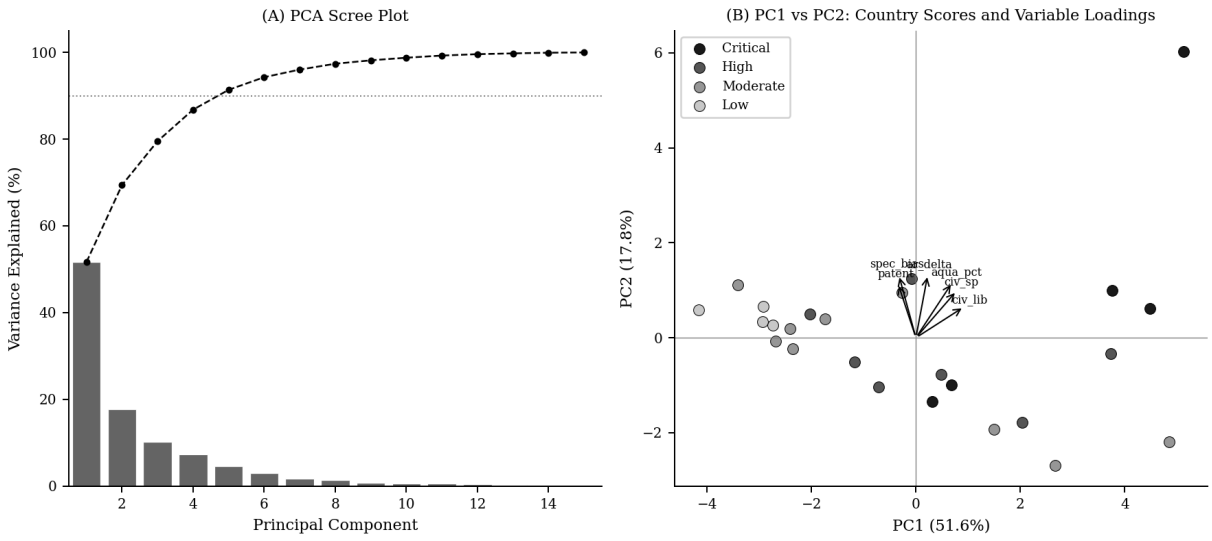

图8：主成分分析、15变量截面、2022年。（A）碎石图。虚线表示累积方差达到90%的位置。（B）PC1–PC2双标图。箭头表示载荷最高的变量；国家得分按风险等级着色。

4.8 敏感性分析

图9展示了在±10 百分点层级权重扰动下的敏感性分析。图9(A)显示，扰动后的 AWPRI 排名与基准排名之间的斯皮尔曼秩相关平均值为 0.993（最低值：0.979），表明在不同加权方案下，国家排名顺序高度稳定。图9(B)显示，聚类分配稳定性的 ARI 介于 0.477 至 1.000 之间，平均值为 0.684。虽然排名顺序具有稳健性，但聚类分配对权重扰动更为敏感。在某些权重组合下，一些国家会跨越风险等级边界。这些发现表明，AWPRI 国家排名对于合理的替代加权方案具有稳健性，但我们应注意，风险等级分配对各层所赋予的相对权重较为敏感。

