



观点：

深度 IA 双向智能*

徐雷^{1,2}

¹ 上海交通大学电子信息与电气工程学院认知机器和计算健康研究中心，中国上海市，200240

² 张江国家实验室脑与智能科技研究院神经网络计算研究中心，中国上海市，201210

E-mail: lxu@cs.sjtu.edu.cn

投稿日期：2019-09-30；录用日期：2019-12-15；Crosschecked：2019-12-23

摘要：概述了一个深度双向智能框架。由底向上方向有两个行为，一是获取信息形成适当的模式表示，二是抽象-自组织认知，简记为“A-S 认知”，将输入模式抽象为概念，由一个标签表示，并通过自组织学习以理解模式构成的层次表示。而顶层内域中的行为统称为“A-I 思维”，包含积累、融合、归纳、和灵感等。由顶向下方向也有两个行为，一个简称“I-S 推理”，进行推理和综合，执行各种形象思维和问题求解任务，另一个是与环境交互，执行控制、通讯和检验的任务。在这个双向智能框架基础上，探讨了进行综合推理的可能性。

关键词：抽象；最小均方误差重建自组织学习（Lmser）；认知；形象思维；抽象思维；综合推理

本文译自 Xu L, 2020. Learning deep IA bidirectional intelligence. *Front Inform Technol Electron Eng*, 21(4):558-562.
<https://doi.org/10.1631/FITEE.1900541>

中图分类号：TP18

1 综合推理

我国人工智能的第一次浪潮始于 20 世纪 80 年代初，彼时符号推理研究占据了国际上人工智能文献的主导地位。我国科学家钱学森（1983）提倡包括人工智能在内的思维科学，把思维科学作为一个突破点，指出形象思维在思维过程中的主导作用。潘云鹤院士（1996）对其进行了继承和发展，认为推理研究已从演绎逻辑到开放逻辑、再到类比和形象推理，呈现明显的松绑趋势。在此基础上，该文提出了综合推理模型，阐述了其与思维模拟的关系，并与传统推理进行了比较。

继潘 1996 文后，其团队进一步探讨了基于单源和多源的综合推理，还就设计问题进行了不少应用尝试。不难想象，由一个或若干已知案例，或者直接作为源形成综合空间，或者得到启发构成综合空间，通过综合推理考察空间的可能点集，可相应地考察若干可能的设计草图或雏型。换言之，综合推理是设计智能研究的一个有效工具。

遗憾的是，就像构建传统的专家系统要依赖人工构建的规则库一样，潘 1996 文中对综合推理的实现，需要依赖人工构建的源、部件、场强和组合结构，这阻碍了进一步的发展和应用。值得期待的是，近年双向深度学习的发展有望激活这方面研究。

下面，我们概述一个深度 IA 双向智能框架，如图 1 所示，通过形象思维、抽象思维和创造性思维的协调进行，实现各种认知和问题求解。并在这个框架的基础上，探讨学习综合空间，实现综合推理。

* 本文得到以下项目资助：中国新一代人工智能重大科技项目（No. 2018AAA0100700），中国博士后科学基金（No. 2015M581634），中国上海交通大学“致远”讲席教授奖励基金（No. WF220103010）

ORCID: 徐雷, <https://orcid.org/0000-0002-2752-1573>

© Zhejiang University and Springer-Verlag GmbH Germany, part of Springer Nature 2020

