

doi: 10.7690/bgzdh.2015.05.016

基于自组织增量学习神经网络的信息融合技术

时晓峰¹, 申富饶¹, 贺红卫²

(1. 南京大学计算机科学与技术系软件新技术国家重点实验室, 南京 210023;

2. 中国兵器科学研究院, 北京 100089)

摘要: 针对传统神经网络在实际信息融合过程中存在的一些缺陷, 提出一种基于自组织增量学习神经网络 (self-organizing incremental neural network, SOINN) 的信息融合方法。对不同类型传感器接收到的异构数据, 使用增量式正交分量分析 (incremental orthogonal component analysis, IOCA) 方法进行数据自适应降维和特征提取, 将提取出的不同类型特征输入到 SOINN 中, 根据不同数据类型生成相应的神经元连接区域, 建立神经区域间的联想记忆, 从而实现在数据层、特征层以及决策层 3 个层面上的信息融合。实验结果表明: 该方法能够实现对机器人传感器采集到的多源异构数据进行自适应降维和自组织学习, 形成机器人的决策判断和行为指令。

关键词: 智能机器人; 信息融合; 自组织增量学习神经网络; 联想记忆

中图分类号: TP183 **文献标志码:** A

Information Fusion Based on Self-organizing Incremental Neural Network

Shi Xiaofeng¹, Shen Furao¹, He Hongwei²

(1. *The State Key Laboratory for Novel Software Technology, Department of Computer Science & Technology, Nanjing University, Nanjing 210023, China*; 2. *Academy of Chinese Weapon Science, Beijing 100089, China*)

Abstract: To solve the problems in information fusion with traditional neural networks, an information fusion method based on self-organizing incremental neural network (SOINN) is proposed. The proposed fusion system can receive the input data with any dimension and any format from different kinds of sensors. The incremental orthogonal component analysis (IOCA) method is used to reduce the dimensionality of data and extract features adaptively. Then the heterogeneous features are learnt by SOINN. During this period, the connected regions of neurons are generated based on the heterogeneous features and the associated relations between the neuron regions are built. By this way, the data fusion is realized at all of the data level, the feature level, and the decision level. It's shown from the experiments that the dimension can be reduced and the data recorded by different sensors can be learnt adaptively, and then the decisions and instructions of the robots are generated accordingly.

Keywords: intelligent robot; information fusion; self-organizing incremental neural network; associative memory

0 引言

随着传感技术的不断发展, 越来越多的传感器被运用在智能机器人系统当中, 智能机器人探知外界环境手段趋向于多元化。在此种类繁多的机器人传感系统中, 如何将所有这些多源传感信息加以融合, 并在机器人的目标检测、目标识别以及决策控制系统中充分利用, 提高信息可探测性和可信度, 增强系统容错能力和自适应性, 从而提高全机器人智能系统的性能, 使智能机器人拥有较好的分析和处理多感官通道异构数据的能力, 成为当下智能机器人发展中亟待解决的关键问题。

1 信息融合技术

信息融合 (information fusion) 起初被称为数据融合 (data fusion), 是一种对多源信息进行加工的形

式框架, 目的是得到高品质的有用信息^[1]。早在 1959 年, Kolmogorov^[2]提出了有关信息集成的定理。不久之后, Richardson^[3]从理论上证明了增加传感器并不会降低原系统的性能。传统的信息融合方法主要包括加权平均法^[4]、贝叶斯理论^[5-6]、D-S 证据理论法^[7]、卡尔曼滤波^[8]等。但是, 上述基于概率统计的信息融合技术面临着一些严峻的问题: 很难获得一些所需的先验参数、概率分布密度函数、数学模型等; 难以形成复杂的判别函数和类别分界面; 随着数据时空维数的不断扩大, 运算量急剧提升等。

为了解决过于依赖先验知识的问题, 能自主学习的神经网络被引入到信息融合方法中。神经网络的学习特性和强大的非线性处理能力, 满足了多传感器信息融合技术处理的要求。包括多层前馈神经网络^[9]、模糊神经网络 (FNN)^[10]和深度学习网络^[11]

