

前向神经网络的武器装备水平评估

李飞, 谷奇平, 张文明

(空军工程大学 导弹学院, 陕西 三原 713800)

摘要:对应用人工神经网络技术解决武器装备水平评估问题进行了探讨,给出了基于BP网络的武器装备水平年代评估模型,对参评武器的性能参数进行了预处理,仿真结果表明了该方法的有效性及应用潜力。

关键词:水平年代;神经网络;BP算法

中图分类号:TP18 **文献标识码:**A **文章编号:**1009-3516(2001)05-0036-03

在武器装备的水平评估中,水平年代是表征同类武器综合性能及其技术水平的方法之一。在评估过程中,通过专家共同确定同类装备中的典型型号作为评估参照点,将其它型号装备的相关性能参数与参照点的性能参数进行比较、分析、综合,从而得到水平年代的评估值。由于在评估中通常选定的性能指标多于参照点数,这是一种小样本多因素的综合判断问题。按照逼近论的观点,小样本多因素的综合判断问题可抽象为映射逼近问题,先将评估模型定义为映射并预先给出映射的一个含参数表示,然后根据确定的逼近准则以样本为基准求出参数。在线性逼近中,通常是选择确定的基函数组张成一函数线性子空间,在一定的度量意义下,寻求待逼近映射在该子空间上的投影,即最佳逼近。对于低维问题,这一思想相当有效,特别是用有限元逼近复杂映射更显巧妙,能以局部简单性的综合表现整体复杂性。但是,逼近高维映射则面临着多种困难,主要是难保基函数的完备性且无法避免维数灾难。因此,需要寻找一种既不需要构造基函数又能对事物进行正确计算的非线性求解方法。

1 前向神经网络原理

人工神经网络是一种由许多人工神经元构成的,模仿生物神经系统的网络系统,具有自组织、自学习和自适应等大规模非线性动力系统的特征。其中,多层前向网络是目前较为成熟且应用广泛的一种网络模型。它由一个输入层、一个输出层和若干隐层组成。每一层的神经元直接受前一层神经元的输入。输入模式经过各层的顺次变换后,得到输出层的输出^[1]。本文在此网络模型的基础上采用了误差的反向传播学习算法,即BP算法。利用BP算法实现高维复杂映射的非线性逼近,具有对逼近参数和基函数自适应寻优的特点,这是一般数学中的逼近方法难以达到的^[2]。网络通过对典型模式的自学习,将学到的知识隐含在网络结构中,需要计算的输入数据通过具有确定网络结构的计算,即可得出模式判断结果。

本文中网络模型为三层前馈网络,由输入层、隐层、输出层组成。其中,隐层、输出层为计算单元。输入节点数为N,即为武器装备的性能指标项,输出节点数为1,即为水平年代值。整个网络是由武器装备的性能指标集合映射到其相应的水平年代值。节点的作用函数选择S型函数 $f(x) = 1/(1 + e^{-x})$ 。

研究第 l 层的第 j 单元。设给定 P 个样本 $(x_p, y_p), p = 1, 2, \dots, p$,各单元的特性为sigmoid型,当输入第 p 个样本时,节点 j 的输入为 $net_{jp}^l = \sum_i W_{ji}^l O_{ip}^{l-1}$,输出为 $O_{jp}^l = f(net_{jp}^l)$,使用平方型误差函数 $E_p = (1/2) * \sum (y_{jp} - Y_{jp})^2$,其中 Y_{jp} 为单元 j 的实际输出。总误差为

$$E = \left(\frac{1}{2 * P} \right) * \sum_{p=1}^P E_p, \text{ 定义 } \delta_{jp}^l = \frac{\partial E_p}{\partial net_{jp}^l}。 \text{ 于是 } \delta_{jp}^l = f'(net_{jp}^l) * \left(\sum \delta_{kp}^{l+1} * W_{kj}^{l+1} \right); \frac{\partial E_p}{\partial W_{ji}^l} = \delta_{jp}^l * O_{ip}^{l-1}。 \text{ 这样,反向传}$$

播算法的步骤可概括如下:

1) 选定权系数初值;

2) 重复下述过程直到收敛:①对 $P=1$ 到 $P:a$. 计算每层各单元之 $O_{jp}^{l-1} * net_{jp}^l$ 和 $Y_p (l=2 \cdots L, \text{正向过程})$; b . 对各层 ($l=L-1$ 到 2) (反向过程), 对每层各单元, 计算 σ_{jp}^l 。②修正权值: $dW_{ji}(t+1) = \mu * \frac{\partial E}{\partial W_{ji}(t)} + \alpha * \text{del}W_{ji}(t)$; $W_{ji}(t+1) = dW_{ji}(t+1)$; $\text{del}W_{ji}(t+1) = \text{del}W_{ji}(t)$ 。其中 $\mu=0.15$ 为学习率, $\frac{\partial E}{\partial W_{ji}} = \sum_{p=1}^P \frac{\partial E_p}{\partial W_{ji}}$, $\alpha=0.075$ 为动态因子^[3]。

