

文章编号: 1000-8152(2004)06-0975-06

随机神经网络发展现状综述

丛爽, 王怡雯

(中国科学技术大学 自动化系, 安徽 合肥 230027)

摘要: 随机神经网络(RNN)在人工神经网络中是一类比较独特、出现较晚的神经网络, 它的网络结构、学习算法、状态更新规则以及应用等方面都因此具有自身的特点. 作为仿生神经元数学模型, 随机神经网络在联想记忆、图像处理、组合优化问题上都显示出较强的优势. 在阐述随机神经网络发展现状、网络特性以及广泛应用的同时, 专门将 RNN 分别与 Hopfield 网络、模拟退火算法和 Boltzmann 机在组合优化问题上的应用进行了分析对比, 指出 RNN 是解决旅行商(TSP)等问题的有效途径.

关键词: 随机神经网络(RNN); Hopfield 网络; 模拟退火算法; Boltzmann 机; 组合优化问题

中图分类号: TP183 **文献标识码:** A

Survey of current progress in random neural network

CONG Shuang, WANG Yi-wen

(Department of Automation, University of Science & Technology of China, Hefei Anhui 230027, China)

Abstract: Random neural network (RNN) is a special kind of artificial neural network, which is developed recently and has its own peculiarities on the structure, the learning algorithm, the state-updating rule and the applications. As a biological neural mathematical model, RNN has particular advantages of associative memory, image processing and combinatorial optimization. The current progress, the characteristics and the broad applications are elaborated in this paper. The applications on the combinatorial optimization problems solved by different networks such as Hopfield network, simulated annealing algorithm, Boltzmann machine and RNN are analyzed and contrasted. RNN is pointed out to be an effective approach to travelling salesman problem (TSP).

Key words: random neural network(RNN); Hopfield network; simulated annealing algorithm; Boltzmann machine; combinatorial optimization

1 随机神经网络的发展 (Progress in random neural network)

按照神经生理学的观点, 生物神经元本质上是随机的. 因为神经网络重复地接受相同的刺激, 其响应并不相同, 这意味着随机性在生物神经网络中起着重要的作用. 随机神经网络 (Random neural network, RNN) 正是仿照生物神经网络的这种机理进行设计和应用的. 人们所说的随机神经网络一般有两种: 一种是采用随机性神经元激活函数; 另一种是采用随机型加权连接, 即是在普通人工神经网络中加入适当的随机噪声, 例如在 Hopfield 网络中加入逐渐减少的白噪声. 第一种主要是指由美国佛罗里达大学(UCF)教授 Erol Gelenbe 于 1989 年提出的一种随机神经网络^[1], 也是人们公认的 Gelenbe 随机神

神经网络(GNN).

GNN 的重要意义在于: 仿照实际的生物神经网络接收信号流激活而传导刺激的生理机制而定义网络. 对于实际的生物细胞来说, 它们发射信号与否与自身存在的电势有关. 历史上, 曾经有著名的 Hodgkin-Huxley 方程^[2]描述过这一行为, 但没有一个独立的数学模型能够准确的描述神经元发射信号这一特征. Gelenbe 的 RNN 模型填补了这个空白.

1991 年 Gelenbe 等人^[3]提出了一种前向型二值随机神经网络 (Bipolar random neural network, BRNN) 模型. BRNN 是由一对互补的标准的 GNN 构成, 这对互补的 GNN 神经元节点的作用刚好相反: 正神经元的运行机制同 GNN 初始定义相同, 负神经元的运行机制与 GNN 初始定义对称相反. 当负信号

到来时,可以增加这个神经元的势,正信号到来时则抵消负信号的作用.已被证明 BRNN 可以作为连续函数的广义函数逼近器.

1994年, Gelenbe 等人^[4]又提出动态随机神经网络(Dynamical neural network, DRNN),它是建立在 GNN 基础上,通过设定初始值以及增加一个 Cohen-Grossberg 型的动态方程作为负反馈回路来提高网络性能解决问题的. DRNN 和 GNN 的主要区别在于: GNN 外界信号的输入在初始化以后就保持恒定不变,是一个开环系统,而 DRNN 是一个闭环负反馈系统. DRNN 已被成功的应用于解最优化的标志性问题——旅行商问题(TSP)上.

1999年, Gelenbe 等人^[5]再次提出多类别随机神经网络(Multiple class random neural networks, MCRNNs).这个网络是 GNN 网络模型的一种合成,是为了建立一个神经网络的数学构架来同时处理不同种类的信息.不同的信号代表复合网络中的不同类别,可以表示声音处理网络中的不同频率,图像处理网络中的不同颜色,或者多传感器信号中不同传感器的信号输入.

