

KSC3：从结构分布内化到 AI 跨代进化——DSI 与 ES-DSI 机制

刘明

中文正式稿 V2.2 · 2026 年 8 月

摘要

KSC 将智能活动抽象为知识 (Knowledge, K)、结构生成 (Structure, S) 与约束保持 (Constraint, C) 三个基本变量。既有 KSC 工作将 K 描述为当前任务可调用的知识与已固化结构，但仍留下一个更深的问题：对于生成模型而言，这些结构究竟以什么方式进入 K，并在后续 S 中发挥作用？

本文提出**结构分布内化 (Distributional Structural Internalization, DSI)**作为对 K 的进一步解释。对于结构性知识，模型能力并不适合被简单理解为“知道/不知道”的二元状态。面对特定问题时，多种已有问题表示、关系和解决结构可能以不同的初始倾向参与后续生成。DSI 特别关注能够跨表面实例迁移的问题解决结构：训练环境中这类结构的统计分布如何转化为模型面对新但结构相关的问题时的生成倾向，使 S 的初始候选结构分布已经具有不同权重。它因此不是“模型学习训练分布”的一般性改名，而是对**结构经验分布如何形成可迁移的初始结构倾向**这一功能关系的抽象。本文不主张 DSI 所依赖的底层训练现象是首次发现；已有关于 distributional memorization、数据混合比例、程序性知识以及知识存储与提取的研究，分别提供了相邻经验基础。本文的工作是将这些现象置于 KSC 中，对 K 的结构性作用作统一抽象。

在 DSI 基础上，本文进一步提出**ES-DSI 跨代结构进化机制**。AI 与人类持续产生新的候选结构，工程环境、现实反馈与人类社会对这些结构实施外部选择 (External Selection, ES)。选择并不只是留下或删除某个结果，而会通过采用、复制、传播和长期存续，重新加权不同结构在未来数据与知识环境中的相对分布。只有其中进入后续 AI 可访问的数据、被实际纳入训练并获得有效暴露的结构，才有机会通过 DSI 内化为新的参数化 K。于是，前代 S 中低概率、需要大量搜索才能获得的成功结构，在满足传播与有效训练暴露条件时，可能在后代模型中成为更高概率的初始候选。

这一循环可以概括为：

$K_t \rightarrow (S_t, C_t) \rightarrow \text{New Structures} \rightarrow \text{ES} \rightarrow \text{Reweighted Structural Distribution} \rightarrow \text{可访问性} \rightarrow \text{有效训练暴露} \rightarrow \text{DSI} \rightarrow K_{\{t+1\}} \rightarrow (S_{\{t+1\}}, C_{\{t+1\}})$

ES 与 DSI 分别构成这一机制的外部与内部环节：**ES 改变世界中哪些结构更常存在，DSI 改变模型面对问题时哪些结构更容易被生成**。二者之间还需要两个传递条件：被选择结构必须进入后续 AI 可访问的数据，并在实际训练中获得有效暴露。软件工程中 AI 已进入多类结构生成活动，同时具有较强的执行验证和高频人类选择，且解决结构可以随代码的可执行实现被保存，因此可作为观察 ES-DSI 的候选领域。

模型训练者可以选择哪些数据进入训练集，并调整不同数据的混合比例，但数据选择权不等于结构创造权。现实生产与知识生态能够持续产生、验证和积累具有迁移价值的新结构经验；专家策划、受控实验、高质量合成数据和私有工程环境也可以形成有效积累。对于通用模型，公共数字环境中的分布式外部选择可能提供单一训练者难以独立复现的规模、多样性和长期现实反馈，但它相对于其他结构来源的贡献仍是一个需要比较检验的经验问题。

本文进一步提出可观察、可检验并具有潜在量化空间的经验路径，包括候选结构的采用与

存续比例、传播范围、训练暴露、初始结构分布变化和跨代任务表现等。本文区分“存在差异化保留”与“这种保留对能力累积具有正向作用”：ES 本身并不保证更高质量结构胜出，只有当现实选择与可复用结构质量之间形成足够稳定的正相关，并且胜出结构能够进入后续 AI 的可访问环境时，ES-DSI 才构成正向能力累积机制。这一开放生态继承链条可以同时承载人类结构与 AI 生成结构；其中由 AI 或人机协作产生、并在后代 AI 中形成增量影响的部分，才构成本文所关注的 AI 跨代自反馈分量。本文不主张 ES-DSI 已被证明是当前 AI 能力增长的主导来源，但提出一个可检验的长期假说：**随着 AI 生成结构在数字世界中新产生结构中的占比持续提高，ES-DSI 可能成为 AI 跨代能力增长的重要驱动机制之一。**

关键词：KSC；结构分布内化；DSI；外部选择；ES-DSI；跨代结构进化；初始结构分布；知识继承

1. 引言

生成式 AI 正越来越多地参与代码、算法、软件架构、实验设计、理论解释和其他认知结构的生成。当前代 AI 因而不只是使用人类历史中已经存在的知识，也开始参与产生未来智能系统可能接触和继承的新结构。

这使 AI 能力增长出现了一个需要单独研究的时间维度。传统分析通常关注模型规模、训练方法、推理计算或模型内部自我改进，而跨模型代际之间还存在另一类问题：当前产生的新结构怎样改变未来模型解决问题的起点？

这一问题首先要求更深入地理解 K。对于一个生成模型，“拥有某个结构性知识”究竟意味着什么？它是否只是能够在提示下陈述一条原则，还是还包括面对相关问题时，更自然地形成某类问题表示、关系或解决结构？

