

交叉重叠类别结构的自主学习优势和集中学习劣势*

岳 芳 陈剑平 甘可鑫 王宇情 刘志雅

(华南师范大学心理应用研究中心/心理学院, 广州 510631)

摘 要 本研究采用四类别交叉重叠结构, 探索了不同学习方式(集中、交错、随机和自主)对基于规则和信息整合类别学习的影响, 通过计算模型的数据分析方法对 265 名被试的学习策略进行了模型拟合。结果发现, 在基于规则和信息整合任务中, 自主学习者均能较多地使用最优策略, 自主学习的分类正确率均显著高于集中学习的分类正确率。并没有出现前人发现的规则学习的集中学习优势和信息整合学习的交错学习优势。结果表明, 自主学习存在学习效率上的优势而集中学习存在劣势, 可能是因为交叉重叠类别结构对自主学习的影响相对少于对集中学习的影响。

关键词 类别学习, 交叉重叠类别结构, 交错学习, 集中学习, 自主学习

分类号 B849: G44

1 前言

人类需要将纷繁复杂的各类知识进行分门别类的加工, 这一对人类生存具有重要影响的认知活动即为类别学习(Ashby et al., 1998; Seger & Miller, 2010)。例如, 自然界中, 许多生物将对象区分为有害或者无害, 并据此做出是否逃避的判断。根据类别学习多系统模型, 如 COVIS 模型(Competition between Verbal and Implicit Systems), 假定类别学习至少存在两个相互竞争的学习系统: 外显的陈述性系统和内隐的程序性系统。前者依赖工作记忆和执行注意, 并通过明确的假设-检验过程来习得类别知识, 后者则基于大脑与特定动作建立的联结来习得类别知识(Ashby et al., 1998; Ashby & Valentin, 2017; Erickson & Kruschke, 1998)。在揭示类别学习多系统的认知机制研究中, 主要涉及的类别结构有两种: 基于规则(Rule-Based, RB)和信息整合(Information-Integration, II)的类别结构(Ashby & Maddox, 2011; Nomura et al., 2007)。基于规则的类

别结构主要依赖于外显的陈述性系统, 分类规则可以明确用言语表达; 信息整合的类别结构则主要依赖于内隐的程序性系统, 需要整合不同维度加以学习, 规则难以用言语表达(如图 1)。

在人类获得类别知识的现实情景中, 学习者通常具有自主性, 有时会在一个类别内集中学习, 有时又会在不同类别间交替学习, 我们把这种学习方式定义为“自主学习”。类别学习多系统理论能否在这种学习方式下获得支持, 有一定的理论研究价值。但对于以往研究, 无论是集中学习或交错学习, 学习者都被视为信息的被动积累者, 不能自行决定刺激的学习顺序(Carvalho & Goldstone, 2014; Noh et al., 2016; Rawson et al., 2015; Rohrer et al., 2020; Zulkipli & Burt, 2013)。其中, “集中学习”指学习者学习完一个类别, 再学习下一类别, 如“AAABBBCCC”。“交错学习”指学习者学习了一个类别的刺激, 再学习另一个类别的刺激, 如“ABCDADBCBADC”。Noh 等人(2016)通过观察学习, 即刺激和类别标签同时呈现的学习, 发现集中

收稿日期: 2023-04-24

* 教育部人文社会科学重点研究基地重大项目“学习认知过程与学科素养培养研究”(22JJD190006); 广东省基础与应用基础研究基金自然科学基金(2023A1515012355)。

通信作者: 刘志雅, E-mail: zhiyaliu@scnu.edu.cn




图 1 基于规则(左)和信息整合(右)的类别结构

注：根据转换公式，将坐标系上的每个点转换成具有物理意义单位的数据，最后生成线段。长度的转换公式为： $l = x + 50$ ，角度的转换公式为： $\alpha = y \times \pi / 500$ ，长度的范围为 0~350 像素，角度的范围为 0~90 度。

学习有利于基于规则的类别学习，交错学习有利于信息整合的类别学习。研究者认为在规则任务中，集中学习可以帮助学习者从不相关的维度中识别出相关维度，并生成每个类别的检验规则，这将有利于基于规则的类别学习；交错学习则需要学习者同时生成 4 个类别的检验规则，这会加重工作记忆的负荷，不利于基于规则的类别学习。而在信息整合任务中，与集中学习相比，交错学习更容易促使学习者放弃基于规则的陈述性系统转而使用信息整合的程序性系统，使交错学习更具有优势。这一研究结果支持了类别学习多系统理论。但当前在类别学习领域，针对自主学习的效率机制研究，仍缺少实证数据。

因此，本研究比较了学习者采用自主、集中、交错和随机学习方式的分类正确率和学习策略，试图更深入地探索类别学习的效率机制，这也为类别学习多系统理论的检验提供更有力的实验证据。Markant 和 Gureckis (2010)发现，当增加类别学习者的主动性，即学习者可以自主调整刺激的特征量进行类别学习时，获得了更好的学习效果。此时，学习者能更快地掌握分类规则。Lu 等人(2021)采用了 Carvalho 和 Goldstone (2014)开发的斑点材料，操纵了类别内与类别间的相似性水平，发现自主学习者比被动学习者表现更好。他们认为，自主学习者可能具有“决策驱动(decision driven)”和“数据驱动(data driven)”的优势。“决策驱动”指自主学习会增加学习者的选择权和学习动力，促使任务参与度的提高(Gureckis & Markant, 2012; Leotti et al., 2010; Markant & Gureckis, 2010)。此时，自主学习

