

反馈集成网络的动力学分析及其应用¹⁾

汪力新 戴汝为

(中国科学院自动化研究所 北京 100080)

摘要 如何由样本的特征描述得到相应的类别属性,是模式识别的主要研究内容。由控制论的观点,它是一个黑箱层次。受控制系统启发,文中提出了反馈集成网络模型,使模式识别系统成为闭环结构,并详细讨论了它的动力学性质,给出系统绝对稳定的充分条件以及相应的学习算法。在自由手写数字样本库上的实验表明,所提模型与普通前向型神经网络相比,具有较好的判别性能。

关键词 综合集成,有教师学习,动力学系统。

1 引言

80年代末,著名科学家钱学森提出从定性到定量的综合集成法(metasyntesis)^[1],其核心思想是人与计算机两者的结合,充分发挥人的“心智”(human mind)与计算机高性能信息处理的作用。综合集成法的构思已在模式识别的研究中产生较大影响^[2]。

另一方面,人们研究模式识别,不仅是为了使计算机更好地帮助我们完成某些任务,而且希望从中得到启示,以了解人类为什么会有这些能力。可以说,模式识别的研究与人类探索自身的过程不断相互促进。Zadeh^[3]曾指出,正如人类所作的模式识别可看成一种黑箱式的映射,基于计算机的模式识别系统也是一个映射。它由三个层次组成,首末两端分别是对象的特征描述与类别属性,至于如何把特征影射到类别以便计算机作出判断,则由中间环节来实现。与人类不一样,基于计算机的模式识别要求我们给出黑箱式映射的明确表示。因此,寻找通用的方法来确定这个映射,一直是模式识别的重要任务。在神经网络复兴前,人们主要通过统计模式识别或是结构模式识别来发现识别的规则,而这些方法,往往容易受到外界因素的干扰。BP算法的提出,给模式识别添加了新的有效手段。

但是,人们在利用人工神经网络解决有关问题的过程中,发现它存在着两大缺陷,一个是学习速度慢,另一个是泛化能力欠佳。前者可通过选择适当的算法来补救,后者则是模式识别的共有问题。它由学习的局限性所致,虽说通过大规模的样本学习能使它有所改善,效果却又未必明显。如何在适当的学习规模之下,大幅度提高分类器的泛化能力,已成为模式识别的研究方向之一。

如果把单分类器看作一个专家,是否能获得一些启发?在人类社会中,为了提高决策的准确性,往往由若干专家组成专家组,形成集体意见。显然,我们也可以把多个单分类器放在一起,对它们的判别结果进行集成。首先使用的方法是投票法^[4],但它的集成模型缺

1) 国家自然科学基金及攀登计划资助课题。

收稿日期 1998-01-20

乏再学习的阶段,优势得不到充分发挥。而若把集成层次看作“黑箱”,人工神经网络自然是有效的手段^[5]。

以上由不同方法实现的映射,本质上都是静态的。与模式识别相仿,控制论也有“黑箱”的概念,但其具体形式可以是开环或是闭环的结构。根据控制系统理论^[6],带反馈的系统一般比开环系统的性能好。能否把闭环引入模式识别,从而提高判别的准确度?显然,在模式识别的已有方法中,人工神经网络提供了引入反馈的可能性,并且存在相应的迭代网络模型。在利用这些模型之前,还应该考虑模型的物理含义。迭代网络的反馈,一般是不同层次间的反馈或是自反馈,反馈的信息首先与其它类型的信息线性求和。当它们用来解决模式识别问题时,通常反馈的是样本的类别属性,与其它信息具有不同的物理意义。因此,模型的合理性还需要解决。

另一方面,反馈的引入使识别系统不再是静态映射,而是一个在识别和泛化方面均会有所提高的非线性动力学系统。为了能应用在模式识别里,它最好是渐进稳定的结构,也就是说,对每一给定的输入,系统将能确定对应的稳定输出。所以,在具体应用前,首先要解决两个问题。第一,什么条件才可避免系统产生振荡或混沌现象,且该条件又易于验证;第二,如何使实际输出与期望值充分接近。前者是网络的动力学性质,后者是它的学习算法。

本文提出的反馈集成网络系统是一类连续状态、离散时间的模型,这里将从迭代方程入手,直接分析它的性质,而不采用 Lyapunov 的能量函数法。根据绝对渐近稳定的定义^[7],对常用的三个向量范数分别得到对应的充分条件。由此,相应的学习算法属受约束的优化过程。本文将简要介绍其具体形式,详细请参看文献[8]。在单分类器与集成两个环节的学习中,反馈集成网络充分发挥了监督学习的优势,体现了人的指导作用。同时,根据控制系统引入的反馈,使它成为真正意义上的系统,其性能应有较大的提高。我们将用有关的实验结果验证这些结论的正确性。