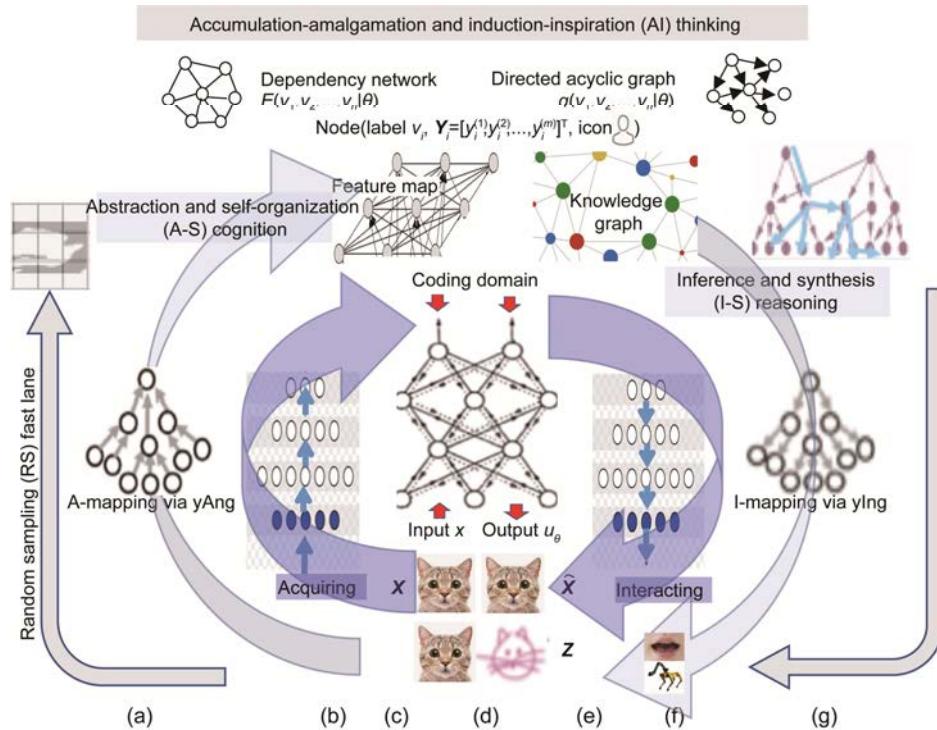


图 1 深度 IA 双向智能 (IA-BI)

2 A-S 认知与形象思维

先看图 1c，在行为一（即 acquiring）获取信息形成模式 \mathbf{X} 之后，行为二即 A-S cognition 执行 A 映射 $\mathbf{X} \rightarrow \mathbf{Y}$ ，即通过监督学习得到深度神经网络，将 \mathbf{X} 抽象映射到顶层内域（简记为 I 域）中一个压缩的代码。它可以是标签 v_i ，用于标记模式、类、概念，也可辅以多个属性 $\mathbf{Y}_i = \{y_i^{(1)}, y_i^{(2)}, \dots, y_i^{(m)}\}^T$ ，做进一步描述。最近在徐 2019b 文中，还建议补充用图标或图元，反映 \mathbf{X} 的结构和拓扑属性。然而，这种由自上而下的监督学习，仅仅实现了映射抽象 $\mathbf{X} \rightarrow \mathbf{Y}$ ，只是最初级的认知。

另一个初级认知功能来自自下而上的无监督学习，如图 1d 所示。该学习将 A 映射 $\mathbf{X} \rightarrow \mathbf{Y}$ 与逆向映射 $\mathbf{Y} \rightarrow \mathbf{X}$ （简记 I 映射）级联，生成 $\hat{\mathbf{X}}$ ，作为 \mathbf{X} 的重建，使得 $\mathbf{X} \rightarrow \mathbf{Y} \rightarrow \hat{\mathbf{X}}$ 近似一个不变映射。最早的例子是所谓的自编码(AE)，出自 Ballard (1987)。具体地，如图 1c 和图 1e 所示，让具有相同结构的两个网络级联，通过最小平方误差 $E \|\mathbf{X} - \hat{\mathbf{X}}\|^2$ 来学习所有未知权系数。这种无监督学习中所得到的压缩代码 \mathbf{Y} ，提供了对 \mathbf{X} 的另一种初级认知。

而最早由 Xu(1991, 1993)提出的最小均方误差重建自组织学习 Lmser，将图 1c 和图 1e 所示的两个网络重叠为图 1d 所示的双向网络，带来了与 AE 大为不同的性能。

