

72-76

CAI

学生模型

推理模型

计算机科学1993Vol.20No.3

分层干扰推理学生模型

张小真 李建国

G 434

(西南师范大学计算机科学系 重庆630175)

摘

要

In this paper, Hierarchical Perturbation Inferring Student Model is proposed. When students learn and understand new concepts, this model divides knowledges into different hierarchy. The students' understanding degree of every hierarchical knowledge is dynamically quantified with the degree of understanding. This method improves the operability to develop program, enhances the accuracy to find out students' mistakes and main causes, and strengthens individual adaptability of ICAI system.

1. 引言

计算机辅助教学(CAI)向智能化发展乃大势所趋。一般来说,智能计算机辅助教学(ICAI)系统应该有三个基本成分:专家模块、学生模块和教学模块。

专家模块是ICAI系统中教授一门专业知识的专家系统,用于向学生传授知识并灵活地回答学生的问题。

学生模块是ICAI系统特有的用于教学过程的模块,主要功能是:

- 根据学生模型和专家知识把当前学生模型化^[1]。
- 为教学模块制定教学决策提供信息。
- 对已建立的学生模型进行维护。

学生模型主要用来刻画学生对所学知识的理解状况,应力求反映特定类型学生所具有的知识水平。学生模型制约教学过程的发展,因其建立的方式不同形成了不同风格的ICAI系统。

教学模块是ICAI实施教学的部分,根据学生模型、专业知识和学生状况制定教学决策。在总体上,确定学生的学习任务、教学目标 and 教学活动序列。在局部上,确定对学

生的学习活动进行干预的时机、内容及方法。采用不同的学生策略可以构造不同的教学环境,从而达到不同的教学效果。

当前,对学生模型和教学策略的研究是发展ICAI的关键,而目前最活跃的领域是对学生模型的研究。作者经过几年的探索和实践,提出一种新的学生模型——分层干扰推理模型(简称为HPI模型)。

建立学生模型的方法取决于表示学生情况的方式。当前流行的学生模型根据建立方法的不同可分为覆盖模型、“靶(Bug)”模型、推理模型、干扰模型四大类。

覆盖模型通过比较学生和计算机内的“专家”行为而构成,把学生知识的状态作为专家知识的一个子集。该模型实现简单,但要求建立一个详细的任务-模型树,因而模型规模大,检索代价高,并且对学生错误所做的解释不够充分。

用“靶(Bug)”表示以专家知识为基准所找到的学生知识不妥或偏离正确轨道之处,根据教师对有关学生错误概念的经验,把正确知识与“靶”联系在一起所建立的学生模型称之为“靶”模型。它要求事先构造一个较详

尽的“靶”目录表,因此对学生答案和“靶”进行匹配时检索工作量大,并受到模型制定者局限性的影响,对未出现过的错误无法解释,适应性较差。

推理模型是运用少量知识,通过对学生在学习活动中的应答来推导学生知识状况的一种学生模型。该模型以归纳推理为主要的推理方法,是机器学习技术在ICAI中的成功应用。其不足之处是:推理过程中需要一定的正、反实例,而确定合适的实例并非易事;此外,在推导模型的过程中,需要的空间相当大。

ICAI利用学生模型中的错误知识对学生的错误进行识别、解释、纠正和补救。学生错误知识的获取主要采取“专家经验积累”和“基于假设进行推导”两种方法,由前者产生“靶”模型,由后者产生干扰模型。干扰模型先对学习者的学习行为提出某些假设,再以此假设为前提确定学生的错误及原因。依据假设进行干扰并推导错误行为及原因的方法较难,时间代价大,并有一定局限性,这降低了干扰模型的一般适应性和广泛使用性。

为了提高一般适应性,BOOK系统在每个别学生模型的基础上运用机器学习技术构建了平均模型^[2],为ICAI生成一般化学生模型开辟了方向。但这种模型仍然存在两个问题:一是对学生的错误均进行同样的处理,推理检索空间大,效率不高;二是在对理解力差的学生指出其错误的关键原因时个别适应性差。


针对上述学生模型的不足,我们提出HPI模型,该模型依据学生在学习和掌握新的知识时,因组成该知识的结构及各成分的作用的不同,而把学生对每层知识的掌握程度动态地用理解度加以量化,在此基础上进行干扰推理。下面对HPI模型进行介绍。