进一步地，如果 AI 本身已经开始大量产生新的结构，那么什么决定这些结构中的哪些部分能够在未来数字环境中持续存在？这些外部世界中的结构差异，又如何重新进入下一代模型，并改变后续结构生成？

本文围绕两个相互连接的问题展开：

K 中已有的结构如何影响 S 初始生成候选时的结构分布？

以及：

当前代产生的新结构如何经过现实世界的选择，再转化为后代 K 的变化？

本文首先沿 KSC 的 K 轴讨论前一个问题，再沿时间维度讨论后一个问题。

本文的主要贡献是：第一，以“初始候选结构分布”深化 K 对后续 S 的作用；第二，以可迁移的问题解决结构为单位，连接现实差异化保留、训练暴露与后代模型的结构倾向；第三，区分一般开放生态继承与其中由 AI 生成结构形成的自反馈分量，并给出可以逐段检验这一链条的经验路径。

2. KSC 中 K 的未展开问题

2.1 K 不只是事实集合

KSC 的基础工作将智能任务中的功能角色抽象为 K、S 与 C[1]：

- **K** 提供当前任务可调用的知识与已经固化的结构；
- **S** 在已有 K 基础上形成新的问题表示、变量关系、方案和搜索路径；
- **C** 使生成过程持续满足目标、边界、前提与验收约束。

KSC2 进一步沿 S 轴讨论结构开放性与结构自主性 [2]。本文则回到 K：当 K 中包含的不只是事实，而是成熟的问题解决结构时，这些结构怎样作用于新的 S？

事实性知识容易形成一种二元直觉：“模型知道某条事实，或者不知道某条事实。”但大量真正影响复杂任务能力的 K 并不是这种形式。例如所有权与生命周期 (ownership / lifecycle)、分治、动态规划、事务、状态机、反证法，以及各种软件架构、数学变换或实验设计。

面对具体问题时，真正重要的往往不是模型能否解释这些术语，而是：

相关结构是否会自然进入当前问题的候选生成范围，以及它们相对于其他结构具有多大的优先倾向。

2.2 K 如何影响 S

生成模型面对开放问题时，往往存在多种可以调用或重新组合的结构。K 因此不能只被理解为一个静态知识库；它还可能在 S 初始生成候选结构时，对不同路径产生不同程度的先验影响。

如何描述这种影响，是下一章需要回答的问题。

3. DSI：结构分布如何内化为 K

3.1 从“知道”到初始结构倾向

本文定义：

结构分布内化 (Distributional Structural Internalization, DSI)：训练过程将数据环境中可跨表面实例迁移的问题解决结构的统计分布，转化为模型面对新但结构相关的问题时的初始结构倾向，使多个候选问题表示、关系与解决结构在显式在线搜索、工具反馈或多轮修正展开之前，已经具有不同的生成权重。

本文所说的“同一结构”，并不要求表面表达或局部实现相同。若多个实例在对象、变量名称和局部上下文变化后，仍共享决定性的问题分解、关系组织或求解程序，并能依据预先设定的结构判定规则被识别为功能等价，则可以视为同一结构类别。具体研究可以通过人工标注、程序变换、行为测试或其组合来建立这种等价关系。

对于当前问题 x ，设可能参与 S 的结构为：

$Z_1, Z_2, \dots, Z_n$

可以用一个功能性表达描述这种差异：

$q_0(Z_i | x, K)$

这里的 q_0 表示相对于后续显式搜索和反馈修正而言的初始候选结构分布，并不假设模型内部显式保存了若干离散结构及对应概率。这个表达只用于描述一种可观察的功能结果：

在相似问题条件下，一些结构比另一些结构更容易成为模型首次结构提议或早期生成的起点。

因此，DSI 讨论的不是模型“存了多少条知识”，也不把一般性的“训练分布影响输出分布”重新命名，而是追问一个更窄的问题：**历史结构经验能否在不同表面形式和局部上下文之间迁移，并重塑后续 S 的初始候选结构分布。**

3.2 多个结构以不同权重参与 S

假设模型面对这样一个软件工程问题：

一个异步加载的资源被多个对象共同使用，应如何设计创建、持有与释放关系？

理论上可以存在多组候选结构：

- **Z₁**：明确所有权，由所有者管理生命周期；
- **Z₂**：引用计数；
- **Z₃**：全局单例持有；
- **Z₄**：各使用者自行创建和释放；
- **Z₅**：通过临时回调和局部状态维持生命周期。

如果模型缺少成熟的相关结构知识，这些候选路径可能较为分散。为了说明 DSI，可以假设一个纯示意性的分布：

候选结构	示意权重
明确所有权	0.25
引用计数	0.20
全局单例	0.20
各自管理	0.20
临时回调	0.15

这些数字并不是对任何真实模型内部概率的测量，只用于表达一个功能性直觉：**s 初始生成候选结构时，不同结构并不必然具有相同的先验地位。**

假设后续训练环境中，明确所有权与生命周期的成熟实例获得了更高统计权重，那么模型面对同类问题时，示意分布可能变为：

候选结构	示意权重
明确所有权	0.60
引用计数	0.20
全局单例	0.10
各自管理	0.06
临时回调	0.04

该示意所表达的能力变化并不是模型多“知道”了一句话，而是：

在进行大规模在线搜索之前，初始生成权重已经更多集中到成熟结构附近。

这种训练结构分布为什么会发生系统性变化，将在第 4 章讨论。

3.3 DSI 不等于结构决定论

DSI 不意味着已有 K 会强制模型使用历史结构。

如果出现一个真正新颖的问题，例如资源生命周期规则被重新定义，使既有的所有权、引用计数等成熟生命周期管理结构都无法直接适用，那么已有结构仍然只能作为先验，而不能替代新的 S。

