

doi:10.3969/j.issn.1673-4785.2011.03.006

# 一种多模块协同参与的神经网络

薄迎春,乔俊飞,杨刚

(北京工业大学电子信息与控制工程学院,北京100124)

**摘要:**针对单一神经网络训练时间长、对复杂问题处理精度较低、易陷入局部极小等问题,提出了一种多模块协同参与信息处理的神经网络。该神经网络具有层级结构,基于条件模糊聚类技术对样本进行分类,根据分类结果实现对神经网络的模块划分,采用代数算法对网络权值进行求解,基于距离测度设计了处理输入信息的子网络选择方法。为提高神经网络对复杂问题的逼近能力,选择数目不等的多个子网络参与给定输入的协同处理,采取“分而治之”与“集成学习”相结合方法以提高网络的性能。实验表明,对于复杂问题,这种多模块协同参与的神经网络可以有效地提高网络的逼近精度,训练时间也优于单一网络。

**关键词:**神经网络;条件模糊聚类;多模块;子网络选择

中图分类号:TP183 文献标识码:A 文章编号:1673-4785(2011)03-0225-06

## A multi-module cooperative neural network

BO Yingchun,QIAO Junfei,YANG Gang

(College of Electronic Information and Control Engineering,Beijing University of Technology,Beijing 100124,China)

**Abstract:** Aiming to solve the problems of long training time, low precision in processing complex problem, and a local minimum in single neural networks, a multi-module cooperative neural network(MMCNN) was proposed. Its structure has hierarchical character. Sample data was first detached by the fuzzy clustering method, and then the neural network was partitioned into several sub-nets based on the clustering results. The linking weights were elicited by solving equations. For a given input data, some multi-modules were selected to deal with it. The approximating performance was improved by combining divide-and-conquer and learning ensemble strategies. A sub-net selection method was designed based on distance measurements. Simulation results demonstrate that a multi-module cooperative neural network can heighten approximating ability effectively for complicated problems, and the training time is faster than in a single back-propagation neural network.

**Keywords:** neural networks; conditional fuzzy clustering method; multi-modules; sub-nets selection

生物医学和解剖学等学科的研究表明,生物神经网络具有模块化和层次化的特性”。借助此特性,人们开始从生物学的角度构建模块化神经网络,其实质是将整个神经网络按照某一规则划分为若干模块,通过将各子模块的信息进行合并获得神经网络总体输出。模块化神经网络采用“分而治之”的原理,简化了计算,成为解决复杂问题的一种有效方

法。1991年,Jacobs提出了模块化神经网络的概念。2001年,Pedrycz系统阐述了模块化神经网络的思想,并指出聚类技术是模块划分的一种有效方法。2005年,Darter等人将模块化神经网络用于车辆控制,整个网络分成了120个模块”。此后,许多学者对模块化神经网络的设计问题进行了研究,如2007年,Santos提出了一种基于信息熵聚类的模块划分方法;2009年,Park 将条件模糊聚类用于RBF 网络模块划分,实现了高维问题的降维处理9。

任务分解是模块化神经网络设计的核心思想,所以,上述设计方法均致力于模块划分的独立性,力

收稿日期:2010-04-07

基金项目:国家自然科学基金资助项目(60873043);北京市自然科学基金资助项目(4092010)。

通信作者:薄迎春,E-mail:boyingchun@sina.com.

求一个模块能够独立地处理一个子任务。首先,由于信息的模糊性,这种设计方法增加了模块划分的难度;其次,对于边界信息,单一的模块处理难度较大,会导致较大的边界误差。所以如何有效地进行子网络的划分仍然是模块化神经网络设计的难点<sup>[7]</sup>。

针对上述问题,本文提出了一种多模块协同参与信息处理的神经网络(multi-modules cooperative neural networks, MMCNN),该网络具有层级结构,每次信息处理都有一个或多个模块的参与,允许各模块在功能上有一定程度的交叠,降低了模块设计的难度。此外,输入信息由多个模块集成处理可以提高网络的精度。

