

文章编号: 1006-3080(2025)03-0371-09

DOI: 10.14135/j.cnki.1006-3080.20240617001

基于 ACT-R 的认知间隔重复学习方法

吴蕴超, 罗飞, 陶俊臣, 王晨, 张子亿

(华东理工大学信息科学与工程学院, 上海 200237)

摘要: 间隔重复学习方法在辅助学生自主学习方面发挥了重要的作用; 然而传统的间隔重复算法在间隔控制上过于僵化, 导致学生每日的学习任务量差异明显, 进而影响学习效率。为了提升自主学习效率, 提出了一种基于 ACT-R (Adaptive Control of Thought-Rational) 的认知间隔重复学习方法。首先, 基于 ACT-R 规划学习过程, 模拟学生学习行为并提取主导模型记忆变化的激活参数; 其次, 提出了遗忘曲线切割算法, 将遗忘特性反映到学习规划之中, 并提取记忆留存率与推荐复习间隔等参数; 最后, 基于二者所得学习参数, 针对特定的学习任务动态地生成间隔重复学习规划。实验结果表明, 相较于传统的间隔重复学习算法, 基于 ACT-R 的认知间隔重复学习方法可以合理有效地安排自主学习任务, 每日学习任务量更加均衡, 每个任务的学习时间分布也更加合理。

关键词: 认知架构; ACT-R; 遗忘曲线; 间隔重复算法; 学习规划

中图分类号: TP391

文献标志码: A

近年来, 互联网信息技术的发展与普及带来了重大社会变革, 标志着全球化、信息社会和知识时代的到来。这促使各行各业与互联网技术结合发展, 其中之一便是教育行业, 越来越多的学习资料在互联网上公开, 使得学生可以更加容易地获取到自身所需的学习资料。与此同时, 结合教育的推荐算法也适时出现^[1], 它能帮助学生从海量的学习资料中获取自身所需内容^[2-4]。虽然这些推荐算法能够根据每个用户的兴趣和偏好提供多种选择^[5], 其针对的是学习方向与学习内容的个性化, 而不能个性化地指导学生怎么学, 也没能帮助学生如何更快更有效地掌握学习内容。

间隔重复学习方法是一种指导学生怎么学的方法, 最初由艾宾浩斯(Ebbinghaus)提出^[6]。它是基于间隔效应和滞后效应的学习方法, 以提高记忆和理解。间隔效应是指人们使用间隔重复练习有效锻炼记忆; 滞后效应指的是人们逐渐增加练习之间的间隔时间得到更好的学习效果^[7]。间隔效应和滞后效

应的影响已经在各方面研究中体现出来, 如语言学习^[8-9]、体育技能锻炼等^[10]。

在艾宾浩斯的间隔重复学习算法中, 间隔是固定的; 在皮姆斯勒(Pimsleur)所提出的学习方法^[11]中, 其间隔是以指数增加的; 莱特纳(Leitner)的间隔重复算法^[12]中, 时间间隔是递增的: 单词学习起始时位于第一个时间间隔, 当学生在规定时间间隔后能回忆起该单词, 那么它将被升级到更高时间间隔, 反之则降低。近年来一些新的间隔重复学习算法被提出, 如 GRU-HLR^[13], 其使用具有马尔科夫特性的记忆模型, 将区间重复优化问题转化为随机最短路径问题, 并采用值迭代法求解; 还有 DRL-SRS^[14], 其使用深度强化学习模型, 通过循环方式训练策略来优化间隔重复策略。

至今为止, 间隔重复学习算法仍然面临一些难以解决的问题, 如间隔控制比较僵硬, 无法动态调整间隔, 导致学习效率下降。若通过拟合数据集来调整学习间隔, 则使得间隔重复学习算法脱离了遗忘

收稿日期: 2024-06-17

作者简介: 吴蕴超(1999—), 男, 上海人, 硕士生, 主要研究方向: 认知计算。E-mail: chenfbj@qq.com

通信联系人: 罗飞, E-mail: luof@ecust.edu.cn

引用本文: 吴蕴超, 罗飞, 陶俊臣, 等. 基于 ACT-R 的认知间隔重复学习方法 [J]. 华东理工大学学报(自然科学版), 2025, 51(3): 371-379.

Citation: WU Yunchao, LUO Fei, TAO Junchen, et al. A Cognitive Spaced Repetitive Learning Method Based on ACT-R[J]. Journal of East China University of Science and Technology, 2025, 51(3): 371-379.

曲线的理论基础。因而,如何动态调整学习间隔,成为了间隔重复学习算法亟待解决的问题。

ACT-R(Adaptive Control of Thought-Rational) 是安德森(Anderson)在 1976 年提出的一种认知架构^[15-16],已经广泛应用于教育^[17]、自动驾驶^[18-19]等领域。本文提出了一种基于 ACT-R 的认知间隔重复学习方法。ACT-R 旨在从过程层面对人类认知进行建模,并模拟人类通过大脑处理其环境信息的过程。该方法通过 ACT-R 体系结构与激活机制模拟学习过程,并提取主导模型记忆变化的激活参数;同时结合遗忘曲线,提出遗忘曲线切割算法,并提取记忆留存率与推荐复习间隔等参数;结合二者的参数,在保留可解释性的基础之上实现动态地调整学习间隔,从而动态地指导学生进行自主学习。

1 学习方法设计

结合 ACT-R 记忆机制与遗忘曲线切割机制,本文提出的认知间隔重复学习方法分为 3 个部分:基于 ACT-R 的学习过程模拟、遗忘曲线切割算法和间隔重复学习规划。

