

# 区间小波神经网络(II)——性质与模拟\*

高协平<sup>1,3</sup> 张钹<sup>2,3</sup>

<sup>1</sup>(湘潭大学数学系 湘潭 411105)

<sup>2</sup>(清华大学计算机科学与技术系 北京 100084)

<sup>3</sup>(清华大学智能技术与系统国家重点实验室 北京 100084)

**摘要** 证明了区间小波神经网络具有一致及  $L^2$  逼近性质,且为相容的函数估计子,其学习收敛速度在  $d$  维情形不随  $d$  增大而减慢,本质上克服了神经网络高维学习的“维数灾难”问题,模拟实例验证了理论的正确性.

**关键词** 神经网络,小波,多尺度分析,收敛.

**中图法分类号** TP18

在文献[1]中,我们通过重新定义  $L^2[0,1]$  上的正交多尺度分析,提出了区间小波神经网络模型.对于实际应用中通常限于有界区域(或空间)上的信号处理,该模型与已有其它神经网络<sup>2~4</sup>相比能使用更少的神经元,完全避免了训练过程陷入不期望局部极小的问题.进一步,我们给出了该模型结构设计即隐层神经元数目的较好的上下界估计.本文考虑区间小波神经网络与学习能力相关的几个理论结果,证明了该模型的学习收敛速度在  $d$  维情形下不随  $d$  增大而减慢,本质上解决了神经网络高维学习的“维数灾难”问题,模拟实例与理论结果吻合.

## 1 逼近性质

**定义 1.** 设  $F_j$  是  $R^d$  中函数集合子列,  $F = \bigcup_j F_j$ ,  $U$  是  $R^d$  中紧子集,称  $F$  在  $U$  中具有  $L^p$  ( $1 \leq p \leq \infty$ ) 逼近性质,如果对任意  $f \in L^p(U)$ , 存在  $f_n \in F_n$ , 在  $L^p$  意义下有  $f_n \rightarrow f$ . 特别地,  $p = \infty$  指一致(Universal)逼近性.

从文献[1]中区间小波神经网络的构造(式(1)), 容易知道它有  $L^2$  逼近性质. 实际上,关于其学习能力,我们有下列进一步的定理.

**定理 1.** 区间小波神经网络具有一致和  $L^2$  逼近性质. 设被分析信号  $f$  在  $[0,1]^d$  上有所有  $N_0$  阶连续偏导数, 则存在区间小波神经网络序列  $f_M \in V_M$ , 使  $\|f - f_M\|_\infty = O(h^{N_0})$ ,  $\|f - f_M\|_{L^2} = O(h^{N_0})$ , 这里  $h = \frac{1}{2^M}$ .

证明: 记  $M_{p,k} = \langle x^p, \varphi_{0k} \rangle$ ,  $N_{p,k} = \langle x^p, \psi_{0k} \rangle$ ,  $m_k = \langle |\varphi_k|, 1 \rangle$ ,  $n_k = \langle |\psi_k|, 1 \rangle$ ,

$$\|f^{(N_0+1)}\|_\infty = \max \left\{ \left| \frac{\partial^{N_0+1}}{\partial x_1^{p_1} \dots \partial x_d^{p_d}} f(x_1, \dots, x_d) \right|; p_1 + \dots + p_d = N_0 + 1, p_i \geq 0 \right\},$$

$$D^m = \{g(x) \mid |g(x)| \leq c \cdot (1 + |x|)^{-(m+1+\epsilon)}, \epsilon > 0\},$$

其余记号沿用文献[1].

设  $\varphi, \psi \in D^{N_0}$ , 由  $L^2[0,1]$  上的正交多尺度分析构造知,  $V_j$  包含所有  $\leq N_0 - 1$  次代数多项式全体, 因此有

$$N_{p,k} = 0, \text{ 对 } 0 \leq p \leq N_0 - 1 \quad (1)$$

这样,我们甚至可以把结论证明得更多一点,即给出误差渐近展式.

设  $f(x_1, \dots, x_d)$  在  $V_n, W_n$  空间的投影算子分别为  $P_n, Q_n$ , 则

$$P_n f(x_1, \dots, x_d) = \sum_{k_1, \dots, k_d \in J_n} \langle f(y_1, \dots, y_d), \prod_{l=1}^d \varphi_{k_l}(y_l) \rangle \prod_{l=1}^d \varphi_{k_l}(x_l) \quad (2)$$

\* 本研究得到国家自然科学基金、国家 863 高科技项目基金和国家攀登计划基金资助. 作者高协平, 1965 年生, 副教授, 主要研究领域为计算智能, 计算数学及应用软件. 张钹, 1935 年生, 教授, 博士生导师, 中国科学院院士, 主要研究领域为人工智能, 计算机应用技术.