2 GNN 模型描述(Description of Gelenbe RNN)

GNN 是一种具有 n 个神经元的开放随机网络.在这个网络中,神经元 $i(i = 1, 2, \dots, n)$ 的状态由其在 t 时刻的兴奋水平 $k_i(t) \in \mathbb{Z}^+$ 来表示,它是一个非负整数,称之为“势”. GNN 中的正信号(+1)表示兴奋,负信号(-1)表示抑制.当正信号到达第 i 个节点,该神经元的势加 1,负信号到达使之减 1(到 0 时不再减).同时,如果一个神经元的势是正值,它将不断地释放信号,释放信号的时间间隔服从均值为 $1/r_i(r_i > 0)$ 的指数分布,并同时使自己的势减 1.

若神经元释放一个信号,它作为正、负信号被传递到神经元 j 的概率分别为 P_{ij}^+ 和 P_{ij}^- ,这个信号也可能离开网络,此概率为 $d(i)$.神经元通过彼此发送和接受正或负信号来完成信息交换,而不自身传递信号,所以有 $P_{ii}^+ = P_{ii}^- = 0(1 \leq i, j \leq n)$.而信号在传递过程中存在损耗,即 $d(i) > 0$,显然,

$$\sum_{j=1}^n (P_{ij}^+ + P_{ij}^-) + d(i) = 1, 1 \leq i \leq n.$$

若令 $w_{ij}^+ = r_i P_{ij}^+$, $w_{ij}^- = r_i P_{ij}^-$,用来表示节点发射正、负信号的速率,它们与一般神经网络模型中的连接权值相似,并且是非负的.从网络外部到达神经元 i 的正、负信号的强度分别服从参数为 Λ_i, λ_i 的 Poisson 过程.根据以上的描述,可以画出如图 1 所示

的 GNN 随机神经网络结构图,图中只画出第 i 个神经元在 t 时刻接受和发出信号的情形.网络中其他节点的状态和此点类似.图中用虚线省略.

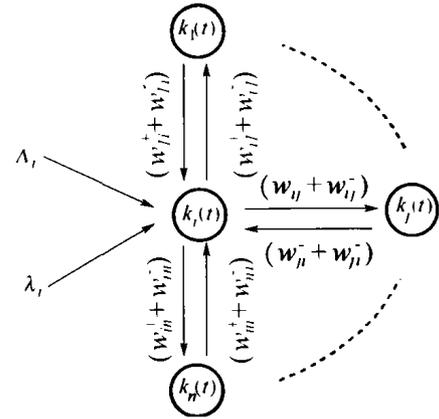


图 1 第 i 个随机神经元被作用的结构

Fig. 1 Structure of the i -th acted neuron's in RNN

3 RNN 的学习算法(Learning algorithm of RNN)

3.1 随机神经网络标准学习算法(Learning algorithm of GNN)

1993年 Gelenbe 提出了随机神经网络的学习算法^[6].其主要目的是为了得到一个适当的权值矩阵,使得输入为一对兴奋和抑制的信号流速率的矢量时,网络输出为期望值,或者其与期望值的二次方差最小.即对于 Q 组输入输出对 (P, Y) , $(P^k = (\Lambda_k, \lambda_k), k = 1, 2, \dots; Q$ 为 n 对兴奋和抑制的信号流速率构成的矢量; y^k 为 n 个网络节点的期望输出构成的矢量),网络在训练过程中调整 $n \times n$ 的权值矩阵规则为

$$w = \frac{w^+(i, j) - w^-(i, j)q_j}{r(j) + \lambda^-(j)},$$

规则为

$$e^{\text{new}}(u, v) = w^{\text{old}}(u, v) - \eta \cdot \frac{\partial E}{\partial w(u, v)},$$

使得性能函数 $E_k = \frac{1}{2} \sum_{i=1}^n a_i (q_i - y_{ik})^2$ (q_i 为网络输出, $a_i \geq 0$) 为最小.这种算法每一步计算的复杂度为 $O(n^2)$,小于梯度迭代法计算的复杂度 $O(n^3)$.

