

G 神经网络函数映射能力的构造性证明¹

韦 岗 田传俊

(华南理工大学电子与信息学院 广州 510641)

摘 要 该文研究了 G 神经网络的函数映射能力, 给出了前馈 G 神经网络映射任意 G 型多项式的构造性证明. 采用该文的方法映射同一个多项式, 所用的神经元数目可少至以往方法的 $2/(n+1)$, 其中 n 是 G 型多项式的次数.

关键词 神经网络, G 神经网络, 函数映射, G 型多项式
中图分类号 TN-052

1 引 言

神经网络的函数映射能力是其实际应用的重要基础之一. 目前经研究发现有多种神经网络具有良好的函数映射能力, 如多层前馈网络 (MLP), 径向基网络 (RBF), 随机神经网络等^[1-5] 都可逼近任意连续函数.

Gelenbe 等在文献 [6-10] 中详细研究了一种特殊的随机神经网络, 简称 GNN 或 G 网. 它是一时间连续、状态离散的模型, 其工作方式与实际生物神经网络较为相似. 研究表明 G 网有多种实际用途, 如可用于最优化、模式识别、图像压缩等, 其优点是易于进行数值计算. 本文将讨论 G 网的函数映射能力, 首先介绍几种常用的 G 网结构.

1.1 单枝和分枝前馈 G 网的结构

G 网是由若干个 G 型神经元或 G 元组成的, 其结构如图 1 所示: 图中 G 元在 t 时刻的状态 $k_i(t)$ 为非负整数; “入 +” 和 “入 -” 表示从网络外输入的正信号和负信号, 并分别服从到达率为 $\Lambda(i)$ 和 $\lambda(i)$ 的普阿松过程; “进 1+” 和 “进 1-” 表示从网络内另一个神经元输入到该元的正和负信号, 可以有多个其它神经元同时输入该元; 当状态 $k_i(t) > 0$ 时, 它会输出一个服从指数分布的随机信号, 输出率为 $r(i) \geq 0$; “出 1+” 和 “出 1-”




图 1 G 网的神经元结构

表示该元输出时, 分别以概率 $p^+(i, j)$ 和 $p^-(i, j)$ 输给另一个神经元 j 的正和负信号, 可以同时输给多个神经元, $d(i)$ 表示输出信号离开网络的概率, 满足 $\sum_j (p^+(i, j) + p^-(i, j)) + d(i) = 1$; 并假设上述不同的随机过程是相互独立的; 当正信号输入时, 该元的状态 $k_i(t)$ 会加 1; 当负信号输入或向其它神经元输出时, 若 $k_i(t) > 0$, 则其状态减 1, 否则不产生影响. 将 G 元按不同方式连接起来可组成各种不同的 G 网. 若将 G 元按通常多层前馈网络方式进行排列就可得前馈 G 网, 其中常用的有单枝前馈 G 网, 其结构见图 2 所示. 对于有 n 个神经元的 G 网, 有下面重要结果.

定理 1 对 n 元 G 网, 记 $w^+(i, j) = r(i)p^+(i, j)$ 和 $w^-(i, j) = r(i)p^-(i, j)$, 则方程组: $\lambda^+(i) = \Lambda(i) + \sum_j q_j w^+(j, i)$, $\lambda^-(i) = \lambda(i) + \sum_j q_j w^-(j, i)$, $i = 1, \dots, n$, 存在非负解 $\lambda^+(i) \geq 0$ 和 $\lambda^-(i) \geq 0$, 其中, $q_i = \lambda^+(i)/(r(i) + \lambda^-(i))$.

