

基于 SA-ANN 的认知机制建模与识别优化算法

陈树婷¹, 谭大鹏²

(1. 杭州医学院基础医学部, 浙江杭州 310053; 2. 浙江工业大学机械工程学院, 浙江杭州 310032)

摘 要: 人脑认知过程机制建模是人工智能研究领域的重要方向, 当前基于统计模板分析与反向传播神经网络 (BP-ANN) 的认知方法在聚类计算与知识理解方面存在不足. 针对上述问题, 提出了一种基于模拟退火神经网络 (SA-ANN) 的认知过程机制建模方法. 对人脑认知物理过程及其基本特征进行了分析, 建立了面向认知过程的 SA-ANN 推理模型. 提出了一种改进的模拟退火神经网络 (ISA-ANN) 识别优化算法, 对认知过程信息特征提取、知识学习训练等关键环节进行了模拟研究. 设计了认知过程机制算例, 开发了相应的原型软件系统, 对理论结果进行了验证. 结果表明, 该方法具有较好的聚类性能, 可以针对具体测试对象进行准确识别, 能够得到相对精确的认知演化规律.

关键词: 认知过程; 机制建模; 信息加工; 人工神经网络; 模拟退火

中图分类号: TP391, B842 **文献标识码:** A **文章编号:** 0372-2112 (2018)08-2011-09

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2018.08.029

SA-ANN Based Cognition Mechanism Modeling and the Improved Recognition Algorithm

CHEN Shu-ting¹, TAN Da-peng²

(1. Department of Basic Medicine, Hangzhou Medical College, Hangzhou, Zhejiang 310053, China;

2. College of Mechanical Engineering, Zhejiang University of Technology, Hangzhou, Zhejiang 310032, China)

Abstract: Human cognition mechanism modeling was an important research direction of artificial intelligence area. Current modeling methods based statistical modes or back propagation artificial neural network (BP-ANN) have the problems of clustering computation and knowledge understanding. Concerning the issue, a mechanism modeling method for cognition process was proposed based on simulated annealing artificial neural network (SA-ANN). The cognition physical process and its fundamental characteristics were analyzed, and a SA-ANN inference model oriented to cognition process was set up. An improved simulated annealing artificial neural network (ISA-ANN) processing algorithm was put forward, and the critical factors of information character extraction and knowledge clustering for cognition process were simulated. Numerical instances for human cognition were provided, and a prototype software system was developed to verify the theoretical results. Experimental results prove that the proposed method is with better clustering performance, can correctly recognize the testing object selected, and can reveal the evolution regulars of psychological cognition process.

Key words: cognition process; mechanism modeling; information processing; artificial neural network; simulated annealing

1 引言

人脑认知是一个典型的信息加工过程, 其机制建模与算法设计是人工智能研究领域的重要方向. 对于信息加工处理, 人与计算机在功能结构及其处理过程方面有诸多相似之处. 两者都是由信息输入、输出、存储

等模块组成的特殊系统, 且需要遵照特定的规程对信息进行加工, 才能完成对信息的提取与认知^[1]. 信息加工理论的实质是以计算机系统为心理认知模型, 得到认知过程与计算机处理存在的对应关系, 进而发现具备一般性的信息加工规律. 人与计算机是由操纵符号组成的信息加工系统; 所谓操纵符号是对语言、标记、记

收稿日期: 2017-03-16; 修回日期: 2017-11-13; 责任编辑: 马兰英

基金项目: 国家自然科学基金 (No. 51775501); 浙江省杰出青年科学基金 (No. LR16050001); 浙江省医药卫生科技计划 (No. 2015KYA067); 浙江省教育科学规划项目 (No. 2017SCG386)

号等概念模式的统称,它的功能是代表、标志或指明外部世界的事物。

人工神经网络(Artificial Neural Network, ANN)是人工智能领域的突出研究成果,它是对实体神经元网络的抽象模拟,具有容错性、高效性及自适应性等特点,且具有较好的学习、记忆等认知功能;ANN的信息处理、运行机制与心理认知过程非常相似,因此它比较适合对认知过程进行模拟研究^[2,3]。利用ANN模型不仅可以对相关实验性结论进行验证,也能够对感知、联想、学习、记忆等认知过程的发生机理进行深入研究。Altmann^[4]利用简单再现网络(Simple Recurrent Network)对婴儿学习语法的发展过程进行了模拟研究,其有效性需要大量的词汇作为训练数据支持。Hallner & Hasenbring^[5]利用ANN技术对慢性腰腿痛(Low Back Pain, LBP)进行了分类模拟研究,他们引入心理风险因素作为ANN的输入神经元,利用误差逆向传播(Back Propagation, BP)算法进行网络训练;结果证明,其对LBP的分类准确率可以达到83.1%。Kaplan等人^[6]提出了一种混合ANN模型,即利用由海明距离(Hamming Distance)组成的海明网络(Hamming Network)来产生问题假设,然后通过Hopfield网络用于联想记忆与优化计算,进而实现对具有重复言语、注意力分散症状对象的模拟研究。Levine^[7]阐述了面向情感计算的神经网络建模方法,并对情感神经机制及认知加工过程进行了系统探讨。Chartier等人^[8]将非线性动力系统引入到ANN领域,提出了一种非线性动力人工神经网络(Nonlinear Dynamic Artificial Neural Network, NDANN),有效弥补了传统ANN在处理非线性推理方面的不足;模拟计算结果证明,NDANN对多值、定点、限定区域对象及非周期(包括混沌)行为进行有效展示。江虹等人^[9]提出了一种基于径向基(Radial Basis Function, RBF)神经网络的认知无线电引擎设计方法,通过对经验知识和环境的学习,重配置通信参数,以达到资源合理分配,提高系统性能。Tsagkaris等人^[10]提出了一种面向可认知无线电系统的神经网络学习方案,从而实现了可对无线电系统的能力预测与智能化管理。汪玲玲等人^[11]将ANN用于自适应测试中,知识状态估计采用极大似然估计,选题策略采用后验加权的KL信息量指标。模拟结果表明,基于BP神经网络的CD-CAT的判准率较为理想。

