

教育资源的深度表征 与智能应用

□文 / 刘淇、汪飞、王新



刘淇

中国科学技术大学计算机学院副教授、博士生导师，CCF 大数据专家委员会委员，CAAI 机器学习专委会委员，中国科学院青年创新促进会优秀会员。主要研究数据挖掘与知识发现、机器学习方法及其应用，相关成果获得过 IEEE ICDM 2011 最佳研究论文奖、KDD 2018 最佳学生论文奖 (Research Track) 等。还曾获中国科学院院长特别奖和优秀博士学位论文、教育部自然科学奖一等奖 (第二完成人)，入选中国科协“青年人才托举工程”等。主持和参与了多项国家、省部级以及与合作企业的合作研究项目。

中国科学技术大学计算机学院硕士研究生。主要研究兴趣是数据挖掘和机器学习。

汪飞



王新

本科毕业于中国科学技术大学，现硕士就读于中国科学技术大学计算机学院。目前主要研究方向是教育领域的数据挖掘。

从信息时代到如今的大数据时代，以数据的不断积累和硬件的快速迭代为基础，大量的数据挖掘和机器学习等算法被提出，促进了数据从资源向价值的高效转变。由此，在电子商务、交通、气象、教育等领域中纷纷诞生了许多智能应用。其中，在教育领域，传统教育场景（如学校）的数字化和新兴教育场景（如线上教育平台）都积累了大量的教育数据资源（如教学视频、习题），并衍生出一系列的智能教育应用（如个性化教育资源推荐）。然而，这些教育资源具有非结构化、形式多样等特点，不利于传统数据挖掘或机器学习方法的直接使用。因此，合适的表征技术是教育资源统一处理和智能应用算法开发过程中的关键步骤之一。

一、教育资源表征

什么是表征

表征(representation)在很多专业领域中都是一个十分重要的概念。在认知心理学中,表征是知识在个体心理的反映和存在方式;在语言心理学中,表征是信息在语言系统中的外化符号;在化学中,表征是通过物理或化学方法对物质的化学性质进行分析、测试和鉴定;在计算机科学中,表征则是对资源特征信息的数字化编码;具体到教育资源深度表征,则是通过深度学习技术对教育领域中的各类数据资源进行特征表示。

虽然表征的内容和方式有所不同,但本质上,表征是指信息记载或表达的方式。在深度学习与数据挖掘相关领域,资源表征的作用主要体现在以下两个方面:(1)信息向量化。通过数字化表征,将资源信息转化为能被计算机接受和理解的数字向量,便于进一步的信息处理和利用。(2)信息预处理。资源对象中大量的噪声和任务无关特征会干扰主要信息的抽取,资源表征可作为信息预处理,弱化任务无关特征,突显任务相关特征,有利于深入挖掘信息模式。

教育资源内涵

本文中所提及的教育资源并不等同于教育大数据。教育大数据是指,整个教育活动过程中所产生的以及根据教育需要所采集到的,一切用于教育发展并可创造巨大潜在价值的数据集合;而教育资源是指,教育素材及其相关信息构成的电子数据集合,如试题库、课件、音视频、电子文献、电子教辅书籍、网络课程等,它是教育大数据的一部分。

当前的教育数据资源主要采集于数字化校园、在线学习平台和智能教辅设备三个场景,按照资源类型大致可分为以下几类:(1)试题资源:包括题面描述、答案解析、图形以及其他相关信息(如考察知识点、题目难度等);(2)多媒体资源:包括教学视频、音频、图片、动画、电子课件、网络课堂等;(3)电子文献:包括电子教辅书籍、电子记录以及相关电子材料等。

不同场景下的数据往往具有不同的数据特征,即使数据类型与形式相似,表征方法也可能大相径庭。因此,在进行数据表征之前,必须进一步分析数据特征,明确表征要点,然后再针对性地设计有效的表征模型。上述教育资源数据主要具有以下三个特点:(1)异质性:教育资源一般包含图片、文本、音视频、知识网络等异构信息,并且其中绝大部分是非结构化或半结构化数据;(2)隐含性:很多属性(如试题难度、考察知识点等)一般是隐含的,无法直接从数据记录中获取;(3)不可比性:由于内在结构及语义复杂性,很难在不同的教育资源之间构建一个稳定、可靠的相关度量,