如图 2a 所示，观察仅有一层的 Lmser 自组织学习，它向下映射重建 u_θ 去近似输入 \mathbf{X} ，同时向上映射执行独立成分分析 (ICA) 使各单元输出相互独立，导致每个单元的权系数形成检测特定方向的特征模板。

进一步地，在 Xu (1991) 的第 5 节中，其第 (b) 和 (c) 点论述还分析预期，多层 Lmser 自组织学习将由底向上逐步使高层发展为针对高阶特征的模板，最终在顶层形成概念。这些在 Hinton 和 Salakhutdinov (2006) 中得到了呼应和进一步发展。计算实验表明，通过 stacked RBMs 的由底向上自组织学习，的确发展出如图 2b 所示的逐层复杂的特征模板系列。Lmser 与这个 stacked RBMs 很相似，详情请参阅 Xu (2019a) 中的图 4。在谷歌的计算实验中，Dean 和 Ng (2011) 进一步在顶层看到人脸和猫脸的概念。

根据 Hubel 和 Wiesel(1962)的特征检测理论，如图 1d 所示，理解一个概念，可观察其树状层次

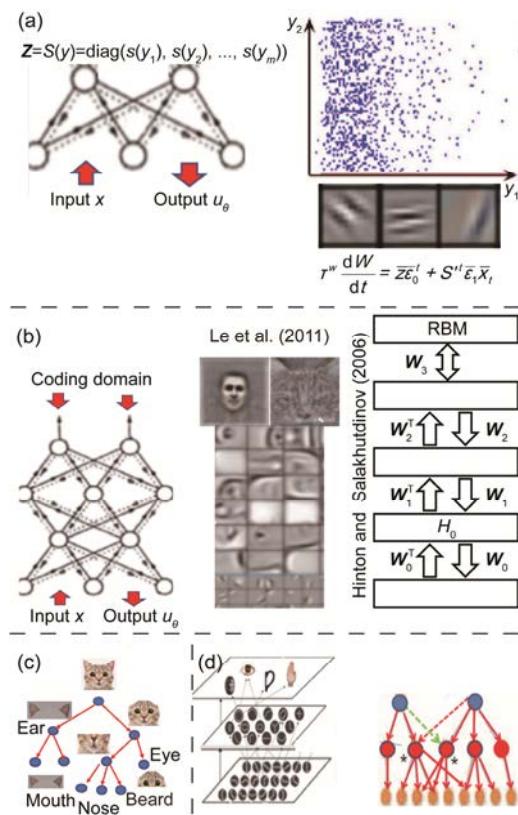


图 2 Lmser 学习与概念的层次表示

结构，即零件或组件如何逐层搭建成此概念。这种树结构有一良好性质，即共父子节点们对于该父节点条件独立。换句话说，随着监督信息由上而下传播，零件或组件将逐层变得相互独立。遗憾的是，通过反向传播进行监督学习，并不能令这一性质得到体现。

而从图 2a 所示的 ICA 可以看出，多层次 Lmser 自组织使得每层单元从下到上逐层实现相互独立，从而使概念或组件变得更容易组织。换句话说，自下而上的 Lmser 自组织有助于形成树状层次结构，而自上而下的监督学习则有助于调整形成的树状层次可有效地共享公共子树，如图 2d 所示。

此外，将图 1c 和 1e 所示的两个网络重叠为图 1d 所示的双向网络，还导致了多个对偶性，带来了若干优点。例如，不仅有诸如最近流行的 U-net、ResNet 和 DenseNet 中常见的跳跃性连接，还有诸如递归神经网络中的反馈连接，详情请参阅 Xu (2019a) 的第 2 节。