本文通讯联系人: 高协平, 湘潭 411105, 湘潭大学数学系

本文 1997-01-21 收到原稿, 1997-09-01 收到修改稿

$$Q_d f(x_1, \dots, x_d) = \sum_{i=0}^{d-1} \sum_{u=D}^M \sum_{\substack{k_1, \dots, k_i \in J_{\rho_i} \\ q_{i+1}, \dots, q_d \in I_{\rho_i}}} \langle f(y_1, \dots, y_d), \prod_{l=1}^i \varphi_{k_l}(y_{u_l}) \cdot \prod_{l=i+1}^d \psi_{m_l}(y_{u_l}) \rangle \cdot \prod_{l=1}^i \varphi_{k_l}(x_{u_l}) \cdot \prod_{l=i+1}^d \psi_{m_l}(x_{u_l}) \quad (3)$$

注意到  $L^i([0, 1]^d) = V_M \oplus_{j \geq M} W_M$ , 所以

$$\varepsilon_M f(x_1, \dots, x_d) \triangleq f(x_1, \dots, x_d) - P_M f(x_1, \dots, x_d) = \sum_{j \geq M} Q_j f(x_1, \dots, x_d) \quad (4)$$

设在  $[0, 1]^d$  上  $f(x_1, \dots, x_d)$  有所有  $N_0 + 1$  阶连续偏导数, 将式(3)中  $f(y_1, \dots, y_d)$  在  $(x_1, \dots, x_d)$  处作 Taylor 展开, 我们有

$$\begin{aligned} Q_j f(x_1, \dots, x_d) &= \sum_{i=0}^{d-1} \sum_{u=D}^M \sum_{\substack{k_1, \dots, k_i \in J_{\rho_i} \\ q_{i+1}, \dots, q_d \in I_{\rho_i}}} \sum_{\substack{0 \leq p_1 + \dots + p_d = N_0 \\ p_{i+1}, \dots, p_d \geq 0}} \frac{\partial^i f(x_{u_1}, \dots, x_{u_d})}{\partial x_{u_1}^{p_1} \dots \partial x_{u_d}^{p_d}} \cdot \frac{1}{(\rho_1)! \dots (\rho_d)!} \times \\ &\quad \langle \prod_{l=1}^i (y_{u_l} - x_{u_l})^{p_l}, \prod_{l=1}^i \varphi_{k_l}(y_{u_l}) \cdot \prod_{l=i+1}^d \psi_{m_l}(y_{u_l}) \rangle \prod_{l=1}^i \varphi_{k_l}(x_{u_l}) \cdot \prod_{l=i+1}^d \psi_{m_l}(x_{u_l}) + \\ &\quad \sum_{i=0}^{d-1} \sum_{u=D}^M \sum_{\substack{k_1, \dots, k_i \in J_{\rho_i} \\ q_{i+1}, \dots, q_d \in I_{\rho_i}}} \sum_{\substack{p_1 + \dots + p_d = N_0 + 1 \\ p_{i+1}, \dots, p_d \geq 0}} \frac{1}{(\rho_1)! \dots (\rho_d)!} \prod_{l=1}^i \varphi_{k_l}(x_{u_l}) \cdot \prod_{l=i+1}^d \psi_{m_l}(x_{u_l}) \times \\ &\quad \langle \frac{\partial^{N_0+1} f(x_1^*, \dots, x_d^*)}{\partial x_{u_1}^{p_1} \dots \partial x_{u_d}^{p_d}} \cdot \prod_{l=1}^i (y_{u_l} - x_{u_l})^{p_l}, \prod_{l=1}^i \varphi_{k_l}(y_{u_l}) \cdot \prod_{l=i+1}^d \psi_{m_l}(y_{u_l}) \rangle \\ &= \Delta_j + \rho_j \end{aligned} \quad (5)$$

这里  $x^* = x^*(x_{u_1}, y_{u_1}), x^* = 1(1)d$ .