因此难以对其属性特征进行有效的比较。

教育资源表征相关技术

文本、知识点、图片和视频是教育资源的主要组成部分，也是各种异构数据的构成元素。本节从这四种基础资源类型出发，首先分别介绍相应的表征技术和算法，然后概述异构教育资源混合表征的技术思想，它们往往是进一步进行信息抽取和资源智能应用的基础。

文本表征

在自然语言中，词是能够独立运用的最小语义单元，因此文本表征的第一步就是将词映射为能被计算机接受和处理的数字向量。在自然语言处理和文本分析领域，词袋 (Bag of Words, BOW) [1] 和词向量 (Word Embedding) [2] 是两种最常用的词数字化模型。

如图 1 所示，词袋模型是一种基于统计的模型，向量每一维表示一个词，其对应的值代表该词的权重，常用的权重计算方法有词频 (TF) 和词频 - 逆文本频率 (TF-IDF)。词袋模型的主要局限在于不考虑词序并假设词间独立，而词向量模型则将词序和语义依赖融入向量编码，相似的词会有相似的向量表示。词向量最为人所津津乐道的特性之一就是“词类比”，比如经典的“国王 - 男人 + 女人 = 女王” (见图 2)。这种关联表征有利于挖掘文本中词语和句子之间的特征关联，因此在深度学习领域中，词向量模型具有相当的优势。目前生成词向量的方法主要基于神经网络训练，经典模型包括 word2vec[5]、Glove[6]、ELMo[7] 和 BERT[8]。

2013 年，Google 发布了 Word2Vec (Word to Vector)，在自然语言处理领域掀起



图 1: 词袋模型示例 [3]

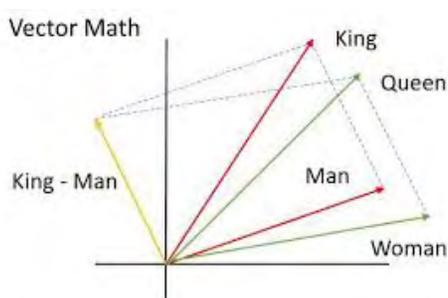


图 2: 词向量模型示例 [4]

[1] Harris Z S. Distributional structure[J]. Word, 1954, 10(2-3): 146-162.
 [2] Bengio Y, Ducharme R, Vincent P, et al. A neural probabilistic language model[J]. Journal of machine learning research, 2003, 3(Feb): 1137-1155.
 [3] <https://www.cnblogs.com/hapjin/p/8119797.html>
 [4] <https://medium.com/@ncku4alex/%E5%BC%95%E8%B5%B7%E4%BD%A0%E5%B0%8D-word2vec-%E5%9F%BA%E6%9C%AC%E6%A6%82%E5%B5%B5-524c8b758f99>
 [5] Mikolov T, Chen K, Corrado G, et al. Efficient estimation of word representations in vector space[J]. arXiv preprint arXiv:1301.3781, 2013.
 [6] Pennington J, Socher R, Manning C. Glove: Global vectors for word representation[C]//Proceedings of the 2014 conference on empirical methods in natural language processing (EMNLP). 2014: 1532-1543.
 [7] Peters M E, Neumann M, Iyyer M, et al. Deep contextualized word representations[J]. arXiv preprint arXiv:1802.05365, 2018.
 [8] Devlin J, Chang M W, Lee K, et al. Bert: Pre-training of deep bidirectional transformers for language understanding[J]. arXiv preprint arXiv:1810.04805, 2018.

了深度学习的热潮。Word2vec 的核心思想是通过词的上下文计算词的向量表示。简单地说就是如果两个词附近的词是相似的，那么这两个词也是相似的。但是 Word2Vec 只考虑词临近范围内的局部信息。斯坦福次年提出了 GloVe (Global Vectors)，它利用共现矩阵的同时考虑了局部信息和整体信息。然而，Word2Vec 和 GloVe 存在一个共同的问题，就是忽略了语境因素，同一个词在不同的语境下往往具有不同的含义，但它们对同一个词在不同语境下的表示是相同的。ELMo (Embeddings from Language Models) 针对这一局限进行了改进，它通过多层的层叠长短期记忆网络 (stack Long Short-Term Memory) [9] 学习单词的复杂用法以及这些复杂用法在不同上下文间的变化。最后着重提一下最近名声大噪的 BERT (Bidirectional Encoder Representations from Transformers)，它不仅具备广泛的通用性和十分简洁的下游接口，而且刷新了当时 11 个 NLP 任务的最佳纪录。BERT 的工作方式本质上跟 ELMo 类似，但 BERT 采用了 Transformer[10] 编码模块，极大地提高了并行能力。同时，BERT 使用了一种新的训练策略——Masked Language Model，用以解决双向信息流融合训练的问题。