¹ 2000-01-07 收到, 2000-08-24 定稿

霍英东青年教师基金、国家自然科学基金 (69772027) 资助课题




图 2 单枝前馈 G 网




图 3 分枝前馈 G 网




图 4 BG 网

分枝前馈 G 网是从单枝前馈 G 网中各 G 元分别引出一个或多个单枝前馈 G 网而得到的新 G 网, 在各分枝上还可进行分枝, 在它的最后或某些分枝前也可加一个输出或输入神经元 O, 其结构图可见图 3, 其中, 圆圈表示 G 元。

1.2 双极 G 网或 BG 网的结构

双极 G 或 BG 网是由一个正 G 网和一个负 G 网组成, 其中正 G 网就是上面介绍的 G 网; 而负网则是由负 G 元组成的, 负 G 元的结构与图 1 是相同的, 但其参数的含义有所不同, 如它的状态 $k_i(t)$ 为非正整数; 当负信号输入时, 其状态减 1; 而当正信号输入或向其它神经元输出时, 若 $k_i(t) < 0$, 则状态加 1, 否则不产生影响; 从第 i 个负 G 元发出的负信号到达第 j 个负 G 元的概率记为 $p^+(i, j)$, 发出正信号的概率为 $p^-(i, j)$, 离开网络的概率为 $d(i)$ 等, 其它是类似的。BG 网的结构见图 4, f 表示某个连续函数。

Gelenbe 等在文献 [10] 中曾得到下面的结果。

定理 2 设 $f: [0, 1] \mapsto R$ 是一个连续函数, 则对任意的 $\epsilon > 0$, 存在一个多项式:

$$p(x) = c_0 + c_1 \left(\frac{1}{1+x} \right) + \dots + c_m \left(\frac{1}{1+x} \right)^m = \sum_{i=0}^m c_i (1+x)^{-i}, \quad 0 \leq x \leq 1 \quad (1)$$

使得 $\sup_{x \in [0,1]} |f(x) - p(x)| < \epsilon$ 成立, 其中 m 是一个自然数。

定理 3 设 $f: [0, 1]^s \mapsto R$ 是多元连续函数, 则对任意的 $\epsilon > 0$, 存在一个多元多项式:

$$p(x) = p(x_1, \dots, x_s) = \sum_{m_1 \geq 0, \dots, m_s \geq 0, \sum_{v=1}^s m_v = m} c(m_1, \dots, m_s) \prod_{v=1}^s \frac{1}{(1+x_v)^{m_v}} \quad (2)$$

使得 $\sup_{x_1, \dots, x_s \in [0,1]} |f(x) - p(x)| < \epsilon$ 成立, 其中 $c(m_1, \dots, m_s)$ 是系数, s 是一个自然数。

下面将形如 (1) 式和 (2) 式的多项式称为 G 型多项式。由定理 2 和 3 可知, 在讨论网络逼近连续函数时, 只需要讨论它能映射 G 型多项式即可。下面就来讨论这个问题。

2 前馈 G 和 BG 网的函数映射能力

设输入矢量为 $X = (x_1, x_2, \dots, x_s)$, 因向量函数 $[0, 1]^s \mapsto R^w$ 总能被分解成 w 个 $[0, 1]^s \mapsto R$ 上的一元函数, 故只需讨论多元连续函数的逼近问题。

对于 s 个输入, 1 个输出, L 层的前馈 G 网络, 用 (l, i) 表示第 l 层的第 i 个神经元, M_l 表示第 l 层神经元的个数, $l = 1, 2, \dots, L$. 前馈网络的构造方法如下^[10]:

(1) 在第一层中, 设 $\Lambda(1, i) = x_i$, $\lambda(1, i) = 0$, $r(1, i) = 1$, $i = 1, 2, \dots, s$, 于是 $q_{1,i} = x_i$;

(2) 在第 l 层中 ($l \geq 2$), $\Lambda(l, i)$, $\lambda(l, i)$, $r(l, i)$, $w^+(\cdot, \cdot)$ 和 $w^-(\cdot, \cdot)$ 是可变的参数, 第 l 层第 i 个神经元的“输出” $q_{l,i}$ 由下式给出, 一般有 $q_{L,1} \in [0, 1)$,

$$q_{l,i} = \frac{\Lambda(l, i) + \sum_{h < l} \sum_{j \leq M_h} q_{h,j} w^+((h, j), (l, i))}{\lambda(l, i) + r(l, i) + \sum_{h < l} \sum_{j \leq M_h} q_{h,j} w^-((h, j), (l, i))} \quad (3)$$

(3) 在第 L 层即输出层唯一的神经元的输出 $q_{L,1}$ 上加上一个非线性变换, 使得整个网络的输出为 $A_{L,1} = q_{L,1}/(1 - q_{L,1})$, 显然 $A_{L,1} \in [0, \infty)$.

