

不同支持方式下学习者的认知负荷与学习收益关系的学习分析研究

Same Load, Different Gains:

Learning Analytics of Cognitive Load and High Effort-Low Gain Learners under Different Support Conditions

李晓宇¹, 尚俊杰^{1*}

¹ 北京大学教育学院

lixiaoyu25@stu.pku.edu.cn

【摘要】本研究基于学习科学理论,以英语写作任务为情境,探究不同学习支持方式对学习者的认知负荷与学习收益的影响机制,并采用随机森林模型有效识别出一类高努力-低收益(HELG)学习者。结果显示,不同支持方式并未显著改变学习者的总体认知负荷水平,但组间学习收益有显著差异,其中AI支持组在总体写作表现及高阶内容维度上表现最优。学习支持通过重塑认知负荷结构而非降低负荷总量发挥作用,具体表现为降低外部认知负荷、提高内部与相关认知负荷的有效投入,从而优化认知资源配置。本研究为理解GAI支持学习的作用机制及优化学习支持设计提供了实证依据。

【关键词】认知负荷;学习支持方式;学习收益;高努力-低收益学习者;学习分析

Abstract: This study investigated learners' cognitive load allocation patterns and learning gains under four support conditions in an English writing task, grounded in learning science theories. A random forest model was used to effectively identify a group of HELG learners. The results showed that different support methods did not significantly change the overall cognitive load level of learners, but there were significant differences in learning gains between groups. The AI support group performed the best in overall writing performance and the high-order content dimension. Learning support reshapes the cognitive load structure by reducing external cognitive load and improving the effective input of internal and related cognitive loads, thereby optimizing the allocation of cognitive resources. This study provides empirical evidence for understanding the mechanism of GAI-supported learning and optimizing the design of learning support.

Keywords: Cognitive Load, Learning Gains, High-Effort-Low-Gain (HELG), Random Forest, Learning Analytics

1. 引言

随着生成式人工智能(GAI)的快速发展,学习情境中的支持方式变得更加多元化。以对话式交互、即时反馈与个性化建议为特征的GAI,逐渐成为学习者在完成复杂学习任务时的重要支持来源。在英语写作任务中,一方面学习者可以获得人类教师的指导与反馈;另一方面,Chat GPT等GAI工具也可以为学习者解答问题、提供修改建议并给出相应示例;此外,写作检查类工具也可对语法、表达与结构给出提示。尽管不同支持方式在实践中被普遍认为有助于提升学习效果(Luckin, R. & Holmes, W. & Griffiths, M. & Forcier, L. B., 2016),但现有研究多聚焦于学习结果层面的比较,而对支持过程中学习者的认知资源分配机制关注不足。因此探究不同支持方式下学习者的认知负荷是否存在差异,以及学习者投入的认知资源能否被有效转化为学习收益具有重要意义。

从认知负荷的理论视角看,在英语写作任务中,学习者往往需要在任务理解、信息整合、策略决策与反复修订之间进行持续的认知投入。学习者在任务过程中同时承受由任务复杂性引发的内部认知负荷、由支持方式与信息呈现引入的外部认知负荷,以及用于理解、整合与图式建构的相关认知负荷。(John Sweller & Paul Ayres & Slava Kalyuga, 2011)对于学习支持的评估,关键在于支持方式是否能减少与目标无关的无效消耗,促进学习者将认知资源投入到任务核心理解与意义建构中,从而提升学习收益。(John Sweller, 1988)若支持方式未提供有效脚手架,则部分学习者会在主观上认为自己付出了高努力和高投入,但是客观成绩的提升却不尽如人意,本文将这类学习者定义为一种高努力-低收益(HELG)的群体。该现象不

仅影响学习体验,也为学习分析与教学干预提出挑战:如果不同支持方式并未显著改变总体认知负荷,却改变了负荷的构成与分配,那么学习失败或低收益的关键原因可能并非努力不足,而是努力被消耗在无效或低效的认知加工上,那么单纯增加支持或强化要求,反而可能加剧认知过载风险。