1.1 基于 ACT-R 的学习过程模拟

基于 ACT-R 的学习过程模拟如算法 1(表 1)所示,总体分 3 个阶段:准备阶段、学习阶段和静默阶段。准备阶段:配置 ACT-R 运行相关参数,等待间隔重复学习规划安排学习任务,并在获得此轮学习任务;学习阶段:ACT-R 模拟学生学习知识点的完整流程,包括看到知识点、回忆内容,加深印象或者进行学习,直到所有知识点学习完毕;静默阶段:ACT-R 将学习阶段激活参数的变化返回至间隔重复学习规划,并等待间隔重复学习规划安排,以模拟学生在完成一轮学习任务后的遗忘过程,等待新一轮学习任务安排。

在算法 1 中, a_i 为知识点对象;本轮学习规划 b_i 是一个集合,包含多个 a_i ; n_1 为本轮学习的新 a_i 数; n_2 为本轮复习 a_i 数。Recognition(a_i) 方法为 ACT-R 使用视觉模块辨识知识点 a_i ; Recall(a_i) 方法为 ACT-R 检索陈述性模块试图回忆知识点 a_i ; DeepenImpression(a_i) 方法为 ACT-R 在回忆成功后加深陈述性模块对知识点 a_i 的印象; Learn(a_i) 方法为 ACT-R 在回忆失败后陈述性模块学习知识点 a_i ; UpdateActivation(a_i) 为从陈述性模块中获取并更新知识点 a_i 的激活参数。基于上述流程,可知算法 1 的时间复杂度为 $O(n_1 + n_2)$ 。

每当 ACT-R 模拟知识点学习时,会创建或影响

表 1 计算激活参数

Table 1 Calculate activation parameter

Algorithm 1: CalculateActivationRate(b_i)

Input: This round of knowledge point learning plan b_i

Output: The activation parameters of a_i have changed

```

1: for  $a_i$  in  $b_i$  do
2:   Recognition( $a_i$ )
3:   if Recall( $a_i$ ) do
4:     DeepenImpression( $a_i$ )
5:   end if
6:   else
7:     Learn( $a_i$ )
8:   end else
9:   UpdateActivation( $a_i$ )
10: end for

```

知识点对应的记忆块,其通过激活参数控制记忆块模拟人类记忆情况;ACT-R 的记忆内容将以记忆块(Chunk)的形式存储在内存中,与此同时,对应该块会生成一个激活参数,具体公式如下:

$$A_i = \ln \left(\sum_{j=1}^n t_j^d \right) + \epsilon_i \quad (1)$$

其中, A_i 为第 i 个记忆块的激活参数; n 是该记忆块总共被调用的次数; d 为基础学习衰减参数,ACT-R 推荐值 0.5; ϵ_i 为第 i 个记忆块的噪音参数; t_j 为第 j 次调用时距离当前计算激活参数时的时间差。

ACT-R 使用幂函数来模拟记忆块的遗忘曲线,且每一次对同一知识点的学习所产生的记忆都会生成一条遗忘曲线,而人类对该知识点的记忆程度则由学习该知识点产生的所有学习记忆去重加权计算。

1.2 遗忘曲线切割算法

记忆遗忘曲线是由德国心理学家艾宾浩斯提出^[20],基于此,研究人员提出了多种遗忘曲线^[21]。在这些遗忘曲线公式中,受试者在第一次学习后进行分组,进而在规定时间内对该知识进行再次学习,并记录下两次学习所耗费时间,最终构成了以时间点为横坐标、节约率为纵坐标的遗忘曲线图,然而这种遗忘曲线未考虑多次复习对学习记忆的影响。因此本文提出一种切割遗忘曲线算法,并基于该算法模拟多次学习一个知识点后的记忆情况,具体内容为:首先,节约率反映知识点随时间在大脑中的留存情况,因而本文将节约率作为该知识点的记忆留存率;记忆留存率越高,说明对该知识点掌握得越完整;且在完成知识点学习的那一刻,记忆留存率为 100%,之后随时间流逝而降低。其次,对一个知识点的复习,反馈在该知识点对应的遗忘曲线变化之中;遗忘曲线中的拟合参数反映了受试者一段时间内的记忆状态,

该参数的变化反映的是长时间大脑机能的改变,而不会在短期内因个别知识点而改变。因此,相对于调整遗忘曲线的参数,本文提出当大脑多次学习同一个知识点时,会刺激该知识点对应的记忆,从而切割部分记忆的急速遗忘阶段,最终使得记忆长久保持在较高留存率的状态。具体公式如下:

$$Q(x) = Q(x - x_i) + y_i \quad (2)$$

其中, $Q(x)$ 为记忆留存率; x 为计算留存率时刻距离上一次学习的时间差; i 为该知识点的复习次数; x_i 为切割区域偏移量,每次学习将会根据推荐复习间隔切割部分曲线; y_i 修正公式偏移量,确保每次复习时记忆留存率为 100%。随着复习次数的增加,公式将切割越来越多的短期记忆区域,记忆留存率的下降速率逐渐由高降低。每次复习后切割的时间长度参考遗忘曲线原始参数,从 20 min 起,直到最长为 30 d 的切割幅度,与此同时也对复习的间隔时间提出要求,每次复习的间隔时间要尽可能贴合切割幅度,具体切割幅度会因为复习间隔时间的长短做缩减,以此控制知识点学习的间隔幅度,具体细节如算法 2(表 2)所示。本文中计算的记忆留存率 $Q(x)$ 均为自学习起时间满 30 d 后的记忆留存率,以保证记忆有充足的时间转化为长期记忆。

