

基于BP神经网络的农机总动力预测*

王吉权^{1,2} 王福林¹ 邱立春²

(1. 东北农业大学工程学院, 哈尔滨 150030; 2. 沈阳农业大学工程学院, 沈阳 110161)

【摘要】 分析了BP神经网络用于预测时存在的不足,进而对基于BP神经网络的时间序列的预测问题进行了探讨。根据BP神经网络结构的特点,依据Z变换理论,提出了这一类预测问题可选用 $y=x$ 作为传递函数,并分析指出了在BP神经网络中,以 $y=x$ 作为传递函数与 $y=a+bx$ 作为传递函数等价的结论,同时指出了网络结构应分为两层网络。在此基础上,推导了相应的计算公式,并分别以单极性S型函数和 $y=x$ 作为传递函数,对于具有增长趋势的农机总动力预测问题进行了实例计算。计算结果表明,以 $y=x$ 作为传递函数的BP神经网络在外推效果、训练样本的数据处理区间影响方面明显优于S型传递函数的BP神经网络,并且克服了S型传递函数的BP神经网络在预测问题中存在的不足。

关键词: 农机总动力 预测 传递函数 BP神经网络

中图分类号: S23-01 **文献标识码:** A **文章编号:** 1000-1298(2011)12-0121-06

Prediction of Total Power in Agriculture Machinery
Based on BP Neural Network

Wang Jiquan^{1,2} Wang Fulin¹ Qiu Lichun²

(1. College of Engineering, Northeast Agricultural University, Harbin 150030, China

2. College of Engineering, Shenyang Agricultural University, Shenyang 110161, China)

Abstract

Based on analysis of the deficiencies of the BP neural network used in prediction, the time series prediction based on BP neural network was discussed. According to the characteristics of BP network structure and Z transform theory, function $y=x$ was put forward to be the transfer function in this kind of prediction. Besides, the conclusion that function $y=x$ and $y=a+bx$ were equivalent in the BP network was proposed. It was pointed out that the layer of network structure should be two. On basis of this, the corresponding formula was derived. With the unipolar S-function and function $y=x$ as the transfer function respectively, the total power of agriculture machinery was calculated. The results showed that the performance of function $y=x$ in BP neural network was better than S-transfer function in external push effect and influences of training sample data processing interval. It also overcame the shortcomings of S-function used in BP neural network.

Key words Total power of agriculture machinery, Prediction, Transfer function, BP neural network

引言

农机总动力是指用于农、林、牧、渔业生产和运输的所有机械动力的总和,它反映一个地区农机装

备的总体水平,是农机化发展规划的主要指标^[1~4]。同时,农机总动力的预测精度又是引导农机化发展与宏观调控的基础性工作。为了提高农机总动力的预测精度,已探讨和研究了许多科学的预测方法。

收稿日期: 2010-06-30 修回日期: 2010-08-23

* 国家自然科学基金资助项目(31071331)和黑龙江省教育厅科学技术研究资助项目(12511049)

作者简介: 王吉权,副教授,沈阳农业大学博士生,主要从事农业装备工程技术研究,E-mail: wang-jiquan@163.com

通讯作者: 邱立春,教授,博士生导师,主要从事农业装备工程技术研究,E-mail: qlcen@126.com

目前,关于农机总动力的预测方法主要有线性回归模型、移动平均法、指数平滑法、灰色 GM(1,1)模型、龚珀兹曲线和人工神经网络等^[5]。由于人工神经网络具有较强的非线性模拟能力,并具有预测精度高、强大的自学习和自适应能力,在农机总动力预测中得到了越来越多的应用。因此,本文利用黑龙江省 1980~2008 年农机总动力数据,运用新传递函数的 BP 神经网络对黑龙江省的农机总动力进行预测。