3.2 随机神经网络强化学习算法(Reinforcement learning algorithm of RNN)

3.2.1 R 规则(R-rule)

1996年, Halici 提出了随机神经网络强化学习算法的概念^[7].1997年 Halici 又提出了基于“奖励”和基于“奖惩”两种 RNN 模型的线性权值更新规

则^[8]。“奖励”线性权值更新规则又称 R 规则,即

$$P_{m+1}(i, j) = \begin{cases} P_m(i, k) + \eta^+ R_m^+(k)(1 - P_m(i, k)), \\ j = k; \\ P_m(i, j) - \eta^+ R_m^+(k)P_m(i, j), \\ j \neq k, j = 1, \dots, N_i. \end{cases}$$

这里, m 表示尝试的次数. k 表示在第 m 次尝试时到达的某个节点. $R_m^+(a_m)$ 是从外界获得的强化, 即奖

$$P_{m+1}(i, j) = \begin{cases} P_m(i, k) + \eta^+ R_m^+(k)(1 - P_m(i, k)) - \eta^- (1 - R_m^+(k))P_m(i, k), & j = k, \\ P_m(i, j) - \eta^+ R_m^+(k)P_m(i, j) + \eta^- (1 - R_m^+(k))(\frac{1}{N_i - 1} - P_m(i, j)), & j \neq k, j = 1, \dots, N_i. \end{cases}$$

这里, η^- 为惩罚的学习速率, $(1 - R_m^+(k))$ 是从外界获得的惩罚. 这种综合了奖励和惩罚的更新规则使得系统对于外界的变化更加敏感. 可以看出, 当 $\eta^- = 0$ 时, L 规则退化为 R 规则.

3.2.3 E 规则(E-rule)

前两种算法在静态情况下的训练效果很好. 但当

$$P_{m+1}(i, j) = \begin{cases} P_m(i, k) + \eta^+ (R_m^+(k) - R_{m, \beta}^+)(1 - P_m(i, k)), & j = k, R_m^+(k) > R_{m, \beta}^+, \\ P_m(i, k) - \eta^- (R_{m, \beta}^+ - R_m^+(k))P_m(i, k), & j = k, R_m^+(k) \leq R_{m, \beta}^+, \\ P_m(i, j) - \eta^+ (R_m^+(k) - R_{m, \beta}^+)P_m(i, k), & j \neq k, R_m^+(k) > R_{m, \beta}^+, \\ P_m(i, j) + \eta^- (R_{m, \beta}^+ - R_m^+(k))(\frac{1}{N_i - 1} - P_m(i, j)), & j \neq k, R_m^+(k) \leq R_{m, \beta}^+. \end{cases}$$

其中, 当 $R_m^+(k) > R_{m, \beta}^+$ (第 m 步的相关奖励期望), 则权值用奖励 $R_m^+(k) - R_{m, \beta}^+$ 来更新; 否则, 用惩罚 $R_{m, \beta}^+ - R_m^+(k)$ 来更新. $R_{0, \beta}^+$ 的初值为 0, 它的更新规则为

$$R_{m+1, \beta}^+ = (1 - \beta)R_{m, \beta}^+ + \beta R_m^+(k).$$

其中, β 是一个小的正常数, 并且有

$$\min(\eta^+, \eta^-) \leq \beta \leq \max(\eta^+, \eta^-).$$

仿真试验表明, E 规则明显优于前两种规则, 系统对外界变化敏感, 能更快、更准确的收敛到最优值, 并且能够解决遗忘的问题, 即网络能够丢弃已经无用的信息, 只对有用的信息做出反映.

3.3 多类别随机神经网络学习算法 (Learning algorithm of MCRNN)

2002 年, Gelenbe 提出了多类别随机神经网络 (MCRNN) 的学习算法^[10]. 这种基于梯度下降法的学习算法同时适用于递归和前向 MCRNN 网络. 其目的依然是为了得到一个适当的权值矩阵, 使得输入为一对兴奋和抑制的信号流速率的矢量时, 网络输出为期望值, 或者与期望值的二次方差 $E_k =$

励. η^+ 为奖励的学习速率. 这个算法的缺点是, 强化 $R_m^+(a_m)$ 随着迭代步数的增加而日趋复杂并且这种算法不是各态遍历的, 另外网络的收敛和初始的条件有关.

3.2.2 L 规则(L-rule)

“奖惩”线性权值更新规则 (又称 L 规则) 与 R 规则的不同之处在于, 第一种规则只有奖励, 而 L 规则奖励惩罚皆有

处于动态时, 训练就会受到以前学习行为的干扰, 而不能将其遗忘. 2000 年, Halici 又提出了一种基于奖励的内部期望更新规则^[9] (又称 E 规则) 对强化学习算法进行扩展: 当学习行为的“奖励”不低于内部期望时, 网络按照“奖励”的模式进行学习; 否则按照惩罚的模式进行学习, 以此来考虑所有其他可能的情况.

