

一种具有正弦基函数权值的反馈型神经网络模型*

李承^{1)2)†} 石丹²⁾ 邹云屏¹⁾²⁾

1) (强电磁工程与新技术国家重点实验室(华中科技大学), 武汉 430074)

2) (华中科技大学电气与电子工程学院, 武汉 430074)

(2011年5月9日收到; 2011年8月11日收到修改稿)

提出了一种新的两层反馈型神经网络模型。该网络采用正弦基函数作为权值, 神经元激活函数为线性函数, 连接形式为两层反馈型结构。研究并定义了该反馈型神经网络的能量函数, 分析了网络运行的稳定性问题, 并证明了在 Liapunov 意义下网络运行的稳定性。网络运行过程中, 其权值不做调整(但随时间按正弦规律变化), 网络状态不断地转换。随着网络状态变化其能量不断减小, 最终在达到稳定时能量到达极小点。由于该反馈型神经网络权值为正弦函数, 特别适合于周期信号的自适应逼近和检测, 为实际中周期性信号检测与处理提供了一种新的、有效的网络模型和方法。作为应用实例把该网络应用于电力系统中电压凹陷特征量实时检测, 仿真结果表明, 网络用于信号检测不仅有很高的静态精度, 而且有非常好的动态响应特性。

关键词: 反馈型神经网络, 正弦基函数权值, Liapunov 稳定性, 实时信号检测

PACS: 07.05.Mh, 42.79.Ta, 42.82.Ds

1 引言

人工神经网络研究, 无论是网络结构模型还是学习算法, 都取得了众多令人瞩目的研究成果, 得到了广泛应。归纳起来, 主要应用领域包括信号智能检测与处理^[1-3]、自适应滤波器^[4,5]、系统智能控制^[6-8]、序列分析与优化计算^[9-11]等, 提供了一种有效途径与方法。

人工神经网络在信号检测与处理方面的应用, 尽管已经有许多成果, 但大多数应用都由自适应线性人工神经网络、BP 网络模型以及径向基函数网络实现^[1-5]。实际中经常需要检测和处理非正弦周期信号, 而现有的人工神经网络模型中没有非常适合这类信号检测与处理的网络。特别是反馈型人工神经网络模型, 当前主要是应用于优化计算和联想存储器^[12,13], 而用于信号检测与处理的例子极少。

本文依据反馈型人工神经网络的运行特点, 从理论上研究并提出一种全新的、非常适合处理周期信号的反馈型人工神经网络模型, 建立了网络的能量函数, 研究了该网络在 Liapunov 意义下运行的稳定性问题, 并证明了网络运行时, 网络状态不断演变, 但权值不变(正弦函数幅值不变), 其状态沿着

能量减小的方向转移, 最终收敛到能量极小点。最后, 作为应用实例, 应用所提出的反馈型人工神经网络模型对电力系统中电压凹陷特征量的检测进行了仿真实验验证。结果表明, 该网络应用于周期信号处理有非常好的动态性能和稳态精度, 对凹陷电压特征量的检测过程可以在 1.5ms 内完成, 检测效果与动态响应速度优于现有的所有检测方法。本文提出的反馈型神经网络模型可适用于所有正弦或非正弦周期信号处理。

2 反馈神经网络模型

数学分析原理指出, 在满足狄里赫利条件时, 非正弦周期信号可以展开成傅里叶级数。如果设 $y(t)$ 为非正弦周期信号, 则有

$$y(t) = y_0 + \sum_{k=1}^{\infty} y_k \sin(k\omega t + \varphi_k) \\ = A_0 + \sum_{k=1}^{\infty} A_k \cos(k\omega t) + \sum_{k=1}^{\infty} B_k \sin(k\omega t), \quad (1)$$

式中

$$A_0 = y_0, \quad A_k = y_k \sin \varphi_k, \quad B_k = y_k \cos \varphi_k.$$

* 国家自然科学基金(批准号: 50277017)资助的课题。

† E-mail: cheng_lyb@163.com

在(1)式中取前 n 项近似, 可得

$$y(t) = A_0 + \sum_{k=1}^n A_k \cos(k\omega t) + \sum_{k=1}^n B_k \sin(k\omega t). \quad (2)$$

设有向量

$$\begin{aligned} A &= (A_0, A_1, A_2, \dots, A_n)^T, \\ B &= (B_1, B_2, B_3, \dots, B_n)^T, \end{aligned} \quad (3)$$

$$\begin{aligned} W_1(t) &= (1, \cos \omega t, \cos 2\omega t, \dots, \cos n\omega t)^T \\ &= (w_{10}, w_{11}, w_{12}, \dots, w_{1n})^T, \end{aligned} \quad (4)$$

$$\begin{aligned} V_1(t) &= (\sin \omega t, \sin 2\omega t, \dots, \sin n\omega t)^T \\ &= (v_{11}, v_{12}, v_{13}, \dots, v_{1n})^T. \end{aligned} \quad (5)$$