另外值得一提的是如图 1a 所示的 RS 快速通道。通过从输入模式中随机采样来拾取信息，并将其快速送到更高层或顶层，形成低分辨率图像样本，再由这些样本快速地识别某些大尺度特征或拓扑性质，然后以注意的方式向下传播去协调自下而上的自组织学习。有关更多讨论，请参阅 Xu (2019b) 的第 3 节。

仅以最小化 $E\|\mathbf{X} - \hat{\mathbf{X}}^2\|$ 为目标，AE 和 Lmser 都没有考虑关于 \mathbf{Y} 的先验知识。将此先验纳入的办法，是考虑描述 I 域的上分布 $q(\mathbf{Y})$ ，而 I 映射由分布 $q(\mathbf{Y}|\mathbf{Y})$ 描述，用最大似然 (ML) 拟合 $q(\mathbf{X}) = \int_q(\mathbf{X}|\mathbf{Y})q(\mathbf{X})d\mathbf{Y}$ ，以替代最佳重构 \mathbf{X} 的原则。为此，A 映射 $\mathbf{X} \rightarrow \mathbf{Y}$ 必须同时实现贝叶斯后验 $p(\mathbf{Y}|\mathbf{X}) = q(\mathbf{X}|\mathbf{Y})q(\mathbf{Y})/q(\mathbf{X})$ 。这种 ML 学习在计算上通常是棘手的。为此，在 Dayan 等人 (1995) 中，预先用深度神经网络来近似 $p(\mathbf{Y}|\mathbf{X})$ ，构成所谓的变分学习，近似实现 ML 学习。

Xu (1995) 提出了 BYY 学习，它致力于 \mathbf{X}, \mathbf{Y} 之联合分布的两个表达之间的最佳匹配或和谐。一个表达是 $q(\mathbf{X}|\mathbf{Y})q(\mathbf{Y})$ ，另一个是 $p(\mathbf{Y}|\mathbf{X})p(\mathbf{X})$ ，其中 $p(\mathbf{X})$ 是 actual sample 所属区域（简称 A 域）上的分布。BYY 学习不仅包括 ML 学习和变分学习，以及若干已有学习方法为特例，而且还给出了适于有限样本学习的新理论。有关 BYY 学习的详细信息，请读者参见 Xu (1995, 2010)，而有关 ML 和变异学习的进一步内容参见 Xu (2019a) 的第 3 节。

根据中国古代的阴阳说，可见域称为 yAng 阳域，而内部不可见域称为 yIng 阴域，这恰好对应前面的 A 域和 I 域。（在当前汉语拼音系统中，阴的拼写是“yin”三个字母。该系统可追溯到 400 多年前 M.Ricci 和 N.Trigault，可能是缺乏阴阳和谐的概念，阳的拼写 Yang 是四个字母。在徐 1995 文中，特意将“阴”拼写为“ying”，以便更符合阴阳和谐的观念。）同样，I 映射或 $q(\mathbf{X}|\mathbf{Y})$ 的角色吻合 yIng 阴性动物之从编码基因到动物实体的转换；而 A 映射或 $p(\mathbf{Y}|\mathbf{X})$ 的角色则吻合 yAng 阳性动物之从动物实体到编码基因的转换。换言之，BYY 学习与中国古代阴阳学说的基本精神是相通的。

不难理解，可以将 I 映射和 A 映射的级联实现扩展到 $\mathbf{X} \rightarrow \mathbf{Y} \rightarrow [\hat{\mathbf{X}}, \mathbf{Z}]$ ，执行从模式 \mathbf{X} 到另一

个模式 \mathbf{Z} 的各种变换，如图 1d 的底部所示，包括图像到图像、语言到语言、文本到图像、文本到草图、草图到图像、2D 图像到 3D 图像、图像到句子、音乐到舞蹈、过去到未来等。这些都是形象思维的典型示例，印证了钱学森（1983）的观点，并具备潘 1996 文提出的综合推理的主要特征。