者的分类成绩与集中、交错方式的切换存在显著的相关关系。“数据驱动”指学习者可以查询刺激空间中最有可能犯分类错误的区域，通过减少不确定性和避免冗余信息来优化学习效果(Gureckis & Markant, 2012; Markant & Gureckis, 2010)。基于上述研究结果推测，学习者在自主学习条件下可能会兼具集中、交错学习的优点，并能克服这两者的不足，最终能在不同类别结构的学习中呈现出优势效应。

此外，在探究学习方式对不同类别结构的影响时，Noh 等人(2016)采用了完全分离的类别结构。这种类别结构容易混淆基于规则和信息整合的学习者，一旦两个类别离决策界限足够远，信息整合任务同样也可以基于规则习得。例如，Ashby 等人(1999)让学习者观察学习完全分离的两类别结构，发现对于信息整合类别，学习者大多使用某种次优的一维规则策略；而对于规则类别，学习者始终使用规则策略，导致无法准确分离两种类别学习者。其次，这两种类别的学习速度存在较大的差异。对于规则类别，学习者可以基于完善的规则学习系统，并利用逻辑推理能力来加速学习进程；对于信息整合类别，由于缺乏明确的逻辑规则，因此学习者必须以更慢、更渐进的联想学习方式对类别成员进行分类(Ashby et al., 2020)。由此可见，需要在学习步调相当的任务间进行比较。更为重要的是，在现实生活中，类别间总是存在着重叠，人们并不能根据某条绝对的界限完美地区分两个类别。而且许多的物品，有时属于这种类别，有时却属于另外一种类别(Murphy & Ross, 1999)，即“边界模糊效应”(Minda & Smith, 2001)。例如，“西红柿”是否属于“水果”？

因此, 交叉重叠类别结构更符合现实生活中的类别。

目前, 已有为数不多的类别学习研究涉及到交叉重叠类别结构, 为本研究采用交叉重叠四类别结构提供了研究基础, 促使我们更好地探索学习者的学习策略。例如, Ell 和 Ashby (2006)通过反馈学习(学习者反应后立即反馈正确结果), 探究了类别交叉重叠水平对两种类别结构的影响。结果发现, 交叉重叠类别结构对规则任务的影响要少于信息整合任务, 并且中等水平的交叉重叠类别结构最有利于学习策略的分离。此时, 学习者使用最优学习策略分类的正确率为 96%, 使用次优学习策略分类的正确率为 75%。即采用中等交叉重叠的类别结构, 更有可能促使基于规则和信息整合类别学习者的准确分离。Maddox 等人(2004)也在类别重叠的中等水平上(学习者采用最优学习策略分类的正确率为 95%), 通过反馈学习方式关注了类别数量对不同类别结构的影响。结果发现: 对于两类别结构, 学习者的基于规则的分类成绩(89.0%)显著高于信息整合的分类成绩(84.6%); 对于四类别结构, 学习者的基于规则的分类成绩(78.8%)则显著低于信息整合的分类成绩(82.7%)。这是因为类别数量的增加对学习者的执行注意和工作记忆提出了更高的要求, 从而降低了规则任务的分类正确率。因此, 本研究认为采用接近中等交叉重叠水平的四类别结构材料, 不仅能促使基于规则和信息整合类别学习者的分离, 还有可能平衡两种类别在学习速度上的差异, 以更准确地探讨学习方式对不同类别结构的影响。

综上, 本研究采用四类别交叉重叠结构, 以平衡基于规则和信息整合任务之间的差异, 使学习者根据两个维度分类的最大正确率为 90%, 接近 Ell 和 Ashby (2006)描述的中等重叠水平, 并将随机学习方式作为基线水平, 全面考察 4 种学习方式对类别学习的影响, 形成了 3 个假设: 第一, 交叉重叠类别结构由于没有绝对的分规则, 基于规则的类别学习将不会出现集中学习优势, 反而可能出现集中学习的劣势; 第二, 从信息加工的角度分析, 在集中条件下, 学习者关注的是类别内的共同性信息, 而在交错学习条件下, 学习者更关注类别间的差异性信息。交叉重叠类别结构会削弱类别间的差异性信息, 保持类别内的共同性信息, 预期也不利于信息整合任务的交错学习。第三, 相对于被动学习, 如果自主学习存在“决策驱动”、“数据驱动”效应, 那么在两种类别结构的学习中将出现学习优势。

2 方法

2.1 被试

采用 G*Power 3.1.9.7 对实验的样本量进行估算, 设置参数 effect size f 为 0.25, I 类错误的概率 α err prob 为 0.05, 检验效能 Power ($1 - \beta$ err prob)为 0.80, 计算得到最低样本量为 237 人。实验最终有偿招募某在校大学生 265 名, 男生 92 名, 女生 173 名, 平均年龄为 20.50 ± 2.37 岁。在规则任务中, 集中学习组 32 人(平均年龄为 21.00 ± 3.24), 交错学习组 30 人(平均年龄为 19.85 ± 1.85), 随机学习组 36 人(平均年龄为 19.75 ± 1.80), 自主学习组 39 人(平均年龄为 20.24 ± 2.31); 在信息整合任务中, 集中学习组 30 人(平均年龄为 21.80 ± 2.88), 交错学习组 30 人(平均年龄为 21.84 ± 2.27), 随机学习组 35 人(平均年龄为 19.76 ± 1.71), 自主学习组 33 人(平均年龄为 20.54 ± 2.20)。所有被试均为右利手、裸眼视力或矫正视力正常, 以前未参加过类似实验, 均签署知情同意书, 伦理号为 SCNU-PSY-2021-102。