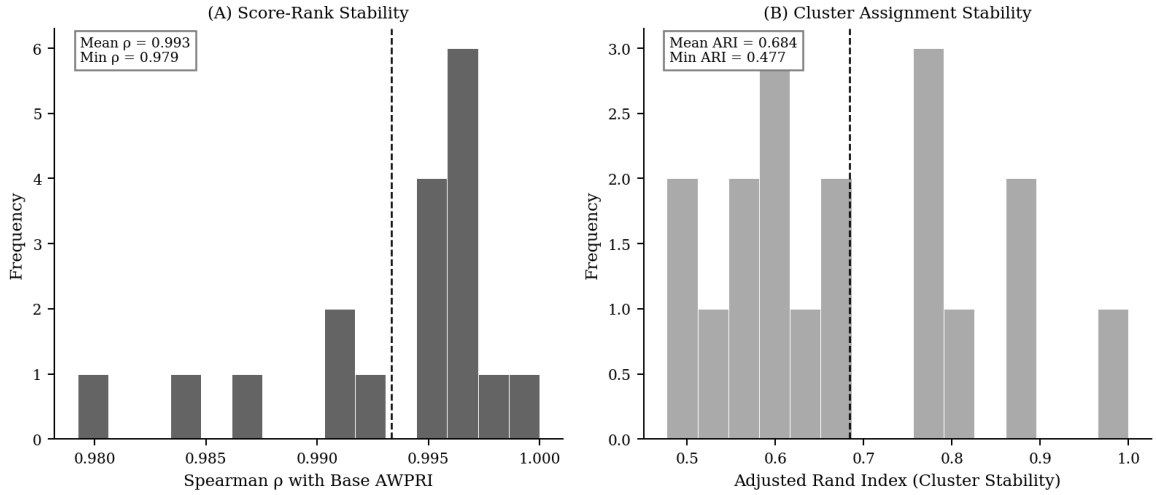

图 9： 敏感性 分析 分析在 的 ±*10* 百分比点-百分点 层权重 扰动。 （*A*） 分布 中 斯皮尔曼 ***ρ*** 之间 后的扰动 各 和 基线 ***AWPRI*** 排名。 （*B*） 分布 中 调整兰德指数 的聚类 分配稳定性。

*4.9 ARIMA*预测至*2030*年

图10展示了基于自回归积分滑动平均的 AWPRI 预测结果，预测至2030年。表6报告了全部25个国家的点预测和95%置信区间。在危急风险群组中，预计到2030年，中国（0.775）和越南（0.602）的状况将有所改善，而泰国（0.642）、巴西（0.590）和阿根廷（0.585）的状况预计将进一步恶化。在高风险群组中，预计墨西哥（0.535）、印度（0.517）、西班牙（0.498）、新西兰（0.493）、南非（0.485）和韩国（0.481）的状况都将恶化，而波兰（0.501）和意大利（0.466）的状况预计将略有改善。在中低风险国家中，大多数国家预计将有所改善，但肯尼亚（0.429）、尼日利亚（0.424）、澳大利亚（0.387）和美国（0.325）是显著例外，其状况预计将恶化。从2022年（实测）到2030年（预测），法国（0.369）和加拿大（0.318）的绝对改善幅度在所有国家中最大，在此期间，两国的数值均下降了0.035点。