1 BP 神经网络存在的问题分析

BP 神经网络模型是人工神经网络的重要模型之一。它是目前研究最多、应用最广泛的一种多层前馈神经网络,理论已经证明 3 层 BP 神经网络只要隐含层节点数足够多,就具有模拟任意复杂的非线性映射的能力^[6~9]。BP 神经网络具有较强的拟合能力,但是将 BP 神经网络应用于预测时却存在一定的问题。为说明问题方便起见,以单极性 S 型传递函数为例,即

$$f(x) = \frac{1}{1 + e^{-x}} \tag{1}$$

该传递函数的图形如图 1 所示,其值域为 [0, 1]。在数据处理时,当将输入数据处理到 [-1, 1] 或 [0, 1] 区间时,对于具有明显增长趋势的预测问题,只能对历史数据进行拟合,而无法进行预测,因为输出永远不会超过已知数据中的最大值。当将输入数据处理到 (0, 0.9] 或 [0.2, 0.8] 时,只能进行短期预测,且预测效果不好。当将输入数据处理到 [-0.5, 0.5] 或 (0, 0.5] 区间时,虽然能外推得到较多的预测值,但由于训练段与预测段变化趋势不一致,预测效果仍然较差。




图 1 单极性 S 型函数
Fig. 1 Unipolar S-function

通过上述分析可知,将 BP 神经网络应用于预测领域时,虽然拟合精度较高,但预测效果并不理想。其根本原因在于传递函数的值域受限,而且各段变化趋势和规律不一致,当数据处理到较小区间内时,就会出现训练段与预测段不一致的问题;当将数据处理到较大区间内时,预测外推能力明显变弱。

将 BP 神经网络用于解决预测问题时,很难取得令人满意的结果。因此,对基于 BP 神经网络的预测问题进行深入的研究不仅具有理论意义,也具有重要的应用价值。

2 标准 BP 神经网络算法

以图 2 所示的 BP 网络结构为例,BP 神经网络算法可描述为^[10]:




图 2 3 层 BP 网络结构图
Fig. 2 Structure chart of three layers BP network

(1) 正向传播过程:输入信号从输入层经隐层单元传向输出层,在输出端产生输出信号,若输出信号满足给定的输出要求,则计算结束;若输出信号不满足给定的输出要求,则转入信号反向传播。

正向传播过程计算如下:

输入层有 $q + 1$ 个输入信号,其中任一输入信号用 i 表示;隐层有 $p + 1$ 个神经元,其中任一神经元用 j 表示;输出层有 o 个神经元,其中任一神经元用 k 表示。输入层与隐层之间的权值用 v_{ij} 表示 ($i = 0, 1, 2, \dots, q; j = 1, 2, \dots, p$), v_{0j} 为隐层阈值;隐层与输出层之间的权值用 u_{jk} 表示 ($j = 0, 1, 2, \dots, p; k = 1, 2, \dots, o$), u_{0k} 为输出层阈值。设隐层的输入为 I_j , 隐层输出为 y_j , 输出层的输入为 I_k , 输出层的输出为 z_k 。训练样本集为 $\mathbf{X} = (\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_r, \dots, \mathbf{X}_n)$, 对应任一训练样本 $\mathbf{X}_r = (x_{r0}, x_{r1}, x_{r2}, \dots, x_{rq})$, $r = 1, 2, \dots, n$, 其中 $x_{r0} = -1$ 。实际输出为 $\mathbf{z}_r = (z_{r1}, z_{r2}, \dots, z_{ro})$, 期望输出为 $\mathbf{d}_r = (d_{r1}, d_{r2}, \dots, d_{ro})$, $r = 1, 2, \dots, n$ 。设 m 为迭代次数,则权值和实际输出是 m 的函数。

网络输入训练样本 $\mathbf{X}_r$, 由工作信号的正向传播过程可得

$$I_j = \sum_{i=0}^q v_{ij} x_{ri} \quad (j = 0, 1, \dots, p) \tag{2}$$

$$y_j = f(I_j) = f\left(\sum_{i=0}^q v_{ij} x_{ri}\right) \quad (j = 0, 1, \dots, p) \tag{3}$$

$$I_k = \sum_{j=0}^p u_{jk} y_{rj} \quad (k = 1, 2, \dots, o) \tag{4}$$

$$z_k=f(I_k)=f\left(\sum_{j=0}^p u_{jk}y_{rj}\right) \quad (k=1,2,\cdots,o) \quad (5)$$