算法 2 为计算遗忘曲线参数的具体步骤,首先设定每次切割的初始时间长度集合 l , 长度间隔参考遗忘曲线实验间隔,即 20 min, 1 h, 9 h, 1 d, 2 d, 6 d, 最后的 30 d 因缺乏调整灵活性,分为多个间隔为 6 d 的时间长度。 s_i 为推荐学习时间间隔, t_i 为当前学习次数; x_i 为偏移量, y_i 初始值为 0, 随着每一次学习, x_i 在基于之前的基础上,结合推荐时间间隔 s_i 与真正时间间隔 x 计算新一轮 x_i , 同时依照新的 x_i 更新 y_i ; 最后计算知识点 a_i 的 $Q(x)$, 以及修正学习次数 t_i 和对应的推荐学习时间间隔 s_i 。算法 2 的时间复杂度为 $O(n_1 + n_2)$, 其中 n_1 为本轮学习的新知识点, n_2 为本轮复习的知识点。

1.3 间隔重复学习规划

间隔重复学习规划如算法 3(表 3)所示。设定学习知识点总数 N , 每轮学习 n_1 个新知识点, 复习 n_2 个已经学习的知识点。总计学习 N 个知识点 $\{a_1, a_2, \dots, a_N\}$, $a_i = \{Q(x), s_i, A(x), t_i, x_i, y_i\}$, $i \in \{1, 2, \dots, N\}$, 其中 $A(x)$ 为知识点 a_i 的激活。将 N 个知识点划分为 3 个集合 S_0, S_1, S_2 , 其中 S_0 包含未学习知识点; S_1 包含正在学习的知识点; S_2 包含完成学习的知识点。

在算法 3 中, 每一轮学习会选择 n_1 个新知识点和 n_2 个旧知识点进行学习(由算法 4(表 4)所示), 然

表 2 计算遗忘曲线参数

Table 2 Calculate curve parameter of the forgetting curve

Algorithm 2: CalculateForgettingRate(b_i)

Input: This round of knowledge point learning plan b_i

Output: Calculate memory retention rate $Q(x)$, and

related parameters s_i, t_i, x_i, y_i

```

1:  $l \leftarrow [0, 1200, 3600, 32400, 86400, 172800, 518400, 518400 \dots]$ 
2: //  $l$  is the set of time lengths set, in seconds.
3: for  $a_i$  in  $b_i$  do
4:    $x_i \leftarrow x_i + e^{-|x-s_i|} * l[t_i]$ 
5:    $y_i \leftarrow Q(x) - Q(x-x_i)$ 
6:    $Q(x) \leftarrow Q(x-x_i) + y_i$ 
7:    $t_i \leftarrow t_i + 1$ 
8:    $s_i \leftarrow l[t_i]$ 
9: end for

```

后根据学习情况重新划分知识点集合(由算法 5(表 5)所示), 最后根据当前学习压力调整次轮的学习参数(由算法 6(表 6)所示), 并将本轮学习规划 b_i 加入完整的学习规划 M 之中, 直到所有知识点全部学习完毕(S_0, S_1 均为空时)。算法 3 的时间复杂度为 $O(T*N)$, 空间复杂度为 $O(N)$, 其中 T 为学习知识点轮次, N 为知识点总数。

算法 4 是选择知识点进行学习的具体步骤, 首先随机选择 n_1 个新知识点加入学习规划 b_i , 对于正在学习的知识点集合, 根据 ACT-R 激活参数、遗忘曲线参数、当前时间与复习推荐时间间隔之差、噪音 ξ (取值范围 $(-0.5, -0.5)$) 加权计算, 依照权重从小到大选择 n_2 个需要复习的知识点加入学习规划 b_i , 然后计算 a_i 的相关参数之后返回学习规划。算法 4 的时间复杂度为 $O(n_1 + n_2)$ 。

算法 5 是根据本轮学习规划 b_i 调整知识点集合划分的具体步骤, 遍历本轮学习规划 b_i , 如果是首次学习, 那么将 a_i 从集合 S_0 调整至集合 S_1 ; 如果是正在学习的知识点, 通过判断该知识点的 $Q(x)$ 与 $A(x)$ 是否均高于阈值, 进而判断该知识点是否被掌握, 如果被掌握, 则将其从 S_1 调整至 S_2 , 阈值可通过模拟其他学习规划进行动态调整抑或设定为静态。算法 5 的时间复杂度为 $O(n_1 + n_2)$ 。

算法 6 是根据学习压力调整学习参数的具体步骤, 算法首先计算 S_1 与 S_2 中知识点的平均学习次数, 理想情况下 S_1 中的平均次数是 S_2 中的一半; 算法 6 的时间复杂度为 $O(N)$ 。

2 实验结果与分析

以单词学习规划为任务, 本文进行实验对比分

表 3 间隔重复学习规划

Table 3 Spaced repetitive learning planning

Algorithm 3: Spaced Repetitive Learning Planning

Input: Total number of knowledge points $N=\{a_1, a_2, \dots, a_N\}$, initial learning parameters n_1, n_2

Output: Knowledge point learning plan $M=\{b_1, b_2, \dots, b_N\}$, b_i is the learning plan for the knowledge points in the i round

- 1: Initialize object $a_i = \{Q(x), s_i, A(x), t_i, x_i, y_i\}$, S_0, S_1, S_2 , in the initial state a_i is in S_0 . $M \leftarrow []$
- 2: while $S_0 \neq \text{null} \ \&\& \ S_1 \neq \text{null}$ do
- 3: $b_i \leftarrow \text{LearningKnowledge}(S_0, S_1, n_1, n_2)$
- 4: Reclassify (S_0, S_1, S_2, b_i)
- 5: Balance (n_1, n_2, S_1, S_2)
- 6: Append (M, b_i)
- 7: end while
- 8: return M

表 4 知识点学习

Table 4 Knowledge learning

Algorithm 4: LearningKnowledge(S_0, S_1, n_1, n_2)