收稿日期: 2015-03-12; 修回日期: 2015-04-30

作者简介: 时晓峰(1993—), 男, 河南人, 在读硕士, 从事神经网络、信息融合、图像识别、脑机接口系统研究。

在内的多种类型的神经网络结构被用于信息融合技术当中。尽管当前国内外基于神经网络已经提出了大量的信息融合算法并成功地在多个应用领域取得成功，但传统神经网络体系结构上的固有缺陷，使其无法适应现代智能机器人所面临的处理高维性、海量性、异构性信息的任务。

使用传统神经网络来实现信息融合的主要流程见图 1。从图中可以看到：该系统首先将异构信号进行不同程度的预处理，对处理后的信号提取特征和归一化，然后再将这些特征向量输入到神经网络中进行学习，以实现多传感信息的融合。其中，异构数据的融合过程主要发生在数据处理层面。但是，这种信息融合方法存在不足之处：1) 神经网络的拓扑结构无法事先确定；2) 网络的拓扑结构一经确定就无法发生变化；3) 数据的融合主要发生在数据处理模块，对于异构数据没有进行对准和统一化学习，而仅仅是将不同类型的数据进行拼接。

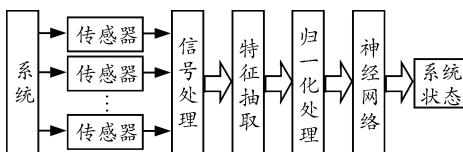


图 1 传统神经网络用于多传感器信息融合的主要流程

自组织增量学习神经网络 (self-organizing incremental neural network, SOINN) 是一种基于竞争学习的通用神经网络模型^[12]，能够对数据进行增量式的无监督学习，可以在不依赖于外界干预及特定先验知识的情况下自适应地构建网络拓扑结构。这些特点使得 SOINN 神经网络能够很好地应对动态变化的外界环境。SOINN 神经网络在机器人智能方面的应用有着突出表现，在文献[13]中，SOINN 神经网络被应用于一个人形机器人学习系统中，实现了机器人在图像、语音等多模信号指导下对环境物理场景的学习和描述，并使用自然语言与人进行简单交流。

受 SOINN 的启发，针对上述基于传统神经网络的信息融合技术(图 1)所存在问题和缺陷，笔者提出了一种基于 SOINN 的信息融合技术。

2 基于 SOINN 的信息融合方法

笔者提出的信息融合方法流程如图 2，对于不同类型传感器接收到的异构数据，首先使用增量式正交分量分析 (incremental orthogonal component analysis, IOCA) 方法进行数据自适应降维和特征提

取，然后将提取出的不同类型的特征输入到 SOINN 中。SOINN 对这些数据进行增量式无监督学习，根据不同的数据类型生成相应的神经元(原型点)，并利用生成的神经元来处理进一步输入的各种数据类型并自动聚类，最终动态地构建出神经网络的拓扑结构。这样能够避免针对每种数据类型设计一个神经网络的传统做法，将所有数据类型的处理统一到同一个神经网络系统中。接下来，对于异构传感源数据所生成的不同神经区域建立通用联想记忆机制 (general associative memory, GAM)，在表示同一类别、模式的神经元结构之间建立关联，在网络的决策层融合表示相同模式的异构数据，最终形成完整的多源异构数据的融合机制。

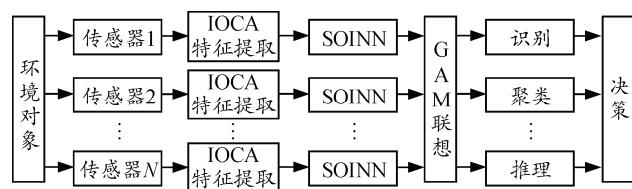


图 2 基于 SOINN 的信息融合系统

2.1 基于 IOCA 的自适应降维与特征提取

在实际多传感器应用场景中，传感器采集到的数据往往具有高维性和海量性，所以需要一种能高效在线地对数据进行降维的特征提取方法。如果采用传统的降维方法来进行降维，一方面对于多源异构数据，无法确定每一类不同的数据应该降到怎样的维度；另一方面，庞大的数据量也必将导致无法忍受的计算工作量。因此文中使用增量式正交分量分析 (IOCA) 方法来对异构数据进行降维和特征提取，从而解决了海量数据的时间复杂度问题。同时，该方法无需事先指定目标维数，能够在学习过程中根据输入数据的不断变化来自动调整所需要的目标维数。该方法还将产生良好的正交分量，避免数据的极大冗余，从而达到更好的维数压缩效果。