在(4), (5)式中

$$\begin{aligned} w_{1k} &= \cos k\omega t, \quad (k = 0, 1, 2, \dots, n), \\ v_{1k} &= \sin k\omega t, \quad (k = 1, 2, 3, \dots, n). \end{aligned} \quad (6)$$

显然, 向量 W_1 和 V_1 是把正弦基函数作为其分量的向量. 将(3)–(5)式代入(2)式, 可以得到

$$\begin{aligned} y(t) &= \sum_{k=0}^n w_{1k} A_k + \sum_{k=1}^n v_{1k} B_k \\ &= W_1^T \cdot A + V_1^T \cdot B, \end{aligned} \quad (7)$$

式中, 如果把 A, B 作为神经网络的权值向量, W_1, V_1 作为神经网络的输入向量, 则 $y(t)$ 是神经网络的输出. 这样就可以得到前向结构的神经网络模型. 此时, 权值通过对样本的学习来调整, 使网络的实际输出 $y(t)$ 逼近期望输出 $y_d(t)$.

对前馈网络来说, 网络实际输出 $y(t)$ 逼近期望输出 $y_d(t)$ 的程度由权值 A 和 B 这两个向量值的决定, 前向网络学习的过程, 就是确定权值的过程. 学习完成后, 权值不再变化. 如果期望输出变化了, 网络需要重新学习以确定新的权值. 显然, 这种重新学习的工作方式使网络的自适应能力受到影响, 使网络的动态响应性能下降.

为了提高网络的自适应能力和动态响应性能, 可以用反馈网络形式. 在(7)式中, 如果把正弦基函数向量 W_1, V_1 作为神经网络的权值向量, 而把 A, B 作为网络的状态, 可建立一个反馈神经网络. 为得到反馈网络模型, 设期望信号 $y_d(t)$ 与网络实际输出信号 $y(t)$ 之间的误差为

$$e = y_d(t) - y(t). \quad (8)$$

均方误差为

$$E(t) = \frac{1}{2} e(t)^2. \quad (9)$$

于是, (9)式可以写为

$$\begin{aligned} E(t) &= \frac{1}{2} [y_d(t) - y(t)]^2 \\ &= \frac{1}{2} \left[y_d(t) - \left(\sum_{k=0}^n w_{1k} A_k + \sum_{k=1}^n v_{1k} B_k \right) \right]^2. \end{aligned} \quad (10)$$

根据反馈网络运行原理, 网络在运行时其权值不变(正弦权值幅值不变), 只是网络状态不断转换, 最后收敛在吸引子上. 由此可知, 我们期望网络随着其状态不断转换, (10)式定义的均方误差逐渐减小, 使网络的输出快速、高精度地跟踪输入信号. 这就要求: 第一均方误差 $E(t)$ 是网络状态 A 和 B 的函数; 第二网络的状态 A 和 B 的变化应使均方误差 $E(t)$ 沿其负梯度方向减小, 即有

$$\frac{dA_k}{dt} = -\eta \frac{\partial E(t)}{\partial A_k}, \quad (k = 0, 1, 2, \dots, n), \quad (11)$$

$$\frac{dB_k}{dt} = -\eta \frac{\partial E(t)}{\partial B_k}, \quad (k = 0, 1, 2, \dots, n), \quad (12)$$

(11), (12)式中, η 为运行速率, 它影响着网络状态转换的快慢程度.

而根据(2), (7), (10)式可知

$$\begin{aligned} \frac{\partial E(t)}{\partial A_k} &= - \left[y_d(t) - \left(\sum_{k=0}^n w_{1k} A_k + \sum_{k=1}^n v_{1k} B_k \right) \right] w_{1k}, \\ &\quad (k = 0, 1, 2, \dots, n), \end{aligned} \quad (13)$$

$$\begin{aligned} \frac{\partial E(t)}{\partial B_k} &= - \left[y_d(t) - \left(\sum_{k=0}^n w_{1k} A_k + \sum_{k=1}^n v_{1k} B_k \right) \right] v_{1k}, \\ &\quad (k = 1, 2, \dots, n). \end{aligned} \quad (14)$$