## 1 神经网络的模块划分与设计

视觉系统的研究表明,视觉信息是按照视皮层简单细胞—复杂细胞—超复杂细胞—更高级的超复杂细胞的序列,由简单到复杂、由低级到高级分级处理的,复杂程度越高的细胞其数量越少<sup>[8]</sup>。这使得视觉系统具有自然的集成学习特性,而集成学习可以有效地提高神经网络的泛化能力和信息处理精度<sup>[8]</sup>。视觉信息特征抽取是由不同形式的感受野实现的,每个感受野只对局部信息敏感,同一形式的感受野映射范围存在交叠。视觉细胞每时每刻都存在生长和死亡,所以,参与信息处理的感受野数量也时刻发生变化。基于视觉系统的信息处理模式,构造了如图1所示的模块化神经网络的基本框架。

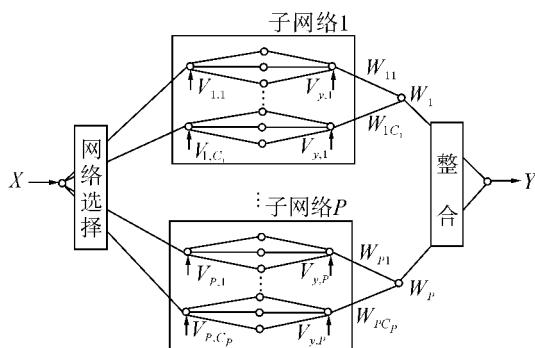


图1 MMCNN 网络结构  
Fig. 1 Structure of MMCNN

如图1所示,这种网络具有明显的层级结构。整个网络被分成了 $P$ 个子网络,每个子网络又被分为 $C_i$ 个亚子网络(相当于单个感受野)。通过后续2级神经元的整合获得网络的最终输出。值得注意的是,每个子网络内的亚子网络可能具有不同的特征,而不同子网络的亚子网络特征可能相似(如人的左眼和右眼均包含对同一特征敏感的感受野细胞,而同一只眼睛却包含了对颜色、形状、尺寸敏感的多种形

式的感受野)。对于某一输入信息,首先通过选择机制从不同的子网络中选择适合对其处理的亚子网络(可能有多个,并分布在不同的子网络中),从而使每个输入信息都有一个或多个亚子网络从不同的角度对其进行处理。

上述网络的设计过程主要包括子网络及亚子网络划分、网络选择及整合、网络学习3个部分。下面就MMCNN的详细设计过程进行系统阐述。

### 1.1 子网络划分

基于样本特征分类进行网络划分是模块化神经网络设计的常用方法<sup>[5,6]</sup>。条件模糊聚类方法<sup>[9]</sup>在样本特征提取时考虑了输出的影响,将目标值作为样本分类的指导,从而使分类更具有客观性。这里采用条件模糊技术进行子网络的划分。给定样本集 $\{(X_k, y_k), k=1, 2, \dots, N\}$ , $N$ 为样本个数,首先将目标值 $y_k$ 进行K-means聚类(分为 $P$ 类),其聚类中心分别为 $\{V_{y,2}, V_{y,3}, \dots, V_{y,P-1}\}$ ,令 $V_{y,1} = y_{\min}$ , $V_{y,P} = y_{\max}$ ,则共有 $P$ 个聚类中心。然后将目标集 $Y$ 按照式(1)构建 $P$ 个模糊集( $y_k$ 的隶属度曲线如图2所示),根据此结果将整个神经网络划分为 $P$ 个子网络。

$$f_{ik} = \begin{cases} \exp\left(\frac{-\|y_k - V_{y,i}\|^2}{\left(\frac{V_{y,i} - V_{y,i-1}}{2}\right)^2}\right), & y_k \leq V_{y,i}; \\ \exp\left(\frac{-\|y_k - V_{y,i}\|^2}{\left(\frac{V_{y,i+1} - V_{y,i}}{2}\right)^2}\right), & y_k > V_{y,i}. \end{cases} \quad (1)$$

式中: $f_{ik}$ 为样本 $y_k$ 对第 $i$ ( $i=1, 2, \dots, P$ )个模糊集的隶属度。

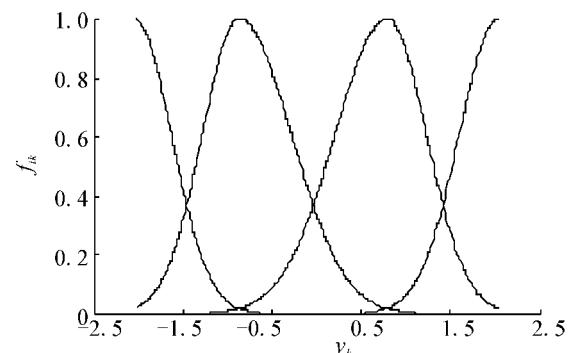


图2 目标值 $y_k$ 的模糊隶属函数  
Fig. 2 Membership degree of  $y_k$

对于每个目标模糊集,将输入 $X$ 按照式(2)、(3)进行模糊聚类<sup>[9]</sup>。

$$V_{ij} = \frac{\sum_{k=1}^N (u_{ijk})^a X_k}{\sum_{k=1}^N (u_{ijk})^a}, \quad (2)$$