2. 知识的层次和理解度

HPI模型为学生所学习的知识设置层次和理解度两个属性,以便抓住本质知识进行

干扰来推导学生模型。它不仅能准确找出学生错误及主要原因,便于因材施教,而且也增加了一般适应性。此外,还减少了推理检索规模,提高了效率。

根据教授知识本身的结构特点及知识各成分之间的联系将其划分出层次,层次划分如图1所示:



1层:核心知识;2层:背景知识;
3层:相关知识;4层:领域知识。

图1

• **核心知识:** 获得正确答案的必备知识,直接用于问题的描述,由专家提供,是学生学习的关键知识,是导致学生可能出错的根源。

• **背景知识:** 它是影响问题求解路径或答案的知识,与核心知识有直接联系,由问题求解过程中用到的核心知识以外的直接支撑核心知识的专业知识构成,可用于识别错误来源和性质。

• **相关知识:** 与核心知识不发生直接的联系,而在学生的问题求解过程中所用到的知识,不直接影响问题求解,但可能导致错误。

• **领域知识:** 核心知识所在领域的有关知识,与核心知识所涉及的问题求解无关,而与相关知识有关。

知识的层次属性值按图示关系由内向外分别为1、2、3、4。

知识的理解度表示知识被学生理解的难易程度,取值范围为0.0~1.0。如果学生容易出现相同错误,则该知识的理解度低,反之,当学生容易按正确方法运用知识时,该知识的理解度就高。

同一知识在不同的教学任务及教学场合

下层次属性值和理解度可不同。知识的层次属性由专家在生成领域知识库时确定。理解度在学生模型构造过程中,根据学生对知识的学习情况动态赋值。

3. HPI模型的表示

在考虑知识层次和理解度的基础上,用Warnier图(图2)来描述学生模型S。其中:



图2

• **K**: 表示学生当前拥有的知识,包括学生学习的专业知识D的一个子集C, $C \subset D$, 系统对D提出问题Q后学生的答案A及可能导致A的干扰假设集合W。C为W的干扰对象, $C = \{C_i | C_i \in D, C_i \cap C_{i+1} = \emptyset, i = 1, 2, \dots, r\}$, W的元素由干扰C_i获取, $W = \{W_j |$ 对C_i使用干扰规则j推出W_j, $j = 0, 1, \dots, K\}$; $A = f(Q)$ 。当A不正确时,运用公式 $D - C + W \vdash A$ 进行推导(+为并运算, -为差运算, $\vdash$ 为可能导出)^[2], 若确能由当前干扰目标C和相应W导出A, 则由C、W与A共同构成K。

• **L**: 表示当前被干扰知识C的层次属性值。

• **G**: 表示C的理解度。在学习C时,若学生多次出现相同的错误,则G值逐渐减小直至0.0,反之,当学生按照正确方法运用C而少犯错误时,G值就渐增至1.0。

• **T**: 表示学生的个人特征。其中CA为能力,由概念掌握牢固程度KC、分析理解力AC、记忆力MC、反应力FC组成;而IN为信息,由学习考察记载TR或学习计划执行记载PR组成。

• **H**: 表示学生学习史,由i个学习点组成。其中LS为学习状态,由当前学习方式

LM、学习级别LG、学习进度LC组成;而LP为学习点位置,由前驱状态PS和后继状态SS组成。

4. 分层干扰推理

建立HPI模型的关键是构造K,我们通过分层干扰推理来实现。分层干扰推理的过程如下:根据学生学习的知识D,对学生提出问题Q,生成Q的求解树TR(TR的子孙结点即D的部分可分解成分C),处理学生对Q的答案A,依据不同C的知识层次对学生学习行为进行假设,再以假设W为前提进行分层干扰推理,若W被证实,则K构造成功。

我们将干扰推理控制过程分为五个状态。SL:学习状态;SQ:提问状态;SA:应答及处理状态;SI:干扰推理状态;SE:结束(推理)状态。在上述状态中进行推理的规则如下:

- (SL, 未结束学习) $\rightarrow$ SQ
- (SL, 结束学习) $\rightarrow$ SE
- (SQ, 问题生成成功) $\rightarrow$ SA
- (SQ, 问题生成失败) $\rightarrow$ SL
- (SA, 答案正确) $\rightarrow$ SL
- (SA, 答案不正确) $\rightarrow$ SI
- (SI, K构造成功) $\rightarrow$ SL
- (SI, K构造失败) $\rightarrow$ SQ

则有干扰推理机PIM(图3)




图3

干扰目标的确定是干扰效率的关键。选择干扰目标的方法是:按照L值由低到高的次序确定干扰对象,L值低的C为主要干扰对象,对L值高的C甚至可以不进行干扰而只记录错误事实。

干扰次序影响到效果(准确性)。我们根据干扰对象的L和G来解决此问题。设置干扰对象的层次属性和理解度表LGL,其结点构造与TR树相同,均为:

CI	LI	GI
----	----	----

其中, CI_i 干扰对象 C_i 的编号; LI_i C_i 的层次属性值; GI_i C_i 的理解度值。LGL 为一 $\min$ 堆, 根结点序号为 1, 则 LGL 中结点序号由小到大的次序即为干扰对象的干扰次序。由求解 Q 的生成树 TR 建立 LGL (确定干扰次序) 的规则如下:

```

rule1: if TR(i)'.L < TR(i+1)'.L THEN TR(i) 入堆
rule2: if TR(i)'.L > TR(i+1)'.L THEN TR(i+1) 入堆
rule3: if TR(i)'.L = TR(i+1)'.L THEN
    IF TR(i)'.G > TR(i+1)'.G THEN TR(i) 入堆
    ELSE TR(i+1) 入堆
  
```

干扰是对正确领域知识的干扰, 我们采用九类干扰^[3]: 记住错误事实、忘记子目录、忘记规则、非法使用子目标、非法使用规则、使用错误规则、混淆已学知识、错误地排列子目标、错误递归等。如果学生的错误源不能用上述干扰方法确定, 就假定学生是因为记住了某个错误事实而产生错误, 将其错误响应记入错误库。根据知识的层次属性选择干扰方法种类。

在复杂情况下, 可能有多个 W 会导致当前学生的答案 A , 为了选择最合适的 W , 需要对学生提出补充问题, 再根据学生对补充问题的响应确定 W 。

进行分层干扰推理的算法如右栏上方所示。

5. 构建 HPI 模型

通过分层干扰推理构成学生模型 S 中学生当前拥有的知识 K , 解决了 HPI 模型建立的关键问题。 S 的 L 和 G 值的初值在描述 C 时由专家暂定, 随着对 S 的使用, 根据学生出错情况动态调整。 S 中的个人特征 T 和学习史 H 由当前学生状态确定。但这时获得的学生模型只具有个别适应性, 我们称为当前学生模型 Scm 。在此基础上, 为其设置可信度因子 R , 运用机器学习技术, 根据 R 值最后构成的学生模型才是具有一般适应性的 HPI 模型。我们把构建 HPI 模型的过程分为四个阶段:

I. 初始化。建立个别学生模型库

Procedure Hierarchical-Perturbation-Inferencing(S),
 生成正干扰推理的当前学生模型

```

BEGIN
  KI ← false; /* KI 为构成标志 */
  call Teaching-Domain-Knowledge(DI);
  /* DI 为学生当前学习领域知识编号 */
  While not KI do
    BEGIN
      call Question-Answer(Q, A); /* 生成 Q 步取 A */
      IF A 正确
        THEN EXIT 并返回相应信息
      ELSE
        BEGIN
          call Buildtr(Q, TR); /* 生成 TR 树 */
          WJ ← false; /* WJ 为 W 成立标志 */
          call Buildlgl(TR, LGL); /* 构建 LGL */
          While LGL 非空 and not WJ DO
            BEGIN
              call Delheap(LGL, LI, GI, CI); /* 确定 C */
              call gethypothesis(CI, LI, GI, WJ); /* 生成 W */
              call Hypothesis-test(DI, CI, W, A, WJ);
              /* 验证 W, 若 W 成立则 WJ ← true */
            END
          END
          IF WJ
            THEN IF LGL 为空
              THEN BEGIN
                将 C, A, W 构成 K; KI ← true;
                K, L, G 送 S; END
              ELSE call Multi-W-processor; /* 多 W 处理 */
            ELSE BEGIN
              将当前 A, Q 记入错误目录;
              KI ← true; END
            END
          END
        END
      END
    END
  END
END
  