因此,本研究以英语写作与修订任务为情境,基于以下四种学习支持条件:AI支持、教师支持、工具支持与无支持开展对比研究:第一,通过对比不同支持条件下学习者的总体认知负荷水平与认知负荷分配模式,探究不同支持方式在提升学习收益方面的机制差异;第二,分析AI组与人类教师组中认知负荷水平与学习收益的关系,并用随机森林方法进一步识别高努力-低收益(HELG)学习者。

2.研究方法

2.1 实验设计

本实验由前测、两阶段正式实验与后测四个部分组成。前测阶段,通过问卷收集被试基本信息、先验知识水平及对GPT与人类教师的判断;正式实验1阶段要求被试观看教学视频、完成读写任务并提交写作初稿;正式实验2阶段为写作修订任务,设置四组条件:控制组(CN,无支持)、教师支持组(HE,人类教师支持)、AI支持组(AI,GPT对话支持)以及写作检查工具支持组(CL,Checklist工具支持),被试经随机分组后在不同支持条件下,对初稿进行修订并提交终稿;后测阶段,通过问卷测量后测知识、迁移能力与情感态度,并结合访谈及对GPT与人类评分的反馈数据进行补充分析。

2.2 认知负荷指标体系构建

认知负荷理论认为人类工作记忆在容量和加工时间上均存在显著限制,而学习过程本质上是对有限认知资源的分配与调控过程。当学习任务对工作记忆提出的加工需求超过个体可承载水平时,便会产生认知超载,从而抑制有效学习的发生(蔡艳玲,2009)。经典三分模型将认知负荷划分为三类,分别是内部认知负荷、外部认知负荷与相关认知负荷。现有研究指出,认知负荷测量需要同时解决三个核心问题:构念界定、观察指标选择以及解释效度,否则即便获得数据,也难以对学习过程作出有效解释(王小明,2021)。

当前,认知负荷的测量方法主要可归为三类:主观测量法、行为测量法以及生理测量法(李金波&许百华,2009)。相比之下,由美国国家航空航天局开发的多维度工作负荷任务指数NASA-TLX,被认为是当前应用最为广泛且最具代表性的认知负荷测量工具之一(蔡艳玲,2009)。尽管NASA-TLX最初主要用于人机交互与任务绩效研究,但已有研究指出,NASA-TLX能够从多个维度较为全面地反映学习者在完成复杂任务时所体验到的认知压力构成,尤其适用于涉及持续认知加工与多重信息整合的学习任务(蔡艳玲,2009)。

因此,本研究基于学习科学中的认知负荷理论,对NASA-TLX的各维度进行了教育情境下的理论映射,并构建了认知负荷测量指标体系,详见表1(Sandra G. Hart & Lowell E. Staveland, 1988)。其中心理需求与时间需求主要反映学习任务本身的复杂性与节奏压力,对应内部认知负荷;挫败感及与信息呈现相关的额外加工需求反映教学或支持方式引入的不必要加工,对应外部认知负荷;努力程度与任务表现感知则体现学习者将认知资源投入于理解、整合和改进任务产出的主观体验,对应相关认知负荷(王小明,2021)。

表1 认知负荷指标评价体系

NASA-TLX	指标的教育情境化定义	负荷类别
----------	------------	------

Performance	学习者对自身写作表现、完成信心与任务难度的综合感知	Germane Load
Effort	学习者完成任务投入的认知和情感资源，通常与任务的复杂度和学习者的能力差异相关	Germane Load
Frustration	学习者在任务过程中遇到困难时的情绪反应，通常表现为焦虑、沮丧或困惑。	Extraneous Load
Mental Demand	学习者在理解学习任务、整合信息过程中所感知的认知复杂性与心理负担	Intrinsic Load
Temporal Demand	学习者在学习过程中因时间受限而感知到的节奏压力与进度紧张感	Extraneous Load
Physical Demand	写作任务中不适用，固定为 0	N/A

2.3 数据分析方法

本研究希望对学习者的认知负荷进行量化分析，进而探究四种支持方式下学习者的认知负荷模式差异。首先，以人工教师的评分作为标准，根据学习者写作初稿与终稿的总分和各子维度分数计算出修订学习过程的学习收益，并使用 Kruskal-Wallis 检验分析组间差异；其次，对 NASA-TLX 理论进行教育情境下的映射并构建认知负荷测量指标体系，将实验中被试在主观问卷中的回答转化为 5 点 Likert 量表，并对部分问题进行反向编码和 Z-score 标准化处理以消除量纲差异后，计算出学习者的总体认知负荷、内部负荷、外部负荷及相关认知负荷，以进一步分析不同组别的差异。最后，探究分析不同支持方式下的学习收益与认知负荷的相关关系并根据研究结果，使用随机森林方法识别高努力-低收益(HELG)学习者群体。