2 基于反馈的集成网络系统

正如引言所述,从控制系统的观点来看,反馈环节的引入虽能改善系统的性能,但却

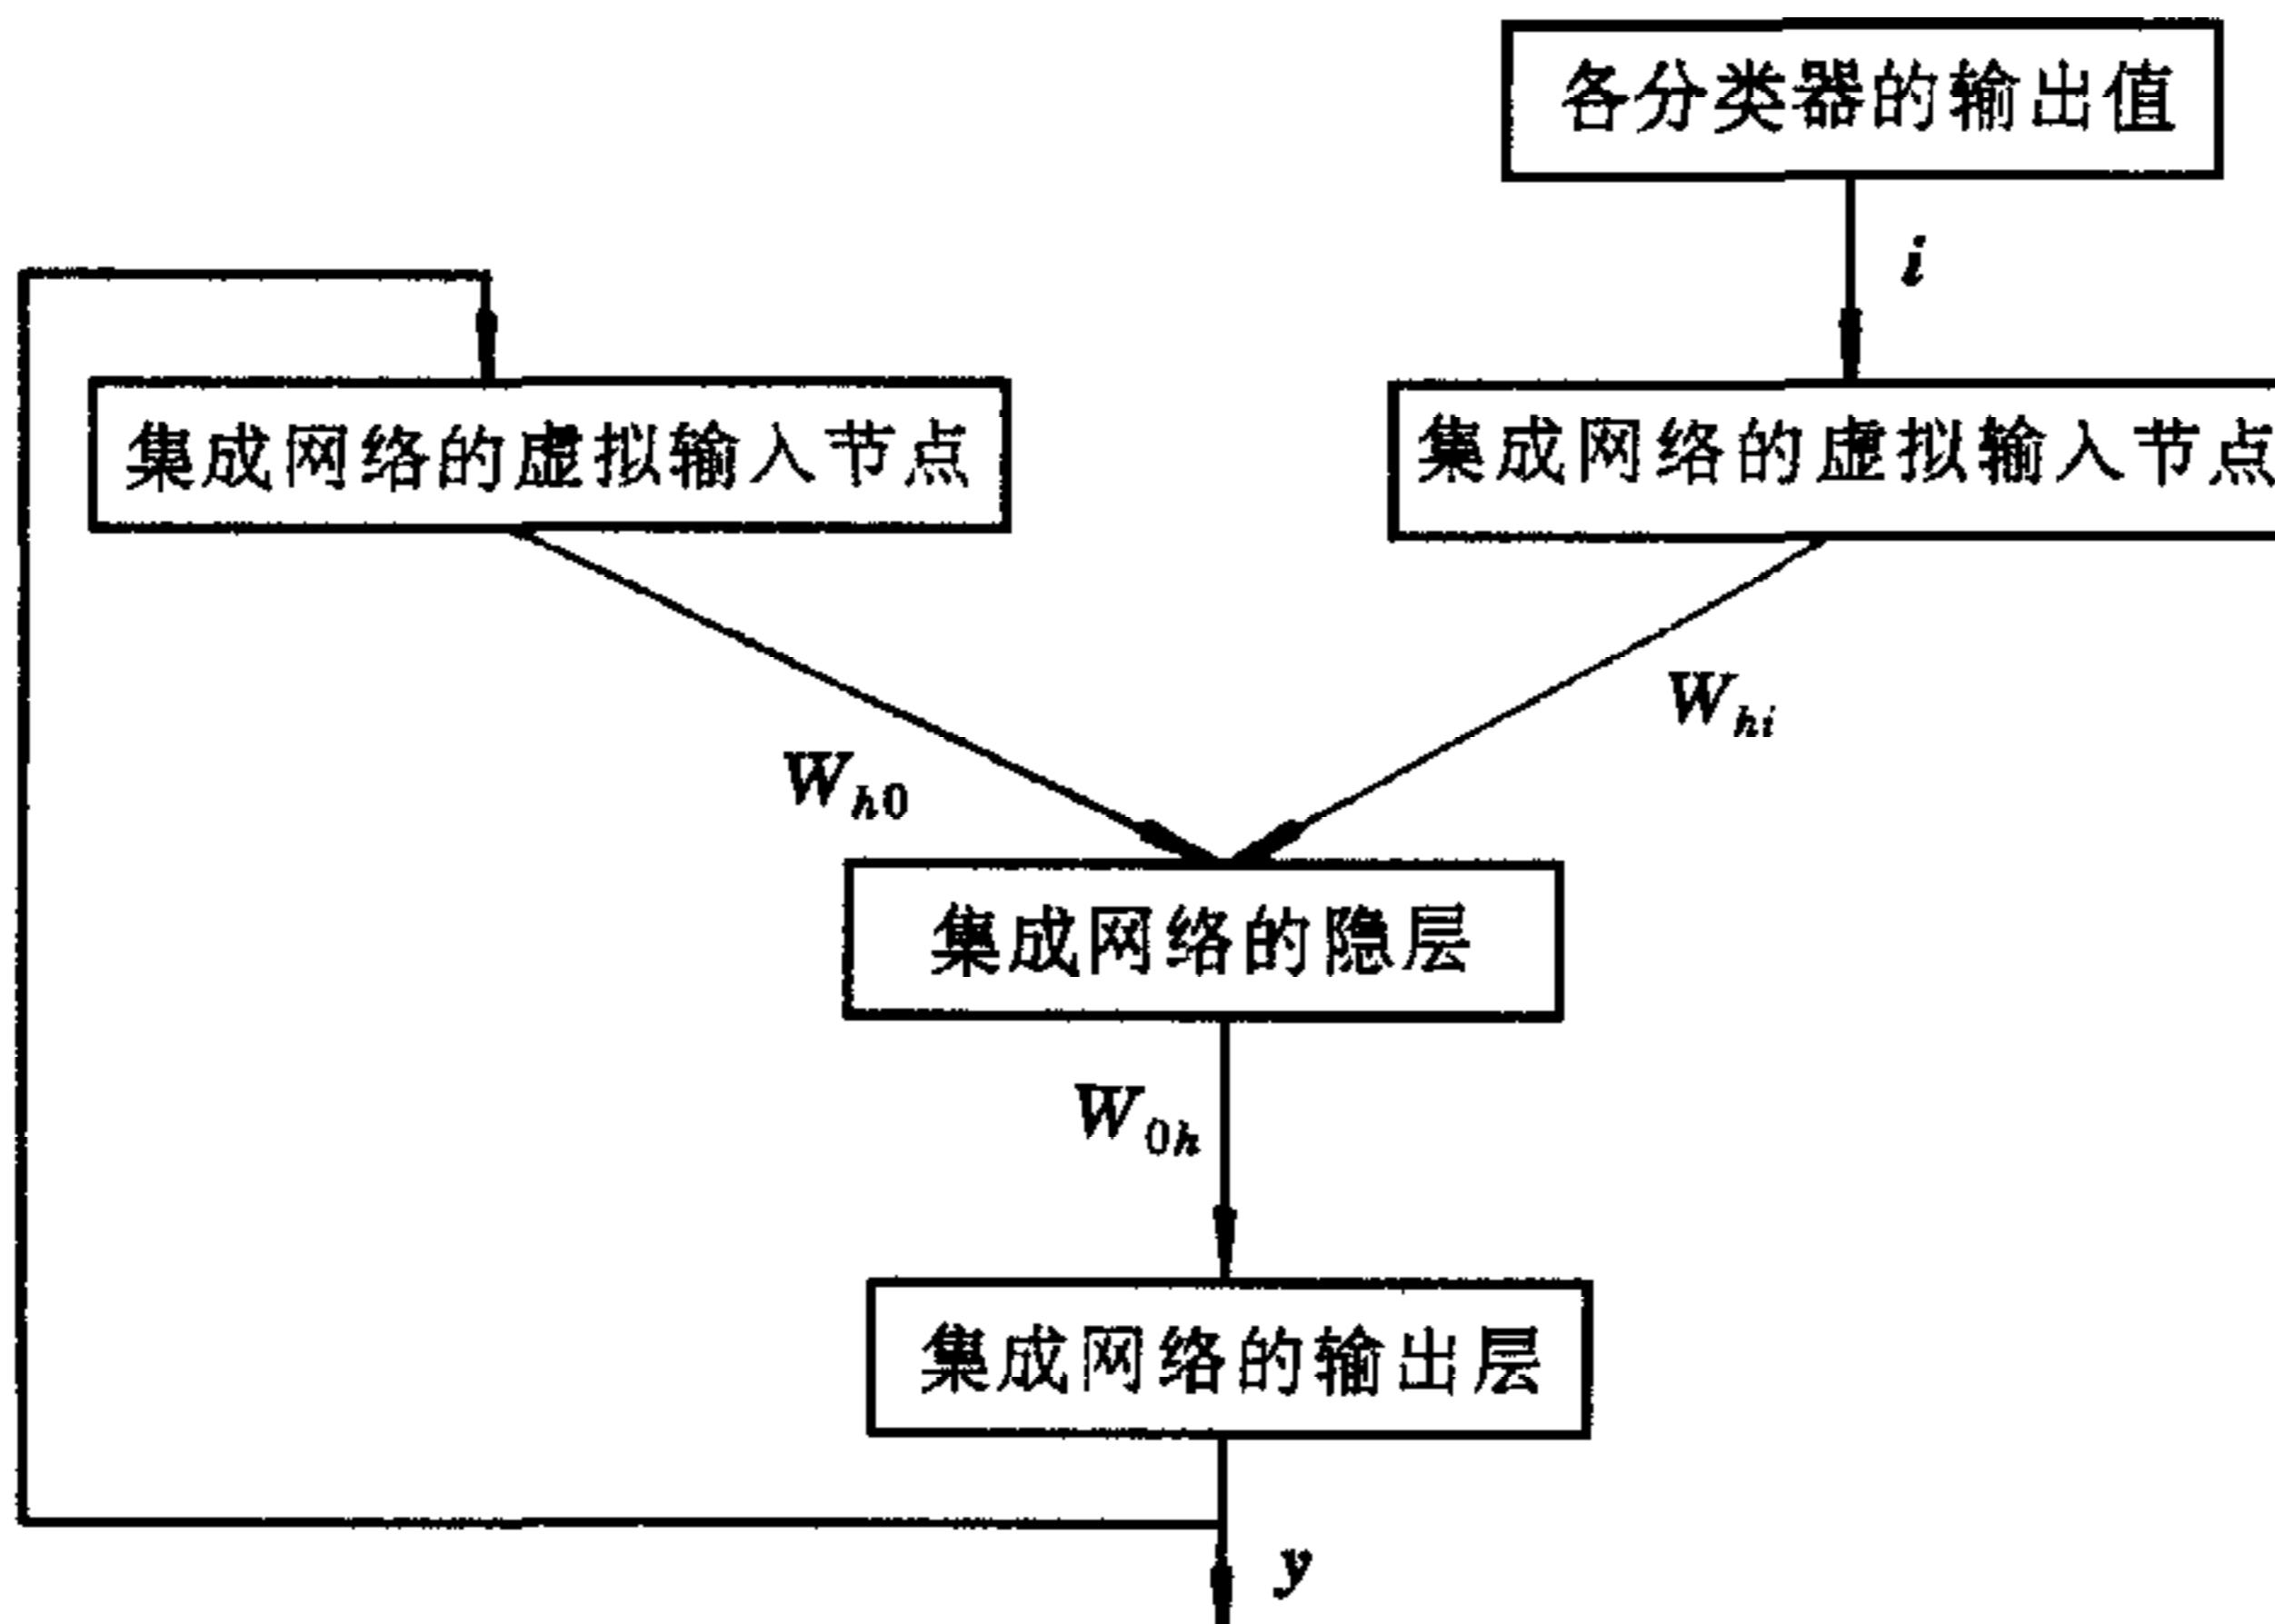


图 1 反馈集成网络模型的结构图

存在模型合理性的问题.因此,我们在网络集成的基础上,提出相应的反馈模型如图1所示,图中的 W_{hi} 、 W_{oh} 、 W_{ho} 分别是输入层到隐层、隐层到输出层及输出层反馈的连接矩阵.我们在集成网络的输入层加入一些虚拟的节点,它们分别对应输出层的节点,而虚拟输入节点与隐层的连接矩阵是相应的反馈连接矩阵 W_{ho} .每一次迭代时,虚拟输入节点的值为上次迭代对应输出节点的值.细心的读者或许会认为,这里所提的基于反馈的网络集成模型只是普通Jordan迭代网络.为什么说它具有明显的物理含义?原因在于,当我们对若干单分类器的判别结果进行集成时,集成网络的输入值均为样本的类别属性,而相应输出也是样本的属性,它们是相同的物理量,具有可加性.因此,与一般的反馈模型相比,具有反馈的集成网络模型更为合理.