先估计第 2 项  $\rho_j$  (记  $H = 2^{-j}, h = 2^{-M}$ ):

$$\begin{aligned} \textcircled{1} &\stackrel{\text{def}}{=} \langle |(y_{u_l} - x_{u_l})^{p_l}|, |\varphi_{k_l}(x_{u_l})| \rangle \cdot |\varphi_{k_l}(x_{u_l})| \stackrel{t_{u_l} = 2^j y_{u_l}}{=} H^{p_l} \cdot \langle |(t_{u_l} - 2^j x_{u_l})^{p_l}|, |\varphi_{k_l}(t_{u_l})| \rangle \cdot |\varphi_{k_l}(2^j x_{u_l})| \\ &\leq H^{p_l} \cdot \sum_{v_l=0}^{p_l} \left[ \binom{p_l}{v_l} \cdot |2^j x_{u_l}|^{v_l} \cdot \langle |t_{u_l}|^{p_l-v_l}, |\varphi_{k_l}(t_{u_l})| \rangle \right] \cdot |\varphi_{k_l}(2^j x_{u_l})| \\ &\leq H^{p_l} \cdot (1 + |2^j x_{u_l}|)^{p_l} \cdot |\varphi_{k_l}(2^j x_{u_l})| \\ &\left[ \because \varphi \in D^{N_0}, \therefore \langle |t_{u_l}|^{p_l-v_l}, |\varphi_{k_l}(t_{u_l})| \rangle \leq \int_0^1 \frac{|t_{u_l}|^{p_l-v_l}}{(1+|t_{u_l}|)^{N_0+1+s}} dt_{u_l} \leq 1 \right] \end{aligned}$$

$$\textcircled{2} \stackrel{\text{def}}{=} \langle |(y_{u_l} - x_{u_l})^{p_l}|, |\psi_{m_l}(y_{u_l})| \rangle \cdot |\psi_{m_l}(x_{u_l})| \leq H^{p_l} \cdot (1 + |2^j x_{u_l}|)^{p_l} \cdot |\psi_{m_l}(2^j x_{u_l})|$$

$$\begin{aligned} \therefore |\rho_j| &\leq \sum_{i=0}^{d-1} \sum_{u=D}^M \sum_{\substack{k_1, \dots, k_i \in J_{\rho_i} \\ q_{i+1}, \dots, q_d \in I_{\rho_i}}} \sum_{\substack{p_1 + \dots + p_d = N_0 + 1 \\ p_{i+1}, \dots, p_d \geq 0}} \frac{\|f^{(N_0+1)}\|_{\infty}}{(\rho_1)! \dots (\rho_d)!} \cdot \prod_{l=1}^i \textcircled{1} \cdot \prod_{l=i+1}^d \textcircled{2} \\ &\leq H^{N_0+1} \cdot \sum_{\substack{p_1 + \dots + p_d = N_0 + 1 \\ p_{i+1}, \dots, p_d \geq 0}} \frac{\|f^{(N_0+1)}\|_{\infty}}{(\rho_1)! \dots (\rho_d)!} \sum_{i=0}^{d-1} \sum_{u=D}^M \sum_{\substack{k_1, \dots, k_i \in J_{\rho_i} \\ q_{i+1}, \dots, q_d \in I_{\rho_i}}} \\ &\quad \prod_{l=1}^i (1 + |2^j x_{u_l}|)^{p_l} \cdot |\varphi_{k_l}(2^j x_{u_l})| \cdot \prod_{l=i+1}^d (1 + |2^j x_{u_l}|)^{p_l} \cdot |\psi_{m_l}(2^j x_{u_l})| \\ &\leq C \cdot H^{N_0+1} (\because \varphi, \psi \in D^{N_0}). \end{aligned}$$

这里  $C$  是与  $h, j$  无关的有界常数, 所以

$$\sum_{j \geq M} |\rho_j| \leq C \cdot h^{N_0+1} \quad (6)$$

再看第 2 项  $\Delta_j$ , 令

$$\begin{aligned} \lambda_{j, i, k_1, q_{i+1}, u} &= \langle \prod_{l=1}^i (y_{u_l} - x_{u_l})^{p_l}, \prod_{l=1}^i \varphi_{k_l}(y_{u_l}) \cdot \prod_{l=i+1}^d \psi_{m_l}(y_{u_l}) \rangle \\ &= \prod_{l=1}^i \langle (y_{u_l} - x_{u_l})^{p_l}, \varphi_{k_l}(y_{u_l}) \rangle \cdot \prod_{l=i+1}^d \langle (y_{u_l} - x_{u_l})^{p_l}, \psi_{m_l}(y_{u_l}) \rangle \end{aligned}$$