2.2 实验材料

实验材料是长度和方向都会变化的线段, 由 Matlab 软件生成。根据 Ashby 和 Gott (1988)的随机化技术, 在 300×300 的坐标系生成 A、B、C 和 D 四个类别的结构图, 每个类别都服从二维正态分布, 具体参数和类别结构图如表 1、表 2 和图 1 所示。

每个类别各有 50 个刺激, 共 200 个刺激。此外, 每个类别的交叉重叠程度为 10%, 如 A 类别有 50 个刺激, 就有 5 个刺激在其他类别的分布范围中。

表 1 基于规则的类别结构参数表

基于规则的类别结构	μ_o	μ_i	σ_i	σ_o	COV_{io}
A	100	200	30	30	0
B	200	200	30	30	0
C	200	100	30	30	0
D	100	100	30	30	0

表 2 信息整合的类别结构参数表

信息整合的类别结构	μ_o	μ_i	σ_i	σ_o	COV_{io}
A	150	220	30	30	0
B	220	150	30	30	0
C	150	80	30	30	0
D	80	150	30	30	0

2.3 设计和程序

采用 2 (类别结构: RB、II) $\times$ 4 (学习方式: 集

中、交错、随机、自主)的被试间设计。因变量为正确率和反应时。

通过 psychopy 2021.1.2 编程,实验分为学习阶段和测试阶段。在学习阶段,被试需要观察学习 100 个类别刺激(每个类别各 25 个)。在测试阶段,被试需要对 100 个新的类别刺激进行分类(每个类别各 25 个),整个过程没有反馈。实验流程如图 2 所示。

对于被动学习(集中、交错、随机),实验流程均相同。即实验以一个可点击的 NEXT 图标作为开始,被试点击后,出现 500 ms 的中央注视点,随后出现一个带有类别标签(A、B、C 或 D)的刺激,持续 3000 ms。刺激呈现结束后,有一个 1000 ms 的空屏,随后将再次出现一个 NEXT 图标,接下来的程序同上。其中,集中学习者需要在进入下一个类别之前先观察学习一个类别的 25 个刺激;交错学习者需要交替学习 100 个类别刺激;随机学习者则需要根据随机顺序对这 100 个类别刺激进行学习。

与上述三种被动学习方式不同,对于自主学习,屏幕中央有 4 个可点击的类别选择按钮,每个类别

选择按钮显示了类别标签和可供学习的刺激数量,被试可自行选择所要学习的类别。被试选择后,屏幕中央会出现一个注视点,持续 500 ms,随后呈现类别刺激及其对应的类别标签,持续 3000 ms,每个刺激之间有 1000 ms 的空屏。值得注意的是,一旦被试学习完一个类别的 25 个刺激,类别按钮会保留在屏幕上,但被试无法点击。

在测试阶段,刺激是随机呈现的,整个过程没有反馈。在每次刺激呈现之后,被试需要在 5000 ms 内点击水平排列在每个刺激下方的 4 个按钮 s、d、k、l (标记为 A、B、C、D)之一,以选择他们认为合适的类别标签。

2.4 决策边界模型

为了进一步识别被试在测试阶段所采取的学习策略,本实验采用了决策边界模型(Decision Bound Model, DCM)。这一模型包含了一维规则模型、联合规则模型、信息整合模型和随机反应模型(Maddox & Ashby, 2004; Noh et al., 2016; Roark et al., 2022)。

一维规则模型包括一维长度和一维角度,假设被试在一个感知维度上设定一个标准,并基于这一




图 2 实验流程图

注: 图 2(a)为被动学习(集中、交错、随机)的实验流程图, 图 2(b)为自主学习的流程图。

标准对刺激做出明确的决策。例如, 如果线段长度是短的, 则归为 A 类, 如果长度是长的, 则归为 B 类。

联合规则模型假设被试根据两个感知维度进行分类。例如, 如果线段长度是短的, 角度比较陡峭, 则归为 A 类; 如果线段长度是长的, 角度比较陡峭, 则归为 B 类; 如果线段长度是长的, 角度比较平缓, 则归为 C 类; 如果线段长度是短的, 角度比较平缓, 则归为 D 类(如图 1)。

信息整合模型假设每个类别的决策界限是线性的。被试需要使用信息整合策略, 即整合长度和角度两个维度的信息去分类, 分类规则难以用言语表达。

随机反应模型假设被试使用随机猜测的方式, 或使用倾向性的随机按键, 如倾向选择 A 类别。

本研究通过上述 4 个模型对测试阶段的数据进行拟合, 并采用最大似然法估计模型参数。最后, 基于贝叶斯信息准则(Bayesian Information Criterion, 简称 BIC)比较模型与数据的拟合, 并对模型额外的自由参数进行惩罚。BIC 的计算公式如下:

$$\text{BIC} = r \ln N - 2 \ln L$$

其中, r 是自由参数的个数, N 是样本数据的数量, L 是最大似然估计值。计算每个模型的 BIC 值, 选择 BIC 值最小的模型作为被试使用的分类策略。

根据模型拟合的结果, 在基于规则的类别结构中, 大部分被试使用了信息整合策略, 不符合实际情况。经检验, 信息整合策略的 BIC 值和联合规则模型的 BIC 值接近, 但信息整合策略的 BIC 值更低, 所以出现上述结果。为了更加准确地判断被试的分类策略, 本研究结合模型拟合的结果和被试的实际反应来重新判断被试的分类策略。

2.5 结果与分析

为了保证被试充分掌握本实验的分类规则并做出正确反应, 在规则任务中, 自主学习组的 1 名被试因正确率未达到随机水平(25%)而被剔除; 在信息整合任务中, 随机学习组的 1 名被试因正确率未达到随机水平(25%)而被剔除。使用 SPSS 26.0 对余下的数据进行统计分析。