基于 IOCA 的多传感数据降维方法能对每一个传感器数据源输入的数据得到一个维数自动确定的正交分量空间 $\{b_1, b_2, \dots, b_n\}$ ，实现快速降维，其实现过程分为以下 2 个主要步骤：首先，对于某一传感器的一条新的输入数据 ξ_{k+1} 和原有已学习到的正交分量空间 $B = \{b_1, b_2, \dots, b_k\}$ ，计算二者之间的线性独立性和可能由 ξ_{k+1} 生成的新的潜在正交分量 b_{k+1} ；然后设定一个自适应阈值来判断 b_{k+1} 能否加入 B 成为一个新的正交分量。具体算法如算法 1 所示。

算法 1:

基于 IOCA 的多传感数据降维算法。

1) 初始化正交分量空间 $B = \emptyset$, 其初始维度 $k = \dim(B) = 0$;

2) 对于某一特定传感器的每一条新输入数据 $x_j (j > k)$:

3) for $i = 1$ to k 计算 $r_{i,k+1} = x_j^T b_i$;

4) 计算 $b'_{k+1} = x_j - \sum_{i=1}^k r_{i,k+1} b_i$;

5) 计算 $r_{k+1,k+1} = \|b'_{k+1}\|_2$;

6) 计算 $b_{k+1} = \frac{b'_{k+1}}{r_{k+1,k+1}}$;

7) if $\frac{r_{k+1,k+1}}{\|x_j\|} \geq \frac{\dim(B)}{d}$, 其中, d 表示原始数据

维度, then;

8) 认为 b_{k+1} 为一个新的正交分量, 将 b_{k+1} 加入到 B ;

9) 更新 $k=k+1$;

10) end if;

11) 跳转至步骤 2)继续学习新的输入数据。

关于 IOCA 的具体推导与详细证明过程可以参考文献[14]。

对于每个传感器的数据, 分别使用相应的正交空间进行特征提取, 最终就能得到多组较低维度的特征向量。接下来就对这些特征向量通过 SOINN 进行学习。

2.2 基于 SOINN 的学习过程

由于 2.1 节的方法对异构数据提取到的特征维度各异, 因此很难预先确定神经网络的拓扑结构使得它可以输入任意维度的数据并进行学习。同时, 由于机器人所处环境是不断变化的, 网络的结构也应该随着输入不断变化以更好地适应环境需要。因此, 笔者基于自组织增量学习神经网络(SOINN)来对不同传感器的异构特征数据进行学习。

SOINN^[12]是一种两层结构(不包括输入层)的竞争神经网络, 可以用来对数据进行在线聚类和拓扑表示。它的第 1 层能够自适应地生成原型神经元及权值向量, 用来表示原始数据的密度分布和拓扑结构; 第 2 层网络则是根据第一层估算原始数据的类间距离和类内距离, 并以此为参数对第一层产生的神经元再次进行聚类, 最终得到分别代表异构输

入数据中代表不同类别的节点集合和聚类的数目。其实现过程主要分为神经元节点的分布、生成、拓扑表示及去噪等 4 个步骤。

使用 SOINN 对异构特征向量进行学习时, 由于来自不同传感器的数据维度各不相同, 因此在进行距离度量时无法对不同源的数据直接进行比较, 因此需要定义新的距离计算方法。

对于来自任意传感器输入的特征向量 x_1^i 和 x_2^j , 其中 i, j 表示对应的传感器变化, 它们之间的距离 $\text{Dis}(x_1^i, x_2^j)$ 定义为:

如果 $i = j$, $\text{Dis}(x_1^i, x_2^j) = D_E(x_1^i, x_2^j)$, 其中 $D_E(x_1^i, x_2^j)$ 表示 x_1^i, x_2^j 之间的欧氏距离;

如 果 $i \neq j$, $\text{Dis}(x_1^i, x_2^j) = \text{INFINITY}$, INFINITY 是一个较大的常数, 表示无穷大。