Gelenbe^[10] 给出了 G 网连续函数逼近能力的存在性证明. 对 G 型多项式, 其构造性的证明是很“粗糙”的. 本文将给出 G 网映射 G 型多项式新的更精细的构造性证明方法.

2.1 一元 G 型多项式映射的构造性证明

定理 4 设 $p^+(x)$ 是一个形如 (1) 式的多项式, 且 $c_v \geq 0$, $v = 0, 1, 2, \dots, m$, 则存在一个有 $m + 2$ 个神经元的单枝前馈 G 网, 使得对一切输入 $x \in [0, 1]$, 其唯一的输出神经元 (O) 的输出为 $q_O = p^+(x)/(1 + p^+(x))$, 因此网络输出 $A_O = p^+(x)$.

证明 下面先构造一个具有 $m + 1$ 个神经元的单枝前馈 G 网, 每层的神经元记为 $(1, 1)$, $(2, 1)$, \dots , $(m + 1, 1)$. 令 $C = c_0 + c_1 + \dots + c_m$, 构造方法如下:

(1) $\Lambda(1, 1) = x$, $\Lambda(2, 1) = 1/m$, $\Lambda(m + 1, 1) = (c_0 + c_1)/C$ 和 $\Lambda(j, 1) = 0$, $j = 3, \dots, m$;

(2) $\lambda(j, 1) = 0$, 对一切 $j = 1, 2, \dots, m + 1$;

(3) $w^-((1, 1), (m + 1, 1)) = 1$, $w^-((1, 1), (j, 1)) = 1/m$, 对一切 $j = 2, \dots, m$;

(4) $w^+((1, 1), (j, 1)) = 0$, 且 $j = 2, \dots, m$, $w^+((j, 1), (j + 1, 1)) = 1/m$, $j = 2, \dots, m - 1$;

(5) $w^+((1, 1), (m + 1, 1)) = c_0/C$, $w^+((j, 1), (m + 1, 1)) = c_j/C$, 对一切 $j = 2, \dots, m$;

(6) $r(m + 1, 1) = 1$, $r(j, 1) = 1/m$, 对一切 $j = 2, \dots, m$;

(7) $d(m + 1, 1) = 1$, 且 $d(j, 1) = 0$, $j = 1, 2, \dots, m$.

显然有 $q_{1,1} = x$, 由 (3) 式可得 $q_{2,1} = 1/(1 + x)$. 假设对一切 $j: 2 \leq j \leq m - 1$, 有 $q_{j,1} = 1/(1 + x)^{j-1}$, 则不难证明 $q_{j+1,1} = 1/(1 + x)^j$. 故由 (3) 式, 得 $q_{m+1,1} = p^+(x)/C$. 在上面的单枝前馈 G 网后增加一个神经元 (O) 组成一个单枝前馈 G 网, 使原 G 网中的各个参数保持不变, 神经元 $(m + 1, 1)$ 的输出率为 $r(m + 1, 1) > 0$, 且

(8) $r(O) = r(m + 1, 1)/(2C)$, 且 $(m + 1, 1)$ 到 (O) 的参数为 $w^+((m + 1, 1), O) = r(m + 1, 1)/2$, $w^-((m + 1, 1), O) = r(m + 1, 1)/2$, 则由 (3) 式得 $q_O = p^+(x)/(1 + p^+(x))$. 证毕

仿照定理 4 的证明, 不难得到如下结果.