3 反馈集成网络的稳定性分析

这里将详细讨论反馈集成网络的稳定性条件.前面已给出它的结构图,相应迭代方程是

$$\begin{cases} \mathbf{y}(k+1) = f(W_{oh} \cdot g(W_{ho} \cdot \mathbf{y}(k) + W_{hi} \cdot \mathbf{i})), k \geq 0, \\ \mathbf{y}(0) = \mathbf{y}, \end{cases} \quad (1)$$

其中 \mathbf{y} 是输出层的任意初始值,一般取零向量.我们把它看作一个动力系统,目的是了解它的运动状态.由于它属离散时间的神经系统,也就是说,要知道当 k 趋于无穷时,输出 \mathbf{y}_k 的终极状态.

根据Matsuoka K提出的分类标准^[9],反馈集成网络属于样本作为恒定输入的一类.一般说来,即使迭代方程(1)含渐近稳定的固定点,它们不但依赖于神经系统的结构(激活函数,连接矩阵等)和输入样本,而且与输出层的初始值 \mathbf{y}_0 有关.然而,模式识别的任务要求最终的输出独立于初始值 \mathbf{y}_0 .也就是说,我们设计的反馈型多层网络,其终极输出只由网络的结构和给定的输入样本决定.这一性质称为绝对稳定性.

定义1^[7]. 如果任意给定输入样本,反馈集成网络(1)都对应唯一渐近稳定的固定点,则称它是绝对稳定的.

对 $n \times m$ 函数矩阵 $C = (c_{ij}(\mathbf{x}))_{ij}$ 定义两个算子

$$R\max(C) = \max_{x \in \mathcal{R}^s} (\sum_{i=1}^m |c_{il}(\mathbf{x})|), \quad C\max(C) = \max_{x \in \mathcal{R}^s} (\sum_{j=1}^n |c_{lj}(\mathbf{x})|),$$

其中函数矩阵的各元素都是有界函数(这一假设在以下讨论将不再特别声明).由这两个算子分别找出 C 行、列绝对值和的最大值.当函数矩阵的各元素都是常量时,它们简记为 R_{\max} 和 C_{\max} .

引理1. 设 H, C, D 分别是 $n \times l, n \times m, m \times l$ 函数矩阵,且 $H = CD$,其中 $H = (h_{ij}(\mathbf{x}))$, $C = (c_{it}(\mathbf{x}))$, $D = (d_{tj}(\mathbf{x}))$.给定 \mathbf{x}_{ij} ,记 $H_{\text{const}} = (h_{ij}(\mathbf{x}_{ij}))$,则

$$R\max(H_{\text{const}}) = R\max((h_{ij}(\mathbf{x}_{ij}))) \leq R\max(H) \leq R\max(C)R\max(D), \quad (2)$$

$$C\max(H_{\text{const}}) = C\max((h_{ij}(\mathbf{x}_{ij}))) \leq C\max(H) \leq C\max(C)C\max(D). \quad (3)$$

证明略.

定义 $d_1 = \max_{i=1, \dots, N} \{f'_{i,i}\} < \infty$, $d_2 = \max_{j=1, \dots, L} \{g'_{j,j}\} < \infty$.关于反馈集成网络的绝对稳定性,

有以下定理.

定理 1. 反馈集成网络(1)是绝对稳定的,当它满足下面不等式中的一个:

1) 对向量范数 $\|\cdot\|_\infty$,

$$d_1 d_2 R \max(W_{oh}) R \max(W_{ho}) < 1; \quad (4)$$

2) 对向量范数 $\|\cdot\|_1$,

$$d_1 d_2 C \max(W_{oh}) C \max(W_{ho}) < 1; \quad (5)$$

3) 对向量范数 $\|\cdot\|_2$,

$$d_1^2 d_2^2 R \max(W_{oh}) C \max(W_{oh}) R \max(W_{ho}) C \max(W_{ho}) < 1. \quad (6)$$

证明. 令 $Ty = f(W_{oh} \cdot g(W_{ho} \cdot y + W_{hi} \cdot i))$. T 是 \mathcal{R}^N 到 \mathcal{R}^N 的映射. 任给输入样本 i , 对 $\forall x, y \in \mathcal{R}^N$, 根据微分中值定理, 有

$$\begin{aligned} Tx - Ty &= \left(\frac{\partial T}{\partial y}\right)_{\text{const}} \cdot (x - y) = \\ &(\text{diag}(f_1, \dots, f_N) \cdot W_{oh} \cdot \text{diag}(g_1, \dots, g_L) \cdot W_{ho})_{\text{const}} \cdot (x - y), \end{aligned} \quad (7)$$

其中 $\left(\frac{\partial T}{\partial y}\right)_{\text{const}} = \left(\frac{\partial T_i}{\partial y_i} \Big|_{x_1, \dots, x_{j-1}, y_j + \theta_{ij}(x_j - y_j), y_{j+1}, \dots, y_N}\right)_{ij} \quad (0 \leq \theta_{ij} \leq 1)$.