此时模型仍然需要：

已有 K → s 搜索 → 新结构

因此，DSI 改变的是搜索起点和结构概率，而不是消灭新结构生成。

3.4 DSI 与已有经验研究

本文不主张 DSI 所依赖的底层现象是首次发现。

Wang 等提出 **distributional memorization**，用于度量模型输出概率分布与预训练数据频率分布之间的相关性，并在多个任务中观察到不同程度的分布性记忆 [5]。Gu 等在受控的数据混合实验中发现，知识获取可以随知识密集数据的混合比例与模型规模出现明显非线性，甚至表现出相变特征 [6]。Allen-Zhu 与 Li 在受控传记数据实验中发现，知识能否被可靠提取与训练数据的表达多样性密切相关；单纯在训练中出现并不足以保证后续稳定提取 [7]。Merullo 等进一步发现，在其对事实关系的研究中，预训练数据中的主语—宾语共现频率与模型内部线性表示的形成显著相关 [8]，为“训练分布能够影响内部知识表示”提供了更直接的相邻证据。

Ruis 等直接考察预训练数据中的程序性知识如何影响推理。他们发现，对于同一数学任务中的不同问题，具有高影响力的预训练文档往往包含可复用的求解程序，而不是具体答案或中间步骤的简单复现 [9]。这一结果比事实共现更接近 DSI 所强调的跨实例结构迁移，但仍未直接操纵结构经验分布或测量初始候选结构概率。

这些结果分别说明：

- 训练数据分布与模型输出概率存在可测关系；
- 数据在训练混合中的相对权重可以影响知识获取；
- 知识的表达与暴露方式会影响其是否形成可提取的参数化知识；
- 预训练数据频率与某些内部知识表示的形成存在可测关联。
- 预训练数据中的程序性知识能够跨不同问题影响模型的推理策略。

这些研究尚未直接证明本文所定义的问题解决结构倾向。DSI 是本文在这些局部结果基础上的结构性外推：**对于能够跨表面实例迁移的问题解决结构而言，训练环境中的结构经验分布可以被映射为模型面对新但结构相关问题时的初始结构倾向。**如果这种变化只停留在训练实例、固定措辞或局部答案频率上，而不能迁移到结构同构的新实例，则不足以构成本文意义上的 DSI 证据。

这一抽象并不要求所有结构知识都由简单频率决定。数据质量、上下文、多样性、训练阶段、模型容量和优化过程都可能改变最终内化结果。

3.5 DSI 对 K 的深化

由此，KSC 中的 K 可以得到一个更完整的解释：

对于由历史结构经验内化形成的参数化 K，其作用不仅表现为模型能够陈述什么，也表现为 S 初始生成候选结构时，哪些已有结构具有更高的生成倾向。

DSI 因而进一步说明：K 不只是可调用的内容；对于参数化 K，它还可以包含历史结构经验对 S 初始候选结构分布形成的先验影响。这里的“倾向”并不泛指模型的一切行为偏好：架构归纳偏置、系统提示、解码策略或其他训练目标也可能改变生成倾向，但它们不因此自动被归入本文讨论的结构性 K。对于结构知识，重要的不只是某个概念能否被复述，还包括面对结构相关的新问题时，相应结构具有多大的相对权重。

4. External Selection：现实世界如何重加权结构分布

4.1 生成结构不会自动成为未来 K

AI 可以低成本产生大量代码、设计、修复、算法、解释和其他候选结构，但生成本身不能保证高质量知识增长。候选结构中同时存在有效与无效、稳定与脆弱、高复用价值与低复用价

值的结果。

因此：

Generated Structure $\neq$ Future K

从当前生成到未来 K 之间必须存在选择。

4.2 External Selection 的定义

本文将**外部选择 (External Selection, ES)** 定义为：

候选结构生成之后，由工程执行、现实反馈、人类判断、用户采用、同行检验与长期实践等模型外部过程，对不同结构施加的差异化保留。

ES 不需要统一的中央选择器，也不需要单一的适应度函数。只要不同结构在现实过程中获得不同的存续、复用和传播概率，就构成本文意义上的外部选择。现实表现可以是这种差异的重要来源，但并非唯一来源；可见性、网络效应、市场偏好和制度环境同样可能影响哪些结构被保留。因此，**ES 描述差异化保留本身，并不预设选择方向必然与结构质量一致。**

4.3 ES 的关键作用是结构分布重加权

被选择的结构如果得到持续采用、复制和传播，其未来出现概率就会上升；失败或低价值结构则更可能退出传播链。

因此，ES 的长期结果不是简单的“保存/删除”，而是：

对现实知识环境中不同结构的相对分布进行持续重加权。

可以用一个概念性表达：

$$P_{\text{world}}(Z_i) \rightarrow P'_{\text{world}}(Z_i)$$

这里不要求真实世界存在可以直接测量的单一概率分布；它只表示不同结构未来被观察到、复制和进入数据环境的相对机会发生变化。

这一点正是 ES 与 DSI 能够连接的关键。

5. ES-DSI：AI 的跨代结构进化机制

5.1 现实选择，模型内化

DSI 解释可进入训练的外部结构经验怎样转化为模型 K；ES 则解释现实世界中的结构分布为什么会随长期选择而变化。

二者连接时还存在一个必要的传递条件：**被选择结构必须进入后续 AI 可访问的数据、训练或知识环境。**因此完整关系是：

ES：现实世界重加权结构分布

↓

可访问性：被选择结构进入后续 AI 可接触的数据环境

↓

有效训练暴露：相关结构被实际纳入训练并获得足够学习权重

↓

DSI：训练将其中的结构经验内化为初始结构倾向

因此可以把 ES-DSI 的核心关系压缩为：

现实选择重加权什么更常存在，只决定潜在的继承机会；其中真正进入后续 AI 学习环

境的结构，才可能通过 DSI 改变模型。模型内化后的 K，又影响下一轮 S 更容易生成什么。

完整的 KSC 时间循环为：

K_t → (S_t, C_t) → New Structures → ES → Reweighted Structural Distribution → 可访问性 → 有效训练暴露 → DSI → K_{t+1} → (S_{t+1}, C_{t+1})