定理 5 设 $p(x)$ 是任一形如 (1) 式的一元 G 型多项式, 则存在一个 BG 网, 记其正 G 网输出神经元为 $(O, +)$, 负 G 网输出神经元为 $(O, -)$, 总神经元数目不超过 $2m + 4$, 使对一切 $x \in [0, 1]$, 其输出满足 $p(x) = A_{[O,+]} + A_{[O,-]}$, 即 BG 网可映射 $p(x)$.

证明 令 $c_v^+ = \max\{0, c_v\}$, $c_v^- = \min\{0, c_v\}$, $v = 1, \dots, m$, 和

$$p^+(x) = c_0^+ + c_1^+(1 + x)^{-1} + \dots + c_m^+(1 + x)^{-m} \geq 0 \quad (4)$$

$$p^-(x) = c_0^- + c_1^-(1 + x)^{-1} + \dots + c_m^-(1 + x)^{-m} < 0 \quad (5)$$

那么 $p(x) = p^+(x) + p^-(x)$. 由定理 4 或仿照其证明可知, 存在一个正单枝前馈 G 网和一个负单枝前馈 G 网, 其神经元数目都不超过 $m + 2$, 使得它们的输出分别为

$$q_{[O,+]} = p^+(x)/(1 + p^+(x)) \text{ 和 } q_{[O,-]} = -p^-(x)/(1 - p^-(x)),$$

故 $A_{[0,+]} = q_{[0,+]} / (1 - q_{[0,+]}) = p^+(x)$ 和 $A_{[0,-]} = -q_{[0,-]} / (1 - q_{[0,-]}) = p^-(x)$.

证毕

注 1 文献 [10] 中是利用若干个单枝前馈 G 网映射多项式的. 这样对于一个形如 (1) 式的多项式, 若每项的系数都大于零, 共需要 $1 + 2 + \dots + (m + 1) = (m + 1)(m + 2)/2$ 个神经元; 而利用定理 4, 只要 $m + 2$ 个神经元, 故当 m 较大时, 可减少许多神经元的数目.

2.2 多元 G 型多项式映射的构造性证明

定理 6 设 $p^+(x) = p(x_1, \dots, x_s)$ 是如 (2) 式的多项式, 且对一切 (m_1, m_2, \dots, m_s) 满足 $c(m_1, \dots, m_s) \geq 0$, 其中 $\sum_{v=1}^s m_v = m$, 则存在具有唯一输出神经元 (O) 的分枝前馈 G 网, 使得其输出 $q_O = p^+(x)/(1 + p^+(x))$ 和 $A_O = p^+(x)$.

证明 假设 $p^+(x)$ 的所有非零项共有 N 项, 设为

$$c(m_{11}, \dots, m_{1s}) \prod_{v=1}^s (1 + x_v)^{-m_{1v}}, \dots, c(m_{N1}, \dots, m_{Ns}) \prod_{v=1}^s (1 + x_v)^{-m_{Nv}} \quad (6)$$

其中 $c(m_{11}, \dots, m_{1s}) > 0, \dots, c(m_{N1}, \dots, m_{Ns}) > 0, \sum_{t=1}^s m_{kt} = m, m_{kt} \geq 0, 1 \leq k \leq N$.

下面将构造一个分枝前馈 G 网来映射 $p^+(x)/(1 + p^+(x))$. 首先构造 s 个子 G 网, 然后再将它们连接起来组成一个分枝前馈 G 网来完成该映射, 其中第一个子网络为单枝前馈 G 网, 其它的则是分枝前馈 G 网. 构造过程分成以下两步:

2.2.1 各个子网络的构造 第一个子网络为单枝前馈 G 网, 其构造如下: 令 $m_1 = \max(m_{11}, \dots, m_{N1}) > 0$, 该子网具有 $m_1 + 1$ 个神经元, 每层的神经元分别记为 $(1, 1), \dots, (1, m_1 + 1)$, 各参数为