若向量范数为 $\|\cdot\|_\infty$,

$$\|Tx - Ty\|_\infty \leq R \max\left(\left(\frac{\partial T}{\partial y}\right)_{\text{const}}\right) \|x - y\|_\infty. \quad (8)$$

$$\begin{aligned} \text{由引理 1, } R \max\left(\left(\frac{\partial T}{\partial y}\right)_{\text{const}}\right) &\leq R \max_{x \in \mathcal{R}^N} \left(\frac{\partial T}{\partial y}\right) \leq \\ &R \max_{x \in \mathcal{R}^N} (\text{diag}(f_1, \dots, f_N) \cdot W_{oh} \cdot \text{diag}(g_1, \dots, g_L) \cdot W_{ho}) \leq \\ &R \max_{x \in \mathcal{R}^N} (\text{diag}(f_1, \dots, f_N)) R \max(W_{oh}) R \max_{x \in \mathcal{R}^N} (\text{diag}(g_1, \dots, g_L)) R \max(W_{ho}) \leq \\ &d_1 d_2 R \max(W_{oh}) R \max(W_{ho}). \end{aligned} \quad (9)$$

$$\text{所以 } \|Tx - Ty\|_\infty \leq d_1 d_2 R \max(W_{oh}) R \max(W_{ho}) \|x - y\|_\infty. \quad (10)$$

对于向量范数为 2) 和 3) 的情形同理可得, 其中不等式(6)用到 Gershgorin 定理^[11].

由压缩映像定理, 当这三个不等式之一满足时, 映射 T 是相应向量范数的一个压缩映像. 从而对给定的输入样本, 系统存在唯一的全局稳定的固定点. 相应反馈集成网络(1)是绝对稳定的. 证毕.

定理 1 给出反馈集成网络绝对稳定的充分条件. 表面上, 绝对稳定性与向量范数有关, 然而并非如此. 由有限维空间范数的等价性可知, 若在某向量范数下系统是绝对稳定的, 那么对其他范数, 它仍是绝对稳定. 因此, 稳定性独立于所选范数. 另一方面, 当满足三个不等式中的一个时, 网络的最后输出由它的内部结构和输入决定. 若连接矩阵和激活函数已调整好, 输出将是输入的函数. 自然会问, 二者有何联系? 定理 2 将回答这个问题.

为讨论方便, 记映射 $T(y)$ 为 $T(y, i)$.

定理 2. 如果定理 1 的条件之一被满足, 反馈集成网络(1)的最后输出连续依赖于输入样本.

证明. 我们只证明范数 $\|\cdot\|_\infty$ 的情形. 其他同理可证.

记 $\rho_1 = d_1 d_2 R \max(W_{oh}) R \max(W_{ho})$, $\rho_2 = d_1 d_2 R \max(W_{oh}) R \max(W_{hi})$. 由定理 1, 当 $\rho_1 < 1$, 反馈集成网络(1)是绝对稳定的, 即对任一输入, 存在唯一的全局稳定固定点.

任取输入 $\mathbf{i}_1, \mathbf{i}_2, \mathbf{y}_1^f, \mathbf{y}_2^f$ 为对应的固定点. 由于 $\mathbf{y}_1^f = \mathbf{T}(\mathbf{y}_1^f, \mathbf{i}_1), \mathbf{y}_2^f = \mathbf{T}(\mathbf{y}_2^f, \mathbf{i}_2)$. 所以

$$\begin{aligned}\|\mathbf{y}_1^f - \mathbf{y}_2^f\|_\infty &= \|\mathbf{T}(\mathbf{y}_1^f, \mathbf{i}_1) - \mathbf{T}(\mathbf{y}_2^f, \mathbf{i}_2)\|_\infty \leq \\ &\quad \|\mathbf{T}(\mathbf{y}_1^f, \mathbf{i}_1) - \mathbf{T}(\mathbf{y}_2^f, \mathbf{i}_1)\|_\infty + \|\mathbf{T}(\mathbf{y}_2^f, \mathbf{i}_1) - \mathbf{T}(\mathbf{y}_2^f, \mathbf{i}_2)\|_\infty.\end{aligned}\quad (11)$$

类似定理 1,

$$\|\mathbf{T}(\mathbf{y}_1^f, \mathbf{i}_1) - \mathbf{T}(\mathbf{y}_2^f, \mathbf{i}_1)\|_\infty \leq \rho_1 \|\mathbf{y}_1^f - \mathbf{y}_2^f\|_\infty, \quad \|\mathbf{T}(\mathbf{y}_2^f, \mathbf{i}_1) - \mathbf{T}(\mathbf{y}_2^f, \mathbf{i}_2)\|_\infty \leq \rho_2 \|\mathbf{i}_1 - \mathbf{i}_2\|_\infty.$$

所以有

$$\|\mathbf{y}_1^f - \mathbf{y}_2^f\|_\infty \leq \rho_1 \|\mathbf{y}_1^f - \mathbf{y}_2^f\|_\infty + \rho_2 \|\mathbf{i}_1 - \mathbf{i}_2\|_\infty. \quad (12)$$

由于 $\rho_1 = d_1 d_2 R_{\max}(W_{oh}) R_{\max}(W_{ho}) < 1$,

$$\|\mathbf{y}_1^f - \mathbf{y}_2^f\|_\infty \leq \frac{\rho_2}{1 - \rho_1} \|\mathbf{i}_1 - \mathbf{i}_2\|_\infty, \quad (13)$$

从而可见绝对稳定的固定点连续依赖于输入.

证毕.

定理 1 和 2 是反馈型多层神经网络的理论基础, 下节将介绍它的学习算法.

4 反馈集成网络的学习算法

第三节给出了反馈集成网络(1)绝对稳定的一个充分条件. 问题是怎样才能把定理 1 的充分条件结合到学习算法里面. 为了简单起见, 我们将讨论在范数 $\|\cdot\|_\infty$ 下的相应算法, 其余两种情况相仿. 算法的详细推导请参阅文献[8].