3. 研究结果

3.1 四种学习支持方式下的多维度学习收益比较

表 2 四种支持方式下总体学习收益的描述性统计

group	n	Mean	SD	Median	Q1	Q3	Min	Max
AI	36	3.611	3.092	3.5	1.75	5.25	-2	10
HE	29	1.783	3.112	0.0	-1.00	4.00	-3	7
CL	33	1.672	2.886	1.0	0.00	2.00	-5	11
CN	33	1.424	2.077	1.0	0.00	3.00	-4	5

从表 2 中可看出，AI 组平均的总体学习收益最高（Mean=3.611, n=36），其次是教师支持组（HE, Mean=1.783, n=29）、工具支持组（CL, Mean=1.672, n=33）及无支持组（CN, Mean=1.424, n=33）。这表明三种学习支持方式均能在写作修订过程中提升学生的学习收益，且 AI 支持的提升效果最为明显。

表 3 Kruskal-Wallis 非参数检验结果

indicator	statistic	p_value	effect_size	significant
TA-essay sum gain	15.34268	0.00154	0.09421	TRUE
TA-Word count gain	2.376359	0.49805	-0.0047	FALSE
TA-Basic writing gain	20.51913	0.00013	0.13373	TRUE
TA-Academic writing gain	6.57037	0.08693	0.02725	FALSE

indicator	statistic	p_value	effect_size	significant
TA-Originality gain	13.79603	0.00319	0.08241	TRUE
TA-The role of AI in education gain	16.33402	0.00097	0.10178	TRUE
TA-Scaffolding to optimise learning gain	5.41635	0.14373	0.01844	FALSE
TA-Differentiation practices in the classroom gain	14.73077	0.00206	0.08954	TRUE
TA-Integration of three topics gain	9.99335	0.01862	0.05338	TRUE
TA-Future vision on education in 2035 gain	3.07063	0.38086	0.00053	FALSE

为进一步探究提升效果与提升原因, 本文将比较 ai、cl、he 和 cn 四组学生在 10 个具体写作增益维度上的差异, 由于各维度增益分数均未满足正态性假设, 因此本文采用 Kruskal-Wallis 检验。结果显示, 在经过 FDR 校正后, 四组在总体分数、基本写作能力、原创性及主题的理解表达与整合等六个方面存在显著组间差异, 而在字数、学术写作能力等四个方面未发现显著差异。此外, 事后两两比较结果进一步表明, 在 TA-Basic writing gain 上, cl 组显著高于 he 和 cn 组; 在 TA-Originality gain 上, ai 组显著高于 he 和 cn 组; 在 TA-The role of AI in education gain 上, ai 组显著高于 cl 和 cn 组。

总体来看, 不同学习支持方式对学生写作发展的影响具有明显的维度特异性。例如, ai 组在综合写作增益及若干高阶内容维度上表现出明显优势, 尤其体现在总分、原创性以及 AI 教育和课堂差异化相关的主题表达上。相比之下, cl 组的优势主要集中在基础写作层面, 而 he 与 cn 组在多数维度上未表现出稳定领先。

3.2 不同支持方式下认知负荷与综合学习收益之间的关系




图 1 认知负荷与学习收益之间的关系

从图 1 可以观察到, 在四种不同的支持条件下, 无论是内部认知负荷、外部认知负荷、相关认知负荷以及总认知负荷, 其与学习收益之间均未呈现出强烈的线性关系。该结果表明, 综合学习收益的提升并非仅依靠单一认知负荷维度的影响, 而是学习者在任务过程中多类认知资源的共同投入与协同作用, 这是因为学习者既需要投入一定的内部负荷以处理任务固有复杂性, 也需要在控制外部负荷干扰的同时, 将认知资源持续投入到有意义加工活动中, 从而实现学习投入向学习收益的转化。因此, 单看某一个认知负荷指标和只关注认知负荷总量很难厘清认知负荷与学习收益之间的关系, 通过探究不同支持方式下学习者的认知资源分配模式来揭示二者关系非常有必要。