2.5.1 分类正确率

对测试阶段的分类正确率进行 2 (类别结构:

基于规则、信息整合) $\times$ 4 (学习方式: 集中、交错、随机、自主) 的完全随机方差分析。结果如表 3 和图 3 所示。

结果发现, 类别结构的主效应显著, $F(1, 255) = 11.58, p = 0.001, \eta_p^2 = 0.04$, 信息整合任务的分类正确率($M = 0.64, SD = 0.12$)显著高于规则任务的分类正确率($M = 0.59, SD = 0.16$)。学习方式的主效应显著, $F(3, 255) = 10.49, p < 0.001, \eta_p^2 = 0.11$, 交错学习($M = 0.62, SD = 0.13$)、随机学习($M = 0.65, SD = 0.13$)、自主学习($M = 0.65, SD = 0.14$)的分类正确率均显著高于集中学习($M = 0.53, SD = 0.14$)的分类正确率。但是两者交互作用不显著, $F(3, 255) = 1.40, p = 0.244$ 。

为了探究在不同类别结构下学习方式的学习效果, 本研究对测试阶段的分类正确率进行事后多重比较检验。结果发现, 对于基于规则的任务, 集中学习的分类正确率显著低于交错($p = 0.012$)、自主($p < 0.001$)、随机学习($p < 0.001$)的分类正确率; 对于信息整合任务, 集中学习的分类正确率显著低于自主学习的分类正确率($p = 0.028$)。这也说明在基于规则的任务中, 没有出现集中学习的优势, 在信息整合任务中, 同样也没有出现交错学习的优势。但不论是基于规则和信息整合任务, 自主学习的分类正确率均显著高于集中学习的分类正确率。此外, 本研究还进一步发现自主学习者在基于规则和信息整合任务中的分类正确率没有显著差异($p = 0.174$)。

对测试阶段的反应时进行 2 (类别结构: 基于规则、信息整合) $\times$ 4 (学习方式: 集中、交错、随机、自主) 的完全随机方差分析。结果如表 4 所示。

结果发现, 类别结构的主效应不显著, $F(1, 255) = 3.38, p = 0.053$ 。学习方式的主效应不显著, $F(3, 255) = 0.80, p = 0.501$ 。两者间的交互作用也不显著, $F(3, 255) = 1.04, p = 1.048$ 。结合正确率和反应时数据, 表明不存在速度-准确性权衡。

2.5.2 自主学习分析

为了进一步分析学习者在交叉重叠类别结构下的自主学习行为, 本研究统计了学习者在阶段的相关指标: (1)学习者在不同类别间切换的比例

表 3 两种类别结构下不同学习方式的平均分类正确率($M \pm SD$)

类别结构	集中	交错	随机	自主	总平均正确率
基于规则的类别结构	0.48 $\pm$ 0.14	0.60 $\pm$ 0.16	0.64 $\pm$ 0.14	0.63 $\pm$ 0.16	0.59 $\pm$ 0.16
信息整合的类别结构	0.59 $\pm$ 0.13	0.65 $\pm$ 0.09	0.66 $\pm$ 0.12	0.68 $\pm$ 0.11	0.64 $\pm$ 0.12




图 3 两种类别结构下不同学习方式的平均分类正确率
注: 误差线代表 95% 的置信区间, * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

(“切换率”), 由于学习阶段有 100 次试验, 每位学习者将有 99 次选择, 而每次选择都可以被定义为“交错”或“集中”。因此, 切换率的计算方法为: 学习者切换的次数除以可选择的总数(99)。(2)学习者集中学习的最长长度, 定义为连续重复学习一个类别, 并且重复次数最多; (3)学习者集中学习的平均长度; (4)学习者交错学习的最长长度, 定义为连续交错学习一段类别刺激(例如, ABCACBAC), 且交

错学习的次数最多; (5)学习者交错学习的平均长度。如表 5 所示。

首先, 学习者在自主学习类别刺激时, 规则任务的切换率为 0.49, 信息整合任务的切换率为 0.44, 尽管两者没有显著差异($p = 0.521$), 但都介于 0.030 (仅仅对 4 个类别切换 3 次, 即完全集中学习)和 1 (交错学习 4 个类别的所有样例)之间。这表明学习者并不是完全集中或交错学习, 而是会有策略性地使用集中、交错学习方式。

其次, 对于不同类别结构, 本研究利用相关分析考察了自主学习者的分类正确率与上述 5 个指标之间的关系。结果表明, 对于规则任务, 学习者集中学习类别刺激的最长长度与其分类正确率呈显著负相关($r = -0.37$, $p = 0.03$), 学习者集中学习类别刺激的平均长度与其分类正确率也呈显著负相关($r = -0.48$, $p = 0.002$), 即学习者集中学习类别刺激的平均长度越长, 其分类正确率越低; 对于信息整合任务, 学习者集中学习类别刺激的平均长度与其分类正确率也呈显著负相关($r = -0.40$, $p = 0.020$)。这也进一步表明集中学习存在劣势。

2.5.3 学习策略分析

根据决策边界模型拟合的结果, 对学习者测试阶段的学习策略进行统计分析。结果如表 6 和图 4 所示。

表 4 两种类别结构下不同学习方式的平均反应时($M \pm SD$)

类别结构	集中	交错	随机	自主	总平均反应时
基于规则的类别结构	1.45 $\pm$ 0.40	1.36 $\pm$ 0.40	1.31 $\pm$ 0.36	1.33 $\pm$ 0.31	1.36 $\pm$ 0.37
信息整合的类别结构	1.26 $\pm$ 0.35	1.35 $\pm$ 0.38	1.29 $\pm$ 0.30	1.23 $\pm$ 0.24	1.28 $\pm$ 0.32