Input: Knowledge point division set S_0, S_1 , learning parameter n_1, n_2

Output: The set of knowledge points for this round of learning is b_i

- 1: $b_i \leftarrow []$
- 2: Randomly select n_1 new knowledge points from S_0 and add them to this round of learning plan b_i
- 3: sort($S_1, 0.4 * (1 - e^{-|t_i - s_i|}) + 0.3 * Q(x) + 0.2 * A(x) + 0.1 * \xi$)
- 4: Select n_2 learning points in sequence from S_1 and add them to the current learning plan b_i
- 5: CalculateActivationRate(b_i)
- 6: CalculateForgettingRate(b_i)
- 7: return b_i

析。首先,为了与传统遗忘曲线、经典的 Leitner 间隔重复学习算法、以及基于 ACT-R 的认知间隔重复学习方法在间隔重复学习规划方面的区别,本文进行了学习规划对比:设定学习时长为 100 d,每日学习总量为 50 个的单词学习实验。通过该实验说明基于 ACT-R 的认知间隔重复学习方法的稳定性。

其次,针对大规模的学习任务规划,本文首先进行学习结果预测,通过数据集去训练得出记忆留存率阈值,并计算该阈值的准确性等指标;然后学习任务规划,在基于得出阈值的基础上进行学习任务规划,并对比均值和标准差等指标。

2.1 实验设置

为了研究不同遗忘曲线对生成的间隔重复学习规划的影响,本文在实验中选取了 3 种典型的遗忘

表 5 集合重划分

Table 5 Reclassify of set

Algorithm 5: Reclassify(S_0, S_1, S_2, b_i)

Input: The set of knowledge points S_0, S_1, S_2 , this round of learning plan b_i

Output: Reclassify the set of knowledge points S_0, S_1, S_2 based on the learning situation

- 1: for a_i in b_i do
- 2: if $a_i \in S_0$ do
- 3: Move a_i from S_0 to S_1
- 4: end if
- 5: else
- 6: if Is Mastered(a_i) do
- 7: Move a_i from S_1 to S_2
- 8: end if
- 9: end else

表 6 平衡学习参数

Table 6 Balance learning parameter

Algorithm 6: Balance (n_1, n_2, S_1, S_2)

Input: Set of knowledge points S_0, S_1 , learning parameters n_1, n_2

Output: Modify learning parameters based on learning situation n_1, n_2

- 1: $u \leftarrow \text{CalculateAverageFrequency}(S_2) / 2 - \text{CalculateAverageFrequency}(S_1)$
- 2: $n_1 \leftarrow n_1 - [u * (n_1 + n_2)]$
- 3: $n_2 \leftarrow n_2 + [u * (n_1 + n_2)]$

曲线。

(1) 文献 [22] 在 1880 年设计的遗忘曲线 (curve1880), 相对于时间 t 的遗忘曲线记忆留存率公式如下:

$$Q(t) = (1 + u_1 t)^{-a_1} \quad (3)$$

其中, u_1 为控制公式反映的短期记忆遗忘速率, a_1 为控制长期记忆遗忘速率。

(2) 文献 [23] 在 1991 年设计的遗忘曲线 (curve1991), 相对于时间 t 的遗忘曲线记忆留存率公式如下:

$$Q(t) = u_1 e^{-a_1 t} + u_2 e^{-a_2 t} \quad (4)$$

式 (4) 通过两个指数函数叠加描述记忆的多阶段特性。其中, $u_1 e^{-a_1 t}$ 反映了短期记忆遗忘, $u_2 e^{-a_2 t}$ 反映了长期记忆衰减。

(3) 文献 [24] 在 2015 年设计的遗忘曲线 (curve2015), 遗忘曲线记忆留存率相对于时间的公式如下:

$$Q(t) = u_1 e^{-a_1 t} + \frac{u_1 u_2 (e^{-a_2 t} - e^{-a_1 t})}{a_1 - a_2} \quad (5)$$

其中, $u_1 e^{-a_1 t}$ 表示记忆在海马体中存储的情况, $u_1 u_2 (e^{-a_2 t} - e^{-a_1 t}) / a_1 - a_2$ 表示记忆稳定的转移到新皮层后的存储情况。

本文实验使用墨墨背单词(Memo)开源的数据集,通过规划学生背单词的方式分析模型的动态规划间隔重复学习方法。首先对数据集进行预处理,去除数据集中对于曾经学习过或已经掌握的单词的复习记录。本文的评价指标有 cMean、cVar、cVarS、sMean、sVarS、 F_1 、AUC。

cMean 为知识点平均学习次数,其计算公式如下:

$$cMean = \frac{1}{n} \sum_{i=1}^n t_i \quad (6)$$

其中, t_i 为单词的学习次数。

cVar 为知识点相较于平均学习次数的方差,其计算公式如下:

$$cVar = \frac{\sum_{i=1}^n (t_i - cMean)^2}{n} \quad (7)$$

cVarS 为知识点相较于平均学习次数的样本标准差,其计算公式如下:

$$cVarS = \sqrt{\frac{\sum_{i=1}^n (t_i - cMean)^2}{n-1}} \quad (8)$$

sMean 为学习的平均间隔时间,其计算公式如下:

$$sMean = \frac{1}{n} \sum_{i=1}^n s_i \quad (9)$$

其中, s_i 为第 i 次学习相较于上一次学习的时间间隔。

sVarS 为学习间隔相较于平均间隔时间的样本标准差,其计算公式如下:

$$sVarS = \sqrt{\frac{\sum_{i=1}^n (s_i - sMean)^2}{n-1}} \quad (10)$$

F_1 值是一个综合考虑精确率和召回率的指标。精确率(Precision)是指在所有被模型预测为正例的样本中,真正为正例的样本所占的比例;召回率(Recall)则是在所有真实为正例的样本中,被模型正确预测为正例的样本所占的比例。 F_1 分数是这两个比例的调和平均数,它在两者之间取得平衡。 F_1 的计算公式如下:

$$F_1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (11)$$

AUC 值代表 ROC 曲线下的面积(Area Under the ROC Curve)。ROC 曲线是以假正率(实际为负例样本而被预测为正例样本)为横坐标、召回率为纵坐标