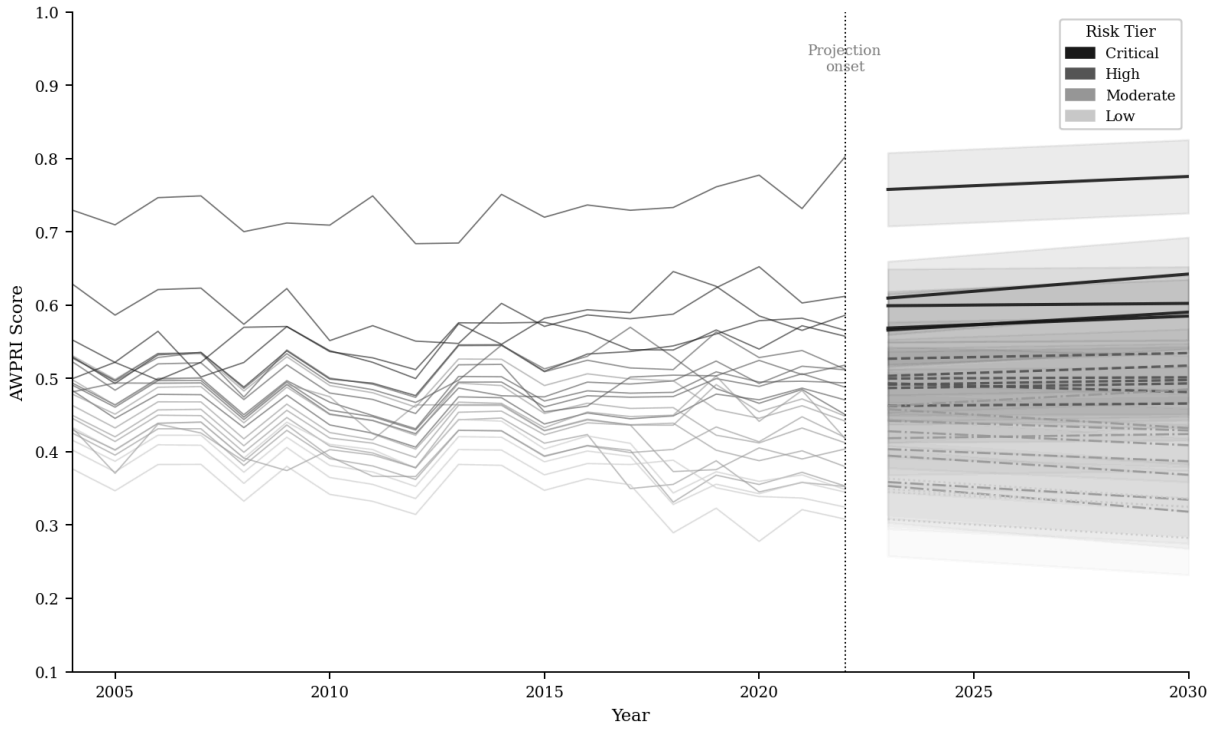

图10：基于自回归积分滑动平均的 AWPRI 预测（截至2030年），涵盖全部25个国家。折线表示自2023年起的均值预测；阴影表示95%置信区间。轨迹颜色表示2022年风险等级。2022年的虚线垂直线标示预测起点。

Ta表6. 基于自回归积分滑动平均的 AWPRI 预测（截至2030年）（95%置信区间 ）

国家	2022年 AWPRI	2030年 AWPRI	95%置信区间下限	95%置信区间上限	趋势
中国	0.802	0.775	0.725	0.825	↓
越南	0.612	0.602	0.552	0.652	↓
泰国	0.586	0.642	0.592	0.692	↑
巴西	0.566	0.590	0.540	0.640	↑
阿根廷	0.558	0.585	0.535	0.635	↑
墨西哥	0.513	0.535	0.484	0.585	↑
印度	0.512	0.517	0.467	0.567	↑
波兰	0.518	0.501	0.451	0.551	↓

西班牙	0.494	0.498	0.448	0.548	↑
新西兰	0.488	0.493	0.443	0.543	↑
南非	0.449	0.485	0.435	0.535	↑
韩国	0.451	0.481	0.431	0.531	↑
意大利	0.471	0.466	0.416	0.516	↓
日本	0.442	0.432	0.382	0.482	↓
肯尼亚	0.418	0.429	0.379	0.479	↑
尼日利亚	0.420	0.424	0.374	0.474	↑
丹麦	0.412	0.409	0.359	0.459	↓
澳大利亚	0.380	0.387	0.337	0.437	↑
法国	0.404	0.369	0.319	0.418	↓
德国	0.353	0.335	0.284	0.385	↓
加拿大	0.353	0.318	0.268	0.368	↓
荷兰	0.349	0.336	0.286	0.386	↓
瑞典	0.345	0.325	0.275	0.374	↓
美国	0.325	0.325	0.275	0.375	↑
英国	0.308	0.282	0.232	0.332	↓

注。↑ = 预测恶化 化；↓ = 预计改善。预测基于国家层面的自回归积分滑动平均模型，并采用基于 *AIC* 的阶数 r 选择。

5. 讨论

5.1 人工智能放大效应：主要风险驱动因素

在各项分析中，我们发现，在完整面板和2022年横截面中，L3 得分均系统性且显著地高于 L1 和 L2。印度（L3 = 0.708）、新西兰（L3 = 0.679）和波兰（L3 = 0.687）等国家的 L3 得分显著高于其对应的 L1 和 L2 得分，这支持了如下理论论点：在治理框架并非为人工智能问责而设计的司法辖区，精准畜牧业部署会加速农业集约化，并以算法监控取代直接的人类监督 [12]。

此外，样本中没有任何国家的 L3 得分低于 0.217（美国），这一发现值得关注。即便是综合 AWPRI 最低、整体治理基线最强的英国，其 L3 得分也达到 0.260。这表明，即使拥有成熟的动物福利立法框架和相对较强执法能力的国家，也面临不可忽视的人工智能放大风险；这一发现与如下论点一致：无论司法辖区的治理质量如何，大多数人工智能农业系统都在缺乏特定于动物福利的问责机制的情况下运行 [13]。

此外，我们的双重差分分析为这一解释提供了准实验支持。2019年人工智能治理风险分类的分化，与处理组和对照组国家之间0.080分的AWPRI差距相关；其中，L3组成部分的效应显著更大，达到0.200，