$\frac{1}{2} \sum_{(i, c)} a_{ic} (f_{ic}(q_{ic}^k) - y_{ic}(k))^2$ (其中 $f_{ic}(q_{ic}^k)$ 为网络输出的函数, $a_{ic} \geq 0$) 最小. 与先前 RNN 的学习算法相比, 不同之处在于这里输入的信号是多种类的. 即对于 Q 组输入输出对 (P, Y) , ($P^k = (\Lambda_k, \lambda_k), k = 1, 2, \dots; Q$ 为 nC 对兴奋和抑制的信号流速率构成的矢量; 不同的是, $y_k = (y_{11}(k), \dots, y_{1c}(k), \dots, y_{n1}(k), \dots, y_{nc}(k))$ 为 n 个网络节点的 C 种类期望输出构成的矢量), 网络在训练过程中调整 $nC \times nC$ 的权值矩阵, 其权值更新规则为

$$w^{new}(u, d; v, e) =$$

$$w^{old}(u, d; v, e) - \eta \cdot \frac{\partial E_k}{\partial w(u, d; v, e)}.$$

可以看出与 GNN 学习算法不同之处在于, $\eta \cdot \frac{\partial E}{\partial w(u, d; v, e)}$ 是一个对不同类别信号的多变量微分. 在这个算法中, 需要求解 nC 个线性方程和 nC 个非线性方程. 对于递归网络, 其计算复杂度为 $O[nC]^3$; 对于前向网络, 其计算复杂度为 $O[nC]^2$.

4 RNN 的应用 (Applications of RNN)

随机神经网络与一般神经网络相比, 具有以下

特性:信号以脉冲形式传递,因而更加接近生物神经网络的实际情况.由于RNN的每个神经元可以用一个累加器来表示,所以硬件实现较方便.1996年Cerkez^[11]提出了一种用TTL IC实现单个神经元的方法.1997年,Badaroglu和Halici等人^[12,13]使用CMOS技术实现了一个有16个神经元的RNN芯片设计.随着RNN的不断扩展,随机神经网络模型已经被成功运用到很多领域.下面给出RNN一些具体的成功应用实例.

4.1 人工纹理生成(Artificial texture generation)

人工纹理生成在图像合成系统中是一项很重要的功能.在文献[14,15]中,RNN被用于各种不同性质的纹理生成.作者为了得到不同特征的纹理(如粒度,倾角,随机性),提出了不同的迭代方程.这些迭代方程的初值均是随机生成的灰度图像.实验结果表明RNN能够得出理想结果的同时,计算机资源的花费要小于Markov random fields(MRF)等方法.在MCRNN提出以后^[5],Gelenbe E等人^[10]又将MCRNN的学习算法应用于彩色纹理模型,设计一个拓扑结构和图像像素直接对应的MCRNN,直接从彩色纹理图像中提取纹理特征、信号类别对应色彩的类别,使用递归MCRNN的权值学习规则来生成一个合成的与原始纹理相似的纹理,并且对多个人工和自然纹理进行实验.最后通过一个表达原始纹理和基于MCRNN生成的纹理两者统计特征的同现矩阵(cooccurrence matrix)来检测这种实验方法的适用性.通过比较发现,虽然生成的纹理和原纹理并不完全相同,在很多细微的地方仍有差异,但是从直觉上判断已非常接近.实验还表明,MCRNN可以有效地对彩色同类小纹理范畴内的图像进行建模,学习规则是有效的,而且计算时间短.

4.2 磁共振图像特征信息抽取(Morphometric information extraction of MRI)

在文献[16]中,RNN被用于从人脑的磁共振图像(Magnetic resonance imaging, MRI)扫描中抽取正确的形态特征信息.作者提出一种从磁共振图像中灰度分类的办法识别磁共振图像的不同部分,用定量估计来确定某一部分所占的大小,从而判断此部分图像是否指示了病理损伤.实验表明,使用RNN分类的结果与现在已知的人类专家对于大脑MR图像人工容量分析的结果十分接近.

4.3 图像编码器(Image coder)

1996年,Cramer和Gelenbe等人首先提出了RNN的图像编码器^[17],并且取得了较满意的结果.