由(11), (12), (13), (14)式可得到

$$\begin{aligned} \frac{dA_k}{dt} &= \eta \left[y_d(t) - \left(\sum_{k=0}^n w_{1k} A_k + \sum_{k=1}^n v_{1k} B_k \right) \right] w_{1k}, \\ &\quad (k = 0, 1, 2, \dots, n), \end{aligned} \quad (15)$$

$$\begin{aligned} \frac{dB_k}{dt} &= \eta \left[y_d(t) - \left(\sum_{k=0}^n w_{1k} A_k + \sum_{k=1}^n v_{1k} B_k \right) \right] v_{1k}, \\ &\quad (k = 1, 2, \dots, n). \end{aligned} \quad (16)$$

写出(15),(16)式对应的差分方程,有

$$\begin{aligned} & \frac{A_k(t+1) - A_k(t)}{(t+1) - t} = A_k(t+1) - A_k(t) \\ &= \eta \left[y_d(t) - \left(\sum_{k=0}^n w_{1k}(t) A_k(t) + \sum_{k=1}^n v_{1k}(t) B(t)_k \right) \right] w_{1k}(t), \\ & \quad (k = 0, 1, 2, \dots, n), \end{aligned} \quad (17)$$

$$\begin{aligned} & \frac{B_k(t+1) - B_k(t)}{(t+1) - t} = B_k(t+1) - B_k(t) \\ &= \eta \left[y_d(t) - \left(\sum_{k=0}^n w_{1k}(t) A_k(t) + \sum_{k=1}^n v_{1k}(t) B(t)_k \right) \right] v_{1k}(t), \\ & \quad (k = 1, 2, \dots, n). \end{aligned} \quad (18)$$

由(17),(18)式可知,当网络状态转换时,应有

$$\begin{aligned} & A_k(t+1) \\ &= A_k(t) + \eta \left[y_d(t) - \left(\sum_{k=0}^n w_{1k} A_k + \sum_{k=1}^n v_{1k} B_k \right) \right] w_{1k} \\ &= A_k(t) + \left[y_d(t) - \left(\sum_{k=0}^n w_{1k} A_k + \sum_{k=1}^n v_{1k} B_k \right) \right] w_{2k}, \\ & \quad (k = 0, 1, 2, \dots, n), \end{aligned} \quad (19)$$

$$\begin{aligned} & B_k(t+1) \\ &= B_k(t) + \eta \left[y_d(t) - \left(\sum_{k=0}^n w_{1k} A_k + \sum_{k=1}^n v_{1k} B_k \right) \right] v_{1k} \\ &= B_k(t) + \left[y_d(t) - \left(\sum_{k=0}^n w_{1k} A_k + \sum_{k=1}^n v_{1k} B_k \right) \right] v_{2k}, \\ & \quad (k = 1, 2, \dots, n). \end{aligned} \quad (20)$$

(19),(20)式中

$$\begin{aligned} & w_{2k} = \eta w_{1k}, \quad (k = 0, 1, 2, \dots, n), \\ & v_{2k} = \eta v_{1k}, \quad (k = 1, 2, \dots, n). \end{aligned} \quad (21)$$

(19),(20)式即为所建立的反馈神经网络模型如图1所示.

由图1可知,该反馈神经网络是一个两层结构、同时具有反馈的网络模型. 网络的第一层有一个神经元,第二层有 $2n+1$ 个神经元,两层神经元的激活函数均为线性函数,即有 $f(x) = x$ 的形式.

该函数的特点是单调增加、处处可导且导数为常数. 第二层的输出 $A_0, A_1, \dots, A_n, B_1, B_2, \dots, B_n$ 不仅反馈到第一层神经元,也对本层相应神经元有反馈连接.

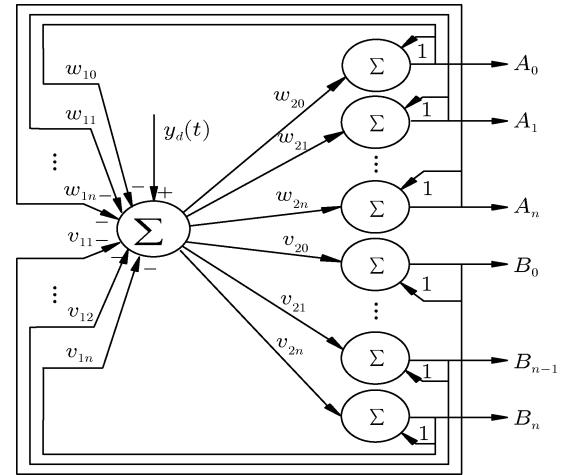


图1 反馈型神经网络模型

3 稳定性分析

在(15)式和(16)式中,令

$$\begin{aligned} & f_1(A, B, t) \\ &= \eta \left[y_d(t) - \left(\sum_{k=0}^n w_{1k} A_k + \sum_{k=1}^n v_{1k} B_k \right) \right] w_{1k}, \end{aligned} \quad (22)$$

$$\begin{aligned} & f_2(A, B, t) \\ &= \eta \left[y_d(t) - \left(\sum_{k=0}^n w_{1k} A_k + \sum_{k=1}^n v_{1k} B_k \right) \right] v_{1k}. \end{aligned} \quad (23)$$