通过上述分析可以发现,ANN技术已经在认知领域获得了广泛应用,并已取得了不错的研究成果。但上述研究多集中在利用ANN来解决某些认知方面的具体应用问题,尚未对认知过程机制及其内在规律进行系统研究。因此,通过ANN技术进行认知过程的模拟研究,提出相应的认知机制建模方法,得到深层次的人脑心理认知演化规律是可行且必要的工作。此外,当前基

于统计模板分析与BP神经网络的认知方法在聚类计算与知识理解方面存在不足,易于陷入局部最优解,使得认知识别结果的准确性收到限制。

针对以上问题,本文将模拟退火(Simulated Annealing, SA)理论引入到认知机制建模领域,提出了一种基于模拟退火神经网络(SA-ANN)的认知机制建模方法,建立了面向认知过程的SA-ANN推理模型。基于上述模型,提出了一种改进的模拟退火神经网络(ISA-ANN)识别算法,与传统的BP-ANN、SA-ANN算法相对比,对认知过程中的知识学习、模式识别等关键因素进行了模拟研究。本文研究功能可以为人工智能与ANN领域的理论研究提供有益参考,也可以为拟人机器人控制器、类脑处理算法等方面的系统研发提供技术支持。

2 基于SA-ANN的认知推理模型

2.1 ANN与人脑认知

ANN具有较好的学习、并行处理及联想记忆能力,现已广泛地应用于自动控制、信号处理、模式识别^[12]等领域。ANN的各神经元之间通过权值和阈值连接,通过其自身的非线性映射能力对经过预处理的外部输入信息进行自适应计算,直到输出满足要求为止。它利用预先提供的一批或多批标准样本数据,得到与之相对应的标准输出数据,进而分析输入/输出之间存在的规律,然后以这些规律为判据,对输入的实时数据进行判断,上述处理过程被称为学习。神经网络通过对经验样本的学习将知识以权值和阈值的形式存储在网络中,形成记忆库,从而具备一定的判断、识别能力。一般情况下,ANN的输入是被处理对象的特征值或序列,输出则为目标对象的所期望特征数据。

通过上述分析,可以发现ANN的信息处理过程与人脑心理认知具有以下相同点:(1)进行某一次学习或识别的输入信息是有限的;外部信息只有经过一定复杂度的信息加工处理,得到某个特征值或序列,才能够被接受。(2)对输入信息的判断与识别决定于记忆,而记忆是建立在不断学习基础上的,因此学习是在整个信息加工处理过程中的关键环节。(3)学习与识别的处理方式是联想思维与非线性识别,具有自适应性;学习、识别可以同时进行,因此也具有实时性。(4)经过信息加工得到的特征参数并不一定有效,系统的实时处理结果只依赖于部分特征信息;信息加工系统对有效的特征是敏感的。

2.2 SA-ANN认知推理模型

SA是一种启发式随机搜索方法,它在搜索策略上与传统的随机搜索方法不同。它不仅引入适当的随机因素,而且还引入物理系统退火过程的自然机理。在迭代过程中不仅接受使目标函数值变“好”的点,而

且还能够以一定的概率接受使目标函数值变“差”的点,接受概率随着温度的下降逐渐减小. SA 的这种搜索策略有利于避免搜索过程陷入局部最优解,用它来训练神经网络,可使相应的算法跳出局部最优解而获得全局最优解,有利于提高求得全局最优解的可靠性.

SA 处理支持跳跃式搜索,且可以按照 Boltzmann 分布规律接收恶化解. 鉴于上述处理模式与认知过程中的知识演化机制具有较高的相似度,本文将 SA 理论引入到认知机制建模领域,建立了基于 SA-ANN 的认知推理模型,如图 1 所示. 模型分为三个基本层次:环境层、感官层、特征提取与识别层. (1) 环境层是客观世界存在的诸多事物,即需要判断或识别的对象;(2) 感官层

由感官知觉模块(Sensory Perception Module, SPM)与感官效应模块(Sensory Effect Module, SEM)组成,它的作用是系统从环境层获取信息的途径,对于人是通过视觉、听觉、触觉等获取外界事物信息,而计算机系统则是通过相应的传感器或者数据采集子系统获取外界事物的信息;(3) 特征提取与识别层由特征信息提取模块(Characteristic Extraction Module, CEM)、知识学习与识别模块(Knowledge Study & Recognition Module, KSRM)、输出结果处理(Output Process Module, OPM)模块组成,它是模型的核心部分,完成信息提取、知识学习、模式识别等关键认知过程处理步骤.

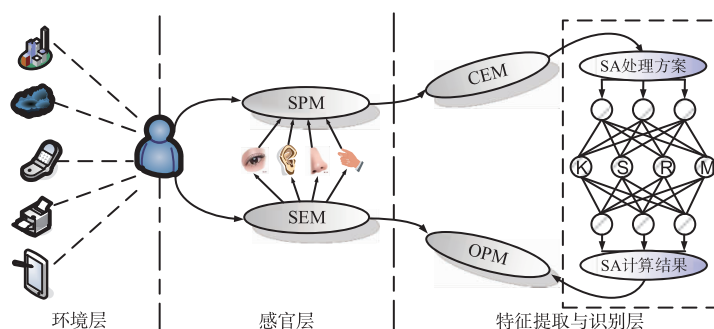


图1 基于ANN的认知推理模型

SA-ANN 认知模型的数据依赖关系和处理流程可以描述如下:SPM 从环境层获取信息,传送至 CEM 进行初步加工,得到范围确定的特征值或序列,作为 KSRM 的输入数据;KSRM 接收特征数据,进行非线性分布计算与状态识别,经过 OPM 处理得到期望状态空间的某个状态数据,最后由 SEM 显示系统处理的最终结果. CEM 是一个海量算法集合,其每一个元素相当于某种信息获取手段. 上述过程中,针对具体对象进行处理时,需要抽取某种或几种算法进行特征提取;显然,初步抽取的算法不一定是最优或有效的(例如某些事物用视觉不易分辨,但用听觉却比较容易区分),这时需要对算法进行优化或者替换,相当于转换/调整手段来处理问题,此方面的内容将在第二节进行详细讨论. KSRM 作为系统的核心构件,需具备对知识学习、模式识别并行处理的能力,其算法的合理性与效率确定系统处理的有效性,也是本文研究的关键内容.