具体而言。该模式表明，人工智能治理中的制度缺口（体现在L3 层）与整体治理质量相关，同时也构成了一条独特且独立的动物福利风险路径。

5.2 地理分布模式和收入群体的差异

风险的地理分布与收入分类相关。2022年，中高收入国家的平均AWPRI为0.583，显著高于高收入国家（0.406；克鲁斯卡尔–沃利斯检验 $\mathrm{H} = 12.130$，$p = 0.002$）。这种收入梯度在L2上最为明显（$\mathrm{H} = 14.602$，$p = 0.001$），体现了主要新兴经济体中动物福利立法改革轨迹更加动荡且持续恶化。中低收入国家的平均AWPRI为0.490，其L3 得分（均值 $= 0.652$）显著高于高收入国家的均值（0.459）。这表明，尽管治理基线处于中等水平，中低收入国家仍面临显著的人工智能放大风险。

相关研究普遍承认英国是全球动物福利立法的领导者 [5, 3], ；本研究所呈现的样本中，英国综合AWPRI得分最低（0.308），与这一评价相符。然而，正如第2节所记录的执法缺口所示，立法领导力与执法能力可能存在显著差异。尽管AWPRI的L2旨在解决这一问题，我们的模型仍无法全面识别法律执行缺口。未来几个月，我们将继续改进并完善AWPRI模型，以更好地呈现人工智能与动物福利交汇处的政策风险指数。

5.3 时间轨迹与政策紧迫性

此外，我们的时间趋势分析显示，不同国家群体的风险变化轨迹存在显著差异。五个国家呈现出统计上显著的恶化趋势（泰国、巴西、南非、中国、阿根廷），而十个国家则呈现出统计上显著的改善趋势（加拿大、荷兰、法国、日本、英国、瑞典、德国、美国、丹麦、澳大利亚）。恶化幅度最大的国家——泰国（每年$\beta = 0.005$）和巴西（$\beta = 0.004$）——是全球主要畜牧业生产国，其国内人工智能治理框架有限，公民空间指标也在恶化。ARIMA预测表明，如果不采取干预措施，这种差异预计将持续至2030年；预计泰国、巴西和阿根廷的风险将维持在重大风险阈值或以上。

5.4 治理启示

在本研究中，我们发现：第一，人工智能治理框架必须明确将动物福利纳入监管领域。L3 主导性发现，以及双重差分结果表明，高人工智能治理风险分类能够预测 AWPRI 的整体恶化，这说明通用的人工智能准备度指标不足以识别特定于福利的风险。第二，动物福利治理中的执法维度在立法文本中体现不足，因此需要加大投入。英国的案例表明，立法领导力与执法能力可能存在显著差异。第三，泰国、巴西和阿根廷的变化轨迹预计将进一步恶化，这表明可将类似于欧盟

《森林砍伐条例》 [25]——该条例以土地利用合规为市场准入条件——的国际治理工具可以扩展适用范围，将可核验的动物福利合规要求纳入农业供应链。

6. 局限性

我们必须指出，本文存在若干局限。首先，AWPRI 依赖公开数据来源，约 7.3% 的观测值通过国家时间序列中的线性插值进行估算。插补保留了国家层面的时间趋势，但对于动物福利治理状况相关的非随机缺失数据，可能会在某些年份引入偏差。其次，尽管根据经合组织—欧盟联合研究中心手册 [21] 确定等层赋权具有合理性，且已通过敏感性分析验证，但这仍然是一项方法论假设。敏感性分析表明，± 10 个百分点的扰动不会改变国家排名或聚类分配，但超出这一范围的扰动可能导致不同的实证结果。

第三，前文提及的双重差分分析存在部分内生性，这是一个实质性局限。处理变量（人工智能_治理_风险）是 L3 中五个构成变量之一，因此双重差分系数包含一个机械性成分。双重差分结果应解读为人工智能治理风险分类与更广泛的 AWPRI 变化轨迹之间存在关联的证据，而不应视为人工智能治理分化对动物福利结果产生因果影响的估计。第四，AWPRI 衡量的是政策风险，而非直接衡量动物福利结果。需要与农场层面指标进行交叉验证，例如死亡率和饲养密度违规情况，以确定风险评分是否对应动物福利状况中可观察到的差异。第五，这项探索性研究所采用的 25 国样本并不具有全球代表性。由于数据限制，印度尼西亚、巴基斯坦和埃塞俄比亚等主要畜牧业经济体未纳入研究。在扩大规模阶段的研究中，我们将通过更广泛的数据收集和分析来弥补这一不足。