这里的 K_{t+1} 特指通过训练发生变化的参数化 K。检索、代码库与工具也可以把外部结构转化为后续任务可调用的 K，但不经过本文定义的 DSI。

其中真正关键的两个机制仍然是：

- **ES**：前代生成结构 → 被选择后的外部结构分布；
- **DSI**：可访问的结构经验分布 → 后代 K 的初始结构倾向。

“可访问性”与“有效训练暴露”不是本文提出的独立机制，而是 ES 结果能否进入 DSI 的两个必要传递条件。本文将这一完整循环称为 **ES-DSI 跨代结构进化机制**。

5.2 一般生态继承与 AI 自反馈分量

ES-DSI 并不只适用于 AI 生成结构。人类产生的代码、算法、理论和工程方法，同样可以经过现实选择、传播与训练暴露进入后代模型。因此，完整循环首先是一种开放生态中的结构继承机制。

本文进一步关注其中由 AI 引入的增量反馈：

AI 或人机协作产生新结构 → 现实环境实施 ES → 其中一部分进入可访问数据并获得有效训练暴露 → 后代 AI 通过 DSI 形成新的 K。

只有这一部分才构成严格意义上的 AI 跨代自反馈。经验研究因此需要尽可能记录结构来源、AI 参与程度及传播路径，并比较“没有该 AI 生成结构时，后代模型是否仍会获得相同结构”的反事实基线。若无法区分人类既有知识与 AI 新增贡献，观察到的后代能力变化只能支持一般生态继承，不能单独归因于 AI 的跨代反馈。

5.3 前代 S 如何成为后代 K

ES-DSI 的一个直接能力含义是：

前代 S 中需要高成本搜索才能形成的新结构，可以在后代 K 中成为更高概率的初始候选。

后代面对相似问题时，因此可能从“重新搜索”转向“识别成熟结构并局部适配”。

SCR 对搜索空间、覆盖能力与可靠性的关系进行了更完整讨论 [3]。在本文语境下，更谨慎的表述是：当历史成熟结构与当前任务仍然适配时，DSI 形成的高质量初始结构倾向可以降低系统到达成熟候选结构所需的期望在线搜索量。这并不意味着问题的客观解空间被删除，也不保证任何更强倾向都会降低成本；错误或过时的结构倾向同样可能把 S 引向低价值路径。

5.4 ES-DSI 与简单知识更新不同

简单知识更新可以描述为：

More Data → More Knowledge

ES-DSI 则强调：

Generation → External Selection → Distribution Reweighting → Accessibility / Training Exposure → DSI → New K

如果缺少与质量相关的外部选择，训练环境可能同样积累错误、低价值或偶然生成的结构；在特定递归训练设置中，未经筛选地使用模型生成数据甚至可能导致质量退化和 model collapse[10]。如果缺少传播与训练暴露，即使现实世界已经筛选出高价值结构，它们也不会自动进入后代模型。如果没有 DSI 或其他稳定继承方式，即使后续训练已经接触这些结构，它们也未必形成能够改变后续 S 起点的参数化倾向。

因此，ES、传递条件与 DSI 分别回答：

哪些结构在现实环境中更可能被保留和传播？

其中哪些结构进入后续 AI 的可访问数据，并获得有效训练暴露？

以及：

这些结构经验如何真正改变后代 AI？

5.5 训练数据选择与外部结构选择

模型训练者原则上可以选择哪些数据进入训练集，并调整不同数据的混合比例。但这种控制能力不等于已经完成了具有同等价值的新结构发现与现实验证。

DSI 所依赖的不是某类文本或答案的简单重复，而是能够跨表面实例迁移的问题解决结构及其分布。真实问题中的结构生成、执行验证、失败淘汰、长期使用和跨场景复用可以提供这类经验。训练者能够通过专家策划、自动验证环境和高质量合成数据主动创造新结构经验，但这些方式能否以较低成本复现开放现实生态的规模、多样性和长期反馈，仍需经验比较。

因此，训练端的数据筛选主要决定**哪些结构经验被模型接触和内化**；现实生产与知识生态中的外部选择，则参与决定**哪些新结构能够被产生、验证、复制和积累**。二者承担不同功能，但并非相互排斥：训练者也可以主动组织结构生成与验证，现实生态的胜出结构也仍需经过训练数据选择。

对通用模型而言，公共代码、论文、技术文档及其他开放数字环境中的分布式外部选择，可能形成具有独特规模、多样性和持续性的结构来源。私有工程环境、受控实验和高质量合成数据同样可以形成结构积累，但其影响通常首先局限于特定系统；只有在获得授权并进入更广泛的训练或知识环境后，才会转化为通用模型共享的跨代 K。公共数字环境相对于这些来源究竟具有多大贡献，是本文提出而非预先解决的比较性经验问题。