记 w_{in}^h 为隐层第 n 个隐节点与输出层第 i 个节点的连接权值, w_{nm}^o 为第 m 个输出节点与第 n 个隐节点的反馈连接. 通用符号 w_{ps} 表示节点 s 的输出端与节点 p 的输入端的连接权值, net_i 表示第 i 个节点输入端的总和. 具体算法如下:

步骤 1. 初始化连接矩阵 W_{hi}, W_{oh}, W_{io} , 权值修改方向 $\Delta w_{ps}(0) = 0$;

步骤 2. 初始化学习次数 $u = 1$;

步骤 3. 令样本数 $a = 1$, 误差 $E = 0$;

步骤 4. 令迭代次数 $k = 0$, 初始化 $\frac{\partial y_i(0)}{\partial w_{ps}} = 0$;

步骤 5. 根据迭代方程

$$\begin{cases} \mathbf{y}(k+1) = \mathbf{f}(W_{oh} \cdot \mathbf{g}(W_{ho} \cdot \mathbf{y}(k) + W_{hi} \cdot \mathbf{i})) (k \geq 0), \\ \mathbf{y}(0) = \mathbf{y}, \end{cases}$$

计算输出 $\mathbf{y}(k+1)$ 以及 $E_{\text{stable}} = \sum_{i=1}^o |y_i(k+1) - y_i(k)|$;

步骤 6. 计算

$$\frac{\partial y_i(k+1)}{\partial w_{ps}} = \left. \frac{\partial y_i(k+1)}{\partial w_{ps}} \right|_{y(k)} + \sum_{m=1}^o \frac{\partial y_i(k+1)}{\partial y_m(k)} \cdot \frac{\partial y_m(k)}{\partial w_{ps}} \quad (i = 1, \dots, o),$$

其中 $\left. \frac{\partial y_i(k+1)}{\partial w_{ps}} \right|_{y(k)}$ 为把 $\mathbf{y}(k)$ 看成常数时的偏导数, 可采用反向传播的方式求得, 而

$$\frac{\partial y_i(k+1)}{\partial y_m(k)} = f'_i(net_i) \sum_n w_{in}^h g'_n(net_n) w_{nm}^o;$$

步骤 7. 令 $k = k + 1$, 当 E_{stable} 小于指定常数, 或者 k 大于指定次数时, 执行下一步; 否则, 返回步骤 5;

步骤 8. 计算 $\frac{\partial E(a)}{\partial w_{ps}} = \sum_{i=1}^o (y_i(k) - y_i^e(a)) \frac{\partial y_i(k)}{\partial w_{ps}}$;

步骤 9. 按公式

$$\Delta w_{ps}(u) = -\alpha \frac{\partial E(a)}{\partial w_{ps}} + \beta \Delta w_{ps}(u-1)$$

修改权值, α, β 分别是梯度方向和惯性项的正系数;

步骤 10. 令 $\max 1 = R_{\max}(W_{oh})$, $\max 2 = R_{\max}(W_{ho})$;

步骤 11. 计算 $\text{abs1}(i) = \sum_{n=1}^H |w_{in}^h|$ 和 $\text{abs2}(n) = \sum_{m=1}^o |w_{nm}^o|$;

步骤 12. 按下面公式归一化权值 w_{in}^h 和 w_{nm}^o ,

$$w_{in}^h = \frac{\lambda_1 w_{in}^h}{\sqrt{\text{abs1}(i) \cdot \max 2}},$$

$$w_{nm}^o = \frac{\lambda_2 w_{nm}^o}{\sqrt{\text{abs2}(n) \cdot \max 1}}, \quad \lambda_1, \lambda_2 \text{ 是满足 } \lambda_1 \lambda_2 < 1/d_1 d_2 \text{ 的正数};$$

步骤 13. 计算误差 $E(a)$, 令 $E = E + E(a)$, 且令 $u = u + 1$;

步骤 14. 当 a 小于样本数 Ω 时, 令 $a = a + 1$, 返回步骤 4; 否则, 继续步骤 15;

步骤 15. 令 $E = E/\Omega$, 若 E 小于指定误差, 或 u 大于指定学习次数, 学习结束; 否则, 返回步骤 3, 开始新一轮学习.

步骤 12 是学习算法的核心, 它使得相应权值满足不等式(4). 因此, 当算法结束时, 反馈集成网络(1)绝对稳定. 此外, 在学习过程中, 适当调整系数 $\alpha, \beta, \lambda_1, \lambda_2$ 能使学习顺利进行. 应该指出的是, 求偏导数的迭代过程是基于仅含一个隐层的网络结构而得, 若隐层数多于 1, 只须作简单修改即可.

5 实验及其结果

为了证明基于反馈的集成网络的有效性, 本实验采用中国科学院自动化研究所的手写数字样本库的样本.

5.1 样本库

中国科学院自动化研究所建立的手写数字样本库, 是由两万多人随意书写十个数字收集而成的. 图 2 和图 3 分别给出部分用于训练和测试的样本图象.