绘制的曲线。AUC 的值介于 0~1 之间,值越大表示模型的性能越好。AUC 能够衡量模型对正负样本排序能力的整体表现。

2.2 学习规划对比

本文对比了不同间隔重复学习算法对学习任务规划的学习结果和稳定程度,具体设定学习时长为 100 d,每天可安排学习单词数量为 50,由不同间隔重复学习算法生成间隔重复学习规划。表 7 中示出了 Leitner 提出的间隔重复学习算法(Leitner)、传统静态间隔重复学习算法的 3 种遗忘曲线(curve1880, curve1991, curve2015),以及基于 ACT-R 的认知间隔重复学习方法结合 3 种遗忘曲线(ACT-R curve1880, ACT-R curve1991, ACT-R curve2015)。表中 Num 为 100 d 总共掌握的单词数目。从表中可以得出,每日的学习任务量固定时,传统算法难以调整学习间隔,导致单词无法在最佳学习间隔被规划入学习任务,所以单词的学习次数方差较大。本文提出的学习方法可以实现动态的间隔重复学习规划,尽可能保证每个单词在最佳学习间隔期间被规划入学习任务,以帮助学生提升学习效率。

2.3 学习结果预测

本文使用遗忘曲线切割算法对 memo 数据集的学习间隔历史($t_history$)进行模拟,得出对应的记忆留存率阈值,同时以该阈值为判断标准,对其他部分数据集的学习间隔进行判断,得出是否掌握,并对结果进行分析对比,结果如表 8 所示。表中,Param 为不同遗忘曲线所使用的不同参数,1、2、3、4 分别对应 Ebbinghaus, Mack, Seitz, Dors 数据集的结果^[24];MQ 值为遗忘曲线切割算法经数据集训练后得出的记忆留存率阈值。

从表 8 可以看到,遗忘曲线切割算法对于单词学习结构的预测整体效果良好,其中 ACT-R curve1991 和 ACT-R curve2015 的第 2 组参数的 F_1 值表现最优,而 ACT-R curve2015 第 4 组参数和 ACT-R curve1880 的 AUC 值表现最优。ACT-R curve1880 的 4 组参数对于实验的影响很低,MQ、 F_1 与 AUC 每组参数之间的差异很小,这表明了这类遗忘曲线的函数体简单,同时其效果也更加受限于该函数体,不同参数的影响并不明显,ACT-R curve1880 未能明显体现出不同数据集之间的差异性;ACT-R curve1991 与 ACT-R curve2015 则体现出了不同参数之间的差异性,这两种曲线对于 4 组数据集拟合出的结果非常相似,这也表明用参数调控两个函数体可以更好地拟合记忆遗忘曲线特性;curve1991 与 curve2015 的第 1 组和第 4 组参数通过数据集训练得出的记忆

表 7 间隔重复学习规划方差

Table 7 Spaced repetitive learning planning variance

Algorithm	Num	cVar
Leitner	371	2.354315
curve1880	419	2.317563
curve1991	428	2.221028
curve2015	439	2.246310
ACT-R curve1880	517	0.007345
ACT-R curve1991	461	0.547167
ACT-R curve2015	510	0.340006

留存率阈值不到 0.9, 低于其他参数, 可能原因是数据集收集的是 20 岁年轻人背诵单词的记录, 而 1、4 两组参数拟合的数据集大多来源为中年人, 这使得这两组参数拟合出的遗忘曲线认为更高频率的学习才能保证较高的记忆留存率, 表现出来就是数据集中的学习轨迹不足以获得足够高的记忆留存率, 这也导致基于该记忆留存率阈值的单词学习结果预测效果不佳, $F1$ 值较低, 但更看重样本排序的 AUC 值并不受到记忆留存率阈值设定的影响。另一个可能的原因是数据集的学习轨迹不规律, 根据该学习轨迹获得的记忆留存率也较低。

2.4 学习任务规划

在基于实验所得的记忆留存率阈值的基础上, 实现对学生学习 5000 个单词任务的间隔重复学习规划, 该任务假设学生每天固定学习 200 个单词, 其中新旧单词学习数目将进行动态调整, 最终整体的学习规划, 结果如表 9 所示。表中, Time/d 为最终需要多少天能够完成 5000 个单词的学习。

从表 9 中可以看到, 相对于 Memo 数据集高达 7.463726 的学习次数标准差, 本文提出的间隔重复学习方法能够很好地调节学习新旧单词的平衡, 使得单词的学习频率较为平稳。ACT-R curve1880 的效果仍然受限于其单个函数, 难以体现不同参数之间的差异, 且 ACT-R curve1880 对于单词频率学习次数的要求最低, 平均间隔学习约 8 次即认定掌握了该单词。ACT-R curve1991 和 ACT-R curve2015 参数之间的差异较为明显, 第 1 组与第 4 组参数在记忆留存率阈值低于其他参数的情况下, 第 4 组参数的学习频率明显降低, 说明第 1 组参数倾向于增加学习频率, 第 4 组参数认为数据集中的学习轨迹不符合该曲线的特性。

基于 ACT-R curve1880, ACT-R curve1991, ACT-R curve2015 的间隔重复学习方法对于 5000 个单词

表 8 单词学习结果预测

Table 8 Word learning result prediction

Algorithm	Param	$F1/\%$	AUC/%	MQ
ACT-R curve1880	1	86.70	81.62	0.943842
	2	86.70	81.61	0.944289
	3	86.76	81.61	0.943226
	4	86.30	81.62	0.952764
ACT-R curve1991	1	87.37	80.77	0.894011
	2	88.05	81.11	0.942725
	3	87.17	80.47	0.93349
	4	84.46	81.60	0.839454
ACT-R curve2015	1	87.81	81.02	0.892609
	2	88.08	81.22	0.942148
	3	87.17	80.52	0.932828
	4	84.79	81.98	0.827532