3 ANN 认知计算与快速收敛算法

3.1 基于 BP 算法的认知计算

在 ANN 技术的实际应用过程中,绝大部分的神经网络模型都是采用 BP 网络和它的变化形式. BP 网络是由输入层、隐含层和输出层组成的无反馈前向网络,其隐含层的数量可以大于 1. 输入层、隐含层和输出层

单元之间通过前向方式连接,每一层的神经元个数可以不同. 在输入层和隐含层以及隐含层和输出层之间神经元的连接权值是可以通过误差 BP 算法来训练,三层之间的阈值也是可以通过这种方法来改变. BP 网络一般采用最快梯度下降法(Steepest Descent Gradient Method, SDGM)来修正权值和阈值^[13].

BP 网络通过一个使误差函数最小化过程完成输入到输出的映射. 误差函数(代价函数)通常可定义为所有输出层单元的期望输出与实际输出的误差平方和,即

$$\varepsilon = \frac{1}{2} \sum_p (\hat{O}_p - O_p)^2 \quad (1)$$

式(1)中: p 为样本个数, \hat{O}_p 为网络期望输出, O_p 为网络实际输出. BP 网络学习过程与人类的学习过程有一定的相似性,因为人类学习也是一种不断摄取外界信息而逐渐积累,最后达到对相似信息认知识别的过程.

利用 BP 网络对相应的目标事物进行认知与识别,首先要确定识别目标所能提供信息的特征量即 BP 网络的输入以及识别目标状态即 BP 网络的输出. 根据本文 2.1 节的分析可知,目标事物所包含的所有信息是部分有效的,需要进行一定的预处理加工后,然后选取 m 个静态或动态参数作为 BP 网络的输入,由符号 $X = \{x_0, x_1, \dots, x_{m-1}\}$ 表示;同时由符号 $\Omega = \{\omega_0, \omega_1, \dots,$

ω_{n-1} 表示所识别目标的各态历经状态信息(见图 2).




图2 BP网络认知识别原理

基于上述分析,基于 BP 网络的认知算法流程如下:

(1) 对网络输入的特征数据 (m 个参数) 与网络输出期望值 (n 种状态) 进行归一化处理,使其便于计算机处理与识别.

(2) 根据识别目标特征,选择合适的作用函数. 本文选取的作用函数为 Sigmoid 函数

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

该函数具有以下特征:值域 $a \in (0, 1)$;非线性、单调性;无限次可微;当 $|x|$ 较小时可近似线性函数;当 $|x|$ 较大时可近似阈值函数.

(3) 在一定范围内选择权值、阈值的初始值,对网络进行初始化.

(4) 输入识别目标特征数据由输入层输入,经网络的权值、阈值和神经元的传递函数作用后得出网络输出,并计算网络输出与期望输出之间的误差平方和 ε . 如果 ε 小于期望误差则结束算法,否则进入下一步操作.

(5) 修改输出层至隐层的权值和输出神经元的阈值

$$\omega_j(n+1) = \omega_j(n) + \eta_n \sum_p \delta_j O_{pj} + \alpha[\omega_j(n) - \omega_j(n-1)] \quad (3)$$

$$\theta(n+1) = \theta(n) + \eta_n \sum_p \delta_j + \alpha[\theta(n) - \theta(n-1)] \quad (4)$$

$$\eta_n = \eta_0 [1 - 1/(N + M)] \quad (5)$$

式(3) ~ (5)中: ω_j 为隐层节点到输出层节点的连接权值, n 为调整次数, η_n 为迭代步长, δ_j 为隐层神经元误差, $a \in (0, 1)$ 为动量因子, θ 为输出层神经元的阈值, N 为迭代次数, M 为任意大整数.

(6) 修改输入层至隐层的连接权值和隐层神经元的阈值

$$\omega_{ij}(n+1) = \omega_{ij}(n) + \eta_n \sum_p \delta_j O_{pj} + \alpha[\omega_{ij}(n) - \omega_{ij}(n-1)] \quad (6)$$

$$\theta_j(n+1) = \theta_j(n) + \eta_n \sum_p \delta_{ij} + \alpha[\theta_j(n) - \theta_j(n-1)] \quad (7)$$

$$\eta_n = \eta_0 [1 - 1/(N + M)] \quad (8)$$

式(6) ~ 式(8)中: ω_{ij} 为输入层节点到隐层节点的连接权值, δ_{ij} 为输出层神经元的误差, θ_j 为隐层神经元的阈值.

(7) 判断算法是否达到最大训练步数. 如果是则结束计算,否则转第(3)步.

3.2 可快速收敛的 SA-ANN 识别算法

虽然 BP 算法具有简单、易用、高效等特点,但其在处理复杂问题时易于出现局部最优问题而无法获得全局最优解,最终无法得到正确的识别结果. 如前所述,基于 SA 的搜索策略有利于避免搜索过程陷入局部最优解,用它来训练神经网络,可使相应的算法跳出局部最优解而获得全局最优解,有利于提高求得全局最优解的可靠性.