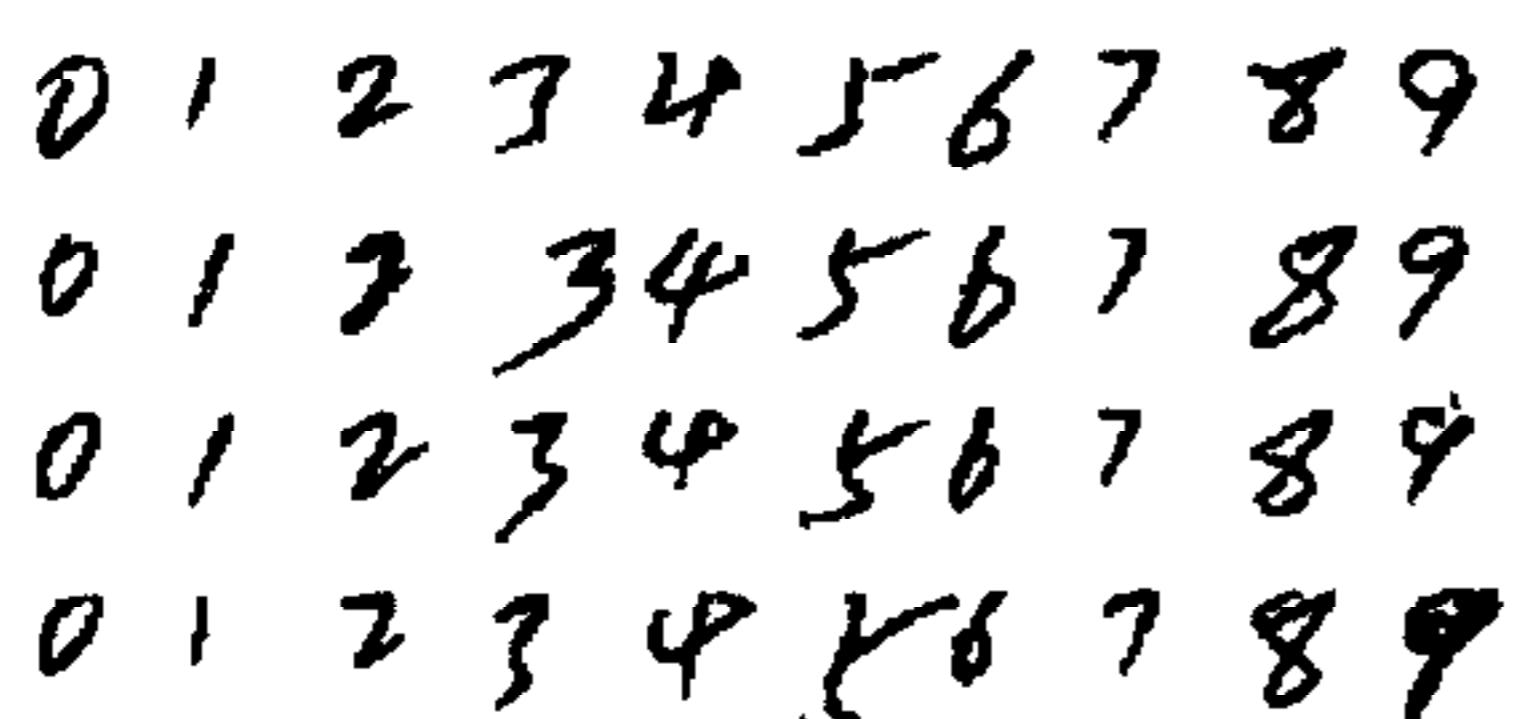


图 2 训练集中的部分样本图象

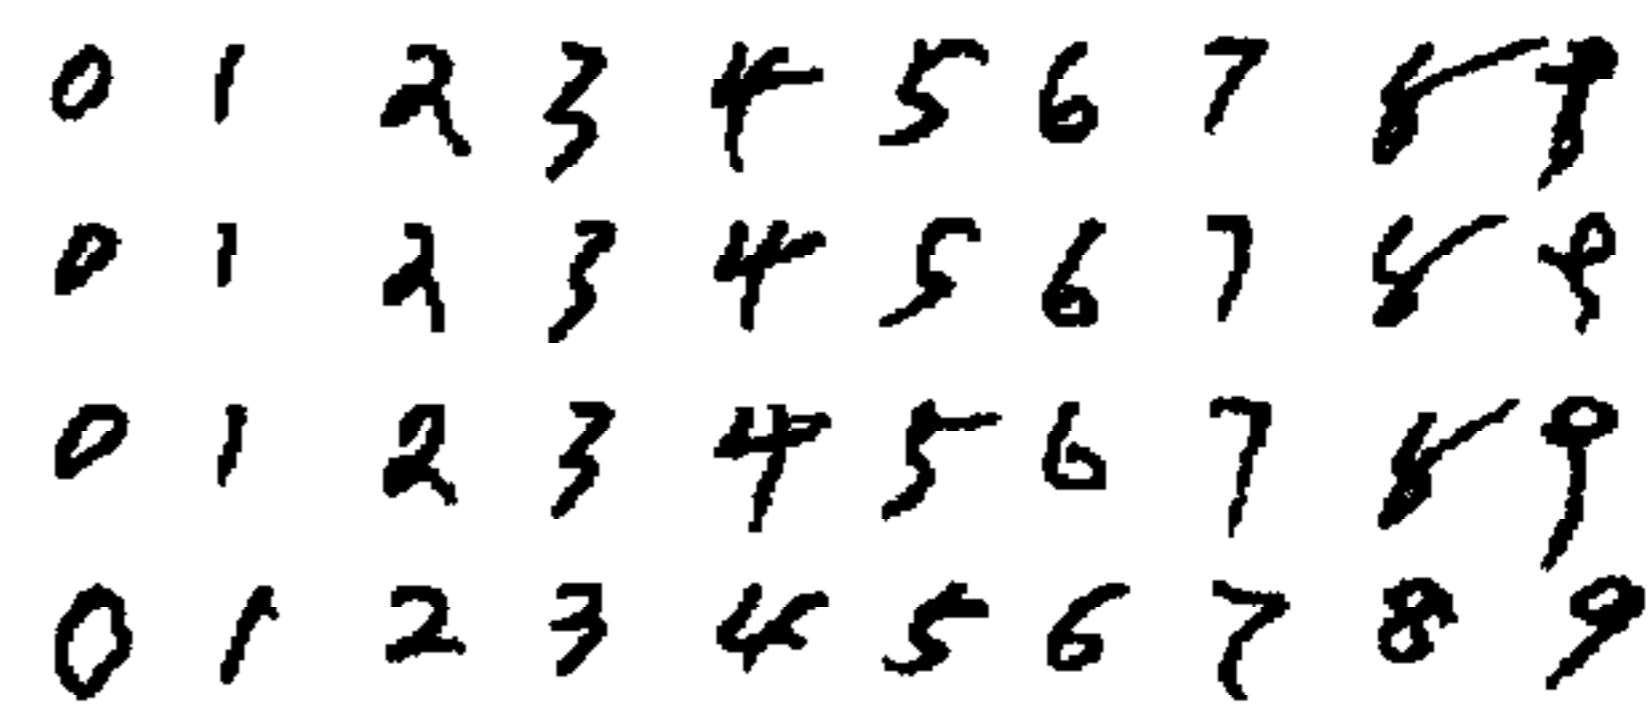


图 3 测试集中的部分样本图象

5.2 三个单分类器

集成在三个单分类器(C_1, C_2, C_3)的基础上进行. C_1 采取轮廓特征和点特征, 用 8000 个样本训练; C_2 采用网络特征, 用 10000 个样本训练; C_3 的输入是方向特征, 用