(15),(16)式又可以写为

$$\frac{dA_k}{dt} = f_1(A_k, B_k, t), \quad (24)$$

$$\frac{dB_k}{dt} = f_2(A_k, B_k, t). \quad (25)$$

由微分方程理论可知,(24),(25)式描述的系统是典型非自治系统. 根据能量函数法可构造出其Liapunov函数^[14]为

$$V(A_k, B_k) = \frac{1}{2} f_1^2(A_k, B_k, t) + \frac{1}{2} f_2^2(A_k, B_k, t). \quad (26)$$

显然,(26)式定义的Liapunov函数 $V(A_k, B_k)$ 正定.

现在只需证明 $\frac{dV(A_k, B_k)}{dt} \leq 0$ 即可证明系统Liapunov意义下稳定.

由(22),(23),(26)式可得

$$V(A_k, B_k) = \frac{1}{2}\eta^2 \left[y_d(t) - \left(\sum_{k=0}^n w_{1k} A_k + \sum_{k=1}^n v_{1k} B_k \right) \right]^2 (w_{1k}^2 + v_{1k}^2). \quad (27)$$

由(6)式可知 $(w_{1k}^2 + v_{1k}^2) = 1$, 因此, (27)式可写为

$$V(A_k, B_k) = \frac{1}{2}\eta^2 \left[y_d(t) - \left(\sum_{k=0}^n w_{1k} A_k + \sum_{k=1}^n v_{1k} B_k \right) \right]^2. \quad (28)$$

又因为

$$\frac{dV(A_k, B_k)}{dt} = \frac{\partial V}{\partial A_k} \cdot \frac{dA_k}{dt} + \frac{\partial V}{\partial B_k} \cdot \frac{dB_k}{dt}, \quad (29)$$

而

$$\frac{\partial V}{\partial A_k} = -\eta^2 \left[y_d(t) - \left(\sum_{k=0}^n w_{1k} A_k + \sum_{k=1}^n v_{1k} B_k \right) \right] w_{1k}, \quad (30)$$

$$\frac{\partial V}{\partial B_k} = -\eta^2 \left[y_d(t) - \left(\sum_{k=0}^n w_{1k} A_k + \sum_{k=1}^n v_{1k} B_k \right) \right] v_{1k}. \quad (31)$$

根据(11),(12)式可知

$$\begin{aligned} \frac{dA_k}{dt} &= -\frac{\partial E(t)}{\partial A_k} \\ &= \left[y_d(t) - \left(\sum_{k=0}^n w_{1k} A_k + \sum_{k=1}^n v_{1k} B_k \right) \right] w_{1k}, \end{aligned} \quad (32)$$

$$\begin{aligned} \frac{dB_k}{dt} &= -\frac{\partial E(t)}{\partial B_k} \\ &= \left[y_d(t) - \left(\sum_{k=0}^n w_{1k} A_k + \sum_{k=1}^n v_{1k} B_k \right) \right] v_{1k}. \end{aligned} \quad (33)$$

把(31)–(34)式代入(30)式可得

$$\begin{aligned} \frac{dV(A_k, B_k)}{dt} &= -\eta^2 \left[y_d(t) - \left(\sum_{k=0}^n w_{1k} A_k + \sum_{k=1}^n v_{1k} B_k \right) \right]^2 \\ &\quad \times (w_{1k}^2 + v_{1k}^2) \\ &= -\eta^2 \left[y_d(t) - \left(\sum_{k=0}^n w_{1k} A_k + \sum_{k=1}^n v_{1k} B_k \right) \right]^2. \end{aligned} \quad (34)$$

由于 $\eta > 0$, 所以可得

$$\frac{dV(A_k, B_k)}{dt} \leqslant 0. \quad (35)$$

(35)式表明由(24)和(25)式所决定的反馈型神经网络从任意初值出发, 最终可达到稳定状态。也表明图1所示的反馈型神经网络运行最终可以达到稳定状态, 而且, 稳定状态对应网络能量极小点。比较(10)式和(27)式可以看到, 当能量达到极小点时, 网络的输出与期望输出间的均方误差也同时达到最小。即网络输出 $y(t)$ 可以在最小均方误差下跟踪期望输出 $y_d(t)$ 。