因此,本文采用快速模拟退火组合优化算法(Fast Simulated Annealing with Combinatorial Optimization, FSA-CO)进行神经网络训练. Powell 算法具有较强的局部搜索能力,尤其是在求解变量、样本数及隐层神经元数相对较少的条件下,其搜索效率的提升较为明显,因此可以用它来搜索一个局部最优解. 基于上述假设,提出了一种改进的模拟退火人工神经网络(ISA-ANN)认知处理算法,以期能够解决 BP 网络可能在局部极小点收敛的问题,从而提高目标参数的预测实时性与精度. 改进算法的流程如图 3 所示,具体计算步骤描述如下:

(1) 利用 FSA-CO 把网络中所有权重的集合看成是

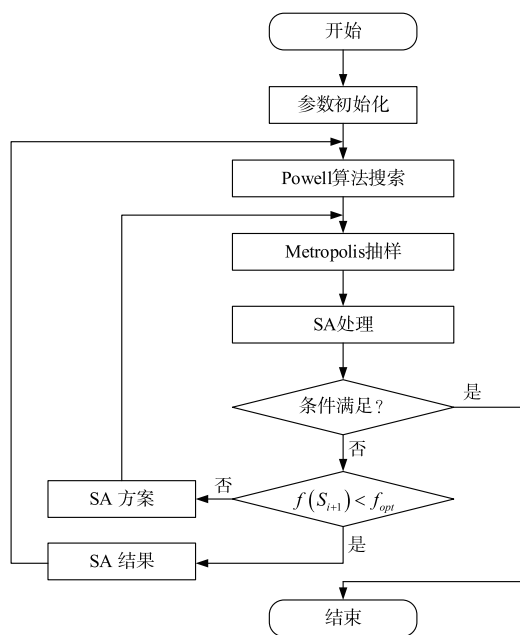


图3 ISA-ANN处理算法流程

一个解向量,然后构造目标函数

$$E = \frac{1}{2p} \sum_p \sum_k (t_{pk} - o_{pk})^2 \quad (9)$$

上述目标函数的最小值对应于问题的最优解;式(9)中, p 为训练样本数, k 为输出层神经元的个数, t_{pk} 为第 k 神经元关于第 p 个样本的期望输出, o_{pk} 为第 k 神经元关于第 p 个样本的实际网络输出。

(2)初始化,随机产生一组初始网络权值 S_0 ,设置初始温度 $T_0 > 0$,迭代次数 $i = 0$,检验精度为 ε ,当前最优解为 f_{opt} ,并令 $f_{opt} = f(S_0)$ 、 $S_p = S_0$ 。

(3)将网络权值 S_p 作为初始点 $S(0)$,利用 Powell 算法进行优化,快速搜索到某一个局部极小点,得到一组新的网络权值 S'_p ,令 $S_i = S'_p$ 、 $f_{opt} = f(S_i)$ 。

(4)将网络权值 S_i 作为迭代值 x ,设当前解 $S(i) = x$,令 $T = T_i$,进行最佳保留模拟退火操作;按照 Metropolis 抽样准则,得到一组新的网络权值 S_{i+1} ;令 $i = i + 1$,其下降实现方法为:

$$T_i = \frac{T_0}{1 + \ln(i)} \quad (10)$$

(5)若经过模拟退火操作后所得的网络权值 S_{i+1} 满足精度要求或迭代次数,则算法结束;否则,若 $f(S_{i+1}) < f_{opt}$,则令 $S_p = S_{i+1}$,转入步骤(3);若 $f(S_{i+1}) \geq f_{opt}$,则令 $S_i = S_{i+1}$,转入步骤(4)。

如图 3 所示,所提出的 ISA-ANN 算法的处理流程可以分为三个阶段:Powell 搜索、Metropolis 抽样、SA 处理。对于第一个阶段,通过 Powell 算法得到一个初始的局部最优点。由于此阶段的数据采样率较低, Powell 算法可以充分发挥其在搜索效率方面的优势,以减少 SA 处理的搜索范围与计算负荷,进而提高整个优化过程的收敛效率。对于第二阶段, Metropolis 抽样算法可支持柯西(Cauchy)代价函数;与 Gaussian 分布相比, Cauchy 具有更陡峭的尖峰与更平坦的侧翼,可以实现更为精确的局部搜索,且具有跳出局部最优的能力。对于第三阶段,在下一步迭代结果优于当前最优解的情况下,保存当前的 SA 结果并跳出当前搜索范围,在通过 Powell 算法锁定下一个局部最优解,直到获得全局最优解为止。

4 认知过程算例

根据上述分析结论,本文设计了面向人脑认知过程机制的算法实例。实例实现方案主要是通过机器视觉方法采集目标影像信息,然后利用图像分割技术得到其特征区分区域,最后实对目标的识别、判断。

如图 4 所示,识别目标为 4 种常见动物:马、驴、骡子与山羊,因为它们有较多的相似特征(四足、有蹄、有尾、两耳、体形轮廓相似),对其进行认知、区分过程能

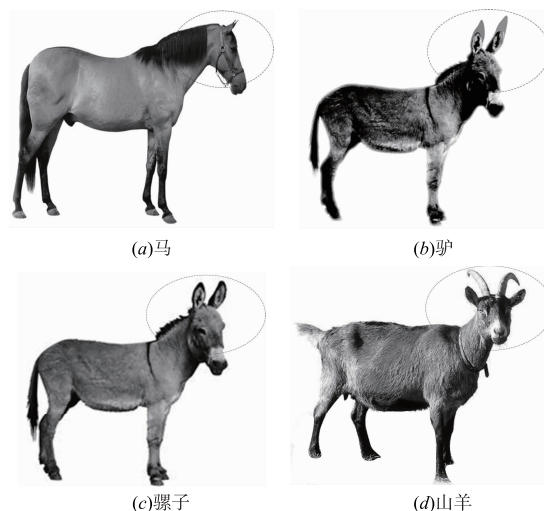


图4 认知算例目标

够较好的反应人类认知的一般过程。针对上述识别目标,本文设计的心理认知过程模拟算法实例主要包括以下 3 个步骤。

(1)首先对马、驴进行认知识别。上述 2 种动物的共有特征为:四足、有蹄、有尾、两耳。根据日常经验可知,马的耳朵是很短的,而驴的耳朵却很长,因此通过它们耳朵的长度就可进行区分。针对此问题,可确定认知识别的特征向量为:

$$\begin{aligned} X_1 &= \{x_{11}, x_{12}, x_{13}, x_{14}\} \\ &= \{四足, 有蹄, 有尾, 长耳\} \end{aligned} \quad (11)$$