6000个样本训练。它们均用10000个样本进行测试。采取的学习算法是竞争监督学习算法^[1],表示同一类的最大输出用来进行比较判别。

本文采用文献[5]中提出的拒识公式 $\max < \frac{1}{4}(\text{sum} + r)$, 可靠性的计算公式为
 $\text{可靠性} = \frac{\text{正确率}}{1 - \text{拒识率}}$. 实验结果如表1所示。

表1 三个单分类器的实验结果

分类器	学习误差	对测试样本的正确率	对测试样本的拒识率	可靠性
C1	<0.08	86.71%	9.60%	95.9%
C2	<0.09	87.72%	9.95%	97.4%
C3	<0.05	91.10%	7.10%	98.1%

5.3 集成实验

为了证明所提模型的有效性,我们采取两种集成方式:基于反馈的集成网络与普通的三层前向神经网络。它们的输入均是30维,含10个隐层节点,输出节点10个。我们进行了两组实验,实验1是2000个样本训练,8000个样本测试;实验2是3000个样本训练,7000个样本测试。表2和表3给出有关的实验结果。

表2 实验1的结果

网络类型	前向网络	反馈集成网络
学习误差	<0.01	<0.021
对测试样本的正确率	94.29%	96.6%
对测试样本的拒识率	5.03%	2.6%
可靠性	99.3%	99.2%

表3 实验2的结果

网络类型	前向网络	反馈集成网络
学习误差	<0.01	<0.012
对测试样本的正确率	97.17%	97.91%
对测试样本的拒识率	2.27%	1.5%
可靠性	99.4%	99.4%

表2和表3说明,对多个单分类器进行网络集成,系统的泛化能力得到大幅度提高,可靠性也明显增加。另一方面,当采取不同的集成模型,反馈集成网络在没有牺牲可靠性的前提下,测试的正确率分别提高了2.31%和0.74%。这表明所提模型性能的优越性。

6 结论

对单分类器的判别结果进行集成已成为模式识别的重要方法。根据控制系统的结论,闭环结构的性能优于相应的开环结构。根据这一观点,本文提出反馈集成网络模型并应用在集成层次上。由于反馈的存在,集成系统不再是简单的静态映射,而是蕴涵丰富性质的动力学系统。为了分析它的稳定性质,本文详细讨论了有关数学条件,并给出相应的学习算法。在手写体数字库上所作的实验表明,所提模型的优越性。

参 考 文 献

- 1 钱学森,于景元,戴汝为.一个科学新领域——开放的复杂巨系统及其方法论.自然杂志,1990,13(1):3—10
- 2 戴汝为,郝红卫.综合集成的构思在模式识别中的应用.自动化学报,1997,23(3):302—307
- 3 Zadeh L A. Fuzzy sets and their application to classification and clustering. Classification and Clustering Ryzin J Van(Ed.), New York: Academic Press, 1977. 251—299

- 4 Suen C Y et al. Computer recognition of unconstrained handwritten numerals. In: Proc. of the IEEE, 1992, **80**(7): 1162—1180
- 5 郝红卫,戴汝为.人机结合的集成方法及其在字符识别中的应用.模式识别与人工智能,1996,9(1):10—20
- 6 钱学森.工程控制论(中译本).北京:科学出版社,1958
- 7 Cohen M A. et al. Absolute stability of global pattern information and parallel memory storage by competitive neural networks. *IEEE Trans. Syst. Man Cybernet.*, 1983, **13**: 815—826
- 8 汪力新,戴汝为.反馈集成网络的学习算法与分析.模式识别与人工智能,已录用
- 9 Matsuoka K. Stability conditions for nonlinear continuous neural networks with asymmetric connection weights. *Neural Network*, 1992, **5**: 495—500
- 10 Horn R A, Johnson C A. Matrix Analysis. New York: Cambridge University Press, 1985
- 11 汪力新,费越,戴汝为.基于人机结合的竞争监督学习.模式识别与人工智能,1997,10(3):186—195

DYNAMIC ANALYSIS OF INTEGRATED NEURAL NETWORK WITH FEEDBACK AND ITS APPLICATION

WANG LIXIN DAI RUWEI

(Institute of Automation, Chinese Academy of Sciences, Beijing 100080)

Abstract In pattern recognition, it is important to find a suitable way to decide a sample's class attribute according to its feature description. From the cybernetics point of view, the transformation is a black box. In this paper, we propose a new model——integrated neural network with feedback, which can be implemented as a combine model for pattern recognition and is a closed-loop structure. We present the mathematical theorems for its absolute stability and the corresponding learning algorithm. Experiments on totally unconstrained handwritten numeral recognition have confirmed the proposed model's superiority.

Key words Metasynthesis, supervised learning, dynamic system.

汪力新 1972年生,1994年厦门大学数学系毕业,1998年在中国科学院自动化研究所获硕士学位,师从中国科学院院士戴汝为研究员.主要研究领域是模式识别、人工神经网络等.

戴汝为 1933年生,毕业于北京大学.长期从事自动控制、模式识别、人工智能、智能控制及思维科学的研究.现任中国科学院院士、中国自动化学会理事长、国务院学位委员会控制科学学科评议组负责人、中国加拿大环境与资源保护中心专家委员会主任等职,并受聘于清华大学、汕头大学等三十余所高校任兼职教授、名誉教授.人工智能与模式识别杂志主编.近年来在著名科学家钱学森教授的直接指导下,在某些交叉性科学的前沿领域进行合作研究.