3.3 不同支持方式对认知负荷分配的影响




图 2 四种支持方式下的认知负荷分配雷达图

图 2 对比了不同支持方式下学习者在内部认知负荷、外部认知负荷与相关认知负荷三个维度上的认知负荷分配特征。结合对不同组别下的总体认知负荷做 Kruskal-Wallis 检验分析结果可知，尽管不同支持条件在总体认知负荷水平上未呈现显著差异，但在认知负荷的结构性分配模式上存在显著差异。

具体而言，第一，不管是 AI 支持、人类教师支持还是写作检查工具支持等，为学生提供一定的学习支持可以显著降低学生的外部认知负荷。这表明适当的支持方式能够显著减少学习过程中由理解障碍、决策不确定性或操作负担引入的非必要认知消耗。第二，为学习者提供支持后，会提高学习者的内部认知负荷和相关认知负荷，说明学习者能够将更多认知资源投入到理解、整合与修订等直接促进学习的加工活动中(王小明, 2021)。第三，相较于外部负荷占比明显偏高的无支持条件，为学习者提供一定支持后，学习者将呈现出更为均衡的认知负荷分配模式。

结合学习收益结果可以发现，不同的学习支持方式并未显著改变认知负荷总量，但通过降低外部负荷、提升内部负荷和相关认知负荷，使认知负荷分配模式趋于均衡等方式，为学习者带来了更高的学习收益。

3.4 AI 组与 HE 组的支持下认知负荷与学习收益的关系




图 3 ai 组中认知负荷与学习收益的关系




图4 he 组中认知负荷与学习收益的关系

在进一步探究学习支持在认知负荷方面的提升机制过程中, AI 组与人类教师组呈现出了较为明确且一致的趋势, 因此本研究分别绘制了 ai 组与 he 组中四类认知负荷与学习收益的关系图。结果表明, 尽管 AI 与人类教师支持均能提升学习者的学习收益, 但认知负荷与学习收益之间的关系是完全相反的趋势, 在 ai 组中, 认知负荷与学习收益呈现正相关, 而在 he 组中, 则呈现出更明显的认知负荷增加但学习收益下降的倾向。这说明在 ai 组和 he 组中, 学习者的学习投入转化为学习收益的效率不同。AI 组的认知负荷结构更可能支持学习者把资源持续投向理解、整合与修订, 但在教师支持情境中, 学习者的努力更可能受反馈理解成本、选择不确定性与情绪压力等因素影响, 因此可能会出现认知过载及面临高努力但低收益的风险。

3.5 随机森林模型识别高努力-低收益学习者




图5 高努力—低收益(HELG)学习者的划分与人数比例

本研究基于学习者主观的学习投入与学习收益的联合分布,如图5所示采用四分之一分位数阈值在个体层面定义了一类高努力—低收益学习者(HELG)。结合图5可知, 约10.7%的学习者被识别为HELG学习者, 且不同支持方式下的HELG群体比例不同, 其中, 人类教师支持下出现高努力—低收益学习者(HELG)的比例最高。

随后, 如图6所示, 本研究利用包含内在负荷、外在负荷、相关认知负荷、努力与挫折感等指标的随机森林模型, 对高努力-低收益学习者(HELG)进行识别, 并通过5折分层交叉验证评估模型的稳健性, 从而检验HELG是否作为一种可识别的学习者模式。结果中的平均AUC约为0.83说明, 基于本研究中构建的多维认知负荷指标体系中的特征, 可以比较稳定地区分学习者是否为高努力-低收益学习者(HELG)及发生了认知破产。(Karalar, H. & Kapucu, C. & Gürüler, H., 2021)




图6 随机森林模型识别高努力-低收益学习者(HELG)的结果

基于上述结果可知, 尽管不同支持方式在总体认知负荷及其结构上并未呈现显著差异, 但学习支持方式显著影响了学习者的学习投入能否被有效转化为学习收益。AI 支持通过提供即时的、低评价压力的过程性支撑, 降低了努力和收益失配的风险; 而人类教师支持在缺乏即时调节的情况下, 更容易放大个体自我调节能力差异, 从而导致部分学习者陷入高努力-低收益状态。