输出层第 k 个神经元误差信号为

$$e_{rk}(m)=d_{rk}(m)-z_{rk}(m)$$

定义神经元 k 的误差能量为 $e_{rk}^2(m)/2$, 则输出层所有神经元的误差能量总和为

$$E(m)=\frac{1}{2}\sum_{k=1}^o e_{rk}^2(m) \quad (6)$$

当 $E(m)<e$ 时(e 为计算期望精度), 计算结束; 否则, 进行反向传播计算。

(2) 误差反向传播过程: 网络的实际输出与期望输出之间差值即为误差信号, 误差信号从输出端开始逐层向前传播, 这是误差信号的反向传播。在误差信号反向传播的过程中, 网络的权值由误差反馈进行调节。通过权值的不断修正使网络的实际输出逐渐接近期望输出。

误差反向传播过程计算如下

$$\Delta u_{jk}(m)=-\eta\frac{\partial E(m)}{\partial u_{jk}(m)} \quad (7)$$

$$u_{jk}(m+1)=u_{jk}(m)+\Delta u_{jk}(m) \quad (8)$$

$$\Delta v_{ij}(m)=-\eta\frac{\partial E(m)}{\partial v_{ij}(m)} \quad (9)$$

$$v_{ij}(m+1)=v_{ij}(m)+\Delta v_{ij}(m) \quad (10)$$

式中 η ——学习速率, 是一个给定的常数
当求出各层新的权值后转向正向传播过程。

3 时间序列预测问题的网络结构与特点

农机总动力是一个时间序列, 因此农机总动力预测问题是一个时间序列预测问题。设农机总动力的时间序列为 $\{x(t)|t=1,2,\cdots,n\}$, BP 神经网络输入层神经元个数为 $q+1$, 神经元的输入分别为 $x_0(t), x_1(t), x_2(t+1), \cdots, x_{q-1}(t+q-2), x_q(t+q-1)$, 且有

$$\begin{aligned} x_0(t) &= -1 \\ x_1(t) &= x(t) \\ x_2(t) &= x(t+1) \\ &\vdots \\ x_{q-1}(t) &= x(t+q-2) \\ x_q(t) &= x(t+q-1) \end{aligned}$$

式中, $t=1,2,\cdots,n-q$ 。

输出层神经元个数为 1, 则 BP 神经网络输入、输出模式如表 1 所示。

根据 Z 变换理论^[11], $x(t+1)$ 的 Z 变换为 $zx(z)-zx(0)$, 所以当 $x(t+1)=wx(t)$ 时, 有

$$x(t)=x(0)w^t \quad (11)$$

表 1 样本的输入、输出模式

Tab.1 Input and output mode of samples

样本编号	输入样本	期望输出
1	$-1, x_1, x_2, \cdots, x_{q-1}, x_q$	$d_1 = x_{q+1}$
2	$-1, x_2, x_3, \cdots, x_q, x_{q+1}$	$d_2 = x_{q+2}$
$\vdots$	$\vdots$	$\vdots$
r	$-1, x_r, x_{r+1}, \cdots, x_{r+q-2}, x_{r+q-1}$	$d_r = x_{q+r}$
$\vdots$	$\vdots$	$\vdots$
$n-q-1$	$-1, x_{n-q-1}, x_{n-q}, \cdots, x_{n-3}, x_{n-2}$	$d_{n-q-1} = x_{n-1}$
$n-q$	$-1, x_{n-q}, x_{n-q+1}, \cdots, x_{n-2}, x_{n-1}$	$d_{n-q} = x_n$

由此可以看出, 各输入神经元之间具有复杂的非线性关系, 当传递函数为 $y=x$ 时, 输入与输出之间具有复杂的非线性关系, BP 神经网络的输入与输出之间也具有非线性映射关系, 因此用 $y=x$ 作为传递函数是可行的。根据式(2)和式(4)可知, 以 $y=x$ 作为传递函数与 $y=a+bx$ 作为传递函数等价。另外, 用 $y=x$ 作为传递函数不仅简单, 而且传递函数的值域为 $(-\infty, +\infty)$, 可使网络具有良好的外推性能, 因此用 $y=x$ 作为传递函数也具有可行性。由于用了 $y=x$ 作为传递函数, 理论上可以证明, 3 层网络结构与 2 层网络结构等价, 所以网络结构应为 2 层。2 层 BP 神经网络的结构如图 3 所示。