$$u_{ijk} = \frac{f_{ik}}{\sum_{m=1}^{C_i} \left( \frac{\|X_k - V_j\|}{\|X_k - V_{im}\|} \right)^{\frac{2}{b-1}}}. \quad (3)$$

式中: $V_j$ 为第*i*( $i=1,2,\cdots,P$ )个目标模糊集对应的第*j*( $j=1,2,\cdots,C_i$ )个输入模糊集的聚类中心; $C_i$ 为第*i*个目标模糊集对应的输入模糊聚类个数; $a,b$ 为常数,通常 $a,b$ 取值都为 $2^{[9]}$ ;  $\mathbf{U} = [u_{ijk}]_{C_i \times N}$ 为第*i*个目标模糊集对应的输入模糊聚类的分割矩阵,满足:

$$\sum_{j=1}^{C_i} u_{ijk} = f_{ik}, u_{ijk} \in [0,1].$$

上述方法将整个输入样本集划分为 $C_T$ 个样本子集,其中 $C_T = \sum_{i=1}^P C_i$ 为每个样本子集构建一个亚子网络,则共有 $C_T$ 个亚子网络,共分为 $P$ 组(对应 $P$ 个子网络,用 $N_{ETi}$ 表示, $i=1,2,\cdots,P$ ),每个亚子网络(用 $N_{ETij}$ 表示, $j=1,2,\cdots,C_i$ )分别处理相应的样本集和输入.

## 1.2 子网络选择

子网络选择的实质是判断输入应该由哪些子网络处理.按照上述分类方法,样本集和子网络存在对应关系,所以,网络选择的首要工作是确定给定输入隶属于哪个子网络和亚子网络的可能性大.按照相近的输入产生相近输出的原理,若输入 $X_k$ 距离样本中心 $V_j$ 越近,则 $X_k$ 隶属于 $N_{ETij}$ 的可能性就越大,这里采用相对距离测度<sup>[10]</sup>对 $X_k$ 隶属于 $N_{ETij}$ 的可能性进行测算.令

$$J_i = \sum_j^{C_i} w_{ij} d_{ij}.$$

式中:

$$\begin{aligned} \sum_{j=1}^{C_i} w_{ij} &= 1, w_{ij} \in [0,1], \\ d_{ij} &= \|X_k - V_j\| / d_{a_{ij}}, \\ d_{a_{ij}} &= \frac{1}{N_{ij}} \sum_{m=1}^{N_{ij}} \|X_m - V_j\|. \end{aligned}$$

式中: $d_{a_{ij}}$ 为 $N_{ETij}$ 训练样本的平均距离; $d_{ij}$ 为输入 $X_k$ 对 $N_{ETij}$ 的相对距离测度; $N_{ij}$ 为 $N_{ETij}$ 的样本数; $w_{ij}$ 为 $X_k$ 对 $N_{ETij}$ 的隶属度.

令性能指标 $J_i$ 最小化,利用拉格朗日(Lagrangian)乘子法可以解出 $w_{ij}$ .

$$w_{ij} = \begin{cases} 1, & d_{ij} = 0; \\ \frac{\left(\frac{1}{d_{ij}}\right)}{\sum_{j=1}^{C_i} \left(\frac{1}{d_{ij}}\right)}, & d_{ij} \neq 0. \end{cases}$$

式中: $i=1,2,\cdots,P,j=1,2,\cdots,C_i$ .显然, $d_{ij}$ 越大, $w_{ij}$ 越小, $X_k$ 进入 $N_{ETij}$ 处理的可能性越小; $d_{ij}$ 越小, $w_{ij}$ 越

大, $X_k$ 进入 $N_{ETij}$ 处理的可能性越大.按照最大隶属度原则选取亚子网络,被选中的亚子网络记为 $N_{ETis}$ ,令 $w_{is}=1, w_{ij}=0, j \neq s$ .这样,对于每个子网络都会选出一个亚子网络用于处理 $X_k$ ,每个子网络的输出即为 $N_{ETis}$ 的输出.但是,这种选择只是一种初选,并不是所有的 $N_{ETis}$ ( $i=1,2,\cdots,P$ )都适合处理 $X_k$ ;所以,必须对不适合处理 $X_k$ 但被选中的亚子网络进行过滤,过滤方法与前述网络选择方法思想相同,方法具体如下.