注意  $N_{p, k} = 0$ , 对  $0 \leq p \leq N_0 - 1$ ,

$$\therefore \langle (y_{u_l} - x_{u_l})^{p_l}, \varphi_{k_l}(y_{u_l}) \rangle = 0, \text{ 对 } 0 \leq p_l \leq N_0 - 1.$$

故

$$\lambda_{j,i,k,q_{i+1},u} \begin{cases} = 0, & \text{当 } p < N_0 \text{ 或 } p = N_0 \text{ 但 } i < d-1 \\ & \text{或 } p = N_0 \text{ 且 } i = d-1 \text{ 但 } p_{u_d} < N_0 \\ \neq 0, & \text{当 } p = N_0 \text{ 且 } i = d-1 \text{ 且 } p_{u_d} = N_0 \\ & \text{(此时 } p_{u_l} = 0, \text{ 对 } 1 \leq l \leq d-1) \end{cases}$$

∴

$$\lambda_{j,i,i_1,q_{i+1},u} = H^{N_0} \cdot \prod_{l=1}^d M_{u_l} \cdot N_{N_0,q_d} \cdot 2^{-jd/2}$$

定义函数  $\sigma_{j,u}(x_1, \dots, x_d) \in L^2([0, 1]^d)$  如下:

$$\sigma_{j,u}(x_1, \dots, x_d) = \sum_{\substack{k_1, \dots, k_{d-1} \in J_j \\ q_d \in L_j}} 2^{-(j-M)N} \cdot N_{N_0,q_d} \varphi(2^j x_{u_1}) \prod_{l=1}^{d-1} (M_{u_l} \psi(2^j x_{u_l}))$$

则对  $j \geq M$ , 有

$$A_j = \frac{h^{N_0}}{N_j!} \sum_{u \in U} \left( \frac{\partial^{N_0} f(x_1, \dots, x_d)}{\partial x_{u_d}^{N_0}} \cdot \sigma_{j,u}(x_1, \dots, x_d) \right) \tag{7}$$

定义  $\tau_{M,u}(x_1, \dots, x_d)$  为一个一致收敛级数的有界函数:

$$\tau_{M,u}(x_1, \dots, x_d) = \sum_{i=0}^{\infty} \sigma_{M+i,u}(x_1, \dots, x_d) \tag{8}$$

于是由式(4)、(6)~(8)得到

$$\varepsilon_M f(x_1, \dots, x_d) = \frac{h^{N_0}}{N_0!} \sum_{u \in U} \left( \frac{\partial^{N_0} f(x_1, \dots, x_d)}{\partial x_{u_d}^{N_0}} \cdot \tau_{M,u}(x_1, \dots, x_d) \right) + O(h^{N_0+1}).$$

这样,定理 1 按  $\|\cdot\|_{\infty}$  收敛结论显然成立. 对  $[0, 1]^d$  上的  $L^2$  收敛性, 只需注意

$$\int_{[0,1]^d} |f(x_1, \dots, x_d)|^2 dx_1 \dots dx_d \leq \text{Sup}_{x_i \in [0,1]} |f(x_1, \dots, x_d)|^2$$

于是,定理 1 得证.

注记: 在神经网络的逼近性质研究中, 收敛速度的估计是十分重要的内容. 设  $q$  表示被逼近函数  $f$  的可微指标, 对径向基函数(RBF)神经网络, 文献[4]提到: Girosi 和 Anzellotti 得到了其一致与  $L^2$  逼近敛速  $O(n^{-\frac{1}{2}})$ ; Corradi, White 和 Xu 等得到其  $L^2$  敛速  $O(n^{-1/(1+d/2q)})$  (详见文献[4]的参考文献[6~8]). 这些收敛速度估计, 后者显然依赖于维数  $d$ , 除非  $f$  无穷光滑, 而前者虽然表面上独立于维数  $d$ , 但被逼近函数类将随维数  $d$  增加而缩小, 因此, 实质上是依赖于维数的; Zhang Q, Benveniste 在文献[3]中提出了一类(标架)小波神经网络, Delyon, Benveniste 等在文献[5]中得到了其  $L_2$  敛速  $O(n^{-\alpha/d})$ , 显然随着维数  $d$  的增大, 收敛速度减慢; Zhang J 等在文献[4]中提出了另一类(正交)小波神经网络, 并给出其一致和  $L^2$  敛速度估计  $O(h^\alpha)$ , 同样不幸的是,  $\alpha$  依赖于维数  $d$  及函数的光滑度  $q$ , 虽然类似于 Girosi, Anzellotti 关于 RBF 的结果, 随着  $d$  增大以缩小函数类为代价可以避开“维数灾难”, 但这绝非根本性的. 因此, “维数灾难”问题并没有真正解决. 本文定理 1 指出, 区间小波神经网络的一致及  $L^2$  收敛速度完全与维数  $d$  无关, 不随  $d$  的增大而减慢, 同时, 对  $f$  的光滑性要求仅与所取多尺度分析相关而不依赖于维数  $d$ , 因此, 从本质上彻底解决了高维学习的“维数灾难”问题. 从我们的证明过程容易看出, 文献[4]的“维数灾难”缘于其证明方法, 而采用完全平行于本文方法, 其“维数灾难”是可以本质解决的.