表 5 衡量学习者集中和交错学习倾向程度的相关指标($M \pm SD$)

类别结构	切换率	集中学习的最长长度	集中学习的平均长度	交错学习的最长长度	交错学习的平均长度
基于规则的类别结构	0.49 $\pm$ 0.30	11.52 $\pm$ 7.88	6.24 $\pm$ 5.58	23.05 $\pm$ 25.65	8.50 $\pm$ 16.30
信息整合的类别结构	0.44 $\pm$ 0.28	10.76 $\pm$ 7.13	6.24 $\pm$ 5.86	18.67 $\pm$ 20.85	8.03 $\pm$ 17.11

表 6 基于规则和信息整合类别结构下学习策略拟合的人数与占比

学习策略	基于规则的类别结构				信息整合的类别结构			
	集中	交错	随机	自主	集中	交错	随机	自主
一维长度	11 (34.4%)	0 (0.0%)	1 (2.8%)	4 (10.5%)	5 (16.7%)	1 (3.3%)	1 (2.9%)	5 (15.2%)
一维角度	4 (12.5%)	5 (16.7%)	7 (19.4%)	2 (5.3%)	2 (6.7%)	4 (13.3%)	5 (14.7%)	2 (6.1%)
联合规则	12 (37.5%)	22 (73.3%)	26 (72.2%)	28 (73.7%)	2 (6.7%)	2 (6.7%)	0 (0.0%)	0 (0.0%)
信息整合	0 (0.0%)	0 (0.0%)	1 (2.8%)	2 (5.3%)	20 (66.7%)	23 (76.7%)	26 (76.5%)	25 (75.8%)
随机响应	5 (15.6%)	3 (10.0%)	1 (2.8%)	2 (5.3%)	1 (3.3%)	0 (0.0%)	2 (5.9%)	1 (3.0%)

注: 某学习策略占比 = 某学习策略人数/总人数




图 4 基于规则(左)和信息整合(右)类别结构下学习策略拟合的占比分布

首先,对于规则任务,仅有 37.5%的学习者在集中学习类别刺激时,采用联合规则策略(这是习得规则任务的最佳策略),而当交错、随机和自主学习类别刺激时,分别有 73.3%、72.2%和 73.7%的学习者采用联合规则策略。进一步分析发现,对于不同的学习方式,学习者采取的学习策略有所不同, $\chi^2(12, n = 137) = 35.35, p < 0.001, effect\ size = 0.45$ 。由此可见,在基于规则的任务中,集中学习交叉重叠类别结构会影响学习者的决策策略,因而并未发现集中学习的优势。

其次,在信息整合任务中,66.7%的学习者在集中学习类别刺激时,采用信息整合策略(这是习得信息整合任务的最佳策略),而当交错、随机和自主学习类别刺激时,分别有 76.7%、76.5%和 75.8%的学习者采用信息整合策略。进一步分析发现,对于不同学习方式,学习者采取的学习策略并没有显著差异($p = 0.272$)。因此,在信息整合任务中,虽然交错、随机以及自主学习均会促进学习者对最优策略的使用,但并未发现自主学习相较于交错、随机学习存在优势的证据。

3 讨论

在真实的类别情境中,学习者可以自由选择每次试验要学习的类别,并自行决定类别的学习顺序。因此,为了更准确和深入地揭示类别学习的效率机制,除了被动学习方式,本研究还增加了对自主学习方式的探索。实验采用接近中等交叉重叠水平的四类别结构材料,试图更好地分离基于规则和信息整合的类别学习者,平衡两种类别在学习速度上的差异,以探讨学习方式对不同类别结构的影响。结果表明,当类别交叉重叠时,基于规则的分类正确率显著低于信息整合的分类正确率。

本研究还进一步发现了不同类别结构下学习

方式的优势效应:对于规则任务,集中学习的分类正确率显著低于交错、随机和自主学习的分类正确率,但这三种学习方式的分类正确率没有显著差异;对于信息整合任务,集中、交错和随机学习的分类正确率没有显著差异,但自主学习的分类正确率显著高于集中学习的分类正确率。综上,当类别交叉重叠时,集中学习存在着劣势,自主学习存在着优势。

3.1 交叉重叠类别结构下被动学习的劣势

前人研究指出,当交错学习类别刺激时,学习者需要为每个类别同时生成多个检验规则,这会增加工作记忆的负担,最终不利于规则学习(Noh et al., 2016);而当集中学习规则类别时,学习者具备从不相关维度中识别出相关维度的优势,尽管整个过程依赖工作记忆和执行注意,但工作记忆促使学习者在学习过程中储存更多的假设或规则,有利于类别间的比较,最终带来更好的学习效果(Noh et al., 2016; Wang et al., 2020)。因此,对于规则任务,集中学习有利于学习者比较来自同一类别的样例,以生成每个类别的检验规则。与之不同,本实验并未在交叉重叠类别结构下发现集中学习规则任务的优势。并且对于自主学习者,集中学习类别刺激的平均长度与分类正确率呈显著负相关,这也为集中学习交叉重叠类别结构处于劣势提供了数据支持。

根据模型拟合的结果,与交错、随机、自主学习相比,集中学习规则类别会导致联合规则这一最优策略使用的减少,即当集中学习类别刺激时,交叉重叠类别结构可能会影响学习者的决策策略。一般而言,类别学习者需要构建一个决策界限将知觉空间分隔成若干反应区域。在每次试验中,学习者先确定类别刺激所属的区域,再对类别进行判断(Ashby & Gott, 1988; Ashby & Maddox, 1992)。因此,本研究认为当集中学习规则类别时,交叉重叠类别结构由于没有绝对分类规则,可能会干扰学习者