在图像压缩中训练RNN网络来对输入数据进行编码和解码,能够使输入/输出的图像之间差别减小.网络的输入和输出层神经元节点数相同,中间层神经元节点数较少.输入层和中间层的节点个数比为压缩比.网络通常训练很多个图像,这样图像压缩的结果不局限于某一个图像,而是适用于一类图像.在文献[17]中,作者采用含有一个中间层的前向RNN,输入层和中间层之间的权值对应于压缩处理,中间层和输出层之间的权值对应于解压缩处理.文章通过权值的改变来检测静态图像压缩网络的鲁棒性.训练权值的一部分是随机选取的,其值在规定的范围内波动.鲁棒性分析表明了RNN的并行结构使得此图像压缩器/解压缩器在硬件执行上有很强的适用性.结果表明,无论是在技术上还是在视觉上,这样使用RNN设定的输入/输出对处理静态图像压缩都有着满意的结果,与其他神经网络相比,使用RNN的编码解码时间快.一旦离线训练完成,压缩和解压缩过程也显著增快.文献[18]将神经网络编码和变换编码相结合,提出了一种基于离散余弦变换(Discrete cosine transform,简称DCT)的随机神经网络编码器.其思想为,针对输入图像先取均值,然后进行分块进行DCT变换.变换后的直流(DC)系数利用差分脉冲编码调制(DPCM)进行编码,而交流(AC)系数利用随机神经网络进行编码.实验获得了优于Cramer和Gelenbe等人的结果,同时利用一般BP神经网络、Cramer和Gelenbe等人的随机神经网络和改进的编码器对标准测试图像Lenna的实验结果进行比较,在图像压缩中使用随机神经网络得到的结果优于一般BP神经网络.

4.4 增强图像放大(Enhanced image enlargement)

增强图像放大是将小的输入图像像素扩大 $R_x \times R_y$ 倍(通常 $R = R_x = R_y$,称扩大倍数 R^2 为放大率)输出新图像 φ .在文献[6]中,作者训练了一个3层的前向网络.对应于原图像中的像素点 (u, v) ,新的图像由两部分构成:一部分是零阶内插值获得的放大图像 $S_{int,i}(u, v)$,另一部分是此放大图像和假设放大图像 $\vartheta_i(u, v)$ 的区别 $T_{diff,i}(u, v)$.作者使用RNN的学习算法使网络在输出得到 $T_{diff,i}(u, v)$,定义性能函数为期望图像与训练输出结果在每一个像素点的二次方差.实验结果表明,RNN方法在数值计算结果上要比零阶内插值法好的多.

4.5 其他应用(Other applications)

运用RNN在联想记忆方面的功能可以检验一

个网络联想记忆的能力以及重组错乱模式的能力.文献[19]中展示了在未知情况下利用分散的联想记忆进行决策的应用.此外,随机神经网络还被应用于矿藏探测.实验证明,使用一种无参数的鲁棒方法训练网络探测十分有效而且能够排除错误的警报.在军事上,通过对雷达的特征分析数据训练 RNN 网络,能够成功的在干扰中准确的区分探测出目标. MRCRNN 还可以用于多传感器的数据融合^[20].

5 其他随机网络(Other stochastic networks)

随机神经网络仿照生物神经元细胞,表达了神经元接受刺激产生兴奋或抑制的生理机制,第一次系统地引入了随机的概念建立细胞神经元数学模型.在此之前的 1982 年,美国加州工学院物理学家 Hopfield 提出的反馈网络中,也同样使用了神经元节点的输出来表达兴奋或抑制的状态,并将其成功地应用于联想记忆和优化计算中.对于 Hopfield 网络在解最优化问题时容易陷入局部极小点的问题,研究者们开始考虑将随机的概念引入神经元网络改变神经元状态更新规则,首先引入的是模拟金属退火的算法——模拟退火算法(Simulated annealing algorithm),它是把神经网络的状态看作金属内部的“粒子”,把网络在各个状态下的能量函数看作是粒子所处的能态.在算法中设置一种控制参数 T ,当 T 较大时,网络能量由低向高变化的可能性也较大;随着 T 的减小,这种可能性也减小.如果把把这个参数看作温度,让其由高慢慢的下降,则整个网络状态变化过程就完全模拟了金属的退火过程.将模拟退火算法的公式反复进行网络状态更新足够多的次数后,网络状态出现的概率将服从 Boltzmann 分布,并且满足 Boltzmann 分布的特点:最小能量状态以最大的概率出现,即 1985 年 Hinton 提出的 Boltzmann 机模型,简称 BM(Boltzmann machine)网络.在模拟退火算法、Boltzmann 机模型中,神经元的输出不像 Hopfield 网络那样由激活函数来决定,而是随机改变的,即由以能量函数 E_i 为变量的概率 $P_{u_i}(0)$ 或 $P_{u_i}(1)$ 来决定输出为兴奋或者抑制的,其输出为简单的 $\{1,0\}$.

Hopfield 网络、模拟退火算法、Boltzmann 机和 RNN 从网络结构上的区别在于,模拟退火算法仅仅是一种将能量函数跳出局部最小值的算法,而其他三种都是有着固定的网络结构:Hopfield 网络是一种单层全反馈网络;Boltzmann 机是一种双向联接网络,一般分为可视层与隐含层两大部分,可视层又可

分为输入部分和输出部分.但它与一般的多层网络结构不同之处在于网络没有明显的层次界限;RNN 是一种开放型的单层递归网络.三种网络节点之间都是双向联接,权值对称相等.所不同的是,在 Hopfield 网络和 Boltzmann 机中,权值连接代表神经元之间的连接强度,而 RNN 中权值连接引入了随机的概念,表示被激活的神经元之间发射信号的概率,更接近细胞的生理机制.