- (1) $\Lambda(1, 1) = x_1, \Lambda(1, 2) = 1/m_1, \Lambda(1, j) = 0$, 对于 $j = 3, \dots, m_1 + 1$;
- (2) $\lambda(1, 1) = 0, \lambda(1, j) = 0$ 和 $r(1, j) = 1/m_1$, 对于 $j = 1, 2, \dots, m_1 + 1$;
- (3) $w^-(1, 1), (1, j) = 1/m_1$, 对于 $j = 2, \dots, m_1 + 1$;
- (4) $w^+((1, 1), (1, j)) = 0, j = 2, \dots, m_1 + 1, w^+((1, j), (1, j + 1)) = 1/m_1, j = 2, \dots, m_1$; 不难证明各个神经元 $(1, j + 1)$ 的输出为 $q_{1,j+1} = 1/(1 + x_1)^j, j = 1, \dots, m_1$.

第二个子网为分枝前馈 G 网, 其构造如下: 首先约定在 (6) 式各项关于 x_2 的次数 $m_{12}, m_{22}, \dots, m_{N2}$ 的非零数中, 当某两个相等时, 设 $m_{i2} = m_{j2}, i \neq j$, 且 $m_{i1} = m_{j1}$, 则 m_{i2} 与 m_{j2} 只算一个, 否则算两个不同的元素. 这样一共有 t_2 个非零的不同元素, 设为 $m_{2k1}, m_{2k2}, \dots, m_{2kt_2}, m_{2ki} \in \{m_{12}, m_{22}, \dots, m_{N2}\}, 1 \leq i \leq t_2$. 若 $t_2 = 0$, 则无 x_2 确定的第二个子网络; 当 $t_2 > 0$ 时, 它的第一层只有一个神经元 $(2, 1)$ 或 $(2, 1, 1)$, 设其参数为

- (1) $\Lambda(2, 1, 1) = x_2$, 它的第二层一共有 t_2 个神经元, 分别设为 $(2, 2, m_{2k1}), \dots, (2, 2, m_{2kt_2})$, 其中记号中的第一个分量 2 表示第二个网络, 第二个分量 2 表示它的第二层. 第一层神经元 $(2, 1, 1)$ 与每个神经元 $(2, 2, m_{2k1}), \dots, (2, 2, m_{2kt_2})$ 都有连接. 但第二层的每个神经元 $(2, 2, m_{2ki}), i = 1, \dots, t_2$, 都是单对单地连接到第三层, 这样直到第 $m_{2ki} + 1$ 层的神经元. 各层的神经元记为 $(2, 3, m_{2ki}), \dots, (2, m_{2ki} + 1, m_{2ki}), i = 1, \dots, t_2$. 第 i 个分支的参数设置为

- (2) $\Lambda(2, j, m_{2ki}) = 0$, 对于 $j = 2, \dots, m_{2ki} + 1$, 其中 $i = 1, 2, \dots, t_2$;
- (3) $\lambda(2, 1) = 0, \lambda(2, j, m_{2ki}) = 0$ 和 $r(2, j, m_{2ki}) = 1/m_{2ki}$, 对于 $j = 2, \dots, m_{2ki} + 1$;
- (4) $w^-((2, 1), (2, j, m_{2ki})) = 1/m_{2ki}$, 对于 $j = 2, \dots, m_{2ki} + 1$;
- (5) $w^+((2, 1), (2, j, m_{2ki})) = 0$, 对于 $j = 2, \dots, m_{2ki} + 1$;
- (6) $w^+((2, j, m_{2ki}), (2, j + 1, m_{2ki})) = 1/m_{2ki}$, 对于 $j = 2, \dots, m_{2ki}$;

第三至第 s 个子网都是分枝前馈 G 网, 参数设置与上相似, 故不再赘述.