知识点表征

知识点是教学过程和教学检测中重点关注的部分，也是许多智能教育算法中常用的输入信息之一。除了部分抽象教育目标（如锻炼学生的逻辑思维、动手能力）外，教学内容通常围绕某些知识点展开，如数学中的“解方程组”、“无理数”，英语中单词的词性、词义等。这些知识点虽然可以以名称区分，但简短的名称文本本身不足以表达出这些知识概念的复杂内涵，因此在智能教育相关算法中，需要相应的表征技术来保留知识点所包含的信息。图 3 所示为知识点表征的几种主要方式，简要介绍如下：

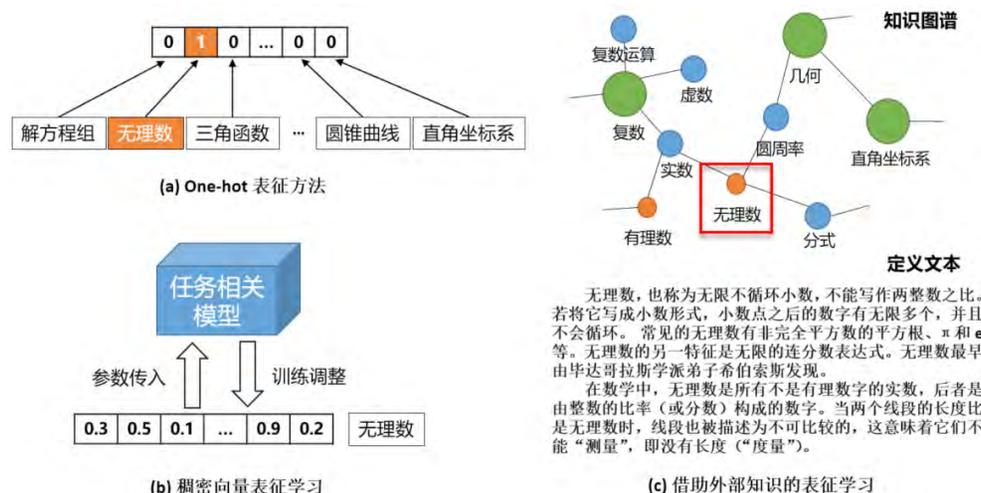


图 3: 知识点表征方法

[9] Graves A, Mohamed A, Hinton G. Speech recognition with deep recurrent neural networks[C]//2013 IEEE international conference on acoustics, speech and signal processing. IEEE, 2013: 6645-6649.

[10] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]//Advances in neural information processing systems. 2017: 5998-6008

One-hot 表征是最简单的表征方法，即用一个长度等于知识点数量的 0-1 向量来表示，向量的每一维对应一个知识点。这种表征方式虽然简单，但向量维数很高且稀疏，并且无法体现出知识点之间的关系。因此，现在多用于模型的初始输入或是其他表征方法的过渡。

另一种方式是将知识点表征融入到具体任务进行自主学习。例如，在预测学生答题结果的模型中，输入试题包含知识点，训练过程中不断调整知识点表征向量。这种方式最终得到的知识点表征向量不仅比 one-hot 向量短得多，而且一定程度上能够反映知识点之间的相关性。其缺点是表征向量一般只适用于该任务模型，无法迁移到其他任务模型上使用。

此外，知识点的表征还可以借助外部知识来学习。例如，可以利用知识概念对应的定义文本，采用文本处理的相关技术获得该知识概念的表征向量。或是利用预先构建的知识图谱，采用图网络相关技术获取该知识点对应图谱中节点的表征。通过此类方法获取的知识点表征通常能够保留知识点之间的关系，且具有较好的迁移性，可以用在各种不同的任务中。

以上表征方法可以互相结合使用。例如，在具体任务模型中，可以先使用 one-hot 表征向量作为知识点的初始输入，然后再以此为基础在模型训练中学习更高层次的稠密表征向量；或者先利用知识图谱学习知识点的表征向量，再在具体模型中加以微调。