7. 结论

本文提出 AWPRI，这是首个用于动物福利治理的纵向跨国人工智能敏感型综合风险指数。该指数应用于 2004–2022 年的 25 个国家（$N = 475$），结果显示，人工智能放大风险（L3）是综合政策风险的主要贡献因素。双重差分分析发现，被识别为人工智能治理高风险的国家，其 AWPRI 得分比低风险国家高出 0.080 分（$\beta = 0.080$，$p < 0.001$），且这一效应集中在 L3 组成部分（$\beta = 0.200$，$p < 0.001$）。国家排名和聚类分配对层权重扰动具有稳健性（斯皮尔曼均值 $\rho = 0.986$；调整兰德指数 $= 1.000$）。此外，我们的 ARIMA 预测表明，如果缺乏政策干预，泰国、巴西和阿根廷的情况将持续恶化至 2030 年。

我们再次强调，农业人工智能的监管框架必须纳入特定于动物福利的问责机制，因为当前的人工智能治理格局系统性地忽视了这一维度。鉴于英国案例表明，在立法文本方面处于全球领先地位，也可能同时存在严重的执法缺口，因此立法发展必须配以执法投入。最后，我们建议将国际贸易工具的适用范围扩展至可核验的动物福利合规，尤其应关注那些来自预计未来十年情况将恶化的国家的高风险供应链。

备注： AWPRI交互式仪表板（https://awpri-dashboard.streamlit.app）提供公开访问所有国家—年份评分、层级分解、聚类分类和ARIMA预测的功能。

参考文献

[1] 联合国粮食及农业组织（FAO）。（2023）。FAOSTAT：畜牧业初级数据。https://www.fao.org/faostat

[2] Blattner, C. E., & Tselepy, J.（2024）。为了谁的利益？保护非人类动物的主要国际条约提案的危急分析。《美国比较法杂志》，72(1)，1–32。https://doi.org/10.1093/ajcl/avae018

[3] Hårstad, R. M. B.（2024）。动物福利的政治：农场动物福利治理的范围综述。《政策研究评论》，41(5)，679–702。https://doi.org/10.1111/ropr.12554

[4] Chaney, P., Jones, I. R., & Narayan, N.（2024）。超越单一制国家：有关动物福利的多层级治理、政治与跨文化视角。《Animals》，14(1)，第79篇。https://doi.org/10.3390/ani14010079

[5] 世界动物保护协会。（2020）。2020 年动物保护指数。https://www.worldanimalprotection.us/siteassets/reports-programmatic/animal-protection-index-2020-report.pdf

[6] 动物法律基金会。（2024）。执法问题：2024 年数据。https://animallawfoundation.org/enforcement

[7] Neethirajan, S.（2024）。人工智能与传感器创新：以人为本的方法提升畜牧业动物福利。《以人为本的智能系统》，4(1)，77–92。https://doi.org/10.1007/s44230-023-00050-2

[8] Papakonstantinou, G. I., Voulgarakis, N., Terzidou, G., Fotos, L., Giamouri, E., & Papatsiros, V. G.（2024）。精准畜牧业技术：应用与挑战。《农业》，14(4)，第 620 号文章。https://doi.org/10.3390/agriculture14040620

[9] DataM Intelligence.（2024）。《2024–2032 年精准畜牧业市场中的人工智能》报告。DataM Intelligence。

[10] Schillings, J.、Bennett, R. 和 Rose, D. C.（2021）。探讨精准畜牧业技术在改善农场动物福利方面的潜力。《动物科学前沿》，2，文章 639678。https://doi.org/10.3389/fanim.2021.639678

[11] Zhang, L., Guo, W., Lv, C., Guo, M., Yang, M., Fu, Q., & Liu, X.（2024）。改善动物福利的人工智能技术进展。《动物研究与一体化健康》，2（1），93–109。https://doi.org/10.1002/aro2.44