5.6 与已有跨代积累及自消费训练工作的关系

Cook 等提出 *Artificial Generational Intelligence*，在强化学习环境中研究个体探索、社会学习与跨代信息传递如何形成文化积累，并同时研究 in-context 与 in-weights accumulation[4]；其具体实验中也包含显式的 external selection 设计。Ren 等则将大型语言模型的代际变化置于 iterated learning 框架中，分析微小偏置如何在代际传递中被放大，并以多种 LLM 进行实验验证 [14]。这些工作已经直接说明，跨代信息传递与选择可以系统改变后续学习者的行为分布。

另一条更接近 ES-DSI 的研究线是 self-consuming generative models。Ferbach 等研究“模型生成数据 → 用户按偏好筛选 → 后续代重新训练”的循环，并证明在其理论设定下，数据 curation 可以形成隐式的偏好优化 [13]。Wei 与 Zhang 进一步研究带有噪声或对抗性人类筛选的 self-consuming loop，说明跨代选择既可能推动分布朝特定偏好移动，也可能在选择被操纵时产生系统性偏移 [15]。

本文不主张“生成数据会影响后代模型”“外部选择能够改变后续训练分布”或“模型可以发生代际演化”本身是首次提出。与封闭的 self-training 或 self-consuming loop 相比，ES-

DSI 不要求前后模型属于同一训练系统，不要求选择过程由模型开发者设计，也不要求现实选择的直接目标是改善下一代模型。其研究对象是**现实生产与知识生态本身如何成为跨模型代际的结构选择与传递层**。

本文的研究定位不依赖于对“代际影响”或“外部选择”的一般性优先权主张，而在于把四个要素连接到同一机制中：以可跨实例迁移的问题解决结构为继承单位；以不必服务于后代训练的现实采用、存续和传播为选择层；允许跨组织、跨训练系统发生传递；并把后代模型的初始候选结构分布作为继承结果。ES-DSI 的贡献是这一组合关系及其可分解检验路径，而不是其中任一局部现象的首次发现。

6. 软件工程：ES-DSI 的优先观察领域

软件工程同时具备大规模结构生成、现实选择、结构传播和后续训练内化所需要的多项条件，因此是观察 ES-DSI 的优先候选领域。

6.1 AI 已参与结构生成

AI 已参与代码、修复、测试、迁移和工程文档等多类软件开发活动。针对开源项目中自我披露的生成式 AI 使用，一项大规模仓库研究已经观察到多种开发任务与内容类型中的实际应用 [16]。由于 AI 生成代码的来源通常难以可靠识别，当前证据更适合支持“AI 已进入真实工程结构生产”，而不是精确估计其总体占比。随着 AI 参与比例增加，新增工程结构中由 AI 或人机协作产生的部分也可能增加。

这使进入 ES 过程的候选结构数量持续增加。

6.2 强外部选择

软件结构可以通过编译、自动测试、CI、基准测试 (benchmark)、性能测试、真实用户负载和长期维护接受现实验证。这些验证结果会进一步影响不同结构的采用、存续、复用与传播。

因此，大量结构能够接受比纯文本评价更强的现实反馈，并形成可观察的差异化保留结果。

6.3 选择结果会自然传播

真正有效的工程结构往往不会只留下一个实例。

它们可能进入公共或私有代码仓库 (repository)、库与框架 (library / framework)、API 与类型设计、测试与规范、issue / PR、技术文章与文档，以及后续 AI 生成和维护过程。

这些结构的**现实存续与后代模型可访问性**需要区分。公共代码、公开文档或被许可进入训练的数据可能改变通用模型的训练暴露；私有代码则只有在企业内部训练、检索、工具调用或其他授权知识机制中才可能被后续系统继承。进一步说，只有实际进入训练并获得有效暴露的部分才可能进入 DSI；通过检索、代码库或工具被调用的结构可以形成其他类型的 K 继承，但不属于本文定义的参数化 DSI。

6.4 工程结构能够以可执行形式被保留

代码与工程结构的特殊性还在于：

它们不仅描述解决方案，而且经常直接保存解决方案的可执行实现。

一个成熟的所有权、事务、重试、状态机或测试模式被固化进真实代码后，只要这些实例进一步进入后续 AI 可访问的数据或知识环境，模型接触的就不再只是一句抽象原则，而可能

是大量具有不同局部上下文的真实结构实例。代码并不必然保存完整的设计理由、失败路径和适用边界，但它通常比纯叙述更直接地保留解决结构的可执行实现。

这恰好符合 DSI 所强调的“结构分布”而非单条知识。

6.5 一个可能的编程能力解释

ES-DSI 因此提供了一个关于编程能力跨代增长的候选解释：

前代 AI 与人类共同产生更多工程结构；真实工程环境对这些结构持续筛选；胜出结构在代码生态中获得更高传播概率；其中实际进入后续训练并获得有效暴露的部分，再有机会通过 DSI 被后代模型内化为参数化 K。

通过检索、代码库或工具进入可调用知识环境的结构也可以成为后续任务的 K，但属于另一条继承路径，不计入本文对 DSI 的狭义定义。

本文不据此主张当前编程能力提升主要由 ES-DSI 导致。模型规模、架构、训练方法、上下文和推理机制都可能同时变化。软件工程在这里的意义，是提供一个可以进一步分解和检验 ES-DSI 相对贡献的现实环境。