4 模拟算例

本文提出的反馈神经网络模型, 可以应用于任意周期信号的逼近, 本节给出的将网络应用于电力系统电压凹陷特征量检测, 仅为一种应用例子。

所谓电压凹陷, IEEE Std.159 对电压凹陷的定义为: 工频电压有效值下降到额定电压的 10%—90%范围内, 持续时间为半个工频周期到 1 min。电压凹陷一般可以用三个量来描述, 即凹陷幅值、持续时间和相位跳变。凹陷幅值反映电压下降程度; 电压凹陷不仅造成电压短时降落, 还会造成相位跳变, 使得利用电压相位来工作的敏感设备容易受到干扰; 凹陷持续时间是指从电压有效值下降到一定门槛值(一般取 90%)开始到电压恢复到此门槛所经历时间。

电压凹陷是严重电能质量问题, 作为补偿电压凹陷装置的动态电压恢复器(dynamic voltage regulator, DVR)在工作时必须快速、实时检测到凹陷电压的特征量, 即检测凹陷电压的幅值、相位以及凹陷发生时间。因此, 专家学者研究了许多电压凹陷检测方法, 但是实时性一直是困扰这一问题的关键。采用本文的反馈神经网络模型可以实时、快速地检测到凹陷电压的特征量。

设 $y_d(t) = u_s(t) = U_{sm} \sin(\omega t + \varphi_s)$ 为供电系统电源电压, 也是神经网络的期望输出。神经网络的神经元个数取 $n = 1$ 。神经网络的状态(实际输出)为 A, B , 而

$$\begin{aligned} U_m^2 &= A^2 + B^2, \quad \varphi = \arctan(B/A), \\ y(t) &= u(t) = U_m \sin(\omega t + \varphi). \end{aligned}$$

$u(t)$ 就是经神经网络检测到的特征量产生的电压, $u(t)$ 与电源电压 $u_s(t)$ 有最小均方误差。检测到的结果如图2、图3、图4和表1所示。图5为现有检测方法的检测波形, 用于和图2—图4比较。

在图 2 和图 4 中, 从上至下分别为电源电压 $u_s(t)$ 、网络检测到的电压幅值 U_m 、检测到的电压相位 φ 、网络检测到的输出波形 $u(t)$ 和误差曲线 $\Delta u = u_s(t) - u(t)$.

正常情况下电源电压 u_s 幅值为 311V, 初相位为 0° . 在 $0\text{--}0.6\text{s}$ 内电压发生 3 次凹陷. 凹陷发生时, 幅值从 311V 降到 155.5V, 持续 0.1s 后又恢复到 311V, 连续 3 次; 图 2 中幅值跌落时相位不变, 图 3 为展宽的电压幅值跌落波形, 图 4 中幅值跌落时伴随相位变化, 相位变化为 $\Delta\varphi = 60^\circ$ 的跳变.

从图 2—4 中所示的检测结果可以看到, 在电压发生凹陷的瞬间, 网络有非常好的动态性能, 可以快速检测到幅值的跳变, 时延非常小. 这正是反馈神经网络的优点, 由于反馈的作用, 网络的输出可

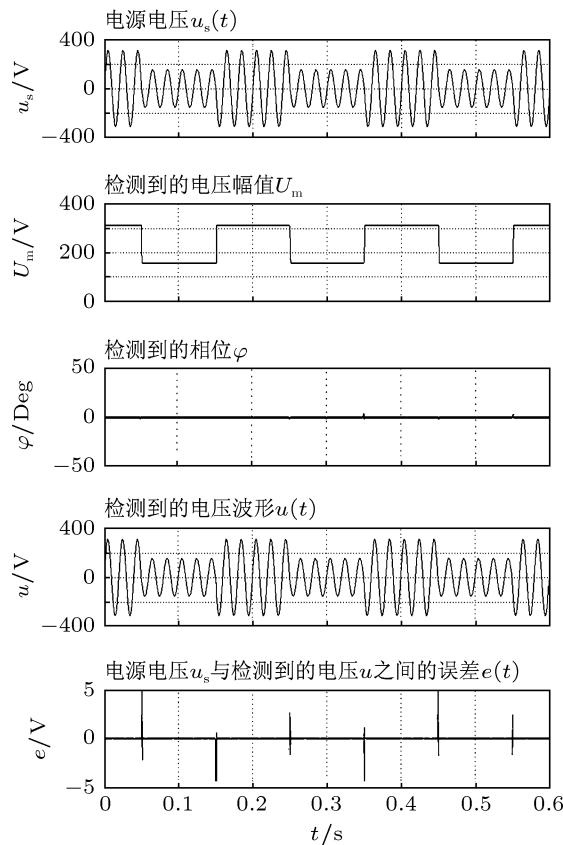


图 2 模拟算例波形 ($\Delta U_m = 155.5\text{V}$, $\Delta\varphi = 0^\circ$)