3 I-S 推理与综合推理

形象思维是通过 A 映射和 I 映射的级联来实现的，而其 I-映射部分的实现主要有两种情况。一是直接通过神经网络整体地执行统计推断 $\mathbf{Y} \rightarrow \mathbf{Z}$ 。二是根据在 A-S 认知过程中学到的层次结构进行的综合。即沿由 \mathbf{Y} 向外的方向，按该树结构逐层添加综合，直到在底层生成 \mathbf{Z} 。我们把 inference and synthesis (I-S) 这两种推理一起称为 I-S 推理。除了输出模式 \mathbf{Z} 外， \mathbf{Z} 还可以是一个序列，其每个元素 z_t 指示决策选择，也即 I-S 推理执行序贯决策。此外，I-S 推理还可以是证明某个陈述的推理树。

这种 I-S 推理驱动紧随其后的 interacting 交互行为，它不仅与外部世界的相对对象进行通信和控制，还充当检验和检查的角色。

这种 I-S 推理接受之前的驱动也主要有两种情况。一是由 A-S 认知中的映射 $\mathbf{X} \rightarrow \mathbf{Y}$ 直接驱动，执行统计推断 $\mathbf{Y} \rightarrow [\hat{\mathbf{X}}, \mathbf{Z}]$ 。二是由 I 域上的思维行为所驱动。如图 1 顶部所示，I 域不仅是概念关系和先验知识的储仓，而且是 Accumulation-amalgamation and Induction-inspiration (A-I) 积累—融合和归纳—灵感等思维行为的工作间，这些统称为 A-I thinking 或 A-I 思维。具体地，通过积累证据增强或减弱认知结果。融合或整合认知和常识，例如借助特征图和知识图谱，形成新概念，并推断概念之间的关系。尤其是，积累-融合可能进一步引发因果归纳，获得有向无环 (DAG) 因果图，有时还可能激励出某种灵感，驱动后面的 I-S 推理进行创造性思维。

这种 I-S 推理也提供了激活综合推理研究的可能性。下面，分别就大样本和小样本情况，做一些进一步讨论。

在设计任务涉及的案例有大量样本的情况下，可以通过学习得到如图 1 所示的深度 IA-BI 系统，其 I 域可充当潘 1996 文中的综合空间，而该文中定义 3 给出的综合函数 $SS(x, y, z)$ 可推广为这个系统的 I 映射 $\mathbf{Y} \rightarrow \mathbf{Z}$ ，它实际上执行综合函数 $\mathbf{Z}=SS(\mathbf{Y})$ 。

综合推理的操作可以沿着两个可能的方向考虑。一是考虑按 $SS(Y_s)$ 进行内插，其中 Y_s 来自于线性或非线性插值由 A 映射 $\mathbf{X} \rightarrow \mathbf{Y}$ 获得的若干代码，例如， (Y_A, Y_B, Y_C) 。二是借助知识图谱、关联网络、因果图 DAG，通过 A-I 思维产生 Y_s ，驱动综合推理 $SS(Y_s)$ 。

在仅由少数案例的情况下，可以考虑迁移学习。首先考虑一个类似或关联的问题并学习获得一个深度 IA-BI 系统，尤其是通过自下而上的 Lmser 自组织和自上而下的监督学习获得如图 2d 所示的树状层次结构，再借助因果关系分析和少量案例知识，对层次结构中的多余链接进行剪枝，然后在该层次结构的约束下进行插值。

甚至可以通过人工分析具体案例，得到如图 2c 所示树状层次结构，直接用于做 Lmser 的连接结构，而且每个节点推广为输出多个属性，不仅表示该节点的激活水平，还描述该节点所对应的部件所具有的主要特征。换句话说，每个节点执行一个有多个向量输入的向量函数。其函数形式可以根据具体案例（如猫脸结构）由人工参与来构造，然后通过 Lmser 自组织和监督学习共同确定其所有未知参数。

遵守伦理准则声明

作者声明发表这篇论文没有利益冲突。

参考文献（从略）