4. 讨论

4.1 学习支持方式并未显著改变认知负荷总量, 但显著影响学习收益

本研究发现在 AI 支持、教师支持、工具支持与无支持四种条件下, 学习者的总体认知负荷水平差异并不显著, 但学习收益却呈现显著组间差异, 其中 AI 支持组的总体学习收益显著高于其他三组。重要的是, ai 组在综合写作增益及内容原创性、主题表达等高阶内容维度上表现出明显优势。这一结果表明, 学习支持方式的作用并非体现在降低了多少认知负荷, 而体现在学习者如何分配其投入的认知资源。这一发现与认知负荷理论中降低负荷并非学习优化的充分条件的观点一致(王小明, 2021)。这提示我们, 仅从负荷总量的角度解释学习效果具有一定的局限性, 探究学习者的认知资源分配模式是必要的。

4.2 学习支持方式通过重塑认知负荷结构影响学习收益

本文通过进一步对不同支持方式下的认知负荷分配进行分析发现: 尽管总体负荷水平相近, 但不同支持条件在内部认知负荷、外部认知负荷与相关认知负荷的相对构成上呈现出系统性差异。具体而言, 无论是 AI 支持、教师支持还是工具支持, 相较于无支持条件, 均显著降低了学习者的外部认知负荷且使学习者的认知负荷结构更加均衡。这表明, 适当的学习支持能够有效减少学习过程中由任务理解困难、决策不确定性或操作负担引发的无效认知消耗。同时, 有支持条件下学习者的内部认知负荷与相关认知负荷水平相对提高, 表明学习者能够将更多认知资源投入到理解、整合与修订等直接服务于学习目标的加工活动中。值得注意的是, 这种降低外部负荷与提升内部负荷和相关认知负荷的变化, 并未伴随总体认知负荷的显著下降, 却对应着更高的学习收益。这表明写作成绩的提升与有效地学习并非是负荷的降低带来的, 更多地则是学习者认知资源分配结构的优化, 认知负荷是影响学习者学习收益的重要因素之一(Zou, B. & Wang, C., 2025)。

4.3 AI 支持与教师支持下认知负荷与学习收益关系的不同机制

从学习收益的结果上来看, AI 支持与教师支持均能提高写作成绩, 但 ai 组在总体分数和高阶内容维度提升上表现出明显优势, 而 he 组却无明显特征。从提升机制上看, 二者在认知负荷与学习收益之间呈现出完全相反的趋势。在 AI 支持组中, 内部认知负荷、相关认知负荷及总认知负荷与学习收益整体呈正向关系。这表明, 在 AI 支持情境下, 学习者所承受的认知挑战更有可能被转化为有效的学习加工。AI 所提供的即时反馈、低评价压力与可反复交互的支持形式, 可能降低了学习者在修订决策过程中的不确定性, 使其能够将认知资源

持续投入到问题诊断、策略选择与文本改进等有意义加工活动中。相比之下,在教师支持组中,外部认知负荷、相关认知负荷及总认知负荷与学习收益呈现负相关趋势。这一结果尤为关键,因为它表明:更高的主观努力并不一定带来更高的学习收益。在教师支持情境中,学习者可能需要同时处理反馈理解、修订方向判断、评价压力以及情绪调节等多重加工需求,这些活动在主观体验上可能被感知为努力投入,却在客观上削弱了认知资源向有效学习加工的转化效率。因此,AI组与HE组的差异并不在于是否提供了支持,而在于支持方式是否有助于提升认知投入向学习收益转化的效率。(Zhai, Xiaoming, 2023)

4.4 从认知负荷失配到高努力-低收益 (HELG) 学习者

基于上述结果,本研究进一步识别出一类高努力-低收益(HELG)学习者,其比例约占总样本的10.7%。尽管这些学习者在主观努力与认知负荷指标上表现较高,但其学习收益却显著偏低,呈现出典型的努力-收益失配特征。随机森林模型的分析结果说明HELG学习者并非偶然出现,而是一种具有可预测特征的学习风险状态。结合支持方式分布可以发现,HELG学习者在教师支持条件下更为集中,这进一步印证了前述发现:当支持方式未能有效降低外部负荷或引导学习者进行高质量加工时,学习者即便投入较高努力,也可能陷入认知过载或资源错配状态。这一结果强调,写作成绩没有提升或提升幅度较小并不一定是努力不足,而更可能源于努力被消耗在无效或低效的认知加工上。