使用这样的距离来对异构特征进行神经元与拓扑结构生成时, 来自同源的相似的输入数据能够聚合成同一个神经元和权值向量, 而对于不同源的数据输入则会形成新的神经元节点。这样, 最终形成的整个网络不同连通区域的神经元节点将代表不同类型传感器的输入, 如图 3 所示。

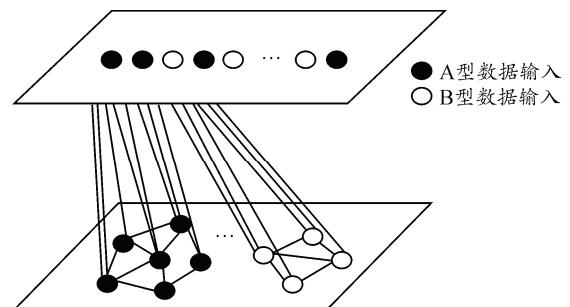


图 3 异构输入数据构建 SOINN 结构示意图

使用 SOINN 对异构数据进行学习的算法如算法 2 所示。

算法 2: 使用自组织增量学习神经网络(SOINN)学习异构数据。

1) 定义基准点集合 $A = \{L_1, L_2\}$, 其中基准点 L_1, L_2 是随机的 2 个输入数据;

2) 初始化边集合 $C \subseteq A \times A$ 为空集, 即 L_1, L_2 之间没有初始连接, 激活数 $M_{L_1} = M_{L_2} = 0$, 范围阈值 $T_{L_1} = T_{L_2} = \text{Dis}(L_1, L_2)$ 以及连接年龄 $\text{age}(L_1, L_2) = 0$;

3) 输入一个新的数据样本 $\xi \in R^D$;

4) 找出 A 中与 ξ 中最相似的 2 个基准点, 胜者基准点 S_1 和亚军基准点 S_2 , 其中 $S_1 = \arg \min_{x \in A} \| \xi - x \|$, $S_2 = \arg \min_{x \in A \setminus \{S_1\}} \| \xi - x \|$;

5) 如果 $\| \xi - S_1 \| > T_{S_1}$ 或者 $\| \xi - S_2 \| > T_{S_2}$ 成立, 就为 ξ 生成一个新的基准点 ξ , 令 $A = A \cup \{ \xi \}$;

跳转至第 3)步;

6) 如果 S_1 与 S_2 间不存在连接, 令 $C = C \cup \{ (S_1, S_2) \}$, 即为 2 个最相似基准点建立连接;

令 $\text{age}(S_1, S_2) = 0$, 即刷新边 $\{S_1, S_2\}$ 的年龄参数;

7) $\text{age}_{(S_1, i)} = \text{age}_{(S_1, i)} + 1$, $\forall i \in N_i \setminus 0$ (与 S_1 相连的所有边年龄增加 1);

8) $M_{S_1} = M_{S_1} + 1$ (S_1 的激活数 M_{S_1} 增加 1);

9) $S_1 = S_1 + \varepsilon(t) \| \xi - S_1 \|$, $S_2 = S_2 + \varepsilon'(t) \| \xi - S_2 \|$ (S_1 与 S_2 向输入样本移动), 其中 $\varepsilon(t) = \frac{1}{t}$, $\varepsilon'(t) = \frac{1}{100}$;

10) 检查所有连接 $(i, j) \in C$ 的当前年龄参数 $\text{age}_{(i, j)}$, 如果 $\text{age}_{(i, j)} > \text{age}_{\max}$, 就从 C 移除该连接, 其中 age_{\max} 是预先定义的参数;

11) 将 S_1 、 S_2 的范围阈值 T_{S_1} 、 T_{S_2} 更新为与 S_1 、 S_2 相邻基准点的最大距离, $T_{S_1} = \arg \min_{(x, S_1) \in C} \| x - S_1 \|$, $T_{S_2} = \arg \min_{(x, S_2) \in C} \| x - S_2 \|$;

12) 如果当前输入的数据样本总数是 λ 的整数倍(即经过了一个学习周期), 检查整个基准点集合 A , 如果存在基准点 L_i 只有一个相邻基准点, 并且 M_{L_i} 小于 M_{\min} , 就在基准点集合 A 中删去 L_i 。