图片表征

在教育数据资源中，图片数据（如图表、函数图像、几何图形、公式图片等）占相当一部分比例。图像是一种层次信息非常丰富的多维数据。图像深度表征是指通过深度学习对图像进行理解和综合表示，使得计算机能像人类那样看到图像蕴含的多维度高层次信息。目前，主流的图像深度表征模型基于如图 4 所示的 CNN（Convolutional Neural Network）框架，主要原因有以下几点：

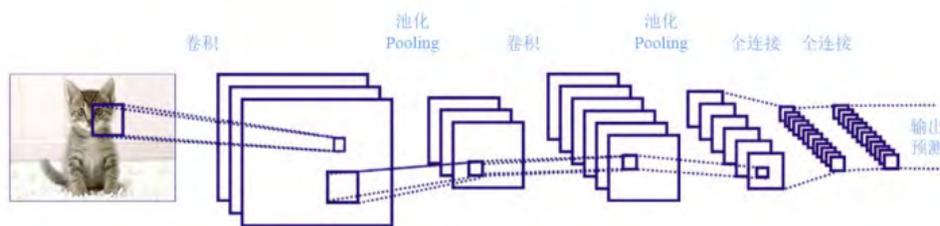


图 4: CNN 图像表征框架

首先，图像本身具有二维空间结构信息，譬如我们看一张猫的图片，可能看到猫的耳朵或者尾巴就知道这是一只猫，这就是因为局部区域蕴含了猫的主要特征。而 CNN 对局部空间结构信息比较敏感，因此对于图像特征抽取具有与生俱来的优势。

其次, CNN 在深度上具有极大的优势, 较深的 CNN 模型能达到上千层, 而模型深度对提取高级特征信息有着重要影响。通常认为, 浅层网络提取的是浅层特征, 深层网络提取的是深度特征。最后, CNN 的权值共享使得网络参数大大降低, 池化操作大幅减少计算量, 并且由于高度并行化, 其训练速度相对较快。

教育领域中很多图像的信息高度集中, 如公式图片和文字图片, 几乎所有的信息都集中在字符区域。对于这类信息高度集中的图像, 转写提供了图像表征的另一种思路。通过转写, 将图像中蕴含主要信息的字符转化为对应的文本表示, 如此便将对图像的深度表征转化为对相应文本的深度表征。以公式图片转写为例, Yin[11] 等人提出了 STN (Spotlighted Transcribing Network) 转写模型, 将图片公式转写为相应的 Latex 文本公式 (图 5)。STN 模仿人看图片的过程: 先确定看的区域, 再识别区域内的内容。该框架首先通过 CNN 对图片进行特征编码, 然后通过转写模块根据当前确定的聚焦识别区域对图片进行转写。

$$f(x) = \frac{\sqrt{x-1}}{x-2}$$

$$\mathbf{f}(\mathbf{x}) = \frac{\sqrt{\mathbf{x}-1}}{\mathbf{x}-2}$$

图 5: 公式图片转写举例

视频表征

目前, 在教育领域中, 视频资源的数据量远超其他类型资源, 其主要分布场景是大型开放式网络课程, 即 MOOC。自 2012 年诞生以来, MOOC 以惊人的速度发展壮大, 截至 2018 年年底, 全球已有 900 多所高校推出 11400 门 MOOC。如此庞大的视频数据意味着巨大的数据宝藏, 同时也意味着前所未有的挑战。如何高效地组织、存储、检索, 以及进一步利用庞大的视频数据, 是当前亟待解决的问题之一。因此, 教育视频的深度表征工作具有十分深远的现实意义。

视频由连续的视频帧构成, 本质上就是一组静态图像的有序序列。虽然视频资源与图像资源关系紧密, 但与相对成熟的图像表征相比, 视频资源表征还处在起步阶段。这主要是因为视频资源携带的信息极其丰富, 不仅包含大量的空间信息, 还涉及复杂的时域信息。因此, 对视频资源的深度表征主要是对帧内空间特征和帧间时域特征进行特征表示。目前深度学习中的主流视频表征框架可分为两大类:

(1) CNN+RNN 的混合结构。CNN 适合捕获图像的空间结构信息, RNN 可捕获时序相关依赖。于是, 人们自然而然地想到将 CNN 和 RNN 结合使用, 优势互补。流程上, 首先利用 CNN 进行单帧表征, 获得单帧表征序列。之后可以将单帧表征序列当作普通的序列数据, 利用 RNN 对其建模。这种结合的思想相当简洁灵活, 将视频表征任务拆分成图像表征和序列建模两个独立的子任务, 可以自由独立地配置每个子模块, 并可以方便地融合其他数据信息。

(2) CNN 变种结构。传统的 CNN 结构之所以无法对序列数据进行建模是因为

[11] Yin Y, Huang Z, Chen E, et al. Transcribing Content from Structural Images with Spotlight Mechanism[C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. ACM, 2018: 2643-2652.

其只在二维空间上进行卷积操作。基于此，产生了 CNN 的两个变种。图 6(b) 将一定长度的连续帧重叠在一起构成一个多通道静态图像，之后使用 3D 卷积核在 2D 空间移动对其进行卷积。该方法通过多帧上进行整体卷积捕获帧间结构信息变化，在运动性强的视频上的表征效果提升明显。但是这种方法在卷积和池化后就丢失了时间域的信息，并不能真正捕捉帧间的时序依赖。而 3D CNN 则将卷积拓展到了时间维度。如图 6(c) 所示，3D CNN 并不是简单地将帧集合作为多通道图像来处理，而是让卷积窗口在空域和时域进行移动，能真正对时序相关依赖进行捕捉。因此，相对于其他 CNN 变种结构，3D CNN 对视频这种序列数据具有更强的表征能力。

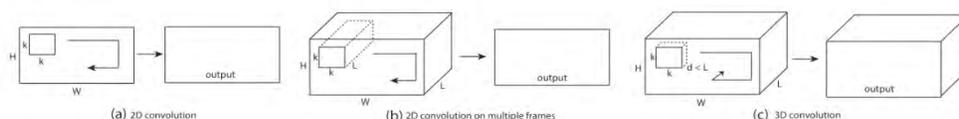


图 6: CNN 及其变种结构 [12]

混合表征

在很多情况下，任务可用的教育资源是同时以多种异构形式呈现的。例如，一段教学视频同时包含图像和音频信息，一道几何数学题可能同时包含文本形式的题面和图片形式的几何图形。因此，为了更好地表征教育资源，需要能够同时处理异构资源的混合表征方法。混合表征方法通常是对单一资源表征方法的整合。例如，对于一道几何数学题，可以分别使用文本和图片教育资源的相关表征技术获取各自的表征向量，共同作为模型输入。在此基础上，可以使用注意力机制获取题面文本表征和几何图形表征之间的相关信息，作为额外信息输入。更进一步，可以将表示同一对象的异构资源表征通过神经网络整合成单个表征张量。

二、相关智能应用

本章针对个性化教育中涉及到的试题难度预测、相似题检测、学生认知诊断和智能推荐等场景，对基于教育资源表征的教育大数据分析 with 智能应用的部分工作进行综述和讨论。

试题难度预测

难度是试题的重要特征之一，通常以答错率或答对率作为其直接反映。但在很多实际情况中，需要在学生对试题作答之前掌握试题的难度。例如，在一些标准化测试和大型招生考试中，需要准确评估试题的难度以确保试题质量。此外，试题难度的准确评估对教学的各方面都具有一定的现实意义。例如，自动组卷在减少人工工作量的同时，

[12] Tran D, Bourdev L, Fergus R, et al. Learning Spatiotemporal Features with 3D Convolutional Networks[J]. 2014

提高组卷的科学性和合理性；根据试题的难度帮助学生筛选难度适中的练习题等。

在大数据时代下，庞大的试题量使得完全的人工评估不再适用，如何利用海量试题资源自动预测试题难度仍然是一个开放性课题。以标准英语测试中的阅读理解试题为例，Huang 等人 [13] 提出了一种新型的基于试题文本深度表征的难度预测框架 TACNN (Test-Aware Attention-Based Convolutional Neural Network)。

如图 7 所示，TACNN 模型框架主要包含四个部分：输入层，将单词映射为词向量；句子卷积层，利用 CNN 对试题中的每个句子进行语义表征，实现试题内容（阅读材料、问题、选项）的统一建模；注意力层，模拟人类阅读习惯，结合问题分化阅读材料和选项中句子的重要度；预测层，将最终的表征向量输入全连接神经网络，得到试题的预测难度。大量基于现实数据的对比试验验证了 TACNN 的有效性，相关研究思路可进一步拓展到其他题型和学科。