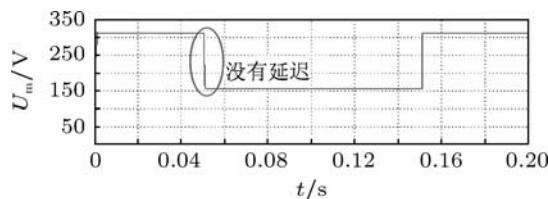


图 3 展宽的电压幅值波形

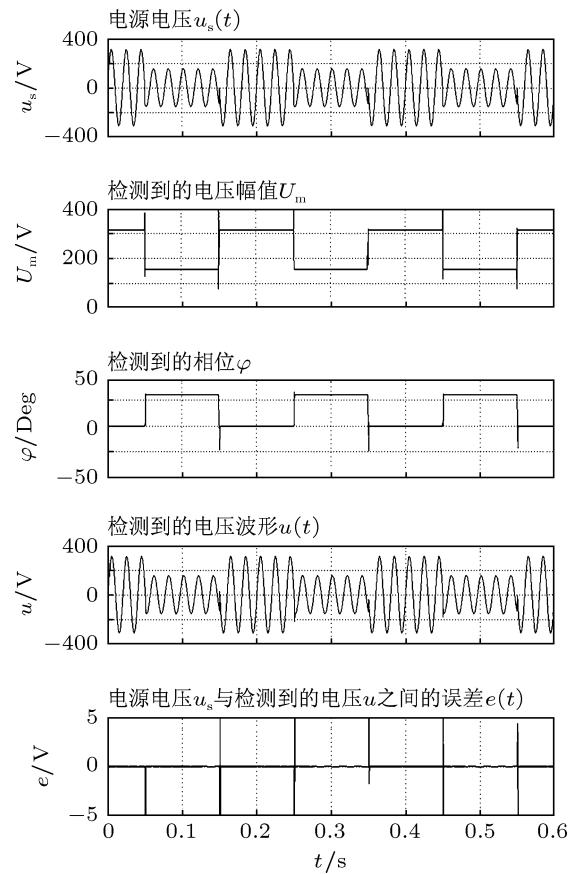


图 4 模拟算例波形 ($\Delta U_m = 155.5\text{V}$, $\Delta\varphi = 60^\circ$)

表 1 检测到的稳态数据

	实际值	检测值	绝对误差
U_m	311	310.9999993	7.1×10^{-7}
	155.5	155.5000000	1.9×10^{-8}
φ	0°	1.69694×10^{-7}	-1.69694×10^{-7}
	60°	59.99999680	3.2×10^{-6}
A	$\varphi = 0^\circ$	311.0000054	-5.4×10^{-6}
	$\varphi = 60^\circ$	77.75000779	-7.79×10^{-6}
B	$\varphi = 0^\circ$	2.09600×10^{-7}	-2.09600×10^{-7}
	$\varphi = 60^\circ$	134.6669478	2.2×10^{-7}

以快速转换. 从表 1 中网络检测结果也可看到, 网络有非常高的静态精度, 网络实际输出与期望输出误差非常小.

图 5 给出了文献 [15] 中列出的两种检测方法关于电压凹陷时幅值检测结果. 图 5(a) 为基本 $d-q$ 变换加低通滤波器的电压幅值检测结果, 图 5(b) 为采用前馈神经网络的电压幅值检测结果. 将图 5 结果与图 2、图 3、图 4 比较可以看出, 本文给出的新结构反馈神经网络具有更好的检测结果, 新型反馈神经网络检测结果中可以看到, 幅值跳变几乎没有时间延迟, 静态也非常精确.

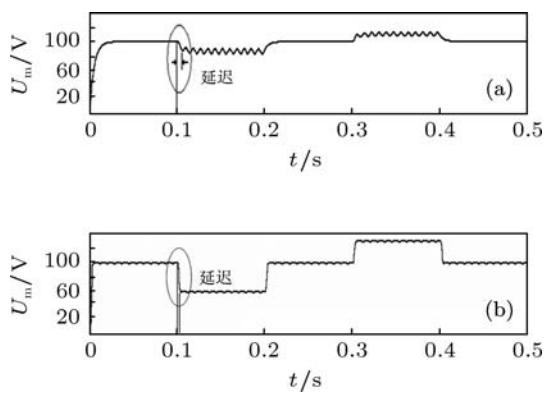


图 5 现有的两种检测方法检测结果 (a) $d-q$ 变换加低通滤波器检测结果; (b) 采用前馈神经网络检测的结果

图 6 为电源电压包含谐波时的情况。电源电压的成分为: 基波幅值 311V, 频率 50Hz; 谐波幅值 62.2V(基波幅值的 20%), 频率 250Hz(5 次谐波); 当凹陷发生时, 基波和谐波幅值均跌落 50%。表 2 为检测到的稳态结果。