为了使网络输出达到期望值, Hopfield 网络、Boltzmann 机和 RNN 都能通过调整权值来达到联想记忆的功能.在 Hopfield 网络中,通常采用其离散型使任意输入矢量经过网络循环最终收敛到网络所记忆的某个稳定样本上.在网络训练过程中,运用的是海布(Hebb)调节规则: $w_{ij} = w_{ij} + t_j^k t_i^k$,即对于第 k 个样本,当第 i 个神经元输出与第 j 个神经元输出同时兴奋或同时抑制时, $t_j^k t_i^k \geq 0$; 连接强度则增强,否则减弱,这与海布提出的生物神经细胞之间的作用规律相同. Boltzmann 机的学习规则可以模拟学习样本的状态概率.网络训练过程中,权值调节规则为

$w_{ij}^{(t+1)} = w_{ij}^t - \eta \cdot \frac{\partial G}{\partial w_{ij}}$,其中, G 为一个交叉熵函数,当它为 0 时表示无论外界是否有输入,可见神经元出现某状态的概率均是相同的,学习的目的是使 G 趋于 0. RNN 学习算法是为了得到一个适当的权值矩阵,使得输入为一对兴奋和抑制的信号流速率的矢量时,网络输出为期望值,或者其与期望值的二次方差 ($E_k = \frac{1}{2} \sum_{i=1}^n a_i (q_i - y_{ik})^2, a_i \geq 0$) 最小,这里权值的调整规则为 $w^{\text{new}}(u, v) = w^{\text{old}}(u, v) - \eta \cdot \frac{\partial E}{\partial w(u, v)}$. 可以看出,三种网络调整权值时,都是在原权值上加上一个修正量.但是,相比较而言, Hopfield 的学习速度快, Boltzmann 机计算工作量大且过程较慢,而 RNN 的计算复杂度较小.

Hopfield 网络、Boltzmann 机和 RNN 都可以解决最优化的问题.旅行商问题(TSP)一般被认为是复合最优化问题中使用启发式算法解决问题的基准. 1985 年 Hopfield 和 Tank 两人用连续 Hopfield 网络(CHNN)为解决 TSP 难题开辟了一条崭新的途径,获得了巨大的成功.其基本思想是把 TSP 问题映射到 CHNN 网络中去,使用换位矩阵表示有效路径,并设法用网络能量代表路径总长作用于反馈回路调节输入变化,从而使得网络能量为最小——得到最短路径.由于 Hopfield 网络状态更新规则只能使能量函数往减小的这一个方向变化,能量函数很容易

陷入局部最小值,使得网络解不能够达到路径最优.因此,使用 Boltzmann 的工作规则,选择适当的温度 T 参数和能量函数的定义,按照交换两个城市位置或者改变一段路径顺序等规则更新网络状态后,按概率接受能量函数的小波动,从而使能量函数跳出局部最小点达到最优.不过当求解城市数量较大的 TSP 时,由于网络状态更新选择的新路径随机性增大,使得网络求解的时间很不稳定^[21].

在解决 TSP 问题上,RNN 与 Hopfield 网络有很大的相似性,同样也是使用换位矩阵表示有效路径,定义适当的参数和能量函数.但是由于反馈回路方程的变化,使网络能在一定范围内接受能量函数的小波动,从而跳出局部最小值,克服 Hopfield 解 TSP 的缺点.而且 RNN 网络输出是由一组无穷多个 Chapman-Kolmogorov 方程推出的严格的解,使得能量函数变化连续,不会出现城市数目多时类似 Boltzmann 机路径随机选择的求解时间不稳定的情况,因此采用 RNN 来解决 TSP 问题是一种有效途径.

6 研究前景(Further work)

人们在随机神经网络的理论研究和应用上已经做了不少工作,并且提出了许多新的研究课题.比如利用 RNN 网络和 MCRNN 网络抓住人工神经网络信号发射的特征,对网络模型进行自然扩展而获得新的模型,对于所扩展的新的数学模型是否还拥有分析计算上的易操作性?这个新模型是否能够发展出一个有效的学习算法来应用于工程?这些都是值得考虑的问题.

RNN 网络曾被用于增强图像放大,实验表明 RNN 方法在数值计算结果上要比零阶内插值法好得多.一个可以研究的方向是将这种方法和高阶内插值法做比较研究.