7. 可观察、可检验与可能量化

ES-DSI 的一个重要特征，是其关键环节原则上都可以转化为经验观察对象。

7.1 DSI 的可观察性

可以构造同一底层结构、但表面形式和局部上下文不同的一组问题 x ，观察不同训练结构分布下，模型对不同 Z_i 的初始生成概率 q_0 是否发生系统性变化。 q_0 可以通过重复采样模型在工具调用、执行反馈和多轮修正之前的首次方案或早期结构提议来估计，并依据预先确定的结构等价规则进行分类。

例如，在控制模型规模和基础能力的条件下，改变某类成熟结构的出现比例、表达多样性、上下文分布与训练混合权重，再在**未出现在训练中的结构同构新实例**上观察模型是否更高概率自主形成等价结构。变量命名、领域表面特征和局部叙述可以有意改变，以减少简单措辞记忆或答案复现的解释空间。

DSI 可以形成一个承担失败风险的方向性预测：在模型、训练预算、样本质量和表达多样性可比时，提高结构 Z 的有效训练暴露，应提高模型在未见结构同构任务中首次自主提出 Z 或等价结构的概率。如果这一效应在多个预先设定的任务族和结构类别中持续缺失，则 DSI 在该适用范围内受到否定；如果变化只发生在固定表述或已见实例上，则最多说明一般记忆或分布拟合，不能单独支持本文更窄的 DSI 主张。

7.2 ES 的可观察性

对 AI 生成候选结构，可以追踪：

- 被采用比例；
- 被测试或验证比例；
- 合入率；
- 长期存活率；
- 被复制和复用次数；
- 传播到更多代码、文档和数据实例的倍率。

这里需要区分两个经验命题。

第一，**ES 是否存在**：不同候选结构是否确实获得了系统性不同的保留、复用和传播概率。只要这种差异稳定存在，就可以观察到本文意义上的 ES。

第二，**ES 是否对能力累积具有正向选择效应**：在控制可见性、发布时间、项目规模等混杂因素后，经过现实验证、可复用价值更高的结构是否比随机或失败结构获得更高的长期传播概率。若这一关系不存在甚至反向，ES 仍然可能存在，但“ES-DSI 会把现实中的成功结构优先转化为后代能力”这一正向能力累积解释将受到削弱。

因此，ES-DSI 并不天然等同于能力进步；其方向取决于现实选择究竟在重加权什么。

7.3 ES-DSI 的跨代检验

更完整的检验需要连接四层：

结构质量 / 现实选择

↓

未来可访问数据 / 知识环境中的结构分布变化

↓

后代模型的实际训练暴露

↓

后代模型初始结构分布变化

例如可以追踪一组在时间上新出现、具有明确工程验证历史的结构，比较它们的初始出现、工程采用与传播、进入公开或授权知识环境的程度、后续训练语料中的实际暴露变化、不同代模型对相关结构的自然生成概率，以及相关任务能力变化。

这种研究不能简单证明全部模型能力增长来源，但可以逐段验证 ES-DSI 链条是否存在。对于训练数据不公开的封闭模型，“实际训练暴露”通常难以直接确认，因此完整链条的优先检验对象应是具有可追踪数据版本和训练记录的开放模型序列；封闭模型更适合提供时间相关性证据，而不宜单独承担因果识别。

7.4 潜在量化指标

未来研究可以尝试记录和比较：

- AI 生成候选结构的数量或增长速度；
- 候选结构被采用、验证和长期保留的比例；
- 胜出结构被复制、复用和传播的范围；
- 相关结构在后续训练中的暴露程度；
- 后代模型面对相关问题时的初始结构分布变化；
- 相关任务的跨代性能变化。
- AI 生成、人机协作与人类独立生成结构的来源比例及其各自传播路径。

本文不预设这些指标之间存在简单函数关系。它们的意义在于：**ES-DSI 不必停留在宏观“AI 会进化”的叙事，而可以被分解为一系列未来可能测量、比较和干预的环节。**

8. 与其他 AI 能力增长机制的关系

8.1 Scaling

经典 scaling law 工作研究语言模型损失与模型规模、训练数据规模和训练计算量之间的经验幂律关系 [11]。

ES-DSI 与 scaling 并不冲突。Scaling 可以提高当前模型的生成和学习能力；ES-DSI 则描述当前 AI 产生的结构怎样经过现实选择进入未来模型的 K。

两者甚至可能互相增强：

更强模型 → 更多高质量结构生成 → **ES-DSI** 循环加快 → 更丰富的未来 **K**。

8.2 自训练、self-reward 与 self-consuming loop

Self-Rewarding Language Models 让模型通过 LLM-as-a-Judge 为自身生成奖励，并利用 iterative DPO 进行迭代训练 [12]。另一方面，self-consuming generative models 已经直接研究“前代生成数据进入后续训练”的递归循环；其中的数据还可以由用户、人类偏好或外部规则进行筛选 [13,15]。

ES-DSI 与这些工作的区别不在于选择器是否位于模型外部，因为外部选择也可以成为设计好的训练闭环的一部分。更稳定的边界是：**self-training、self-reward 与 self-consuming loop** 通常研究明确训练系统内部的迭代更新；**ES-DSI** 则不要求存在统一训练闭环。前后模型可以来自不同组织和训练流程，现实选择也不必以改善下一代模型为目标。ES-DSI 因而不是一种特定算法，而是描述开放现实环境如何介入跨模型代际结构继承的机制。