### 2 相容性质

定义 2. 一个函数估计子(如区间小波神经网络)称为是  $L^p$  相容的, 如果随着训练样本数趋于无穷大, 估计子在  $L^p$  意义下收敛于被逼近函数.

记

$$K = \{k \mid k = (k_1, \dots, k_d), k_i \in J_M, i = 1(1)d, x = (x_1, \dots, x_d)\}$$

设对某足够大的  $M, f \in V_M$ , 则

$$f(x) = \sum_{k \in K} c_k^{(0)} \varphi_{M,k}(x) \tag{9}$$

$$c_k^{(0)} = \langle f, \varphi_{M,k} \rangle$$

这里

设  $\tilde{f}_{M,N}(x)$  是关于  $f(x)$  由训练数据集  $T_N$  的一个区间小波神经网络实现, 则

$$\tilde{f}_{M,N}(x) = \sum_{k \in K} \tilde{c}_{N,k} \varphi_{M,k}(x) \quad (10)$$

其中系数  $\tilde{c}_{N,k}$  由文献[1]提供的算法(4)(5)获取.

由多尺度分析的规范正交性, 有

$$\begin{aligned} E[\|f - \tilde{f}_{M,N}\|^2] &= E\left[\int_{[0,1]^2} (f(x) - \tilde{f}_{M,N}(x))^2 dx\right] \\ &= E\left[\int_{[0,1]^2} \left(\sum_{k \in K} (c_k^{(0)} - \tilde{c}_{N,k}) \varphi_{M,k}(x)\right)^2 dx\right] \\ &= E\left[\sum_{u \in K} \sum_{v \in K} (c_u^{(0)} - \tilde{c}_{N,u})(c_v^{(0)} - \tilde{c}_{N,v}) \langle \varphi_{M,u}, \varphi_{M,v} \rangle\right] \\ &= E\left[\sum_{k \in K} (c_k^{(0)} - \tilde{c}_{N,k})^2\right] = \sum_{k \in K} E[(c_k^{(0)} - \tilde{c}_{N,k})^2] \quad (11) \end{aligned}$$

**定理 2.** 设训练样本集  $T_N = \{(x^{(i)}, y^{(i)}), i = 1(1)N\}$  是独立恒等分布和一致分布的,  $\tilde{f}_{M,N}(x)$  是  $f \in V_M$  的区间小波神经网络实现, 则

$$E[(c_k^{(0)} - \tilde{c}_{N,k})^2] = O\left(\frac{1}{N}\right), \quad k \in K \quad (12)$$

从而区间小波神经网络在均方根期望意义下是  $L^2$  相容的, 且收敛速度为  $O\left(\frac{1}{N}\right)$ .

证明: 注意到式(11), 故只需证式(12)为真即可, 过程完全类似于文献[4], 从略.

**推论.** 在定理 2 的条件下, 设对任何  $M, f \in L^2([0, 1]^2)$  但  $f \notin V_M$ ,  $\tilde{f}_{M,N}$  是  $f$  的区间小波神经网络实现, 则它在均方根期望意义下是  $L^2$  相容的.