对于选出的亚子网络构建性能指标函数.令

$$J = \sum_i^P w_i d_i.$$

式中:

$$\begin{aligned} \sum_{i=1}^P w_i &= 1, w_i \in [0,1], \\ d_i &= \|X_k - V_i\| / d_{a_i}, \\ d_{a_i} &= \frac{1}{N_i} \sum_{j=1}^{N_i} \|X_j - V_i\|. \end{aligned}$$

令性能指标 $J$ 最小化,利用拉格朗日乘子法可以解出 $w_i$ .

$$w_i = \begin{cases} 1, & d_i = 0; \\ \frac{\left(\frac{1}{d_i}\right)}{\sum_{i=1}^P \left(\frac{1}{d_i}\right)}, & d_i \neq 0. \end{cases}$$

式中: $d_{a_i}$ 为 $N_{ETis}$ 训练样本的平均距离; $d_i$ 为输入 $X_k$ 对 $N_{ETis}$ 的相对距离测度<sup>[10]</sup>; $N_i$ 为 $N_{ETis}$ 的样本数; $V_i$ 为 $N_{ETis}$ 的样本聚类中心; $w_i$ 为 $X_k$ 对 $N_{ETis}$ 的隶属度.由于每个子网络只有1个 $N_{ETis}$ 处理 $X_k$ , $w_i$ 实际上也是 $X_k$ 对 $N_{ETi}$ 的隶属度,并且考虑到样本的交叠特性;因此设置一隶属度阈值 $K$ ,满足 $w_i \geq K$ 的子网络对 $X_k$ 进行处理.通过上述的选择机制,对于给定输入 $X_k$ ,随 $X_k$ 分布位置的不同和 $K$ 的取值不同,将数量不定的子网络参与 $X_k$ 的处理.

## 1.3 子网络整合

对于输入 $X_k$ ,令 $\mathbf{w} = (w_1, w_2, \dots, w_P)$ ,若 $w_i < K$ ,令 $w_i = 0$ ( $i=1,2,\cdots,P$ ),然后对 $\mathbf{w}$ 进行归一化处理.设网络总输出为 $Y$ ,则

$$Y = \sum_{i=1}^c w_i y_i.$$

式中: $y_i$ 为 $N_{ETi}$ 对 $X_k$ 的输出, $w_i$ 为 $N_{ETi}$ 的权值( $\mathbf{w}$ 进行归一化处理后的第*i*个分量).对于没有被选中的子网络,其权值 $w_i=0$ ,即未被选中的子网络对总输出无贡献,总输出为被选中的子网络输出的加权和.

## 2 网络学习

在整个网络中,每个子网络由多个亚子网并联

而成,每一个亚子网均采用多层感知器结构,所以仅以  $N_{ETij}$  为例来说明子网络学习过程。此外,由于每个  $N_{ETij}$  结构简单,因此这里采用代数算法对权值进行求解。 $N_{ETij}$  的输入为  $X_{ij,k} - V_{ij}$ , 其中  $X_{ij,k} \in X_{ij}$ ,  $X_{ij}$  为  $N_{ETij}$  对应的样本子集,  $k = 1, 2, \dots, N_{ij}$ ,  $N_{ij}$  为  $N_{ETij}$  对应的样本子集样本个数。训练目标为:

$$\min \sum_{k=1}^{N_{ij}} \| (y_{ij,k} - V_{ij,i}) - N_{ETij}(X_{ij,k} - V_{ij}) \| ,$$

$$N_{ETij}(X_{ij,k} - V_{ij}) = \sum_{m=1}^{M_{ij}} w_{ij,m} g_{m,k}. \quad (4)$$