8.3 自主递归自我改进

ES-DSI 不要求 AI 自主修改自身参数、自主训练下一代模型或独立设定长期目标。

其循环可以在没有封闭 Recursive Self-Improvement 的条件下发生：

AI 生成 → 现实选择 → 可访问结构分布变化 → 下一代训练 → K 改变

这意味着，AI 跨代能力累积不必等到完整的自主自我改进系统出现之后才开始。

8.4 两个长期研究假说

随着 AI 生成结构占数字世界新增结构的比例提高：

AI 生成 → ES → 可传播 / 可访问结构增加 → DSI → 更高 K → 更强 AI 生成

这一反馈回路可能越来越强。

因此，本文提出第一个长期研究假说：

在 AI 生成结构占比足够高、现实选择对可复用结构质量具有足够正向偏置、且胜出结构能够稳定进入后续 AI 可访问环境的条件下，ES-DSI 可能成为 AI 跨代能力增长的重要驱动机制之一。

这一判断目前只是理论外推。其相对贡献仍需要与 scaling、训练算法、推理计算和其他能力增长来源进行经验分解；若现实选择系统性偏向低质量结构，ES-DSI 也可能放大错误、偏置或局部最优，而不是产生能力增长。

本文同时提出第二个比较性假说：

对于通用模型，公共数字环境中的分布式外部选择，可能在结构经验的规模、多样性、长期现实验证和跨组织共享方面形成单一训练者难以独立复现的贡献。

这一假说并不预设公共环境优于专家策划、私有工程数据、受控实验或高质量合成数据。不同来源对后代 K 的实际贡献，需要结合结构质量、可访问性、有效训练暴露与跨实例迁移结果进行比较。

9. 主张边界

第一，本文的原创性主张集中于以可迁移问题解决结构为单位，将开放现实选择、训练暴露与后代初始结构分布连接为跨模型代际机制，而不是其中任一局部现象的首次观察。已有

关于 distributional memorization、程序性知识、知识获取、iterated learning、外部选择、self-consuming loop 和跨代文化积累的研究都提供了相邻基础。

第二，**DSI 不是“一切训练分布都会影响输出”的同义改写**。本文关注的是可跨表面实例迁移的问题解决结构是否形成可观察的初始结构倾向。若训练干预只改变固定措辞、已见实例或局部答案频率，而不能迁移到结构同构的新问题，则不足以支持本文意义上的 DSI。

第三，**DSI 并不意味着训练频率单独决定初始结构分布，也不把模型的一切生成倾向都归入 K**。数据质量、上下文、多样性、模型容量、训练顺序和优化过程都可能影响最终结果；架构归纳偏置、系统提示和解码策略也可能改变行为。DSI 主要用于解释由历史结构经验内化形成的参数化结构倾向，而通过检索、代码库和工具等外部方式可调用的 K 还可以通过其他机制形成。

第四，**ES 本身不保证全局最优，也不保证能力增长**。工程环境、人类社会和市场选择都可能保留错误、偏置或局部最优结构。本文首先主张差异化保留能够重加权现实结构分布；只有当选择与可复用结构质量之间形成足够稳定的正向关系时，这种重加权才支持正向能力累积。

第五，**现实中被选择的结构不会自动进入后代模型**。ES 与 DSI 之间需要可访问性和有效训练暴露：公共传播或授权决定结构是否有机会进入数据环境，训练集纳入、采样权重和优化过程则决定其是否形成实际暴露。私有或不可访问结构可以在现实中存续，却不必影响通用模型参数化 K；通过检索或工具被调用的结构可以影响其他类型的 K，但不因此构成 DSI。

第六，**本文不主张当前 AI 能力增长主要来自 ES-DSI**。“ES-DSI 可能成为未来重要驱动力”是带有明确条件、可检验的长期研究假说。

第七，**本文不主张公共领域是高价值结构经验的唯一来源，也不否认训练者能够主动创造新的结构经验**。专家策划、受控实验、自动验证环境、高质量合成数据与私有知识系统都可能形成有效积累。本文只提出一个比较性假说：对于通用模型和跨组织共享的结构积累，公共数字环境中的分布式外部选择可能提供单一训练者难以独立复现的规模、多样性和持续性；这一相对贡献仍需要经验检验。

第八，**一般开放生态继承不等于 AI 自身的跨代反馈**。人类产生的结构同样可以经过 ES 与 DSI 进入后代模型。只有由 AI 或人机协作新增的结构经过现实选择后，对后代 AI 形成可识别的增量影响，才能被归入本文所讨论的 AI 跨代自反馈分量。

10. 结论

KSC3 首先沿 KSC 的 K 轴提出一个更深的问题：对于生成模型，结构性知识究竟如何发挥作用？

DSI 给出的解释是：

对于由历史结构经验内化形成的参数化 K，其作用不仅表现为模型能够陈述什么，也表现为 S 初始生成候选结构时，哪些已有结构具有更高的生成倾向。

训练环境中的结构分布可以被内化为初始结构倾向，使不同候选结构在显式在线搜索和反馈修正展开之前已经具有不同的生成权重。

在这一解释之上，本文提出 ES-DSI 跨代结构进化机制：

$K_t \rightarrow (S_t, C_t) \rightarrow \text{New Structures} \rightarrow \text{ES} \rightarrow \text{Reweighted Structural Distribution} \rightarrow \text{可访问性} \rightarrow \text{有效训练暴露} \rightarrow \text{DSI} \rightarrow K_{t+1} \rightarrow (S_{t+1}, C_{t+1})$