表 9 单词学习规划模拟参数

Table 9 Word learning planning simulation parameter

Algorithm	Param	cMean	cVarS	Time/d
ACT-R curve1880	1	8.0782	0.085713	216
	2	8.0074	0.085713	216
	3	8.0074	0.085713	216
	4	8.0074	0.085713	216
ACT-R curve1991	1	11.0102	0.728424	309
	2	13.7606	1.015231	392
	3	11.6064	1.045609	334
	4	9.0068	0.082189	245
ACT-R curve2015	1	11.884	0.569745	334
	2	12.8514	1.275478	375
	3	12.1676	0.698003	343
	4	8.0074	0.085713	218
Memo	—	12.02318	7.463726	

的学习规划与 Memo 数据集本身的学习轨迹特征分别如图 1~4。由于数据集中存在学习轨迹过长的数据, 图 4 选取了学习轨迹长度小于 20 的情况。图中横坐标为单词的学习次数, 纵坐标为单词的间隔重复长度。

从图 1~4 中可以看出, 相对于 Memo 数据集的学习路径, 间隔重复学习规划的学习间隔随着学习

次数的提升而稳步增加,符合遗忘曲线所表示的遗忘规律,同时学习间隔的标准差保持在低水平,这表明该学习规划有合理的学习路径安排,使得每个单词都在最佳时间点进行学习与复习,且能够体现不同遗忘曲线的特性。其中,ACT-R curve1880和

ACT-R curve1991, ACT-R curve2015 第4组参数认为学习间隔随着学习次数的增加,在经过1~2次时隔一周的学习之后认定该单词已被掌握,而其余的曲线表明至少要经过4次的时隔一周的学习才能认定为该单词已被掌握,学习频率根据学习轨迹而变得更多。

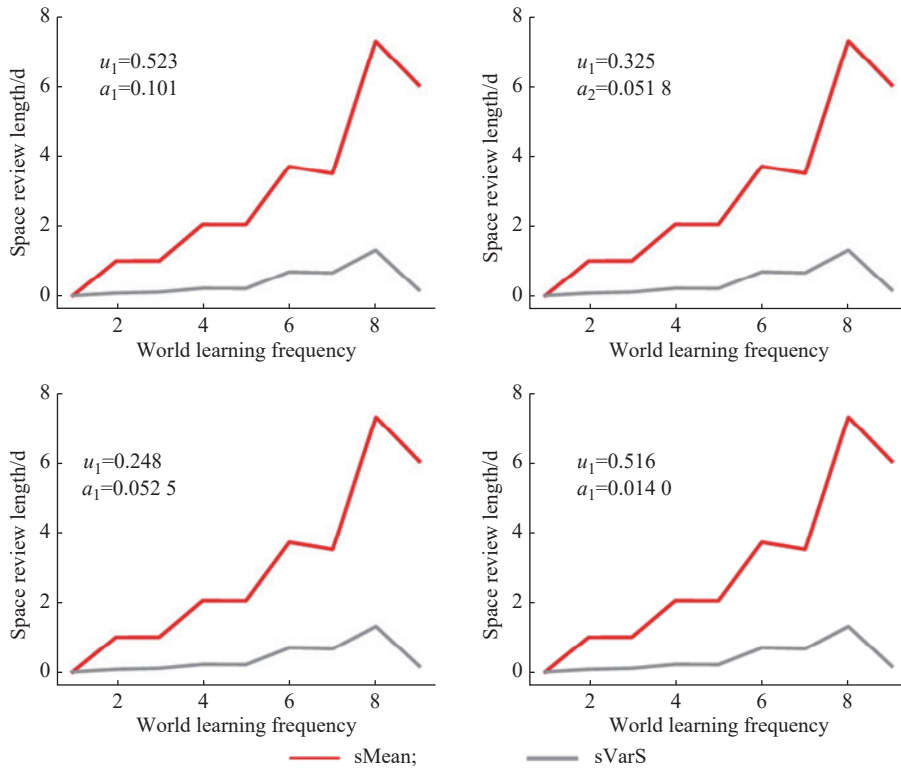


图1 基于ACT-R curve1880 4组参数的间隔重复学习规划

Fig. 1 Spaced repetitive learning planning based on four parameters of ACT-R curve1880