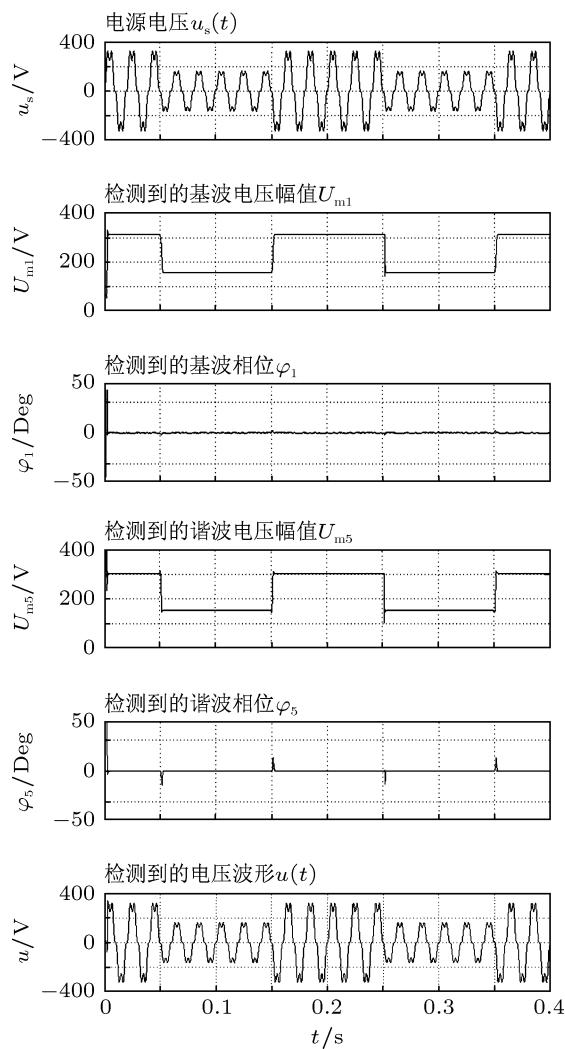


图 6 电源包含谐波时模拟算例波形

表 2 含谐波检测到的稳态数据

	理论值	检测值	绝对误差
基波	311	311	0
U_{m1}	155.5	155.5	0
谐波	62.2	61.09	1.11
U_{m5}	31.1	30.5	0.6
ϕ	基波 0° 谐波 0°	-2.71×10^{-8} -3.98×10^{-7}	-2.71×10^{-8} -3.98×10^{-7}
基波	$A1$	311	0
A, B	$B1$	0	1.47×10^{-7}
谐波	$A5$	62.2	0
A, B	$B5$	0	4.3×10^{-7}
			4.3×10^{-7}

从图 6 可以看到, 当电源含有谐波成分时, 本文提出的反馈网络也能得到很好的检测结果。而且, 本网络可以将基波与谐波分开, 分别得到检测结果。从表 2 可以看到信号含有谐波时, 网络检测的稳态结果也有很高的精度。

根据本文所提出网络的特点并结合 (10) 式和 (27) 式, 可以说明检测结果有很高的静态精度和很好的动态响应特性。

1) 由 (10) 式和 (27) 式可以知到, 随着网络的运行, 网络实际输出与期望输出之间的均方误差(或能量)函数将沿着负梯度方向快速下降, 这使得网络运行最终结果是误差达到最小, 网络表现出很好的静态特性;

2) 另一方面看, 该网络检测结果有很高的静态精度的原因还在于, 网络模型针对周期量提出, 非常适合周期函数的逼近, 因此对于周期量检测有很高的静态精度;

3) 网络的动态特性还由它的反馈结构决定。从图 1 中可以看到, 该网络有两种反馈, 一是第二层的自反馈, 二是两层之间的反馈, 这种反馈使网络在运行中具有很好的动态特性。网络在运行时, 使网络的状态不断变化, 快速达到稳定。因此, 网络有很好的快速响应特性。所以反馈对动态特性的影响至关重要。

图 5(b) 也是采用神经网络的电压凹陷检测, 结果表明实时性不是特别理想。原因是前向函数网络对周期函数的逼近精度与逼近速度与其算法有直接关系, 特别是动态特性, 前向网络无法与反馈网络相比。

5 结 论

本文从非正弦周期函数展开为傅里叶级数出

发, 导出一种具有正弦基函数权值, 每个神经元激活函数都为线性函数的两层反馈神经网络模型. 经过构造该反馈型神经网络的能量函数, 分析了新提出神经网络的稳定性, 结果表明: 该网络运行过程沿着能量函数减小的方向进行, 最终达到 Liapunov

意义下的稳定. 作为模拟算例, 将该网络应用于电力系统中电压凹陷特征量检测, 结果表明: 该网络动态响应速度快, 检测结果静态精度高. 该网络很适合于周期信号的自适应逼近和检测, 为实际应用中周期性信号检测与处理提供了一种新的途径.