图 3 2 层 BP 神经网络结构图

Fig.3 Structure chart of two layers BP neural network

4 新传递函数的 BP 算法

以图 3 所示网络为例, 设输入向量为 $X=(X_1, X_2, \cdots, X_r, \cdots, X_{n-q})$, 输出层的输出向量为 $Y=(Y_1, Y_2, \cdots, Y_k, \cdots, Y_{n-q})$, 期望输出向量为 $d=(d_1, d_2, \cdots, d_r, \cdots, d_{n-q})$ 。对于任一训练样本 $X_r=(-1, x_r, x_{r+1}, \cdots, x_{r+q-2}, x_{r+q-1})$, 输出层的输入为 I , 输出为 y_r , 期望输出为 d_r 。输入层到输出层之间的权值矩阵用 W 表示, $W=[w_0 \ w_1 \ w_2 \ \cdots \ w_i \ \cdots \ w_q]$, 其中 w_i 为输入层第 i 个神经元与输出层神经元之间的连接权值。

当以 $y=x$ 作为传递函数时, 正向传播过程仿照标准 BP 神经网络的计算公式。

令

$$E=\frac{1}{2}(d-y)^2 \quad (12)$$

由于

$$I=\sum_{i=0}^q w_i x_i \quad (13)$$

$y=f(I)$ (14)

误差反向传播计算过程为

$\Delta w_i = -\eta \frac{\partial E}{\partial w_i}$ (15)

$-\frac{\partial E}{\partial w_i} = -\frac{\partial E}{\partial y} \frac{\partial y}{\partial I} \frac{\partial I}{\partial w_i}$ (16)

$-\frac{\partial E}{\partial y} = d - y$ (17)

$\frac{\partial y}{\partial I} = 1$ (18)

$\frac{\partial I}{\partial w_i} = x_i$ (19)

所以 $-\frac{\partial E}{\partial w_i} = (d - y)x_i$

令 $\delta = -\frac{\partial E}{\partial I} = d - y$, 有

$\Delta w_i = \eta \delta x_i$ (20)

权值的调整过程与方法 and 标准 BP 算法相同。

5 计算实例

根据 2008 年黑龙江省统计年鉴, 黑龙江省的农机总动力数据如表 2 所示。

表 2 1980 ~ 2008 年黑龙江省农机总动力
Tab.2 Total power of agriculture machinery in
Heilongjiang province from 1980 to 2008

年份	农机总动力/MW	年份	农机总动力/MW
1980	7 093	1995	12 261
1981	7 604	1996	12 548
1982	8 141	1997	12 854
1983	8 616	1998	14 545
1984	9 017	1999	15 597
1985	9 495	2000	16 138
1986	9 352	2001	16 483
1987	10 935	2002	17 418
1988	11 052	2003	18 077
1989	11 628	2004	19 522
1990	11 734	2005	22 340
1991	11 795	2006	25 706
1992	11 726	2007	27 853
1993	11 853	2008	30 184
1994	11 900		

对表 2 中的数据进行归一化处理

$$x'_i = a + (b - a) \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (i = 1, 2, \cdots, n)$$
 (21)

式中 x_i ——输入样本数据

x'_i ——归一化后的样本输入数据, $x'_i \in [a, b]$

$x_{\max}, x_{\min}$ ——输入样本数据 x_i 最大、最小值

n ——样本数

当传递函数为单极性 S 型函数时有 $a \in (0, 1)$, $b \in (0, 1)$, 且 $a < b$ 。当传递函数为 $y = x$ 时 $a \in [-1, 1]$, $b \in [-1, 1]$, 且 $a < b$ 。

在单极性 S 型传递函数的标准 BP 神经网络和新传递函数的标准 BP 神经网络的网络结构中, 在神经元总数相等的情况下, 即 S 型传递函数的结构为 6-4-1, 新的传递函数的 BP 神经网络的结构为 10-1 时, 其预测精度情况如表 3 所示。