因为式(11)的组成元素均为存在性定性特征,所以马、驴对应的特征向量可分别记作为: $X_{1h} = \{1, 1, 1, 0\}$ 与 $X_{1d} = \{1, 1, 1, 1\}$,上述 2 个特征向量即为进行此次认知识别所需要的训练数据(输入模式)。这时需要识别的对象范围只涉及两种动物,而对应的期望输出(输出模式)为: $\Omega_{1h} = \{1, 0\}$ 与 $\Omega_{1d} = \{0, 1\}$,如表 1 所示。

表 1 第一步模拟计算输入/输出对应关系

对象	输入模式	输出模式
马	$X_{1h} = \{1, 1, 1, 0\}$	$\Omega_{1h} = \{1, 0\}$
驴	$X_{1d} = \{1, 1, 1, 1\}$	$\Omega_{1d} = \{0, 1\}$

(2)第二步是对马、驴、骡子进行认知识别。上述 3 种动物的共有特征为:四足、有蹄、有尾、两耳。根据日常经验可知,马的耳朵是很短(占头部长度比例 10 ~ 20%),驴的耳朵很长(占头部长度比例 60 ~ 80%),而骡子的耳朵长度是介于二者之间的(占头部长度比例 30 ~ 40%),因此通过它们耳朵的长度就可进行区分,但式(2)所表示的特征向量却不能满足此次识别的要求。针对此问题,需要对式(2)中的元素 x_{14} 进行向量元素细化操作 Ref(),可确定此时的认知识别特征向

量为:

$$\begin{aligned} \mathbf{X}_2 &= \{x_{21}, x_{22}, x_{23}, \text{Ref}(x_{14}, 1)\} \\ &= \{\text{四足, 有蹄, 有尾, 耳长}\} \end{aligned} \quad (12)$$

因为式(12)的组成元素 x_{21}, x_{22}, x_{23} 为存在性定性特征, x_{14} 经过细化后转化为定量特征分量 x_{24} , 所以马、驴、骡子对应的特征向量为: $\mathbf{X}_{2h} = \{1, 1, 1, 0.1 \sim 0.2\}$ 、 $\mathbf{X}_{2d} = \{1, 1, 1, 0.6 \sim 0.8\}$ 、 $\mathbf{X}_{2m} = \{1, 1, 1, 0.3 \sim 0.4\}$, 上述 3 个特征向量即为进行此次认知识别所需要的训练数据(输入模式). 这时需要识别的对象范围涉及 3 种动物, 而对应的期望输出(输出模式)为: $\mathbf{\Omega}_{2h} = \{1, 0, 0\}$ 、 $\mathbf{\Omega}_{2d} = \{0, 1, 0\}$ 、 $\mathbf{\Omega}_{2m} = \{0, 0, 1\}$, 如表 2 所示.

表 2 第二步模拟计算输入/输出对应关系

对象	输入模式	输出模式
马	$\mathbf{X}_{2h} = \{1, 1, 1, 0.1 \sim 0.2\}$	$\mathbf{\Omega}_{2h} = \{1, 0, 0\}$
驴	$\mathbf{X}_{2d} = \{1, 1, 1, 0.6 \sim 0.8\}$	$\mathbf{\Omega}_{2d} = \{0, 1, 0\}$
骡	$\mathbf{X}_{2m} = \{1, 1, 1, 0.3 \sim 0.4\}$	$\mathbf{\Omega}_{2m} = \{0, 0, 1\}$

(3) 第三步是对马、驴、骡子、羊(雄羊)进行认知识别. 上述 4 种动物的共有特征为: 四足、有蹄、有尾、两耳. 根据日常经验可知, 羊的耳朵长度绝对尺寸虽然比较小, 但其占头部长度的比例却与骡子非常接近, 因此式(11)、(12)所表示的特征向量都不能满足此次识别的要求. 针对此问题, 需要对式(11)进行行向量维数追加操作 $\text{Aep}()$, 增加一个维度: “是否有角”, 可确定此时的认知识别特征向量为

$$\begin{aligned} \mathbf{X} &= \text{Aep}(\mathbf{X}_1, 1) = \{x_{31}, x_{32}, x_{33}, x_{34}, x_{35}\} \\ &= \{\text{四足, 有蹄, 有尾, 长耳, 有尾}\} \end{aligned} \quad (13)$$

因为式(13)的组成元素均为存在性定性特征, 所以马、驴、骡子、羊对应的特征向量可分别记作为: $\mathbf{X}_{3h} = \{1, 1, 1, 0, 0\}$ 、 $\mathbf{X}_{3d} = \{1, 1, 1, 1, 0\}$ 、 $\mathbf{X}_{3m} = \{1, 1, 1, 0, 0\}$ 、 $\mathbf{X}_{3s} = \{1, 1, 1, 0, 1\}$, 上述 4 个特征向量即为进行此次认知识别所需要的训练数据(输入模式). 这时需要识别的对象范围涉及 4 种动物, 而对应的期望输出(输出模式)为: $\mathbf{\Omega}_{3h} = \{1, 0, 0, 0\}$ 、 $\mathbf{\Omega}_{3d} = \{0, 1, 0, 0\}$ 、 $\mathbf{\Omega}_{3m} = \{0, 0, 1, 0\}$ 、 $\mathbf{\Omega}_{3s} = \{0, 0, 0, 1\}$, 如表 3 所示.