-
- [1] Xing H Y, Xu W 2007 *Acta Phys. Sin.* **56** 3771 (in Chinese)[行鸿彦, 徐伟 2007 物理学报 **56** 3771]
 - [2] Watabe K, Shimizu K, Yonyama M 2003 *IEEE Trans. Microwave Theory and Techniques* **51** 1512
 - [3] Reznik L, Von Pless G., Al Karim T 2011 *IEEE Sensors Journal* **11** 791
 - [4] Wei Q, Fung K S A, Chan F H Y 2002 *IEEE Trans. on Biomedical Engineering* **49** 225
 - [5] Selvan S, Srinivasan R 1999 *IEEE Signal Processing Letters* **6** 330
 - [6] Li H Q, Liao X F, Huang H Y 2011 *Acta Phys. Sin.* **60** 020512 (in Chinese) [李华青, 廖晓峰, 黄宏宇 2011 物理学报 **60** 020512]
 - [7] Yuan X F, Wang Y N, Wu L H 2010 *IEEE Transactions on Vehicular Technology* **59** 3757
 - [8] Mevawalla Z N, May G S, Kiehlbauch M W 2011 *IEEE Transactions on Semiconductor Manufacturing* **24** 182
 - [9] Ma Q L, Zheng Q L, Peng H 2009 *Acta Phys. Sin.* **58** 1410 (in Chinese)[马千里, 郑启伦, 彭宏 2009 物理学报 **58** 1410]
 - [10] De W E, Chu Q P Mulder J A 2009 *IEEE Trans. on Neural Networks* **20** 638
 - [11] Barbarosou M P, Maratos N G. 2008 *IEEE Trans. Neural Networks* **19** 1665
 - [12] Qiu S S, Deng F Q, Liu Y Q 2004 *Acta Auto. Sin.* **30** 507 (in Chinese)[邱深山, 邓飞其, 刘永清 2004 自动化学报 **30** 507]
 - [13] Gao W X, Luo X J 2005 *Trans. of China Elecrotechnical Society* **20** 58 (in Chinese)[高炜欣, 罗先觉 2005 电工技术学报 **20** 58]
 - [14] Ma Z E, Zhou Y C 2001 *Qualitative and Stability Method of Ordinary Differential Equation*(Beijing: Science Press) pp78–95 (in Chinese)[马知恩, 周义仓 2001 常微分方程定性与稳定性方法(北京: 科学出版社) 第 78–95 页]
 - [15] Chung Y H, Kim H J, Kwon G H 2007 *IEEE on Power Engineering Society General Meeting*

A feedback neural network with weights of sinusoidal functions*

Li Cheng^{1)2)†} Shi Dan²⁾ Zou Yun-Ping¹⁾²⁾

1) (*State Key Laboratory of Advanced Electromagnetic Engineering and Technology (Huazhong University of Science and Technology), Wuhan 430074 China*)

2) (*College of Electric & Electronic Engineering, Huazhong University of Science and Technology, Wuhan 430074 China*)

(Received 9 May 2011; revised manuscript received 11 August 2011)

Abstract

A new feedback neural network model is proposed. The network has the sinusoidal basis functions as its weights. Neuronal activation function is a linear function. The network connection form is feedback structure. An energy function is defined for the feedback neural network. And then, the network stability issue in operation is analyzed. In the Liapunov sense, the proposed feedback network stability is proved. During the operation of the network, the network states are changed ceaselessly but network weights vary according to time-dependent sinusoidal law. As the network state changes continuously, its energy will be reduced. Finally, when network comes to a stable state, its energy arrives at a minimum value. The network is particularly suited for the adaptive approximation and the detection for periodic signals because of its sinusoidal basis function weights. It is, in practice, a new and effective way for periodic signal detection and processing. The very good detection results are obtained in the detection of power system voltage sag characteristics. Simulation examples show that the dynamic response speed of the network is very high.

Keywords: feedback neural network, sinusoidal basis function weights, Liapunov stability, signal detection

PACS: 07.05.Mh, 42.79.Ta, 42.82.Ds

* Project supported by the National Natural Science Foundation of China (Grant No. 50277017).

† E-mail: cheng_lyb@163.com