[12] Tuyttens, F. A. M., Molento, C. F. M., & Benaissa, S.（2022）。精准畜牧业（PLF）对动物福利的十二项威胁。《兽医科学前沿》，9，文章889623。https://doi.org/10.3389/fvets.2022.889623[13] Elliott, K., & Werkheiser, I.（2023）。精准畜牧业透明度框架。《Animals》，13（21），文章3358。https://doi.org/10.3390/ani13213358[14] Parlasca, M., Knößlsdorfer, I., Alemayehu, G., & Doyle, R.（2023）。发展中国家的动物福利关切如何以及为何不断演变。《动物前沿》，13（1），26–33。https://doi.org/10.1093/af/vfac082[15] 联合国开发计划署（UNDP）。（1990）。《1990年人类发展报告》。https://hdr.undp.org/system/files/documents/hdr1990encompletenostats.pdf[16] Wolf, M. J., Emerson, J. W., Esty, D. C., de Sherbinin, A., & Wendling, Z. A.（2022）。2022年环境绩效指数。耶鲁大学环境法与政策中心。[17] 经济与和平研究所（IEP）。（2024）。2024年全球和平指数。https://www.economicsandpeace.org/wp-content/uploads/2024/06/GPI-2024-web.pdf[18] Browning, H.（2022）。动物福利衡量方法评估。《生物学与哲学》，37（4），文章36。https://doi.org/10.1007/s10539-022-09862-1[19] Hausman, J. A.（1978）。计量经济学中的设定检验。《计量经济学》，46（6），1251–1271。https://doi.org/10.2307/1913827[20] Angrist, J. D., & Pischke, J.-S.（2009）。《基本无害的计量经济学：一位经验主义者的伴侣》。普林斯顿大学出版社。[21] 经济合作与发展组织（OECD）与联合研究中心（JRC）。（2008）。《综合指标构建手册：方法论与用户指南》。经合组织出版。https://doi.org/10.1787/9789264043466-en[22] V-Dem研究所。（2024）。国家—年份：V-Dem完整 + 其他版本 15 [数据集]。哥德堡大学。https://v-dem.net/data/the-v-dem-dataset/country-year-v-dem-fullothers-v15/[23] Oxford Insights。（2023）。2023年政府人工智能准备度指数。Oxford Insights。https://oxfordinsights.com/wp-content/uploads/2023/12/2023-Government-AI-Readiness-Index-1.pdf[24] 斯坦福大学以人为本人工智能研究院（HAI）。《2024年人工智能指数报告》。斯坦福大学。https://hai.stanford.edu/ai-index/2024-ai-index-report[25] 欧洲议会与欧盟理事会。（2023）。《欧洲议会和欧盟理事会〈欧盟条例2023/1115〉》。《欧盟官方公报》。http://data.europa.eu/eli/reg/2023/1115/oj

附录

表 A1. AWPRI 构成变量、数据来源与覆盖范围

Code	变量	来源	层	n（国家）
养殖动物_人均_	人均养殖动物	联合国粮农组织 FAOSTAT [1]	L1	25
水产养殖_百分比	水产养殖产量占比（%）	联合国粮农组织 FAOSTAT [1]	L1	25
动物_权利_风险	动物权利立法框架（风险编码）	WA保护指数 [5]	L1	25
法治_指数_风险_	法治指数（风险编码）	V-Dem v15 [22]	L1	25
肉类_消费量_千克	人均肉类消费量（千克）	联合国粮农组织 FAOSTAT [1]	L1	25
动物_权利_变化	动物权利趋势得分（同比变化）	WA保护指数 [5]	L2	25
植物蛋白风险	植物蛋白风险指数	联合国粮农组织 FAOSTAT [1]	L2	25
公民空间风险	公民空间风险（风险编码）	V-Dem v15 [22]	L2	25
公民自由风险_ _	公民自由风险（风险编码）	V-Dem v15 [22]	L2	25
公众_关切_风险	公众关切代理指标	V-Dem v15 [22]	L2	25
人工智能_治理_风险	人工智能治理风险	Oxford Insights [23]	L3	25
人工智能福利研究风险 _ _ _	人工智能福利研究对齐风险	斯坦福人工智能指数 [24]	L3	25
人工智能感知能力风险 _ _	人工智能感知能力研究风险	斯坦福人工智能指数 [24]	L3	25
物种歧视偏见_比率_	人工智能系统中的物种歧视偏见比率	OpenAlex	L3	25
专利_强度	畜牧业人工智能专利强度	OpenAlex	L3	25

表 A2. 按风险等级划分的 2022 AWPRI 两两 Mann–Whitney U 检验及 Bonferroni 校正

A 级	B 级	U	p（未经校正）	p（Bonferroni 校正）	显著
危急	High	4	0.400	1.000	No
危急	中等	11	0.167	1.000	No
危急	Low	9	0.200	1.000	No
High	中等	44	0.001	0.009	是***
High	Low	36	0.003	0.017	Yes*
中等	Low	99	< 0.001	0.001	是***

注。 K 均值解中的关键层级样本数为 $= 1$ （中国为单例）； 涉及关键层级的比较应谨慎解读。* $p < 0.05$； *** $p < 0.001$。