5. 结论

综合来看,本研究揭示的关键差异并不在于学习者承受了多少认知负荷,而在于投入的认知资源是否被有效配置并转化为学习收益。尽管不同支持条件下总体认知负荷水平相近,但其在内部、外部与有意义加工维度上的配置方式存在系统性差异,而这种差异与学习收益呈现出高度一致的对应关系。AI支持通过优化认知负荷结构等方式能较为有效地将学习者的学习投入转化为学习收益,降低学习者出现高努力-低收益风险;而教师支持在缺乏即时调节机制的情况下,更容易放大个体差异,导致部分学习者出现努力折损。这一发现对理解生成式AI支持学习的机制提供了一定参考。此外,认知负荷是影响学习者学习收益的一个重要因素,但不是唯一因素。学习收益的提升并非由某一单一负荷维度的变化所决定,而是内部负荷、外部负荷与相关认知负荷等其他因素在一定结构比例下共同作用的结果。当外部负荷占比过高而未能转化为有意义加工时,即便学习者投入较高努力,也可能出现高努力-低收益(HELG)的风险状态。这提示我们,学习支持并非是简单的多给帮助或减少负担,真正有意义的支持能够降低无效的认知消耗,并促使学习者将努力投入到真正促进学习的加工活动中。

参考文献

- 白成杰和曹娟. (2011). e-Learning 环境中学习者认知负荷的测量. *电化教育研究*, (5), 32-35, 48. <https://doi.org/10.13811/j.cnki.eer.2011.05.006>
- 蔡艳玲. (2009). 学习任务认知负荷与测量方法研究. *郑州大学学报(哲学社会科学版)*, 42(1), 128-130.
- 李金波和许百华. (2009). 人机交互过程中认知负荷的综合测评方法. *心理学报*, 41(1), 35-43.
- 王小明. (2021). 认知负荷测量中的三大问题: 构念、观察指标与解释. *全球教育展望*, 50(6), 50-66.
- Baker, R., & Siemens, G. (2014). Educational data mining and learning analytics. In R. K. Sawyer (Ed.), *The Cambridge handbook of the learning sciences* (2nd ed., pp. 253-272). Cambridge University Press.

- Hart, S. G., & Staveland, L. E. (1988). Development of NASA-TLX (Task Load Index): Results of empirical and theoretical research. In P. A. Hancock & N. Meshkati (Eds.), *Advances in psychology* (Vol. 52, pp. 139–183). North-Holland. [https://doi.org/10.1016/S0166-4115\(08\)62386-9](https://doi.org/10.1016/S0166-4115(08)62386-9)
- Karalar, H., Kapucu, C., & Gürüler, H. (2021). Predicting students at risk of academic failure using ensemble model during pandemic in a distance learning system. *International Journal of Educational Technology in Higher Education*, 18(1), Article 63. <https://doi.org/10.1186/s41239-021-00300-y>
- Luckin, R., Holmes, W., Griffiths, M., & Forcier, L. B. (2016). *Intelligence unleashed: An argument for AI in education*. Pearson.
- Sweller, J. (1988). Cognitive load during problem solving: Effects on learning. *Cognitive Science*, 12(2), 257–285. [https://doi.org/10.1016/0364-0213\(88\)90023-7](https://doi.org/10.1016/0364-0213(88)90023-7)
- Sweller, J., Ayres, P., & Kalyuga, S. (2011). *Cognitive load theory*. Springer. <https://doi.org/10.1007/978-1-4419-8126-4>
- Zhai, X. (2023). ChatGPT and AI: The game changer for education. *ChatGPT: Reforming Education on Five Aspects*. In *Shanghai Education* (pp. 16–17). SSRN. <https://ssrn.com/abstract=4389098>
- Zou, B., & Wang, C. (2025). ChatGPT for language teaching and learning. In L. McCallum & D. Tafazoli (Eds.), *The Palgrave encyclopedia of computer-assisted language learning*. Palgrave Macmillan. https://doi.org/10.1007/978-3-031-51447-0_97-1