为每个类别生成特定的规则,不利于决策界限的形成,导致难以分离不同类别。这一损害程度大于交错学习类别刺激时工作记忆的增加所造成的负担,最终影响分类决策。

此外,信息整合的类别学习是内隐学习,不依赖执行注意和工作记忆,是一种程序性学习。研究表明,对于程序性学习,交错学习会比集中学习的效果更好(Kornell & Bjork, 2008; Noh et al., 2016)。因为交错学习不仅有助于学习者并列比较类别刺激,以缩小每个类别的特征定义,还能促使学习者快速放弃基于规则的次优策略,最终有利于信息整合的类别学习。根据本研究模型拟合的结果,与集中学习信息整合类别相比,交错学习会导致信息整合这一最优策略使用的增加和规则策略使用的减少。然而,本研究并未在信息整合任务中发现交错学习的优势。

根据区别对比假说(discriminative-contrast hypothesis),当类别间的相似性高,不同类别难以被区分时,交错学习可以促使学习者比较不同类别的刺激,突出类别间的差异性信息,以此促进类别学习(Kang & Pashler, 2012; Rohrer, 2012)。然而,交叉重叠类别结构会削弱类别间的差异,不利于学习者掌握类别间的差异性特征,这可能会进一步干扰学习者将刺激和特定反应形成联结。类别学习多系统理论认为,在类别学习过程中,基于规则主导的陈述性系统和信息整合主导的程序性系统同时运行,两个系统都在争夺分类响应的控制权(Ashby et al., 1998; Ashby & Valentin, 2017; Erickson & Kruschke, 1998)。尽管在本研究中,交叉重叠类别结构可能会影响学习者在信息整合任务中使用信息整合策略的学习效果,但仍会优于规则策略,即程序性系统仍占主导地位。因此,交错学习信息整合类别虽能促使学习者快速放弃基于规则的次优策略,但交叉重叠类别结构可能会削弱类别间的差异性信息,进而干扰刺激与特定反应联结的形成,最终难以出现交错优势。

3.2 交叉重叠类别结构下自主学习的优势

本研究从交叉重叠类别结构这一材料着手,比较了自主学习与被动学习方式的优势效应。结果表明,无论是基于规则和信息整合的类别结构,自主学习的分类正确率均显著高于集中学习的分类正确率,并且自主学习者都更有可能使用最优策略。而对于中间水平方式(交错、随机),其优势效应仅体现在基于规则的类别结构中。因此,本研究初步

认为交叉重叠类别结构下自主学习方式存在着优势。

尽管交叉重叠类别结构增加了每个类别的例外样例,但不同于被动学习方式,自主学习者可以自由选择每次试验学习的类别,并自行决定类别的学习顺序。根据学习者的切换比例,自主学习者不仅限于集中学习或交错学习,而是会有策略性地使用这两种学习方式。这可以增加学习者的选择权和学习动力,促使任务参与度的提高(Gureckis & Markant, 2012; Leotti et al., 2010; Lu et al., 2021; Markant & Gureckis, 2010),呈现出“决策驱动”的优势。

此外,本研究发现了自主学习方式给规则类别和信息整合类别带来不同程度的益处。对于规则任务,自主学习者可以通过对任务的感知调整学习方式,并将复杂的任务分解成一系列简单的问题。例如,学习者可以通过一遍又一遍地选择学习相同的类别,即集中学习,以生成并检验类别内共同特征的假设,还可以随时切换类别以明确类别间的差异特征,这促使自主学习者在学习过程中加快了假设检验的过程,从而有利于规则的类别学习。对于信息整合任务,类别知识的习得客观上依赖信息的累积,学习者通过不断尝试正确或错误类别刺激,缩小了每个类别的特征定义。这促使学习者快速放弃基于规则的次优策略转而使用最佳的信息整合策略,由此程序性系统占主导地位,最终有利于信息整合的类别学习。然而,交叉重叠类别结构会增加学习者的工作记忆负担,从而不利于规则学习。此消彼长,致使自主学习者在基于规则和信息整合任务的分类正确率上没有显著差异。综上,不论是基于规则还是信息整合任务,自主学习者都能更好地习得类别内的共同性信息和类别间的差异性信息,通过减少不确定性来优化他们的决策界限,呈现出“数据驱动”的优势。

3.3 研究局限与进展

首先,本研究未能控制类别间的交叉重叠程度,未来可以从主客观两因素(主动学习、重叠程度)来进一步探索学习方式对不同类别结构的影响。其次,本研究仅探讨了单一学习方式对类别学习的影响,未来可以探索多种学习方式叠加的效果,如研究先集中后交错学习的效果(Rau et al., 2010; Sorensen & Woltz, 2016)。最后,本研究发现的自主学习优势效应尚不够充分,仅揭示了自主学习方式在两种类别结构下都优于劣势的集中学习,未能发现自主学习相较于中间水平学习方式(交错、随机)存在显著

优势的证据,因此,未来还需进一步探究。

4 结论

对于交叉重叠类别结构的学习,(1)无论是基于规则和信息整合任务,自主学习的效果均显著优于集中学习;(2)对于规则任务,没有出现集中学习的优势,反而出现了集中学习的劣势;(3)对于信息整合任务,没有出现交错学习的优势,而只有灵活运用集中和交错的自主学习方式呈现出学习优势。