通过上述学习过程, 就能够实现对不同传感器采集到的信息进行增量式在线学习, 并建立出多源异构数据融合的 SOINN 神经网络结构。

2.3 基于联想记忆机制的模式表示

经过第 2.2 节中 SOINN 体系的构建, 文中实现了在记忆层面上对多源异构数据的融合与建模, 但是来自不同类型传感器的数据仍然用相互不连通的拓扑结构表示, 同一模式在不同传感器下的表现还没有实现统一的表示与学习。受文献[15]的启发, 笔者提出一种基于联想记忆的异构数据模式关联机制, 通过在记忆层之上建立联想层, 来实现对表示

同一模式的不同神经区域的关联网络结构。

图 4 描述了该联想记忆机制的结构示意图。从图中可以看到, 在 SOINN 的记忆层之上又添加了一个联想层。在记忆层中, 将来自同一传感器数据源表示相似模式的数据进行聚类并用神经元和权值连接的方式来表示, 对于来自不同传感器数据源的异构数据, 则通过将记忆层学习到的模式在联想层抽象成一个节点, 然后把表示相同或相似模式的节点相关联, 从而实现融合系统内多感官的相互联想, 最终形成机器人大脑产生的同一模式。

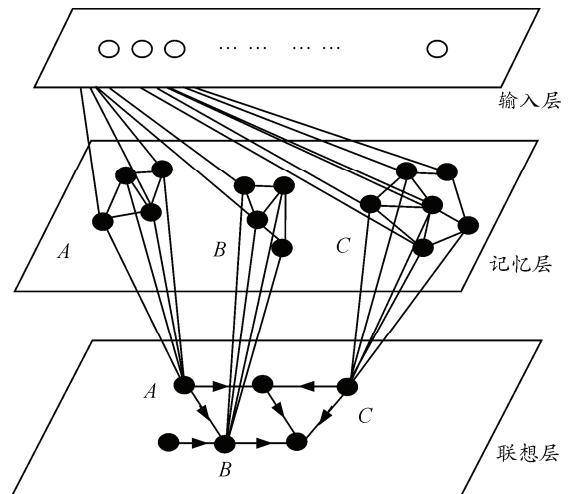


图 4 异构数据联想机制结构示意图

算法 3 给出了在实现记忆层的基础上建立多源异构信息联想记忆的过程。

算法 3: 多源异构信息联想记忆算法。

1) 初始化联想层节点集合 $B = \emptyset$, 节点之间边的集合 $D \subset B \times E = \emptyset$;

2) 对于任意传感器输入数据 x 及其类标 c_x ;

3) 根据算法 2 在记忆层学习向量 x , 并激活神经元连通区域 b ;

4) if 如果在联想层中不存在 b 来表示类 c_x , 即 $b \notin B$ then;

5) $B = B \cup \{ b \}$, $c_b = c_x$, 初始化 b 的关联编号 $m_b = 0$, b 的权重向量 $W_b = x$;

6) else b 的关联编号增加 1: $m_b = m_b + 1$;

7) 在记忆层表示类 c_x 的神经元子区域中寻找获胜次数最多的神经元节点: $i = \arg \max_{j \in c_x} M_{c_x^j}$;

8) 在联想层更新 b 的权重: $W_b = M_{c_x^j}$;

9) end if;

10) 对于另一输入数据 y 及其类标 c_y , 重复步骤 2)~9), 得到所激活神经元连通区域 d , d 所属类别 c_d , d 在联想层中的权重 W_d 以及 d 的关联编号 m_d ;

11) if 在联想层没有 b 指向 d 的边, then;

12) 添加一条由 b 指向 d 的有向边(b, d), 加入边集合 D : $D = D \cup \{b, d\}$;

13) 将类 b 的第 m_b 次关联设为类 d , 即:

$$RC_b[m_b] = c_d;$$

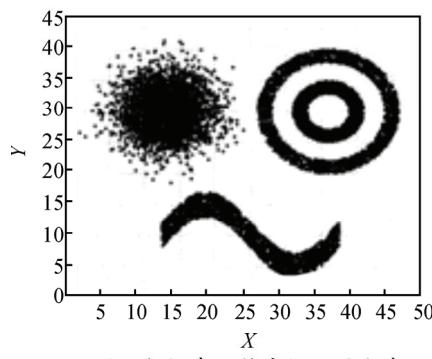
14) 将边(b, d)之间的权重设为 1: $W_{(b,d)} = 1$;