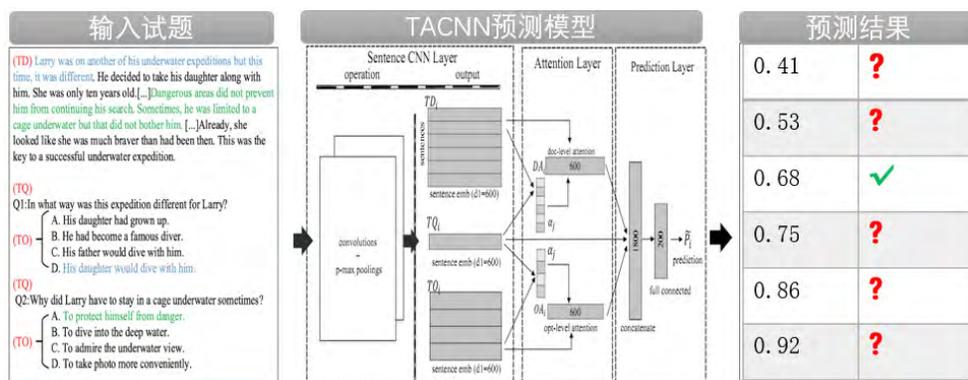


图 7：英语阅读理解试题举例

相似题检测

相似题检测是许多智能教育应用场景中的基础任务。例如，在智能教辅系统中，学生未能答对某道题，那么系统为了进一步检测学生对相关知识的掌握程度，或者为了让学生掌握相关知识，需要从题库中选择相似的题目提供给学生。题库十分庞大，完全由人工标注的工作量过于庞大，因此需要相似题检测算法自动形成习题分类。又例如，高考试题必须严格避免与现有试题雷同的情况，而在我国教育发展中，不论是学校还是线上教育平台，积累的试题量都是极其庞大的，因此需要将相似题检测自动化，提高相似题排查效率。

习题相似性按照题型有不同的评估方式。简单的方法是直接提取习题的“关键字”作为表征，通过计算“关键字”（例如词语填空中的文本词袋特征、数学公式中的运算符等）的相似性来评估习题相似性。更高层次的表征则需要领域相关的表征技术。例如，对于文本类习题，可以运用前面所述的相关表征技术；对于编程类习题，可以提取类似函数使用、代码长度、变量类型、嵌套深度等特征，作为代码类习题的表征。

[13] Huang Z, Liu Q, Chen E, et al. Question Difficulty Prediction for READING Problems in Standard Tests[C]//Thirty-First AAAI Conference on Artificial Intelligence. 2017.

而复杂的习题所包含的资源通常不止一种形式。例如，数学习题可能既包含文字描述也包含图片，习题涉及的知识点也可视为一类信息资源。因此，需要更复杂的混合表征技术来辅助相似性检测。图 8 所示是一个数学相似题的示例：习题 E₁ 和 E₂ 都涉及到几何三视图和体积计算，在题面、图形和考核知识点上都有很高的相似性，而 E₃ 虽然也是一道几何题，在文本上出现了体积（volume），图形是几何体，且涉及知识点也与 E₁ 相同，但它们的考察目标并不相同。对单一资源类型的表征技术不足以区分这类复杂试题的相似性。

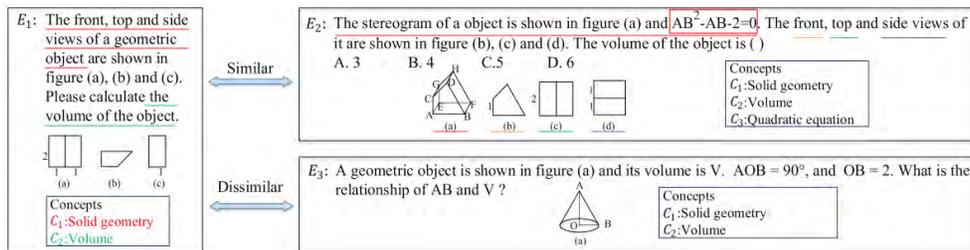


图 8：数学题示例

Liu 等人 [14] 针对此类习题设计了一个相似题检测模型 MANN (Multimodal Attention-based Neural Network)。其中首先利用神经网络分别获取题面文本、图形和知识点的表征张量，然后使用注意力机制考虑图形与文本、知识点与文本的相关关系，最后使用基于注意力机制的 LSTM 神经网络得到习题不同成分（题面的不同位置）的表征集合和习题的整体表征，将这些表征用于后续的相似检测。图 9 所示是 MANN 模型中该混合表征模块的流程图。