事实上, 取  $N > n = 2^M$ , 并让  $n \rightarrow \infty$  (从而  $N \rightarrow \infty$ ), 由定理 1, 存在一个区间小波神经序列  $f_n \in V_M$ , 使  $f_n \xrightarrow{L^2} f (n \rightarrow \infty)$ ; 由定理 2, 存在序列  $\tilde{f}_{M,N}$ , 使  $\tilde{f}_{M,N} \xrightarrow{L^2} f_n (N \rightarrow \infty)$ . 这样, 对充分大的  $n$  和  $N$ , 有

$$E[\|f - \tilde{f}_{M,N}\|^2] \leq \|f - f_n\|^2 + E[\|f_n - \tilde{f}_{M,N}\|^2] \xrightarrow{L^2} 0.$$

### 3 模拟实验

本节给出了区间小波神经网络及  $L^2(R)$  小波神经网络<sup>[4]</sup>的模拟实例结果. 为了科学地评价逼近效果, 对样本数据集  $T_N = \{(x^{(j)}, y^{(j)})\}_{j=1}^N$  和神经网络输出  $f_{M,N}(x)$ , 采用如下评判标准:

$$\varepsilon_{\Delta} E(f_{M,N}) = \sqrt{\frac{\sum_{j=1}^N [f_{M,N}(x^{(j)}) - y^{(j)}]^2}{\sum_{j=1}^N (\bar{y} - y^{(j)})^2}}$$

其中  $\bar{y} = \frac{1}{N} \sum_{j=1}^N y^{(j)}$ . 分别使用  $N_0 = 2$  的 Daubechies 小波和相应的区间小波. 模拟结果见表 1, 2. 它们验证了理论的正确性.

例 1:

$$f(x) = \begin{cases} 43.72x - 8.996, & 0 \leq x < 0.4 \\ -84.92x + 42.46, & 0.4 \leq x \leq 0.5 \\ 10e^{-2} \sin(12x^2 + 2x - 4), & 0.5 < x \leq 1 \end{cases} \quad (13)$$

取一致样本数  $N = 128$ .

例 2:

$$g(x, y) = (x^2 + y^2) \sin \frac{\pi}{2} x \cdot \sin \frac{\pi}{2} y, 0 \leq x, y \leq 1 \quad (14)$$

取一致样本数  $N = 1024$ .

表1 对  $f(x)$  的逼近

方法	隐层单元数	迭代次数	误差控制 $\epsilon$
区间小波网	32	5	0.049 449
$L^2(\mathcal{R})$ 小波网	34	62	0.048 261

表2 对  $g(x, y)$  的逼近

方法	隐层单元数	迭代次数	误差控制 $\epsilon$
区间小波网	462	4	0.046 756
$L^2(\mathcal{R})$ 小波网	510	17	0.042 194

## 参考文献

- 1 高协平, 张钹. 区间小波神经网络(I)——理论与实现. 软件学报, 1998, 9(3): 217~221  
(Gao Xie-ping, Zhang Bo. Interval-wavelets neural networks(I)— theory and implements. Journal of Software, 1998, 9(3): 217~221)
- 2 Pati Y C, Krishnaprasad P S. Analysis and synthesis of feedforward neural networks using discrete affine wavelet transformations. IEEE Transactions on Neural Networks, 1993, 4(1): 73~85
- 3 Zhang Q, Benveniste A. Wavelet networks. IEEE Transactions on Neural Networks, 1992, 3(6): 889~898
- 4 Zhang J, Walter G G, Miao Y *et al.* Wavelet neural networks for function learning. IEEE Transactions on Signal Processing, 1995, 43(6): 1485~1497
- 5 Delyen B, Juditsky A, Benveniste A. Accuracy analysis for wavelet approximations. IEEE Transactions on Neural Networks, 1995, 6(2): 332~348

## Interval-wavelets Neural Networks (II)—— Properties and Experiment

GAO Xie-ping<sup>1,3</sup> ZHANG Bo<sup>2,3</sup><sup>1</sup>(Department of Mathematics Xiangtan University Xiangtan 411105)<sup>2</sup>(Department of Computer Science and Technology Tsinghua University Beijing 100084)<sup>3</sup>(National Key Laboratory of Intelligent Technology and Systems Tsinghua University Beijing 100084)

**Abstract** In the present paper, it is proved that the interval wavelets neural networks has universal and  $L^2$  approximation properties and is a consistent function estimator. Convergence rates associated with these properties do not decrease as  $d$  increases in  $d$ -dimensional function learning, *i. e.*, the “curse of dimensionality” is eliminated substantially. In the experiments, the proposed interval wavelet neural networks, compared to traditional wavelet networks, has performed better.

**Key words** Neural network, wavelets, multiresolution analysis, convergence.