式中:  $g_{m,k}$  为第  $m$  个隐层节点对输入样本  $X_{ij,k}$  的输出;  $M_{ij}$  为  $N_{ETij}$  隐层节点的个数;  $w_{ij,m}$  为  $N_{ETij}$  的第  $m$  个隐节点与输出节点的连接权值。显然当式(4)中所有项均为 0 时,式(4)才达到最小,于是有:

$$\begin{cases} w_{ij,1}g_{1,1} + w_{ij,2}g_{2,1} + \dots + w_{ij,M_{ij}}g_{M_{ij},1} = y_{ij,1} - V_{ij,i}; \\ w_{ij,1}g_{1,2} + w_{ij,2}g_{2,2} + \dots + w_{ij,M_{ij}}g_{M_{ij},2} = y_{ij,2} - V_{ij,i}; \\ \vdots \\ w_{ij,1}g_{1,N_{ij}} + w_{ij,2}g_{2,N_{ij}} + \dots + w_{ij,M_{ij}}g_{M_{ij},N_{ij}} = y_{ij,N_{ij}} - V_{ij,i}. \end{cases}$$

令

$$\mathbf{H}_{ij} = \begin{bmatrix} g_{1,1} & g_{2,1} & \cdots & g_{M_{ij},1} \\ g_{1,2} & g_{2,2} & \cdots & g_{M_{ij},2} \\ \vdots & \vdots & \vdots & \vdots \\ g_{1,N_{ij}} & g_{2,N_{ij}} & \cdots & g_{M_{ij},N_{ij}} \end{bmatrix},$$

$$\mathbf{W}_{ij} = \begin{bmatrix} w_{ij,1} \\ w_{ij,2} \\ \vdots \\ w_{ij,M_{ij}} \end{bmatrix}.$$

则

$$\mathbf{H}_{ij} \mathbf{W}_{ij} = \mathbf{T}_{ij},$$

于是

$$\mathbf{W}_{ij} = (\mathbf{H}_{ij})^{-1} \mathbf{T}_{ij}.$$

式中:  $\mathbf{W}_{ij}$  为  $N_{ETij}$  的隐层与输出连接权向量;  $(\mathbf{H}_{ij})^{-1}$  是  $\mathbf{H}_{ij}$  的 Moore\_Penrose 逆, 上述推导过程没有涉及输入与隐层之间的连接权值; 所以, 输入与隐层之间的连接权值可以随机给定, 即此求解方法只需要学习隐层输出连接权值矩阵即可。

### 3 仿真实验

为验证网络的逼近能力, 选取文献[11]的实验函数, 该函数常被用于网络逼近能力测试, 函数形式如下:

$$z = 1.9(1.35 + e^{x-y} \sin(13x - 0.6)^2 e^{-y} \sin(7y)).$$

式中:  $x, y \in [0, 1]$ 。仿真过程中, 取  $P=4$ ,  $C = \{3, 4, 4, 1\}$  为每个子网络的亚子网个数,  $K = 0.1$ , 每个亚

子网的节点数均取为 7。仿真结果如图 3~5 所示, 其中图 3 为样本曲面, 图 4 为 MMCNN 拟合曲面, 图 5 为拟合误差曲面。函数拟合均方误差为  $7.9750 \times 10^{-4}$ , 尺度最小方差 (scaled least squares error, SLSE)<sup>[11]</sup> 为  $8.03 \times 10^{-3}$ , 而文献[11] 网络的 SLSE 为 0.017, 因此 MMCNN 网络具有较强的逼近能力。