15) else 将类 b 的第 m_b 次关联设为类 d , 即:

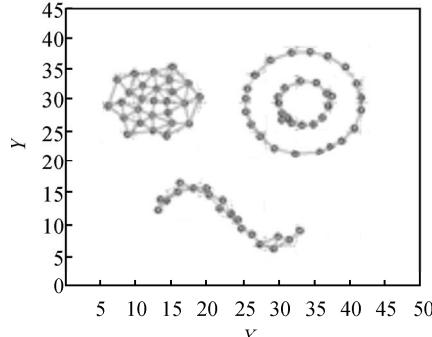
$$RC_b[m_b] = c_d;$$

16) 将边 (b, d) 之 间 的 权 重 加 1 :

$$W_{(b,d)} = W_{(b,d)} + 1;$$



(a) 原始数据在二维空间下的分布



(c) 对(a)中数据学习得到的聚类模型

图 5 使用 SOINN 神经网络对不同维度数据学习后得到的聚类效果

为了验证联想记忆模型对多源异构数据进行融合的有效性, 文中使用 Robovie-X 机器人作为展示平台来实际模拟机器人对图像与声音信息进行融合的过程。实验使用的操作系统是 Windows 7, 编译器是 Visual Studio 2010, Robovie-X 机器人配有摄像头和麦克风分别作为视觉和听觉传感器, 可以用来采集彩色图像和接收用户语音输入(如图 6)。

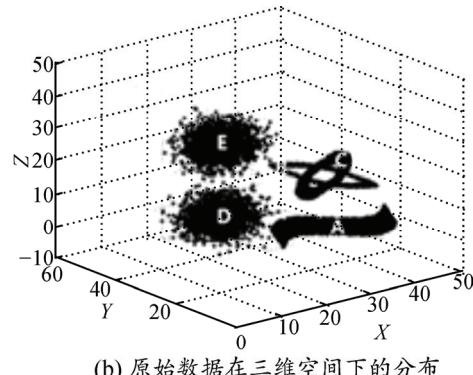
17) end if;

18) 重复 10)~17), 不断接收新的输入数据, 动态建立联想层结构。

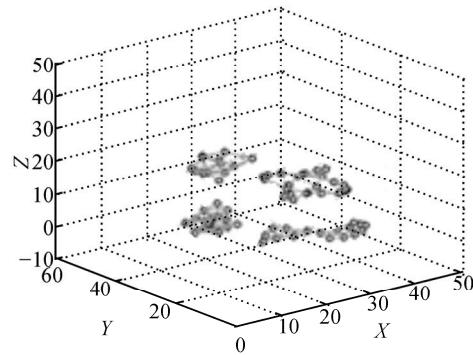
由于联想层的拓扑结构同样随着数据的不断输入动态建立, 因此整个网络是一个增量式可扩展的神经网络。

3 实验与结果分析

笔者首先在一组人工数据集上模拟了 SOINN 对异构数据进行学习的过程, 学习效果如图 5 所示。在图 5 中, 第 1 行的 2 幅图分别表示了在二维和三维空间下原始数据的分布形态, 第 2 行则表示使用 SOINN 神经网络分别对 2 组数据进行学习后得到的聚类结构模型。从实验中可以看到: 笔者提出的基于 SOINN 的异构数据学习方法能够很好地对不同维度的数据进行学习, 模拟多源信息的分布情况, 并对数据进行有效聚类。



(b) 原始数据在三维空间下的分布



(d) 对(b)中数据学习得到的聚类模型

在本实验中, 笔者希望实现机器人融合视觉与听觉双通道传感器下采集到的环境数据信息, 并根据对物体的识别结果执行相应的行为指令。在学习阶段, 分别向机器人展示苹果、香蕉 2 种模型, 机器人通过摄像头采集模型图像数据; 同时, 在向机器人展示苹果模型时, 用户反复发出“苹果”的中文拼音, 在向机器人展示香蕉模型时, 用户反复发