参考文献

- Ashby, F. G., Alfonso-Reese, L. A., Turken, A. U., & Waldron, E. M. (1998). A neuropsychological theory of multiple systems in category learning. *Psychological Review*, 105(3), 442–481. <https://doi.org/10.1037/0033-295X.105.3.442>
- Ashby, F. G., & Gott, R. E. (1988). Decision rules in the perception and categorization of multidimensional stimuli. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 14(1), 33–53. <https://doi.org/10.1037/0278-7393.14.1.33>
- Ashby, F. G., & Maddox, W. T. (1992). Complex decision rules in categorization: Contrasting novice and experienced performance. *Journal of Experimental Psychology: Human Perception and Performance*, 18(1), 50–71. <https://doi.org/10.1037/0096-1523.18.1.50>
- Ashby, F. G., & Maddox, W. T. (2011). Human category learning 2.0. *Annals of the New York Academy of Sciences*, 1224(1), 147–161. <https://doi.org/10.1111/j.1749-6632.2010.05874.x>
- Ashby, F. G., Queller, S., & Berretty, P. M. (1999). On the dominance of unidimensional rules in unsupervised categorization. *Perception & Psychophysics*, 61(6), 1178–1199. <https://doi.org/10.3758/BF03207622>
- Ashby, F. G., Smith, J. D., & Rosedahl, L. A. (2020). Dissociations between rule-based and information-integration categorization are not caused by differences in task difficulty. *Memory & Cognition*, 48(4), 541–552. <https://doi.org/10.3758/s13421-019-00988-4>
- Ashby, F. G., & Valentin, V. V. (2017). Multiple systems of perceptual category learning: Theory and cognitive tests. In H. Cohen & C. Lefebvre (Eds.), *Handbook of Categorization in Cognitive Science* (2nd ed., pp. 157–188). Elsevier. <https://doi.org/10.1016/B978-0-08-101107-2.00007-5>
- Carvalho, P. F., & Goldstone, R. L. (2014). Putting category learning in order: Category structure and temporal arrangement affect the benefit of interleaved over blocked study. *Memory & Cognition*, 42(3), 481–495. <https://doi.org/10.3758/s13421-013-0371-0>
- Ell, S. W., & Ashby, F. G. (2006). The effects of category overlap on information-integration and rule-based category learning. *Perception and Psychophysics*, 68(6), 1013–1026. <https://doi.org/10.3758/bf03193362>
- Erickson, M. A., & Kruschke, J. K. (1998). Rules and exemplars in category learning. *Journal of Experimental Psychology: General*, 127(2), 107–140. <https://doi.org/10.1037/0096-3445.127.2.107>
- Gureckis, T. M., & Markant, D. B. (2012). Self-directed learning: A cognitive and computational perspective. *Perspectives on Psychological Science*, 7(5), 464–481. <https://doi.org/10.1177/1745691612454304>
- Kang, S. H. K., & Pashler, H. (2012). Learning painting styles: Spacing is advantageous when it promotes discriminative contrast. *Applied Cognitive Psychology*, 26(1), 97–103. <https://doi.org/10.1002/acp.1801>
- Kornell, N., & Bjork, R. A. (2008). Learning concepts and categories: Is spacing the “enemy of induction”? *Psychological Science*, 19(6), 585–592. <https://doi.org/10.1111/j.1467-9280.2008.02127.x>
- Leotti, L. A., Iyengar, S. S., & Ochsner, K. N. (2010). Born to choose: The origins and value of the need for control. *Trends in Cognitive Sciences*, 14(10), 457–463. <https://doi.org/10.1016/j.tics.2010.08.001>
- Lu, X., Penney, T. B., & Kang, S. H. K. (2021). Category similarity affects study choices in self-regulated learning. *Memory & Cognition*, 49(1), 67–82. <https://doi.org/10.3758/s13421-020-01074-w>
- Maddox, W. T., & Ashby, F. G. (2004). Dissociating explicit and procedural-learning based systems of perceptual category learning. *Behavioural Processes*, 66(3), 309–332. [https://doi.org/10.1016/S0376-6357\(04\)00060-9](https://doi.org/10.1016/S0376-6357(04)00060-9)
- Maddox, W. T., Filoteo, J. V., Hejl, K. D., & Ing, A. D. (2004). Category number impacts rule-based but not information-integration category learning: Further evidence for dissociable category-learning systems. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 30(1), 227–245. <https://doi.org/10.1037/0278-7393.30.1.227>
- Markant, D., & Gureckis, T. (2010). Category learning through active sampling. In S. Ohlsson, & R. Catrambone (Eds.), *Proceedings of the annual meeting of the cognitive science society* (Vol. 32, pp. 248–253). Cognitive Science Society.
- Minda, J. P., & Smith, J. D. (2001). Prototypes in category learning: The effects of category size, category structure, and stimulus complexity. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 27(3), 775–799. <https://doi.org/10.1037/0278-7393.27.3.775>
- Murphy, G. L., & Ross, B. H. (1999). Induction with cross-classified categories. *Memory & Cognition*, 27(6), 1024–1041. <https://doi.org/10.3758/bf03201232>
- Noh, S. M., Yan, V. X., Bjork, R. A., & Maddox, W. T. (2016). Optimal sequencing during category learning: Testing a dual-learning systems perspective. *Cognition*, 155, 23–29. <https://doi.org/10.1016/j.cognition.2016.06.007>
- Nomura, E. M., Maddox, W. T., Filoteo, J. V., Ing, A. D., Gitelman, D. R., Parrish, T. B., ... Reber, P. J. (2007). Neural correlates of rule-based and information-integration visual category learning. *Cerebral Cortex*, 17(1), 37–43. <https://doi.org/10.1093/cercor/bhj122>
- Rau, M. A., Aleven, V., & Rummel, N. (2010). Blocked versus interleaved practice with multiple representations in an intelligent tutoring system for fractions. In V. Aleven, J. Kay, & J. Mostow (Eds.), *Intelligent tutoring systems* (pp. 413–422). Springer. https://doi.org/10.1007/978-3-642-13388-6_45
- Rawson, K. A., Thomas, R. C., & Jacoby, L. L. (2015). The power of examples: Illustrative examples enhance conceptual learning of declarative concepts. *Educational Psychology Review*, 27(3), 483–504. <https://doi.org/10.1007/s10648-014-9273-3>
- Roark, C. L., Smayda, K. E., & Chandrasekaran, B. (2022). Auditory and visual category learning in musicians and nonmusicians. *Journal of Experimental Psychology: General*, 151(3), 739–748. <https://doi.org/10.1037/xge0001088>
- Rohrer, D. (2012). Interleaving helps students distinguish among similar concepts. *Educational Psychology Review*, 24(3), 355–367. <https://doi.org/10.1007/s10648-012-9201-3>