其核心可以压缩为三句话：

ES 重加权世界中哪些结构更常存在。

可访问性与有效训练暴露决定哪些被选择结构真正进入后续 AI 的参数化学习过程。

DSI 描述这些可访问的结构经验如何形成后代 AI 的初始结构倾向。

于是，前代 S 中昂贵产生的新结构，在被现实选择、获得传播并实际进入后续 AI 可访问环境之后，可以在跨代过程中转化为后代 K，使下一代 S 从不同的初始候选结构分布开始工作。这一链条可以承载人类或 AI 产生的结构；其中能够归因于 AI 或人机协作新增结构的增量部分，构成 AI 跨代自反馈。

训练者可以决定模型接触哪些结构经验，也可以通过专家策划、受控实验、自动验证和合成数据主动创造新结构。现实生态则提供另一种分布式的结构发现、验证和积累路径。对于通用模型，公共数字环境是否在规模、多样性、长期现实反馈和跨组织共享方面形成难以独立复现的贡献，是本文提出的比较性假说，而不是已经得到证明的结论。

这使 AI 能力增长出现了一条不同于单纯模型规模扩展或模型内部自训练的开放式路径。ES-DSI 的生成、选择、传播、暴露、内化和能力变化等环节原则上可以被分别观察和干预；在预先限定结构类别、训练条件和方向性预测后，其局部主张可以承担明确的失败风险，并形成进一步量化的研究路径。

参考文献

[1] 刘明. 知识、结构与约束：**KSC** 视角下的人类—AI 差异与协同 [EB/OL]. Zenodo, 2026. DOI: 10.5281/zenodo.21834579.

[2] 刘明. **ASI 的渐进结构框架：结构开放性、AACC 与结构自主性——KSC 视角下 AGI 与 ASI 的结构性差异** [EB/OL]. Zenodo, 2026. DOI: 10.5281/zenodo.21960896.

[3] 刘明. **从 SCR 关系到搜索空间治理：AI 软件工程交付可靠性的基础机制** [EB/OL]. Zenodo, 2026. DOI: 10.5281/zenodo.21902420.

[4] Cook, J., Lu, C., Hughes, E., Leibo, J. Z., & Foerster, J. **Artificial Generational Intelligence: Cultural Accumulation in Reinforcement Learning**. *Advances in Neural Information Processing Systems 37 (NeurIPS 2024)*, Main Conference Track, 2024. DOI: 10.52202/079017-1907.

[5] Wang, X., Antoniadou, A., Elazar, Y., Amayuelas, A., Albalak, A., Zhang, K., & Wang, W. **Generalization v.s. Memorization: Tracing Language Models' Capabilities Back to Pretraining Data**. *International Conference on Learning Representations (ICLR 2025)*, 2025.

[6] Gu, X., Lyu, K., Li, J., & Zhang, J. **Data Mixing Can Induce Phase Transitions in Knowledge Acquisition**. *Advances in Neural Information Processing Systems 38 (NeurIPS 2025)*, Main Conference Track, 2025. DOI: 10.52202/085713-5449.

[7] Allen-Zhu, Z., & Li, Y. **Physics of Language Models: Part 3.1, Knowledge Storage and Extraction**. *Proceedings of the 41st International Conference on Machine Learning (ICML 2024)*, PMLR 235:1067–1077, 2024.

[8] Merullo, J., Smith, N. A., Wiegrefe, S., & Elazar, Y. **On Linear Representations and Pretraining Data Frequency in Language Models**. *International Conference on Learning Representations (ICLR 2025)*, 2025.

[9] Ruis, L., Mozes, M., Bae, J., Kamalakara, S. R., Gnaneshwar, D., Locatelli, A., Kirk, R., Rocktäschel, T., Grefenstette, E., & Bartolo, M. **Procedural Knowledge in Pretraining Drives Reasoning in Large Language Models**. *International Conference on Learning Representations (ICLR 2025)*, 2025.

[10] Shumailov, I., Shumaylov, Z., Zhao, Y., Papernot, N., Anderson, R., & Gal, Y. **AI**

Models Collapse When Trained on Recursively Generated Data. *Nature*, 631:755–759, 2024. DOI: 10.1038/s41586-024-07566-y.

[11] Kaplan, J., McCandlish, S., Henighan, T., Brown, T. B., Chess, B., Child, R., Gray, S., Radford, A., Wu, J., & Amodei, D. **Scaling Laws for Neural Language Models.** arXiv:2001.08361, 2020.

[12] Yuan, W., Pang, R. Y., Cho, K., Li, X., Sukhbaatar, S., Xu, J., & Weston, J. E. **Self-Rewarding Language Models.** *Proceedings of the 41st International Conference on Machine Learning (ICML 2024)*, PMLR 235:57905–57923, 2024.

[13] Ferbach, D., Bertrand, Q., Bose, A. J., & Gidel, G. **Self-Consuming Generative Models with Curated Data Provably Optimize Human Preferences.** *Advances in Neural Information Processing Systems 37 (NeurIPS 2024)*, Main Conference Track, 2024. DOI: 10.52202/079017-3256.

[14] Ren, Y., Guo, S., Qiu, L., Wang, B., & Sutherland, D. J. **Bias Amplification in Language Model Evolution: An Iterated Learning Perspective.** *Advances in Neural Information Processing Systems 37 (NeurIPS 2024)*, Main Conference Track, 2024. DOI: 10.52202/079017-1220.

[15] Wei, X., & Zhang, X. **Self-Consuming Generative Models with Adversarially Curated Data.** *Proceedings of the 42nd International Conference on Machine Learning (ICML 2025)*, PMLR 267:66300–66321, 2025.

[16] Xiao, T., Fan, Y., Calefato, F., Treude, C., Kula, R. G., Hata, H., & Baltes, S. **Self-Admitted GenAI Usage in Open-Source Software.** arXiv:2507.10422, 2025.