网络的总误差在训练 20 次不变时就停止训练, 此时 S 型传递函数的标准 BP 算法的训练时间为 354. 594 4 s, 训练次数为 46 502 次; 新传递函数的 BP 算法的训练时间为 22. 348 7 s, 训练次数为 22 214 次。考虑到初始权值选取对结果的影响, 表 3 中的结果、训练时间和训练次数是在随机选取初始权值和阈值的情况下, 训练 10 次后取平均值所得到的。由表 3 可知, 单极性 S 型传递函数的标准 BP 算法的平均相对误差为 2. 46%, 而新传递函数的标准 BP 算法的平均相对误差为 1. 91%, 新传递函数 BP 算法的计算精度比单极性 S 型传递函数的标准 BP 算法提高了 22. 36%, 计算精度明显提高。另外, 以 S 型曲线作为传递函数和 $y = x$ 作为传递函数时, 当数据分别处理到 $[0, 1]$ 、 $[0. 1, 0. 8]$ 、 $[0. 1, 0. 5]$ 区间时, 其外推预测效果如图 4 所示。从图 4 可以看出, S 型曲线作为传递函数时其外推效果与实际观测值的变化趋势不一致, 而以 $y = x$ 作为传递函数时, 其外推效果与实际观测值的变化趋势相吻合; 另外, $y = x$ 作为传递函数的外推效果基本不受数据处理区间的影响, 而单极性 S 型函数作为传递函数时外推效果受处理区间的影响较大。由此可以得出, 以 S 型曲线作为传递函数的 BP 神经网络用于预测时, 其预测效果不理想。

6 结论

(1) 分析了基于 BP 神经网络的预测问题存在的不足, 提出了基于 BP 神经网络的时间序列预测问题的一种新方法。

(2) 根据 BP 神经网络的时间序列预测问题的结构特点, 依据 Z 变换理论, 提出了一种新的传递函数。

(3) 分析了 BP 网络中, 以 $y = x$ 作为传递函数与 $y = a + bx$ 作为传递函数等价的原因, 若选用 $y = a + bx$ 作为传递函数将使简单问题复杂化。

(4) 推导给出了以 $y = x$ 作为传递函数的 BP 算法的计算公式和模型。

表 3 预测精度情况
Tab.3 Accuracy of prediction

年份	观测值 /MW	单极性 S 型传递函数 BP 算法			新传递函数的 BP 算法		
		预测值/MW	相对误差/%	平均相对误差/%	预测值/MW	相对误差/%	平均相对误差/%
1986	9 352	9 914. 45	- 6. 01				
1987	10 935	9 817. 44	10. 22				
1988	11 052	11 182. 68	- 1. 18				
1989	11 628	11 223. 16	3. 48				
1990	11 734	11 739. 73	- 0. 05		11 542. 60	1. 63	
1991	11 795	12 013. 30	- 1. 85		11 635. 54	1. 35	
1992	11 726	11 591. 66	1. 15		11 408. 16	2. 71	
1993	11 853	12 203. 90	- 2. 96		11 886. 55	- 0. 28	
1994	11 900	12 243. 66	- 2. 89		12 465. 31	- 4. 75	
1995	12 261	12 525. 28	- 2. 16		12 625. 23	- 2. 97	
1996	12 548	12 923. 37	- 2. 99		12 835. 57	- 2. 29	
1997	12 854	13 227. 17	- 2. 90	2. 46	13 247. 98	- 3. 07	
1998	14 545	13 435. 68	7. 63		13 388. 21	7. 95	
1999	15 597	15 376. 19	1. 42		15 604. 12	- 0. 05	1. 91
2000	16 138	16 272. 10	- 0. 83		16 148. 07	- 0. 06	
2001	16 483	16 873. 48	- 2. 37		16 875. 80	- 2. 38	
2002	17 418	17 358. 62	0. 34		17 423. 15	- 0. 03	
2003	18 077	18 161. 12	- 0. 47		18 390. 28	- 1. 73	
2004	19 522	19 635. 07	- 0. 58		19 363. 00	0. 81	
2005	22 340	21 949. 06	1. 75		21 994. 52	1. 55	
2006	25 706	25 413. 68	1. 14		25 326. 47	1. 48	
2007	27 853	28 309. 53	- 1. 64		28 160. 50	- 1. 10	
2008	30 184	30 012. 34	0. 57		30 212. 00	- 0. 09	
2009		31 427. 95			33 259. 15		
2010		32 217. 86			36 623. 64		
2011		32 873. 90			40 721. 66		
2012		33 601. 62			46 842. 62		
2013		33 987. 38			54 389. 44		
2014		34 266. 74			62 137. 26		
2015		34 442. 55			70 466. 98		
2016		34 520. 43			80 407. 20		
2017		34 558. 52			91 811. 63		
2018		34 615. 49			105 087. 42		