2.2.2 子网络间的连接 下面给出各子网络间的连接方式, 以 (6) 式的第一项如何映射为例, 其它项相同.

若 $m_{11} \neq 0$, 则在第一个网络的第 $m_{11} + 1$ 神经元引出一条连接线, 若 $m_{12} \neq 0$, 则将它连接到第二个子网络的第二层的某个具有 m_{12} 个神经元的分支上, 其参数为 $w^+((1, m_{11} + 1), (2, 2, m_{12})) = 1/m_{12}$, 则由 (3) 式, $q_{2,2,m_{12}} = 1/\{(1+x_1)^{m_{11}}(1+x_2)\}$. 若 $m_{12} = 0$, 设 $m_{1i} \neq 0$, 且 $m_{1j} = 0, 1 < j < i$, 即 m_{1i} 是 m_{11} 后第一个非零的数, 则将它连接到第 i 个子网络的第二层的某个具有 m_{1i} 个神经元的分支上, 取其参数为 $w^+((1, m_{11} + 1), (i, 2, m_{1i})) = 1/m_{1i}$; 然后再从这一分支的最后一个神经元引出一条连接线, 其方式与上面相同, 直到 $m_{11}, m_{12}, \dots, m_{1N}$ 中的最后一个非零次数对应的变量所确定的网络上. 显然, 其最后一个神经元 $(O, 1)$ 的输出为 $q_{(O,1)} = \prod_{v=1}^s (1+x_v)^{-m_{1v}}$.

若 $m_{11} = 0$, 则在 $m_{11}, m_{12}, \dots, m_{1N}$ 中找出第一个不为零的数, 设为 $m_{1i}, i > 1$. 在变量 x_i 所确定的第 i 个网络中找出一个具有 m_{1i} 个神经元的分支, 从这一分支出发进行与以上相似的连接同样可得到输出 $q_{(O,1)} = \prod_{v=1}^s (1+x_v)^{-m_{1v}}$.

对 (6) 式中其它项也作与以上相似的连接, 可得一个 G 网. 设它各个分支的最后输出神经元分别为 $(O, 1), \dots, (O, N)$, 则它们输出的全体为

$$q_{(O,1)} = \prod_{v=1}^s (1+x_v)^{-m_{1v}}, \dots, q_{(O,N)} = \prod_{v=1}^s (1+x_v)^{-m_{Nv}}$$

设 $C = \max\{1, \max(c(m_{k1}, \dots, m_{ks}), k = 1, \dots, N)\}$. 在每个输出神经元的后面增加一个神经元 (O) , 各个神经元 $(O, 1), \dots, (O, N)$ 到 (O) 的连接参数为

$$(1) w^+((O, j), O) = c(m_{j1}, \dots, m_{js})/(2C), \quad j = 1, \dots, N;$$

$$(2) w^-((O, j), O) = c(m_{j1}, \dots, m_{js})/(2C), \quad j = 1, \dots, N;$$

(3) $\Lambda(O) = \lambda(O) = 0, r(O) = 1/(2C)$. 由 (3) 式, 得 $q_O = p^+(x)/(1+p^+(x))$, 因而 $A_O = p^+(x)$. 证毕

注 2 由证明过程, 所需神经元数不超过 $1 + s + m_1 + \sum_{u=2}^N \sum_{v=2}^s m_{ukt_v} \leq 1 + s + \sum_{u=1}^N \sum_{v=1}^s m_{uv}$.

与一元 G 型多项式情形一样可得下面的结果.

定理 7 设 $p(x)$ 是任一形如 (2) 式的齐次多元多项式, 则存在一个 BG 网, 记其正网的输出神经元为 $(O, +)$, 负网的输出神经元为 $(O, -)$, 对一切输入变量 x , 其输出满足 $p(x) = A_{[O,+]} + A_{[O,-]}$, 即 BG 网可映射任意齐次 G 型多项式.

注 3 由以上证明方法知, 对于一般非齐次 G 型多项式也可用 BG 网来映射.