除了利用习题本身的信息外，如果习题积累了足够的学生答题结果，还可以用答题结果来计算习题相似性。例如，可以将习题被每个学生的答题结果表示成向量，

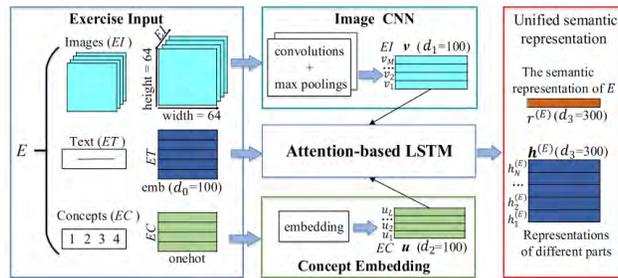


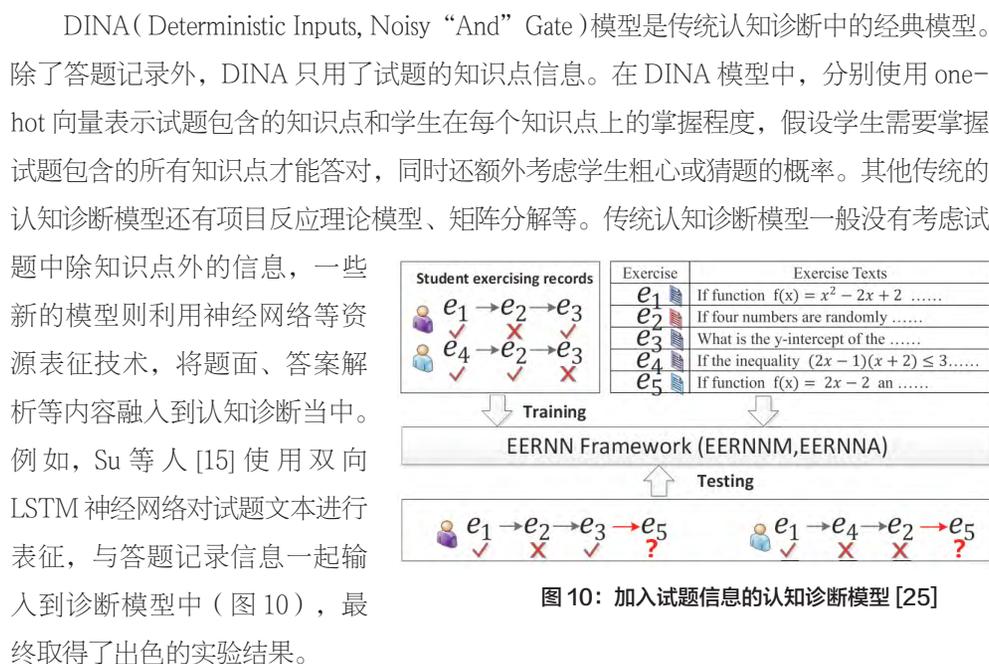
图 9：相似题检测混合表征

比较习题间该答题结果向量相似性，或者作为补充信息加入其他相似检测模型中。

认知诊断

认知诊断是指通过分析学生的答题记录获得学生的知识掌握情况，生成诊断报告，进而可以预测学生未来答题情况，并对学习进度提出建议。认知诊断在智能教育中具有重要的地位，不仅可以提供学生学习状态的反馈，而且可以作为其他任务（如习题推荐等）的前驱模块。

[14] Liu Q, Huang Z, Huang Z, et al. Finding similar exercises in online education systems[C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. ACM, 2018: 1821-1830.