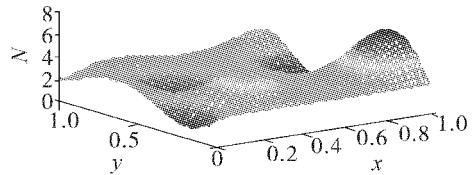


图 3 样本曲面

Fig. 3 Curved surface of sample data

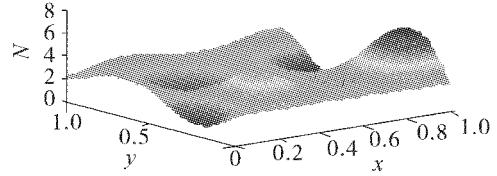


图 4 MMCNN 拟合曲面

Fig. 4 Approximating curved surface of MMCNN

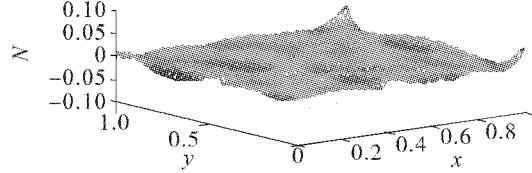


图 5 拟合误差曲面

Fig. 5 Approximating error curved surface

为进一步研究 MMCNN 的逼近能力与训练时间, 选取函数  $z = \sin(\alpha x) + \sin(\alpha y)$  进行测试(该函数随  $\alpha$  趋向  $\infty$ , 函数复杂度也趋向  $\infty$ , 所以文献[11-12]将此三角函数作为网络性能测试函数)。MMCNN 与其他网络的比较结果如表 1 所示, 表 1 中  $t_1$ 、 $t_2$ 、 $t_3$  分别为 MMCNN、单一 BP 网络和 RBF 网络的训练时间。由表 1 可见, MMCNN 的训练时间较单一的 BP 网络及 RBF 网络有明显改善, 这是由于 MMCNN 的训练采用代数算法, 其训练时间只是解  $C_T$  个方程组的时间。随着函数复杂度的提高, MMCNN 的亚子网个数也随之增加(由于所有测试函数目标值范围均为  $[-2, 2]$ , 所以在所有测试中  $P=4$  不变), 但每个亚子网的隐层节点只做了较小的调整。即使对于很复杂的函数, 通过 MMCNN 亚子网个数的调整(如表 2), 也可以使网络有较强的逼近能力。当函数复杂度不高时, 3 种网络的测试均方差相当, 可通过增加隐层节点数来提高 BP 网络的逼近精度。但当函数复杂度较高时( $\alpha$  为  $16\pi$  或  $32\pi$ ), MMCNN 的测试均方差明显小于 BP 和 RBF 网络,

尤其是 $\alpha$ 增加到 $32\pi$ 时,由于BP网络和RBF可调参数过多,基于误差反向传播的梯度下降算法已经很难学习到较优的参数,BP网络及RBF网络的训练时间大幅增加,泛化能力也急剧降低,已不能通过增加隐层节点数的方法提高其逼近能力.相比之下,

MMCNN由于每个亚子网络保持了简单的结构,并在学习中采用了代数直接求解权值的方法,避免了局部极小的风险,训练时间也大大减少.从表1可以看出,对于复杂问题,MMCNN的逼近能力优于单一BP网络及RBF网络.

表1 MMCNN与BP网络的性能比较

Table 1 Performance comparison of BP network and MMCNN

$\alpha$	测试均方差 $\varepsilon_{MSE}/10^4$			训练时间/s		
	MMCNN	BP	RBF	$t_1$	$t_2$	$t_3$
$2\pi$	6.79	7.13	6.13	1.2	17.4	2.0
$4\pi$	7.06	7.27	6.98	3.5	45.1	6.0
$8\pi$	7.10	9.35	8.21	6.7	540.1	232.3
$16\pi$	9.62	99.50	24.80	10.1	1 620.0	789.6
$32\pi$	2.61	2 448.00	322.00	28.2	2 160.0	1 867.0

表2 MMCNN与BP网络的参数

Table 2 Parameters of BP network and MMCNN

$\alpha$	隐层节点个数 $n$			$P$	$C$	$K$
	MMCNN	BP	RBF			
$2\pi$	6	15	6	4	{1,2,2,1}	0.20
$4\pi$	6	40	15	4	{4,4,4,4}	0.15
$8\pi$	8	65	20	4	{8,8,8,8}	0.10
$16\pi$	10	95	56	4	{16,16,16,16}	0.10
$32\pi$	10	100 *	7	4	{32,32,32,32}	0.10

MMCNN的每个亚子网络都有较为简单的结构,虽然函数复杂时,亚子网络较;但对于任一输入信息,只有少数几个亚子网络参与计算,所以计算复杂度并不会提高.为简单起见,仿真过程中亚子网络的隐层节点数相同,这必然会存在冗余的隐层神经元,针对这个问题可以采用适当的修剪算法<sup>[13]</sup>剔除冗余神经元.