出“香蕉”的中文拼音。在机器人的每次采样中，视觉传感器拍摄下水果模型图像，同时声音传感器记录每次水果名称的发音。接下来，对机器人学习效果进行检验。在验证过程中，文中向机器人提供某种水果的水果模型或者该水果中文拼音的语言。同时按照表 1 来规定机器人根据识别结果应该做出的动作，如果机器人识别出该水果为苹果，则抬起左臂；如果机器人识别出该水果为香蕉，则抬起右臂。

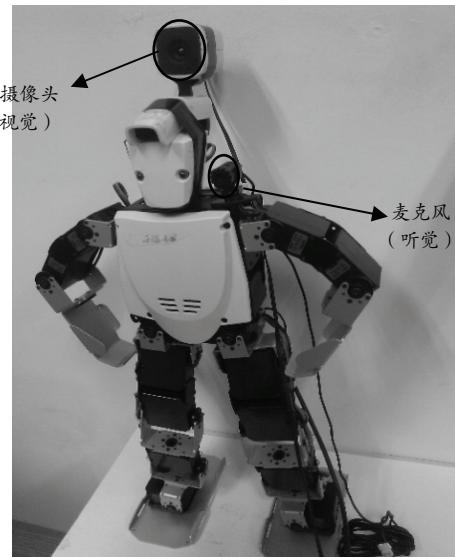


图 6 Robovie-X 机器人及传感设备

表 1 机器人在识别出某种水果时应执行的动作

识别结果	应执行动作
苹果	抬起左臂
香蕉	抬起右臂

在上述实验中，机器人在对水果的反复学习中能够融合图像与声音的双模信息，构建开放式感知神经网络，建立苹果模型与“苹果”语音发音、香蕉模型与“香蕉”语音发音的联想记忆，从而在双模信息融合的基础上学习到苹果、香蕉这两个概念。在检验阶段，机器人对图像、声音双模信息融合学习的验证实验结果如表 2 所示。

表 2 水果概念学习验证实验

编号	视觉传感器输入	听觉传感器输入	机器人执行动作
1	苹果	苹果	抬起左臂
2	香蕉	香蕉	抬起右臂
3	(空)	苹果	抬起左臂
4	(空)	香蕉	抬起右臂
5	苹果	(空)	抬起左臂
6	香蕉	(空)	抬起右臂
7	梨	香蕉	抬起右臂

从实验结果可以看到：在第 1、2 组实验中，分别同时向机器人输入苹果或香蕉的视觉模型和语音

信号，机器人同时处理 2 种传感器的异构数据，通过学习到的网络激活苹果或香蕉的概念，然后执行正确的操作。而在第 3~6 组实验中，对机器人的视觉或听觉传感器单方面模拟失灵或发生故障的情形，机器人未能成功接收到视觉或听觉输入，此时，机器人仍能够通过未故障的传感器接收到的数据进行识别，激活相应概念并完成正确的指令动作。在第 7 组实验中，机器人接收到“香蕉”语音，但是同时接收到了梨的视觉模型，而“梨”这种水果是机器人不曾学习到的，因此机器人在视觉通道上的识别置信度较低，而听觉通道上的识别置信度相对较高，因此机器人最终给出的判断为香蕉，并抬起右臂。

4 结论

笔者基于自组织增量学习神经网络来解决机器人对异构数据进行信息融合的问题，该神经网络是一个三层的网络结构，能够接受任意形式、任意维数的数据输入，在输入层对海量输入数据进行自适应降维，在记忆层根据不同的数据类型生成相应的神经元及权值连接，并对异构数据自动聚类，在联想层构建异构数据聚类模型的相互联想机制，从而实现在数据层、特征层和决策层 3 个层面的信息融合，并最终形成机器人的决策判断或行为指令。

在智能机器人上的实验结果验证了文中所提案方法的有效性。相较于传统的信息融合方法，该信息融合技术具有以下几大优势：1) 不依赖于先验知识，能够自主确定网络拓扑结构，同时网络的结构能够随环境的变化不断发生改变；2) 能够对海量多源异构数据进行自适应降维，实现在数据层面对异构数据的融合；3) 能够对维度不同的异构数据特征进行增量式学习和自主聚类，实现对数据在特征聚类层面的融合；4) 建立表示相同模式神经区域之间的相互联想机制，在决策算法层面融合不同传感器数据信息。

参考文献：

- [1] 潘权, 余昕, 程咏梅, 等. 信息融合理论的基本方法与进展[J]. 自动化学报, 2008(4): 599–615.
- [2] Kolmogorov A N. Entropy per unit time as a metric invariant of automorphism[J]. Doklady of Russian Academy of Sciences, 1959(124): 754–755.
- [3] Richardson J M, Marsh K A. Fusion of Multisensor Data[J]. I. J. Robotic Res, 1988, 7(6): 78–96.
- [4] Lee D H, Park D. An efficient algorithm for fuzzy weighted average[J]. Fuzzy sets and systems, 1997, 87(1): 39–45.