教育资源个性化推荐

教育资源推荐在教育中扮演着重要的作用, 尤其是在资源量相当大的线上智能教育中, 智能推荐算法的使用能够同时为老师和学生提供大量便利。现有的许多线上教育平台或智能教辅产品都包含资源推荐服务, 例如有道智能答题板的习题、课程推荐, 可汗学院的相关课程视频推荐, 智学网的课程推荐、错题本类似题推荐等。

教育资源推荐是涉及到多方面技术的一类智能教育应用。电商推荐系统中的协同过滤等技术可以用在资源推荐中, 例如, 仿照电商系统建立课程资源评价机制, 给相似的学生推荐相同的资源; 挖掘习题和课程之间的关联规则并用在推荐当中等。而针对智能教育自身的特点, 资源推荐也有其自己的一些推荐策略。根据实际场景的不同, 推荐的目标可能是相似题、包含特定知识点的试题或课程视频、难题等, 可涉及到相似题检测、知识点预测、试题难度预测等技术。例如, 在推荐课程视频或课件时, 需要通过认知诊断等技术获得学生对于各个知识点的掌握情况; 在试题推荐时, 不仅需要知道知识点掌握情况, 同时还可能需要考虑推荐的试题难度是否适合, 推荐的试题与做过的试题是否相似等。

在智能教辅系统中, 教育资源的需求可通过分析学生的学习进度、做题记录等来获得。而在网络学习平台 (如 MOOC) 中, 学习论坛是推荐需求较多的区域。由于老师和同学缺乏有效、直接的交流方式, 课程论坛成为学习者提出疑惑和意见的主要渠道, 其参与人数多、非结构化和难以管理等问题使资源推荐有较大的用武之地。斯坦福大学为此设计了

[15] Su Y, Liu Q, Liu Q, et al. Exercise-enhanced sequential modeling for student performance prediction[C]//Thirty-Second AAAI Conference on Artificial Intelligence. 2018

教学视频短片推荐系统 YouEDU[16]，其结构如图 11 所示。在该系统中，首先对论坛中的帖子进行分类，识别出其中的提问贴，然后对提问贴的内容进行深度表征，提取出推荐需求。另一方面，将教学视频切成包含不同内容的短片并各自表征。通过比较提问贴深度表征与视频片段表征的相关性进行精确的推荐。

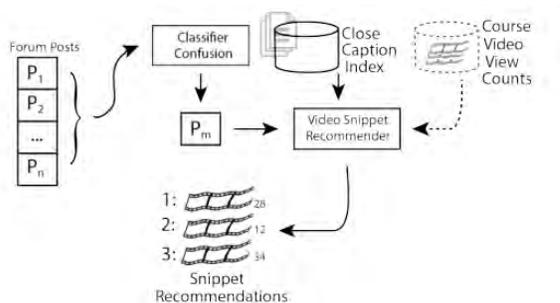


图 11: YouEDU 结构框架

三、总结与展望

对教育资源的深度表征是个性化智能教育研究的基础，也是各类智能教育应用的前提。在此背景下，本文概述了教育资源深度表征相关技术和智能应用场景。可以预测，随着深度学习领域的不断发展，教育资源相关的表征技术与应用工作将在诸多方面不断产生技术革新：

1. 无监督表征。有监督模型的训练需要大量的标注数据，而教育资源存在大量属性标注缺失的现象，造成了数据资源的极大浪费，限制了有监督表征建模方法的实际应用场景和效果。因此，如何设计有效的无监督表征框架以解决大规模教育资源数据的多源异构、标注缺失等问题，具有极其重要的现实意义，同时也是当前研究的热点方向。

2. 教育知识图谱的结合。现阶段知识工程和知识图谱理论与技术已有较大突破，各种公开的知识图谱层出不穷。在教育领域中，如果能够根据大量的、多源的教育知识，构建有效的教育知识图谱，并结合教育知识图谱对异构教育资源之间隐含逻辑关系的抽取和复杂语义结构关联的挖掘，将能够产生极大的帮助。

3. 学习路径优化和推荐。在多数情况下，在线教育平台并没有老师对学生进行指导，学生在面对平台积累的大量教育资源时，难以高效、有利地加以利用。因此，如何为学生找到最高效的学习方案，帮助学生进行高效率的学习，是非常有意义的研究目标。基于深度学习的表征技术为教育资源建立多维度的表征信息，结合学生的认知水平和学习目标，进行个性化试题推荐以及学习路径优化，也是一个重要的应用研究方向。



查看内容精选

[16] Agrawal A, Venkatraman J, Leonard S, et al. YouEDU: addressing confusion in MOOC discussion forums by recommending instructional video clips[J]. 2015.