RNN 网络已被证明可以作为连续函数的广义函数逼近器^[15],考察 MCRNN 在这一领域是否能够有更强大的功能也是一个有趣的问题.

考虑到纹理生成方面的应用,注意到某些动物在受到外界不同刺激的情况下能够改变皮肤的外观和颜色,可以仿照这种动物的颜色控制,为不同条件下纹理的外观和色彩变化建模.

RNN 作为一种分析计算上的易操作的神经网络模型,如果继续更加细致的研究,相信会出现更多有前景的研究方向,从而在现实中得到有效的应用.

7 总结(Conclusion)

对 RNN 网络在网络结构、学习算法、状态更新

规则以及应用等方面分别予以了详尽的阐述.随机神经网络模型信号以脉冲的形式传递更接近生物神经网络的实际,具有出色的仿生特点.用非负函数而非二值状态表示神经元的兴奋水平,对系统状态描述更为细致.作为前馈网络结构,随机神经网络比起于标准的网络算法计算简便,易于学习.此外它易于硬件仿真,应用领域十分广泛.特别地,在组合优化的问题上的应用,将 RNN 分别与 Hopfield 网络、模拟退火算法、Boltzmann 机和 RNN 网络进行了分析对比并指出了进一步研究方向.RNN 作为与其他网络截然不同的仿生的神经元数学模型,它所具有的独特学习算法和工作规则使得它在联想记忆、图像处理、组合优化问题上有着独特的优势.但是关于随机神经网络,还有很多理论问题,目前只对一些特殊网络有确定结论,这还需要进一步去探索.

参考文献(References):

- [1] GELENBE E. Random neural networks with negative and positive signals and product form solution [J]. *Neural Computation*, 1989, 1(14):502-511.
- [2] HODGKIN A L, HUXLEY A F. A quantitative description of ion currents and its applications to conduction and excitation in nerve membranes [J]. *J of Physiology (London)*, 1952, (117):550-544.
- [3] GELENBE E, STAFYLOPATIS A, LIKAS A. Associative memory operation of the random neural network model [C]// KOHONEN H, eds. *Proc of Int Conf Artificial Neural Network*. North-Holland: Amsterdam, 1991:307-312.
- [4] GELENBE E, KOUBI V, PERKERGIN F. Dynamical random neural network approach to the traveling salesman problem [J]. *ELEKTRIK*, 1994, 2(1):1-10.
- [5] GELENBE E, FOURNEAU J M. Random neural networks with multiple classes of signals [J]. *Neural Computation*, 1999, 11(4):721-731.
- [6] GELENBE E. Learning in the recurrent random neural network [J]. *Neural Computation*, 1993, 5(1):154-164.
- [7] HALICI U. Reward, punishment and expectation in reinforcement learning for the random neural networks [M]// *Workshop on Biologically Inspired Autonomous Systems: Computation, Cognition and Control*. Durham, NC, USA: Duke University, 1996.
- [8] HALICI U. Reinforcement learning in random neural networks for cascaded decisions [J]. *J of Biosystems*, 1997, 40(1/2):83-91.
- [9] HALICI U. Reinforcement learning with internal expectation for the random neural network [J]. *European J of Operational Research*, 2000, 126(2):288-307.
- [10] GELENBE E, KHALED F. Hussain, Learning in the multiple class random neural network [J]. *IEEE Trans on Neural Networks*, 2002, 13(6):1257-1267.

(下转第 985 页)

5 结论 (Conclusion)

将系统分解 n_1 为 $n - n_1$ 和维等价的两个子系统, 并通过估计子系统的状态获得原系统的状态估计. 常规子系统的状态估计采用现代时间序列分析方法, 基于 ARMA 新息模型、白噪声估值器和观测预报器, 得出了 Wiener 状态滤波、预报和平滑器. 由于分解使滤波器的维数降低, 减少了计算量. 并且由于分解过程可预先完成, 因此本文的算法可用于实时估计.