下面用例子说明 G 网在映射多元 G 型多项式时, 本文所得结果较文献 [10] 的优越之处.

例 1 设 $p(x, y, z) = (1+x)^{-6}(1+y)^{-3}(1+z)^{-1} + (1+x)^{-6}(1+y)^{-1}(1+z)^{-3} + (1+x)^{-4}(1+y)^{-4}(1+z)^{-2} + (1+x)^{-4}(1+y)^{-2}(1+z)^{-4}$, 则利用文献 [10] 的方法需要 $(7+4+2) + (7+2+4) + (5+5+3) + (5+3+5) + 1 = 53$ 个神经元; 而用本文的方法需要 $7 + (1+3+1+4+2) + (1+1+3+2+4) + 1 = 30$ 个神经元, 减少了 1/3 多的神经元数目.

3 结 论

本文采用更精细的构造性证明方法得到了 G 网能映射任意的 G 型多项式, 从而可逼近任意连续函数. 从给出的例子可看出, 利用本文的方法映射 G 型多项式较文献 [10] 中的方法所用 G 网的神经元数要少许多, 因而更加精确. 这样在应用时更加方便.

参 考 文 献

- [1] C. Chui, X. Li, Approximation by ridge functions and neural networks with one hidden layer, *Journal of Approximation Theory*, 1992, 70(2), 131-141.
- [2] 韦岗, 李华, 徐秉铮, 关于前馈多层神经网络多维函数逼近能力的一个定理, *电子科学学刊*, 1997, 19(4), 433-438.
- [3] 韦岗, 贺前华, 欧阳景正, 关于多层感知器的函数逼近能力, *信息与控制*, 1996, 25(6), 321-324.
- [4] K. Hornik, Some results on neural network approximation, *Neural Networks*, 1993, 6(8), 1069-1072.
- [5] J. Park, I. W. Sandberg, Universal approximation using radial-basis-function networks, *Neural Comput.*, 1991, 3(2), 246-257.
- [6] E. Gelenbe, Y. Feng, K. R. R. Krishnan, Neural network methods for volumetric magnetic resonance imaging of the human brain, *Proc. IEEE.*, 1996, 84(10), 1529-1543.
- [7] E. Gelenbe, Random neural networks with negative and positive signals and product form solution, *Neural Comput.*, 1989, 1(4), 502-511.
- [8] E. Gelenbe, Learning in the recurrent random neural network, *Neural Comput.*, 1993, 5(1), 154-164.
- [9] E. Gelenbe, A. Stafylopatis, A. Likas, Associative memory operation of the random network model, in *Proc. Int. Conf. Artificial Neural Networks*, Helsinki, Finland, 1991, 307-312.
- [10] E. Gelenbe, Z. H. Mao, Y. D. Li, Function approximation with spiked random networks, *IEEE Trans. on Neural Networks*, 1999, NN-10(1), 3-9.

CONSTRUCTIONAL METHOD OF
FUNCTION APPROXIMATION OF GNN

Wei Gang Tian Chuanjun

(College of Electron. and Info. Eng., South China Uni. of Tech., Guangzhou 510641, China)

Abstract In this paper, the function approximation of Gelenbe Neural Network (GNN) is discussed and it is proved that GNN can approximate any G-type polynomial by using constructional method. Number of units used by this method can be reduced to $2/(n+1)$ of that used by previous methods for a same G-type polynomial, where n is the degree of G-type polynomial.

Key words Neural network, GNN, Function approximation, G-type polynomial

韦 岗: 男, 1963 年生, 教授, 博士生导师, 国家自然科学基金委员会电子与信息学科评委; 中国电子学会通信学分会、电子线路与系统分会及信息论分会委员; 中国通信学会通信理论委员会委员。主要研究方向为通信与信号处理, 神经网络等。

田传俊: 男, 1964 年生, 副教授, 博士生, 主要研究方向为神经网络, 微分和差分方程稳定性等。