表 3 第三步模拟计算输入/输出对应关系

对象	输入模式	输出模式
马	$\mathbf{X}_{3h} = \{1, 1, 1, 0, 0\}$	$\mathbf{\Omega}_{3h} = \{1, 0, 0, 0\}$
驴	$\mathbf{X}_{3d} = \{1, 1, 1, 1, 0\}$	$\mathbf{\Omega}_{3d} = \{0, 1, 0, 0\}$
骡	$\mathbf{X}_{3m} = \{1, 1, 1, 0, 0\}$	$\mathbf{\Omega}_{3m} = \{0, 0, 1, 0\}$
羊	$\mathbf{X}_{3s} = \{1, 1, 1, 0, 1\}$	$\mathbf{\Omega}_{3s} = \{0, 0, 0, 1\}$

5 原型系统与对比实验

5.1 原型软件系统

根据本文所提出的算法与算例, 开发了基于 SA-

ANN 的认知计算原型软件系统, 其主控界面如图 5 所示. 软件可提供系统参数设置、认知与识别、处理过程优化等 Tab-widget 选项. 针对本文 4 节所描述的识别目标(马、驴、骡子、羊), 通过计算机视觉技术进行目标数据采集, 然后对原始图像进行灰度及矢量化等预处理操作, 再根据既定的图像区域对经过预处理的图像数据进行区域分割. 本实例所规定的目标特征区域为头部, 因此在获得目标原始数据后, 可得到其特征区域轮廓(见图 5); 在此基础上提取 4 节所设定的特征值组成特征向量, 然后通过 ISA-ANN 处理算法进行识别, 最后给出识别结果.

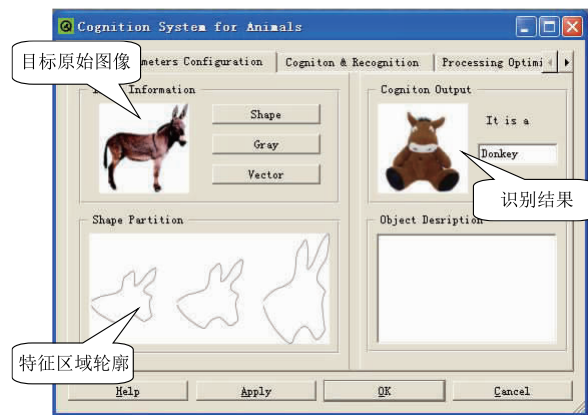


图 5 基于 SA-ANN 的认知原型软件

5.2 聚类对比实验

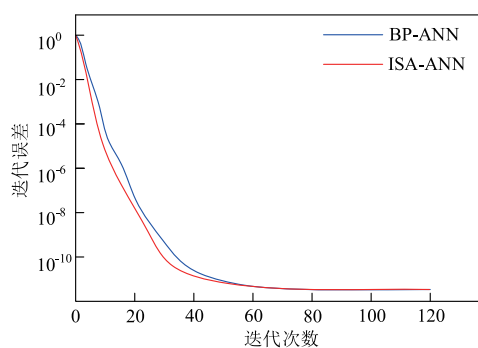
聚类过程是体现 ANN 处理算法性能的关键参数. 对于 BP 算法来讲, 可供选择的聚类函数主要有: 最速下降函数、动量函数、可变学习率函数、弹性函数等. 对于一个给定的网络和样本, 使用哪一种聚类方法使得收敛速度最快、误差最小是难以预知的, 需要根据具体情况来选择. 经过多次演算与反复尝试, 本文最终选用最速梯度下降算法(SDGM)来实现本算例的样本初始化与知识学习, 其实现过程如下: 首先根据样本文件中的网络模型参数, 创建一个 BP 网络, 然后用 SDGM 聚类函数来对建好的神经网络进行训练. SDGM 就是利用负梯度方向来决定每次迭代的新搜索方向, 使得每次迭代能使待优化的目标函数逐步减小, 其基本形式为:

$$\omega(n+1) = \omega(n) - \eta \cdot \nabla[\omega(n)] \quad (14)$$


式(14)中, ω 为网络节点权值, n 为迭代计算次数(调整次数), ∇ 为向量微分算子, η 为学习速率, 即沿负梯度方向的迭代计算步长. η 大小的选择对 SDGM 算法的成败起到非常重要的作用. 若 η 取值过大, 误差函数值可能发生振荡, 甚至无法得到计算结果; 若 η 取值过小, 收敛速度较慢, 影响计算效率, 使计算结果的实时性难以保证. 对于 SDGM 算法学习速率 η 的选取标准, 相关研究认为取 0~1 之间较合适, 但缺乏可靠的理论依据

作为支撑. 本文通过对多次计算结果的分析, 取 $\eta = 0.65$.


对于本文所提出的 ISA-ANN 算法, 首先通过 FSA-CO 进行初始化与聚类计算, 然后结合 Powell 算法进行迭代过程优化, 从而较好地弥补了传统 SA-ANN 算法在收敛速度方面的不足. 基于上述假设, 以算例中的 3 个计算步骤为对象, 进行了聚类过程对比实验, 结果如图 6 所示. 从图中可以看出, 随着算例复杂度的加大, 聚类收敛的计算次数迅速增加, 这与人类认知学习的趋势相符; 相对于 BP 算法, 本文所提出的 ISA-ANN 算法具有较好的收敛性能, 尤其是在算例复杂度较高的情况下.



(a) 算例1



(b) 算例2



(c) 算例3

图6 聚类计算误差曲线

5.3 识别对比实验

为了验证本文所提出建模与识别方法的有效性, 进行了相应的对比实验. 根据算例中的四个识别对象, 将实验样本集分四组, 每组 30 个样本, 共计 120 个图

像. 对比实验分为 3 个阶段, 分别对应第 3 节算例中的 3 步模拟计算, 其流程步骤如下: (1) 根据识别实验需求, 从样本集中随机选择所需个数的样本; (2) 采集所选样本的头部区域图像, 然后进行灰度平滑、色彩平均等预处理操作; (3) 对经过预处理的区域图像进行锐化、分割, 提取目标区域的边缘轮廓; (4) 提取目标轮廓的特征数据作为 ANN 的输入, 通过 BP 算法与 ISA-ANN 算法进行在线识别, 并得到识别结果.