- Rohrer, D., Dedrick, R. F., Hartwig, M. K., & Cheung, C. N. (2020). A randomized controlled trial of interleaved mathematics practice. *Journal of Educational Psychology*, 112(1), 40–52. <https://doi.org/10.1037/edu0000367>
- Seger, C. A., & Miller, E. K. (2010). Category learning in the brain. *Annual Review of Neuroscience*, 33(1), 203–219. <https://doi.org/10.1146/annurev.neuro.051508.135546>
- Sorensen, L. J., & Woltz, D. J. (2016). Blocking as a friend of induction in verbal category learning. *Memory & Cognition*, 44(7), 1000–1013. <https://doi.org/10.3758/s13421-016-0615-x>
- Wang, J., Liu, Z., Xing, Q., & Seger, C. A. (2020). The benefit of interleaved presentation in category learning is independent of working memory. *Memory*, 28(2), 285–292. <https://doi.org/10.1080/09658211.2019.1705490>
- Zulkipli, N., & Burt, J. S. (2013). The exemplar interleaving effect in inductive learning: Moderation by the difficulty of category discriminations. *Memory & Cognition*, 41(1), 16–27. <https://doi.org/10.3758/s13421-012-0238-9>

Self-regulated learning advantage and blocked learning disadvantage on overlapping category structure

YUE Fang, CHEN Jianping, GAN Kexin, WANG Yuqing, LIU Zhiya

(Center for Studies of Psychological Application / School of Psychology, South China Normal University, Guangzhou 510631, China)

Abstract

Previous studies have found that participants benefit more from blocked learning in rule-based category learning but perform better with interleaved learning in information-integration category learning. In interleaved learning, participants need to generate four categories at the same time, which will create a high working memory load if applying a rule-based learning strategy and hence will encourage participants to switch from this sub-optimal strategy to information integration. However, previous studies always require passive conduct of blocked learning or interleaved learning. In real life, people will strategically switch between these two kinds of learning schedules. To grasp a better understanding, we compared passive and proactive learning schedules (blocked, interleaved, self-regulated, random). In addition, the categories used in previous studies are mutually exclusive, which contradicts real life where categories always overlapped each other and cannot be perfectly distinguished according to one or more combinations of features. For mutually exclusive structures, it is easy to confuse rule-based and information-integrated learners, and there is a countable difference in the learning speed of these two category structures. To gain more reliable results, an appropriate overlap level and the number of categories were chosen for this study.

The classical four categories rule-based and information integration task is revised to contain overlapping stimuli. If classified by both two dimensions the highest accuracy was 90%. A 2×4 between-subject design was adopted. The dependent variables are accuracy and response time, and the first independent variable was the category structure: rule-based (RB) and information-integration (II). The second variable was the schedule of learning: blocked, interleaved, self-regulated, and random, with random presentation as the baseline condition. 265 college students were paid to participate in the experiment. Each participant should observe and report to which categories the line segment belonged. There were 100 trials each for both the learning phase and the test phase. Each phase comprised 25 trials for each category. For the test phase, a new set of stimuli are used and no feedback is provided. The behavioral data collected fit into a mathematical model to analyze what strategies participants used during tasks.

The results showed a significant main effect of category structure. That is, the classification accuracy of the information-integration task is significantly higher than the rule-based task. The main effect of learning schedules was also significant. That is, the classification accuracy of interleaved, self-regulated, and random learning was significantly higher than that of blocked learning. Post hoc tests showed that the classification accuracy of the blocked learning was significantly lower than that of interleaved, self-regulated, and random learning under rule-based conditions. For the information-integration condition, the classification accuracy of the blocked learning was significantly lower than that of self-regulated. In addition, this study further analyzed learners' self-regulated learning behaviors under the overlapping category structure and found that for both

rule-based tasks and information-integration tasks, learners' average length of blocked learning was significantly negatively correlated with their classification accuracy. A mathematical technique of the "Decision Bound Model" was used to analyze the data from the experiment. The results of model fitting showed that in both rule-based and information-integration tasks, self-regulated learners can use the optimal strategy more frequently.

In conclusion, this study makes up for the deficiency of perfectly classified categories, finds the advantages of self-regulated learning and the disadvantages of blocked learning in category overlap, and preliminarily reveals the self-regulated learning advantages and information processing characteristics of overlapping category learning. It believes that category overlap interferes with the corresponding rules formed by learners for each category under the condition of blocking learning, which is not conducive to the blocked learning of rule-based tasks. In addition, the overlapping category structure will weaken the different information between categories and retain the common information within categories, which is not conducive to the interleaved learning of information-integration tasks. However, compared with passive learning, self-regulated learning has advantages in the learning of the two types of category structure because of its "decision-driven" and "data-driven" effects.

Keywords category learning, category overlap, interleaved learning, blocked learning, self-regulated learning