图 4 模型的拟合精度及外推情况

Fig.4 Fitting accuracy and extrapolate situation
of proposed model

(5) 用单极性 S 型函数作为传递函数和 $y = x$

作为传递函数时,对具有增长趋势的时间序列预测问题进行了实例计算。计算结果表明,对于具有增长趋势的时间序列预测问题单极性 S 型函数作为传递函数时其外推预测效果很差, $y = x$ 作为传递函数时具有较好的外推效果。另外, $y = x$ 作为传递函数的外推效果基本不受数据处理区间的影响,而单极性 S 型函数作为传递函数时外推效果受处理区间的影响较大。并且以 $y = x$ 作为传递函数可克服 S 型传递函数在预测问题中存在的不足。

(6) 在神经元个数相同的情况下,从模型的拟合精度、训练时间、学习次数方面来看, $y = x$ 作为传

递函数的 BP 神经网络明显优于单极性 S 型函数作为传递函数的 BP 神经网络。

络用于农机总动力预测时的预测效果明显优于 S 型传递函数的 BP 神经网络,从而证明了 $y = x$ 传递函数 BP 算法的有效性。

(7) 实例计算表明, $y = x$ 传递函数 BP 神经网络

参 考 文 献

1 宋琿,董欣,王兵. 基于 BP 神经网络的农机总动力预测模型研究[J]. 东北农业大学学报,2009,40(4):116~120.
Song Hui, Dong Xin, Wang Bing. Research on prediction model of the total power of agricultural machinery based on BP neural network[J]. Journal of Northeast Agricultural University, 2009, 40(4):116~120. (in Chinese)

2 刘玉静,李成华,杨升明. 辽宁省农机总动力组合预测与分析[J]. 农机化研究,2007(5):31~33.
Liu Yujing, Li Chenghua, Yang Shengming. Combination prediction and analysis of total power of agricultural machinery in Liaoning province[J]. Journal of Agricultural Mechanization Research, 2007 (5): 31~33. (in Chinese)

3 鞠金艳,王金武,王金峰. 基于 BP 神经网络的农机总动力组合预测方法[J]. 农业机械学报,2010,41(6):87~92.
Ju Jinyan, Wang Jinwu, Wang Jinfeng. Combined prediction method of total power of agricultural machinery based on BP neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2010, 41(6):87~92. (in Chinese)

4 张淑娟,赵飞. 基于 Shapley 值的农机总动力组合预测方法[J]. 农业机械学报,2008,39(5):60~64.
Zhang Shujuan, Zhao Fei. Combinatorial forecast of agricultural machinery total power based on Shapley value [J]. Transactions of the Chinese Society for Agricultural Machinery, 2008, 39(5):60~64. (in Chinese)

5 朱瑞祥,黄玉祥,杨晓辉. 用灰色神经网络组合模型预测农机总动力发展[J]. 农业工程学报,2006,22(2):107~110.
Zhu Ruixiang, Huang Yuxiang, Yang Xiaohui. Method for estimating total power of agricultural machinery based on mixed grey neural network [J]. Transactions of the Chinese Society of Agricultural Engineering, 2006, 22 (2):107~110. (in Chinese)

6 周玲,孙军,袁宇波,等. 混合激活函数对 BP 算法收敛速度的影响[J]. 河海大学学报,1999,27(5):107~108.
Zhou Ling, Sun Jun, Yuan Yubo, et al. Effects of combined activation function on BP algorithm's convergence speed[J]. Journal of Hehai University, 1999, 27(5):107~108. (in Chinese)

7 唐万梅. BP 神经网络网络结构优化问题的研究[J]. 系统工程理论与实践,2005,25(10):95~100.
Tang Wanmei. The study of the optimal structure of BP nueral network[J]. Systems Engineering—Theory & Practice, 2005, 25(10):95~100. (in Chinese)

8 Funahashi K. On the arrpoximate realization of continous mappings by neural networks[J]. Neural Networks, 1989, 2(7):183~192.

9 Hecht-Nielson R. Theory of the backpropagation neural network[C]//Proceedings of IEEE International Joint Conference on Neural Networks, 1989, 1:593~603.

10 高隽. 人工神经网络原理及仿真实例[M]. 北京:机械工业出版社,2007.

11 张金水. 经济控制论[M]. 北京:清华大学出版社,1999.