第一阶段对比实验: 马、驴作为识别对象, 分别以目标模式代号 ω_1 、 ω_2 来表示. 针对上述识别对象, 进行了 200 次对比实验, 结果如表 4 所示. 由于第一阶段识别对象比较简单, 运算复杂度低, 因此 BP-ANN 与 ISA-ANN 方法均可以获得 100% 的识别成功率, 无明显差异.

表 4 第一阶段对比实验结果

识别目标	识别结果				识别成功率 / %	
	ω_1		ω_2		BP-ANN	ISA-ANN
	BP-ANN	ISA-ANN	BP-ANN	ISA-ANN		
ω_1	200	200	0	0	100	100
ω_2	0	0	200	200	100	100

第二阶段对比实验: 马、驴、骡子作为识别对象, 分别以目标模式代号 ω_1 、 ω_2 、 ω_3 来表示. 针对第一阶段对比实验结果, 提升了计算难度与负荷, 进行了 300 次对比实验, 结果如表 5 所示. 通过表 5 中的对比实验数据, 可以得到如下规律: 由于 BP-ANN 方法记忆与学习能力相对较差, 在本阶段实验开始出现错判结果; 驴子具有显著的长耳特征, 因此两种方法都可以获得较高的识别成功率; 由于对特征向量进行了针对性细化操作, 本文方法能够精确的识别 3 个目标对象.

第三阶段对比实验: 马、驴、骡子、羊作为识别对象, 分别以目标模式代号 ω_1 、 ω_2 、 ω_3 、 ω_4 来表示. 针对第一、二阶段对比实验结果, 继续提升计算难度与负荷, 进行了 500 次对比实验, 结果如表 6 所示. 通过表 6 中的对比实验数据, 可以得到如下规律: 随着计算复杂度的不断增加, BP-ANN 方法的识别成功率明显下降, 在对骡子与羊的识别方面尤为明显; 由于不同的目标样本存在差异, 随着实验难度与次数的增加, 本文方法开始出现误判; 经过元素细化与维数追加操作, 本文方法可以稳定的识别山羊对象, 其识别性能与人脑相近.

为了进一步验证本文方法的有效性, 将识别对象样本集扩充一倍, 并通过提高透明度、改变 RGB 平衡、调整对比度、增加误差点、降低分辨率等方法, 对识别对象进行有损处理, 形成所谓的有损样本集, 如图 7 所示.

针对上述有损样本集, 进行第三阶段识别实验, 并与 BP-ANN 方法进行对比, 具体结果如表 7 所示. 通过

表 7 中的对比实验数据,可以得到如下规律:由于在容错处理方面的缺陷,BP-ANN 方法的识别成功率降低至 90% 以下;随着识别对象复杂度的增加,本文所提出的

ISA-ANN 算法可以保持 99% 以上的识别成功率,说明该方法具有较好的容错识别能力。

表 5 第二阶段对比实验结果

识别目标	识别结果						识别成功率 / %	
	ω_1		ω_2		ω_3			
	BP-ANN	ISA-ANN	BP-ANN	ISA-ANN	BP-ANN	ISA-ANN	BP-ANN	ISA-ANN
ω_1	296	300	0	0	4	0	98.67	100
ω_2	0	0	298	300	2	0	99.33	100
ω_3	5	0	3	0	292	300	97.33	100

表 6 第三阶段对比实验结果

识别目标	识别结果								识别成功率 / %	
	ω_1		ω_2		ω_3		ω_4			
	BP-ANN	ISA-ANN	BP-ANN	ISA-ANN	BP-ANN	ISA-ANN	BP-ANN	ISA-ANN	BP-ANN	ISA-ANN
ω_1	480	497	2	0	10	3	8	0	96.00	99.40
ω_2	0	0	488	499	9	1	3	0	97.60	99.80
ω_3	12	2	10	2	443	496	35	0	88.60	99.20
ω_4	10	0	2	0	40	2	448	498	89.60	99.60