- [5] Zhang Y, Ji Q. Active and dynamic information fusion for multisensor systems with dynamic bayesian networks[J]. Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on, 2006, 36(2): 467–472.
- [6] Pavlin G, de Oude P, Maris M, et al. A multi-agent systems approach to distributed bayesian information fusion[J]. Information fusion, 2010, 11(3): 267–282.
- [7] Murphy R R. Dempster-Shafer theory for sensor fusion in autonomous mobile robots [J]. Robotics and Automation, IEEE Transactions on, 1998, 14(2): 197–206.
- [8] Sun S L, Deng Z L. Multi-sensor optimal information fusion Kalman filter[J]. Automatica, 2004, 40(6): 1017–1023.
- [9] Tafti A D, Sadati N. A Novel Adaptive Tracking Algorithm for Maneuvering Targets Based on Information Fusion by Neural Network[C]//EUROCON, 2007. The International Conference on &# 34; Computer as a Tool&# 34;. IEEE, 2007: 818–822.
- [10] Inguva R, Johnson J L, Schamschula M P. Multifeature fusion using pulse-coupled neural networks[C]// AeroSense'99. International Society for Optics and Photonics, 1999: 342–350.
- [11] Furao S, Hasegawa O. An incremental network for on-line unsupervised classification and topology learning[J]. Neural Networks, 2006, 19(1): 90–106.
- [12] Furao S, Ogura T, Hasegawa O. An enhanced self-organizing incremental neural network for online unsupervised learning[J]. Neural Networks, 2007, 20(8): 893–903.
- [13] He X, Ogura T, Satou A, et al. Developmental word acquisition and grammar learning by humanoid robots through a self-organizing incremental neural network[J]. Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on, 2007, 37(5): 1357–1372.
- [14] Xu Y, Furao S, Zhao J, et al. To obtain orthogonal feature extraction using training data selection[C]//Proceedings of the 18th ACM conference on Information and knowledge management. ACM, 2009: 1819–1822.
- [15] Shen F, Ouyang Q, Kasai W, et al. A general associative memory based on self-organizing incremental neural network[J]. Neurocomputing, 2013, 104: 57–71.
-

(上接第 49 页)

同时考虑到数据处理平台弹上工作的特性, PCB 采用八层板设计, 并且布局时尽量压缩印制板面积, 因此 PCB 板体积较小, 整体大小为 91 mm × 60 mm。

8 结论

经过测试、试验以及实际验证, 数据处理平台能够高速有效地在苛刻的外部环境下进行数据的处理及传输, 具有较高的实用价值, 并已成功应用到某弹体的惯性测姿数据处理系统中。基于数据处理平台的通用性、高性能与高可靠性, 该数据处理平

- 台还可广泛应用于其他航天产品和地面武器装备。

参考文献:

- [1] 陈刚, 张京, 唐建. 一种基于 FPGA 的 PCIe 总线及其 DMA 的设计方法[J]. 兵工自动化, 2014, 33(5): 75–77.
- [2] 苑大威, 黄波, 刘伊华. 基于 DSP 的地磁陀螺组合测姿系统[J]. 兵工自动化, 2014, 33(1): 87–90.
- [3] 卢峰, 程涛, 李坤贺, 等. 一种基于串口的 DSP 程序烧写的方法[J]. 兵工自动化, 2014, 33(3): 59–62.
- [4] 张淳, 潘再平. 逆变电源在微网中的控制策略仿真研究[J]. 机电工程, 2013, 30(4): 72–75.
- [5] 车兵辉, 张鹏, 巍然. 基于 CAN 总线的风洞试验模型电动舵机系统[J]. 兵工自动化, 2014, 33(11): 75–78.