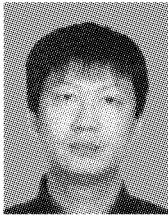
#### 4 结束语

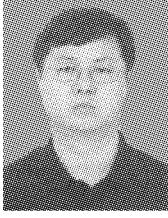
MMCNN网络从生物视觉信息处理角度出发,模块划分的过程中同时考虑每个子网络的独立性和功能交叠,借鉴了集成学习的思想,根据输入信息的特征采取多模块协同参与信息处理,任务分解与集成处理并存更符合生物认知的思想.这种方式使复杂任务的分解难度降低,实验表明,对于复杂问题,该网络在逼近能力上有所提高,此外,采用代数方法求解权值,极大地减小了训练时间.但是,相比单一网络,MMCNN网络需要确定的参数较多(如子网、亚子网个数、每个亚子网的节点数以及阈值  $K$  等),

这些参数都在不同程度上影响系统的性能,如何根据样本特征自动选择合理的参数是一个值得研究的问题.

#### 参考文献:

- [1] GARPENTER G A. Large-scale neural systems for vision and cognition[C]//Proceedings of International Joint Conference on Neural Networks. Boston, USA, 2009: 14-19.
- [2] JACOBS R A, JORDAN M I. A modular connectionist architecture for learning piecewise control strategies[C]//Proceedings of the American Control Conference. Boston, USA, 1991: 343-351.
- [3] PEDRYCZ W, VUKVICH G. Granular neural networks [J]. Neurocomputing, 2001(36): 205-224.
- [4] DATER M A, GORDON V S. Vehicle steering control using modular neural networks [C]//IEEE International Conference on Information Reuse and Integration. Las Vegas, USA, 2005: 374-379.
- [5] SANTOS J M, ALEXANDRE L A, De SA J M. Modular neural network task decomposition via entropic clustering

- [C]//Proceedings of the Sixth International Conference on Intelligent Systems Design and Applications. Porto, Portugal, 2006: 1-6.
- [6] PARK H S, PEDRYCZ W. Granular neural networks and their development through context-based clustering and adjustable dimensionality of receptive fields[J]. IEEE Transactions on Neural Networks, 2009, 20(10): 1604-1616.
- [7] CIMINO M G C A, PEDRYCZ W, LAZZERINI B, et al. Using multilayer perceptrons as receptive fields in the design of neural networks[J]. Neurocomputing, 2009, 72(10/11/12): 2536-2548.
- [8] GOH H L, LIM J H, QUEK C. Learning from an ensemble of receptive fields[C]//Proceedings of the 8th IEEE International Conference on Cognitive Informatics (ICCI). Hong Kong, China, 2009: 86-93.
- [9] PEDRYCZ W. Conditional fuzzy clustering in the design of radial basis function neural networks [J]. IEEE Transactions on Neural Networks, 1998, 4(9): 601-612.
- [10] 王攀, 李幼凤, 范衡, 等. 模块化神经网络子网的动态集成方法学研究[J]. 系统工程与电子技术, 2008, 30(6): 1143-1147.  
WANG Pan, LI Youfeng, FAN Zhun, et al. Methodological research for dynamic integration of modular neural network's sub-networks[J]. Systems Engineering and Electronics, 2008, 30(6): 1143-1147.
- [11] WANG Shuning, HUANG Xiaolin, JUNAID K M. Configuration of continuous piecewise-linear neural networks[J]. IEEE Transactions on Neural Networks, 2008, 19(8): 1431-1444.
- [12] WEDGE D, INGRAM D, MCLEAN D, et al. On global-local artificial neural networks for function approximation [J]. IEEE Transactions on Neural Networks, 2006, 17(4): 942-952.
- [13] 乔俊飞, 张颖. 一种多层前馈神经网络的快速修剪算法 [J]. 智能系统学报, 2008, 3(2): 173-176.  
QIAO Junfei, ZHANG Ying. Fast unit pruning algorithm for multilayer feedforward network design [J]. CAAI Transactions on Intelligent Systems, 2008, 3(2): 173-176.
- 作者简介:**
- 

薄迎春,男,1977年生,博士研究生,讲师,主要研究方向为神经计算与智能优化控制.
- 

乔俊飞,男,1968年生,教授,博士生导师,博士,中国人工智能学会理事、科普工作委员会秘书长,中国自动化学会智能专业委员会委员,北京自动化学会常务理事,北京人工智能学会理事、秘书长.主要研究方向为复杂过程建模与控制、神经计算与智能优化控制.主持多项国家“863”计划项目,发表学术论文多篇,被SCI、EI检索50余篇.
- 

杨刚,男,1983年生,博士研究生,主要研究方向为神经计算与智能优化控制.