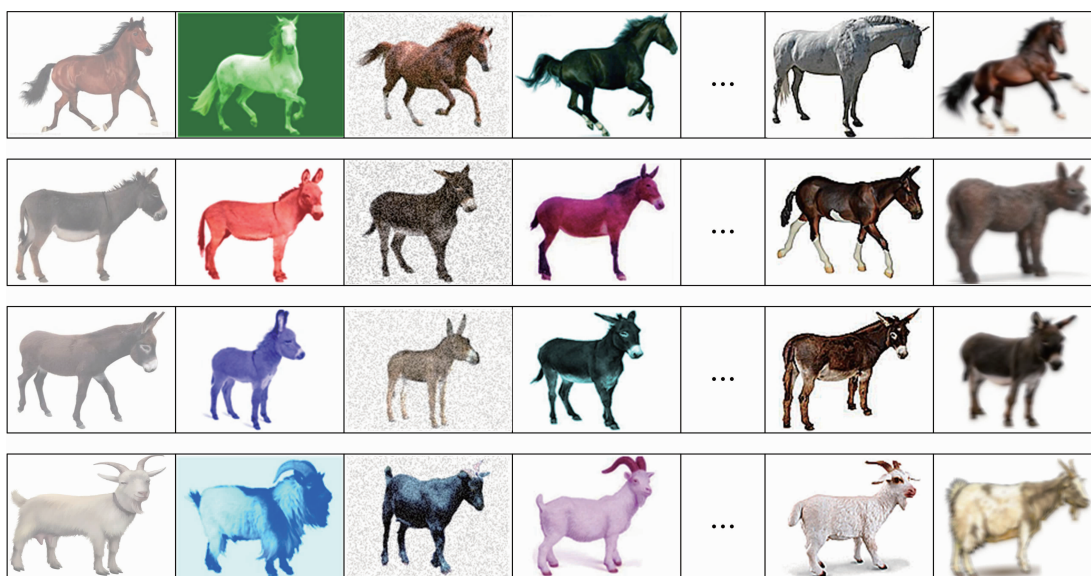


图 7 识别对象有损样本集

表 7 有损样本第三阶段对比实验结果

识别目标	识别结果								识别成功率 / %	
	ω_1		ω_2		ω_3		ω_4			
	BP-ANN	ISA-ANN	BP-ANN	ISA-ANN	BP-ANN	ISA-ANN	BP-ANN	ISA-ANN	BP-ANN	ISA-ANN
ω_1	428	498	32	1	15	0	25	1	85.6	99.6
ω_2	22	2	413	492	53	2	12	4	82.6	98.4
ω_3	3	1	29	1	435	498	33	0	87.0	99.6
ω_4	12	0	40	2	23	2	425	496	85.0	99.2

6 结论

(1) 针对信息加工过程中的若干关键环节,提出了一种基于 SA-ANN 的人脑认知机制建模方法。

(2) 对认知物理过程及其基本特征进行了分析,建立了面向认知过程的 SA-ANN 推理模型,并对其层次结构、功能模块组成及数据依赖关系进行了详细描述,并指出 KSRM 为模型的核心构件,需具备对知识学习、模式识别并行处理的能力,其算法的合理性与效率是决定模型有效性的关键所在。

(3) 基于所建立的 SA-ANN 认知推理模型,提出了一种可快速收敛的 ISA-ANN 处理算法,发现特征提取的最终目标就是在最小的向量范围内,利用最少维数的向量,得到能够满足实际识别要求的覆盖率,且具备足够的通用性。

(4) 设计了面向人脑认知的具体算例,设计开发了基于 SA-ANN 的认知计算原型软件系统。基于上述系统,针对认知过程中的信息特征提取、知识学习训练、实物模式识别等关键环节进行了对比研究。实验结果证明,该方法具有较好的聚类性能,可以针对具体测试对象进行准确识别,能够得到相对精确的心理认知演化规律。

(5) 后续的研究工作将围绕自主学习、创造性学习过程等方面的模拟研究展开。

参考文献

- [1] 席旭刚,左静,罗志增. 肌电模糊熵特征的加权核 FDA 跌倒识别[J]. 电子学报,2016,44(6):1376-1382.
XI Xu-gang, ZUO Jing, LUO Zhi-zeng. Weighted kernel FDA fall recognition of EMG fuzzy entropy[J]. Acta Electronica Sinica,2016,44(6):1376-1382. (in Chinese)
- [2] Tan D P, et al. SA-ANN-based slag carry-over detection method and the embedded WME platform [J]. IEEE Transactions on Industrial Electronics,2013,60(10):4702-4713.
- [3] 李凯,曹喆. 一种基于神经网络的广义熵模糊聚类算法[J]. 电子学报,2016,44(8):1881-1886.
LI Kai, CAO Zhe. A fuzzy clustering algorithm with generalized entropy based on neural network[J]. Acta Electronica Sinica,2016,44(8):1881-1886. (in Chinese)
- [4] Altmann G T M. Learning and development in neural networks-the importance of prior experience [J]. Cognition, 2002,85(2):B43-B50.
- [5] Hallner D, Hasenbring M. Classification of psychosocial risk factors (yellow flags) for the development of chronic low back and leg pain using artificial neural network[J]. Neuroscience Letters,2004,361(1-3):151-154.
- [6] Kaplan G B, et al. A composite neural network model for perseveration and distractibility in the Wisconsin card sorting test[J]. Neural Networks,2006,19(4):375-387.
- [7] Levine D S. Neural network modeling of emotion [J]. Physics of Life Reviews,2007,4(1):37-63.
- [8] Chartier S, Renaud P, Boukadoum M. A nonlinear dynamic artificial neural network model of memory [J]. New Ideas in Psychology,2008,26(2):252-277.
- [9] 江虹,等. 基于 RBF 神经网络的认知无线电认知引擎设计[J]. 系统仿真学报,2012,24(12):2489-2495.
JIANG Hong, et al. Design of cognitive engine based on radial basis function neural network in cognitive radio [J]. Journal of System Simulation,2012,24(12):2489-2495. (in Chinese)
- [10] Tsagkaris K, Katidiotis A, Demestichas P. Neural network-based learning schemes for cognitive radio systems [J]. Computer Communications,2008,31(14):3394-3404.
- [11] 汪玲玲,陈平,辛涛,等. 基于 BP 神经网络的认知诊断计算机自适应测验实现[J]. 北京师范大学学报(自然科学版),2015,51(2):206-211.
WANG Ling-ling, CHEN Ping, XIN Tao, et al. Realizing cognitive diagnostic computerized adaptive testing based on BP neural network [J]. Journal of Beijing Normal University (Natural Science),2015,51(2):206-211. (in Chinese)
- [12] Tan D P, et al. A WP-based nonlinear vibration sensing method for invisible liquid steel slag detection [J]. Sensors and Actuators B-Chemical,2014,202:1257-1269.
- [13] Quan G Z, Wen H R, Pan J, et al. Construction of processing maps based on expanded data by BP-ANN and identification of optimal deforming parameters for Ti-6Al-4V alloy [J]. International Journal of Precision Engineering and Manufacturing,2016,17(2):171-180.

作者简介



陈树婷 女,1981 生于山东莱芜. 现为杭州医学院基础医学部教师. 主要研究方向为人工智能、模式识别.
E-mail: shutinren@163.com



谭大鹏(通信作者) 男,1980 年生于山东淄博. 现为浙江工业大学教授、博士生导师. 主要研究方向为人工智能、数字信号处理.
E-mail: tandapeng@zjut.edu.cn