参考文献 (References):

- [1] NIKOUKHAH R, WILLSKY A S, BERNARD C L. Kalman filtering and Riccati equations for descriptor systems [J]. *IEEE Trans on Automatic Control*, 1992, 37 (9): 1325 - 1341.
- [2] DENG Z L, XU Y. Descriptor Wiener state estimators [J]. *Automatica*, 2000, 36(11): 1761 - 1766.
- [3] 秦朝英, 戴冠中. 广义离散随机线性系统的最优滤波 [J]. 控制与决策, 1993, 8(1): 65 - 68.
(QIN Chaoying, DAI Guanzhong. Optimum filtering for singular discrete stochastic linear systems [J]. *Control & Decision*. 1993, 8(1): 65 - 68).
- [4] 邓自立. Kalman 滤波与 Wiener 滤波——现代时间序列分析方法 [M]. 哈尔滨: 哈尔滨工业大学, 2001.
(DENG Zili. *Kalman Filtering & Wiener Filtering - Modern Time Series Analysis Approach* [M]. Harbin: Harbin Institute of Technology Press, 2001.)
- [5] SHIELD D N. Observers for singular discrete-time descriptor systems [J]. *Control & Computers*, 1994, 22(2): 58 - 64.
- [6] ANDERSON B D O, MOORE J B. *Optimal Filtering* [M]. Englewood Cliffs, NJ: Prentice-Hall, 1979.
- 作者简介:
石莹 (1971 —), 女, 黑龙江大学自动化系讲师, 哈尔滨工业大学博士研究生, 主要研究方向为 Kalman 滤波、状态估计等, E-mail: shiying89@tom.com;
沈永良 (1964 —), 男, 黑龙江大学自动化系副教授, 主要研究方向为信号处理、自动检测与仪表等, E-mail: shenyl64@126.com;
孙书利 (1971 —), 男, 黑龙江大学自动化系教师, 哈尔滨工业大学博士研究生, 主要研究方向为 Kalman 滤波、状态估计与信息融合等, E-mail: sunsl@hlju.edu.cn;
邓自立 (1938 —), 男, 黑龙江大学应用数学研究所和自动化系教授, 主要研究方向为状态估计、信号处理、信息融合、最优滤波和现代时间序列分析等。
- (上接第 980 页)
- [11] CERKEZ C. A digital neuron realization for random neural network model [D]. Famagusta, North Cyprus: Eastern Mediterranean University, 1996.
- [12] HALICI U, BADAROGLU M, AYBAY I, et al. A digital random neural network chip design [C] // *Proc of Neural '97*. [s.l.]: [s.n.], 1997: 78 - 83.
- [13] BADAROGLU M, HALICI U, AYBAY I, et al. Digital neural network chip for the random neural network model with programmable architecture [C] // *Proc of the 12th Int Symposium on Computer and Information Sciences*. [s.l.]: [s.n.], 1997: 412 - 418.
- [14] GELENBE E, MAO Z H, DA-LI Y. Function approximation: Random neural networks with multiple classes of signals [J]. *IEEE Trans on Neural Networks*, 1999, 10(1): 3 - 9.
- [15] ATALAY V, GELENBE E, YALABYK N. The random neural network model for texture generation [J]. *Int J of Pattern Recognition and Artificial Intelligence*, 1992, 6(1): 131 - 141.
- [16] GELENBE E, FENG Y, KRISHNAN K. Neural network methods for volumetric magnetic resonance imaging of the human brain [J]. *Proceedings of the IEEE*, 1996, 84(10): 1488 - 1496.
- [17] CRAMER C, GELENBE E, BAKIRCIOGLU H. Low bit rate video compression with neural networks and temporal subsampling [J]. *Proceedings of the IEEE*, 1996, 84(10): 1529 - 1543.
- [18] 王琪, 钟玉琢. 一种基于 DCT 变换的随机神经网络图像编码器 [J]. 小型微型计算机系统, 1999, 20(7): 481 - 484.
(WANG Qi, ZHONG Yuzhuo. A DCT Based image coder with random neural network [J]. *Mini-micro Systems*, 1997, 20(7): 481 - 484.)
- [19] GELENBE E. Distributed associative memory and the computation of membership functions [J]. *Information Sciences*, 1991, 57/58: 171 - 180.
- [20] BAKIRCIOGLU H, KOCAK T. Survey of random neural network applications [J]. *European J of Operational Research*, 2000, 126: 319 - 330.
- [21] 王怡雯, 丛爽, 窦秀明. 用 Boltzmann 机求解典型 NP 优化问题 TSP [M] // 丛爽, 自动化理论、技术与应用. 合肥: 中国科学技术大学出版社, 2003, 10: 163 - 170.
(WANG Yiwen, CONG Shuang, DOU Xiuming. Typical NP Optimization Solution of TSP with Boltzmann Machine [M] // CONG Shuang, *Automatic Theory Technology & Application*. Hefei: University of Science & Technology of China Press, 2003, 10: 163 - 170.)
- 作者简介:
丛爽 (1961 —), 女, 博士, 教授, 博士生导师, 现主要从事人工神经网络、模糊神经系统、运动控制、智能控制等方向的研究, E-mail: scong@ustc.edu.cn;
王怡雯 (1980 —), 女, 硕士生, 主要从事随机神经网络和局部连接神经网络的研究。