```

IML, 其初值由人类教师专家确定。设 E_1 为学生模型 S 由 IML 进入 HPI 模型库 GML 的可信度因子 R 的阈值。对于 IML 中各学生模型 S 令 $R = E_1$, 在 IML 的使用过程中对 R 再作调整。

II. 生成当前学生模型 Scm 。运用分层干扰推理方法, 根据当前学生个人信息及学习情况构成 K , 进而形成 Scm , 并令其 $R \approx E_2$ 。此处 E_2 为 Scm 进入 IML 的阈值, 并且 $E_1 > E_2$ 。

III. 生成 HPI 模型库 GML。凡已确定为 HPI 模型的学生模型都存放在 GML 之中, 以初始化建立的 IML 作为 GML 的初值。由 II 生成的 Scm 先送入 IML。根据 IML 中各个学生模型 S 的使用情况修改相应的 R 值。多次使用的 S 的 R 值升高, 而使用频率低的 S 的 R 则降低。当 $R \geq E_1$ 时, 则将该学生模型 S 送入 GML, 作为已构造成功的 HPI 模型提供给系统。

IV. 动态调整 HPI 模型库 GML。GML 是

ICAI 系统分析学生错误及原因的主要依据,在其获得初值后便可使用。在使用GML的过程中,运用机器学习技术,对所用的HPI模型的R及G值进行动态修改(成功使用的S的G值应减少,否则便增大),并对该模型进行评价。若 $E2 \leq R < E1$,则从GML中删除该学生模型并将其送回IML;若 $E2 > R$,则将该学生模型从GML中删除后送往错误库EDL。

重复执行Ⅱ、Ⅲ、Ⅳ,就构成了ICAI系统教学所需用的HPI模型。HPI模型构建数据流程图如图4所示。




图4

6. 结束语

HPI模型的形成经历了从个别到一般的推导过程,局限性小,具有一般适应性。

依据D、C、A、L及G值确定干扰目标和干扰次序,进而对HPI模型中学生当前知识K进行推导,其方法简单可行,且不需事先构造庞大的错误库,检索代价小,构建模型效率高。在“诊断驱动”^[4]的教学方法中提供了对学生情况的识别环境;采用机会教学^[5]

与规划教学混合的策略可以为“诊断驱动”提供诊断点和用于干扰的知识。这不仅为HPI模型的建立与维护提供了学生信息,并使其能够因材施教,因而HPI模型易于实现,便于广泛使用。

建立HPI模型的目的在于克服当前流行的学生模型的主要缺点,在学生知识的形式化和量化方面做些工作,以改善程序实现的可操作性,增强学生错误原因查找的准确性。HPI模型已在我们研制的智能程序设计语言辅助教学系统IPLATS中得以运用,具体细节在该系统的报告中予以说明,本文不再详述。

主要参考文献

- [1] Raeth Peter G. Expert System. Los Alamitos, IEEE Computer Society Press, 1990,98
- [2] Setsuko Otsuki and Akira Takeuchi, Generating Average Student Model by Machine Learning. Shanghai:Proceeding of APCCE' 88, 1988, 277, 274
- [3] Ercoli P. and Lewis R., Artificial Intelligence Tools in Education. Amsterdam:Elsevier Science Publishers B.V, 1991, 99-101
- [4] Wenger E., Artificial Intelligence and Tutoring System. LOS AL TOS:Morgan Kaufmann Publishers, INC. 1988,414
- [5] (美) 巴尔A.费根鲍姆E.A.主编,钟玉琢等译,人工智能手册 第二卷。北京:科学出版社, 1988, 297

下期主要内容预告

面向对象并发语言的基础理论;信任函数理论的研究进展;基于事例的设计推理研究;CBR检索模型的研究;基于面向对象的形象模型的研究;九十年代软件工程展望;JDS与面向对象的信息系统开发;软件重用项目的若干管理问题和对策