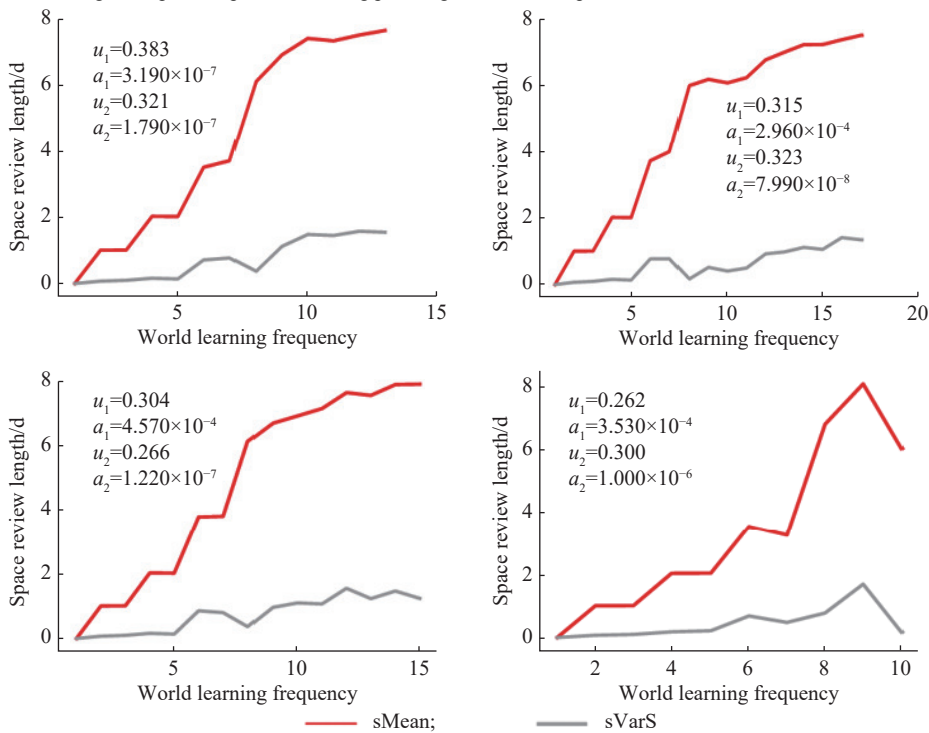


图2 基于ACT-R curve1991 4组参数的间隔重复学习规划

Fig. 2 Spaced repetitive learning planning based on four parameters of ACT-R curve1991

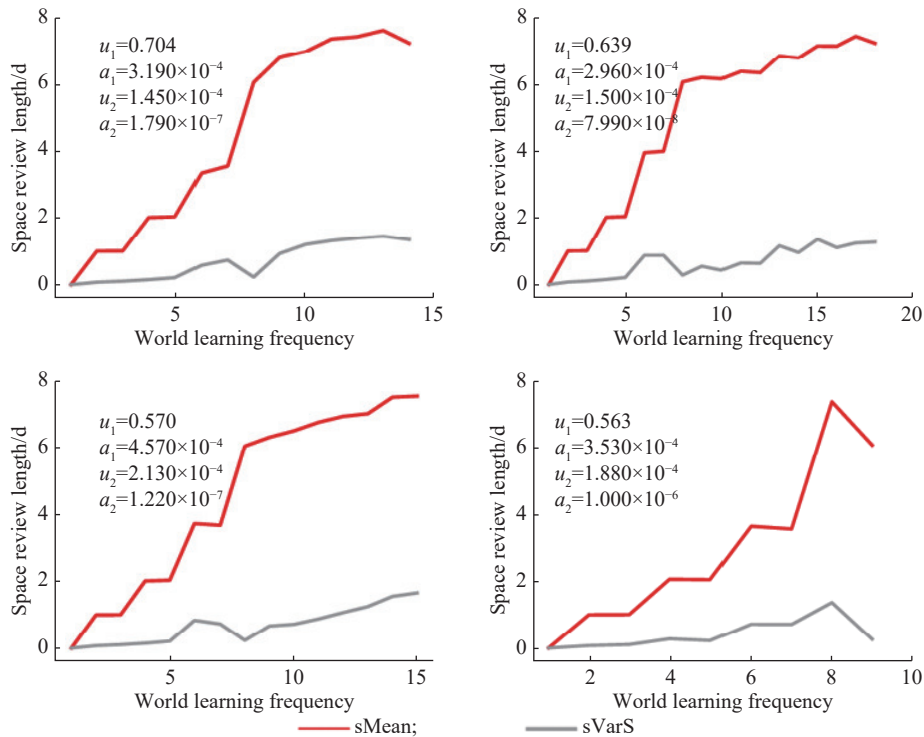


图 3 基于 ACT-R curve2015 4 组参数的间隔重复学习规划

Fig. 3 Spaced repetitive learning planning based on four parameters of ACT-R curve2015

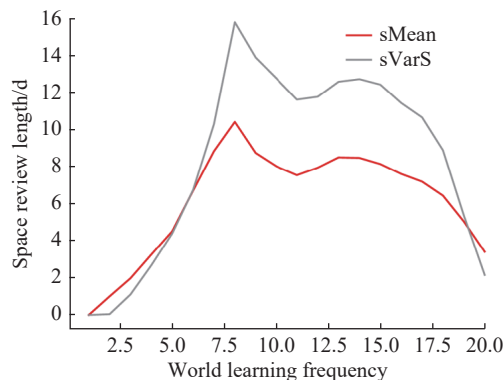


图 4 Memo 数据集中学习规划

Fig. 4 Learning planning for Memo datasets

本文提出的基于 ACT-R 的认知间隔重复学习方法可以根据不同的遗忘曲线设计不同的学习规划,设计的学习规划表现出了良好的稳定性,并且能安排更符合遗忘曲线参数与 ACT-R 指标的学习频率与学习间隔。

3 结论

本文提出了一种基于 ACT-R 的认知间隔重复学习方法,基于 ACT-R 的学习过程模拟、遗忘曲线切割算法和间隔重复学习规划。它通过 ACT-R 学习过程模拟和遗忘曲线切割算法,在设定学生学习的指标后进行学习规划推演,最终根据推演结果与相关参数生成间隔重复学习规划。通过模拟背诵单词

的实验可以证明,相比于 Memo 数据集,该方法生成的学习规划能够实现对于各个单词学习频率和学习间隔的合理和稳定,并且能够通过 ACT-R 合理搭建学习流程,将遗忘曲线的不同特性反映到学习轨迹上,为学生提供一种可调整的、稳定的自主学习方法。

参考文献:

- [1] ALHIJAWI B, AWAJAN A, FRAIHAT S. Survey on the objectives of recommender systems: Measures, solutions, evaluation methodology, and new perspectives[J]. *ACM Computing Surveys*, 2022, 55(5): 1-38.
- [2] 云岳,代欢,张育培,等.个性化学习路径推荐综述[J].*软件学报*, 2021, 33(12): 4590-4615.
- [3] 董永峰,王雅琮,董瑶,等.在线学习资源推荐综述[J].*计算机应用*, 2023, 43(6): 1655-1663.
- [4] 吴正洋,汤庸,刘海.个性化学习推荐研究综述[J].*计算机科学与探索*, 2022, 16(1): 21-40.
- [5] URDANETA-PONTE M C, MENDEZ-ZORRILLA A, OLEAGORDIA-RUIZ I. Recommendation systems for education: Systematic review[J]. *Electronics*, 2021, 10(14): 1611.
- [6] EBBINGHAUS H. Hermann Ebbinghaus: Grundzüge Der Psychologie. Band 1[M]. Berlin, Germany: Walter de Gruyter GmbH & Co KG, 2020.
- [7] KORNMEIER J, SOSIC-VASIC Z, JOOS E. Spacing learning units affects both learning and forgetting[J]. *Trends in Neuroscience and Education*, 2022, 26: 100173.
- [8] KARATAS N B, ÖZEMIR O, LOVELETT J T, et al. Improving second language vocabulary learning and reten-

- tion by leveraging memory enhancement techniques: A multidomain pedagogical approach[J]. *Language Teaching Research*, 2025, 29(12): 112-149.
- [9] CARPENTER S K. Distributed Practice or Spacing Effect[M]. Oxford, United Kingdom: Oxford Research Encyclopedia of Education, 2020.
- [10] LATIMIER A, PEYRE H, RAMUS F. A meta-analytic review of the benefit of spacing out retrieval practice episodes on retention[J]. *Educational Psychology Review*, 2021, 33: 959-987.
- [11] SHAH D P, JAGTAP N M, SHAH S S, *et al.* Spaced repetition for slow learners[C]//2020 IEEE Bombay Section Signature Conference (IBSSC). Mumbai, India: IEEE, 2020: 146-151.
- [12] ZHANG R, ZOU D, XIE H. Spaced repetition for authentic mobile-assisted word learning: Nature, learner perceptions, and factors leading to positive perceptions[J]. *Computer Assisted Language Learning*, 2022, 35(9): 2593-2626.
- [13] SU J, YE J, NIE L, *et al.* Optimizing spaced repetition schedule by capturing the dynamics of memory[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(10): 10085-10097.
- [14] XIAO Q, WANG J. DRL-SRS: A deep reinforcement learning approach for optimizing spaced repetition scheduling[J]. *Applied Sciences*, 2024, 14(13): 5591.
- [15] KIM N, NAM C S. Neuroergonomics: Principles and Practice[M]. Berlin, Germany: Springer Nature, 2020.
- [16] LANGENFELD V, WESTPHAL B, PODELSKI A. A formal operational model of ACT-R: Structure and behaviour[C]//Proceedings of the Annual Meeting of the Cognitive Science Society. Merced, California, America : UC Merced, 2021.
- [17] FISHER C R, HOUP T J W, GUNZELMANN G. Developing memory-based models of ACT-R within a statistical framework[J]. *Journal of Mathematical Psychology*, 2020, 98: 102416.
- [18] CINA M, RAD A B. Categorized review of drive simulators and driver behavior analysis focusing on ACT-R architecture in autonomous vehicles[J]. *Sustainable Energy Technologies and Assessments*, 2023, 56: 103044.
- [19] OH H, YUN Y, MYUNG R. Driver behavior and mental workload for takeover safety in automated driving: ACT-R prediction modeling approach[J]. *Traffic Injury Prevention*, 2024, 25(3): 381-389.
- [20] SUBIRANA B, BAGIATI A, SARMA S. On the Forgetting of College Academic: At "Ebbinghaus Speed"?[R]. Cambridge, MA, United States: Center for Brains, Minds and Machines (CBMM), 2017.
- [21] FERREIRA J Â, VALMORBIDA E L, SATO B G, *et al.* Forgetting curve models: A systematic review aimed at consolidating the main models and outlining possibilities for future research in production[J]. *Expert Systems*, 2024, 41(2): e13405.
- [22] MURRE J M J, CHESSA A G. Why ebbinghaus' savings method from 1885 is a very 'pure' measure of memory performance[J]. *Psychonomic Bulletin & Review*, 2023, 30(1): 303-307.
- [23] MÜLBERGER A. Early experimental psychology: How did replication work before p-hacking?[J]. *Review of General Psychology*, 2022, 26(2): 131-145.
- [24] MURRE J M J, DROS J. Replication and analysis of ebbinghaus' forgetting curve[J]. *PloS One*, 2015, 10(7): e0120644.

A Cognitive Spaced Repetitive Learning Method Based on ACT-R

WU Yunchao, LUO Fei, TAO Junchen, WANG Chen, ZHANG Ziyi

(School of Information Science and Engineering, East China University of Science and Technology, Shanghai 200237, China)

Abstract: The spaced repetitive learning method has played an important role in assisting students in self-directed learning. However, traditional spaced repetition algorithms are too rigid in spaced control, resulting in significant differences in daily learning tasks for students, which in turn affect learning efficiency. In order to improve the efficiency of self-directed learning, we propose a cognitive spaced repetitive learning method based on ACT-R. On the one hand, by basing on ACT-R programming learning process, this paper simulates student learning behavior and extracts activation parameters for the dominant model's memory changes. On the other hand, a forgetting curve cutting algorithm is proposed, which reflects the forgetting characteristics in learning planning and extracts parameters such as memory retention rate and recommended review interval. Finally, based on the learning parameters obtained from both approaches, this paper dynamically generates spaced repeat learning plans for specific learning tasks. Experimental analysis shows that, compared to traditional spaced repetitive learning algorithms, the cognitive spaced repetitive learning method based on ACT-R can arrange autonomous learning tasks more reasonably and effectively. It achieves a more balanced daily amount of learning tasks and a more reasonable distribution of learning time for each task.

Key words: cognitive architecture; ACT-R; forgetting curve; spaced repetition algorithm; learning planning

(责任编辑: 王晓丽)