2 参评参数预处理

神经网络进行学习和计算时,神经元的处理函数为有界的 S 型函数,输出被控制在 $[0,1]$ 中。所以在实际评估中,必须将装备的水平年代值按比例变换到 $[0,1]$ 中。同时,若将输入值变换到 $[0,1]$ 内,神经元计算将有比较敏感的反映,网络收敛的速度也比较快。因此,输入值也应当按照某种规律变换到 $[0,1]$ 中。

当给出参加评估的武器装备的各项性能参数原始数据后,首先对之进行归一化预处理,以产生适于神经网络处理的数据。本模型采用的是非线性 S 型可导函数归一法。这是基于对武器装备性能参数物理意义上的考虑:采用非线性可导 S 型函数进行归一,可突出性能参数的饱和特性。一方面,装备的某项性能参数有其物理或当今技术实现能力的极限;另一方面,提高装备某项性能所带来的效益本质上也有 S 型曲线的趋向。因此,我们考虑用 S 型函数做归一化处理。即 $f(x) = 1/1 + \alpha e^{-\beta x}$ 其中 α, β 为调节曲线的参数。最后确定数据的归一化准则如下:

1) 对于数值越大越好的项,则有 $X_i = \frac{1}{1 + e^{-\tan\left(\frac{2\arctan(\ln 2)}{x_{\max} - x_{\min}} * (x_i - \frac{x_{\max} + x_{\min}}{2})\right)}}$ 。其中, X_i 为归一化后的值, x_i 为原始性能参数值, x_{\max} 为所有同类装备中某项性能参数的最大值, x_{\min} 为最小值。

2) 对于数值越小越好的项,则有 $X_i = \frac{1}{1 + e^{-\tan\left(\frac{2\arctan(\ln 2)}{x_{\min} - x_{\max}} * (x_i - \frac{x_{\max} + x_{\min}}{2})\right)}}$ 。(参数定义同 1)。

3 结果后处理

神经网络计算所得的结果是 $[0,1]$ 之中的数据,还不足以成为装备的水平年代的评估值。随后要进行结果后处理。

1) 多项式插值。为使非线性评估映射的逼近具有插值性,即对训练样本取指定值,将神经网络直接输出值经二次多项式插值得到水平年代值。插值计算方法采用分段插值法,即将插值区域划分为若干子域,然后在每个子域或分段上使用低阶插值,如线性插值或二次抛物线插值。例如,若典型样本数为三,即使用三点 x_1, x_2, x_3 及其相应的函数值 $f(x_1), f(x_2), f(x_3)$, 其插值公式为

$$f(x) = \frac{(x - x_2)(x - x_3)}{(x_1 - x_2)(x_1 - x_3)} f(x_1) + \frac{(x - x_1)(x - x_3)}{(x_2 - x_1)(x_2 - x_3)} f(x_2) + \frac{(x - x_2)(x - x_1)}{(x_3 - x_2)(x_3 - x_1)} f(x_3)$$

2) 迭代计算。由于任何评估问题参评参数的选择本质上带有主观性,因此,可将每轮评估值作为一项性能参数再进行新一轮评估,能得到不断修正的结果。从逻辑上,此做法与人为选定性能参数无本质矛盾,同时还蕴含着人们进行评估时本质上是逐步逼近的特点。在数学上,这一做法相当于定义评估是其定义域到自身的连续映射,而评估结果便是该映射的不动点。因为,上述神经网络的结构和 BP 算法保证了逼近映射在 N 维欧氏空间单位闭立方体上连续、自反的,而欧氏空间的闭立方体必是紧凸集,由 Brouwer 不动点定理可知其不动点存在,故迭代必收敛。

4 模型实现

本文建立的模型如图 1 所示。在评估过程中,首先由领域专家共同确定某类武器的典型型号作为神经网络学习的样本,即将其可比性能参数及其已确定的水平年代值经过归一化处理后分别作为神经网络学习

的输入参数和输出结果,经过神经网络的反复学习后,确定了神经网络的内部结构。然后将待评型号的性能参数经过预处理后输入神经网络,经过神经网络的计算及结果后处理,从而得出该型号的水平年代值。

5 实例计算

以高炮的水平年代评估为例计算结果如表 1 所示。经专家评定,该评估结果较好地反映了各型高炮综合水平的情况,可以作为装备发展论证的评价参考。

表 1 外军高炮水平年代评估情况表

装备名称	有效射程 /m	有效射高 /m	初速 /m/s	射速 /m/s	弹丸重 /g	全重 /g	方向瞄速 /(°)	高低瞄速 /(°)	参照年代	计算年代
M/36L60 式 40 mm 高炮	2 560.00	1 200.00	880	120	930	2 150	60.00	40.00	31.00	31.00
L/70 式 40 mm 高炮	4 000.00	3 000.00	1 005	240	960	5 150	85.00	45.00	50.00	50.00
BOFI 式 40 mm 高炮	4 000.00	3 000.00	1 025	300	880	5 300	85.00	45.00		52.29
GCF-BM2 式 30 mm 双管高炮	3 000.00	2 500.00	1 080	1 300	360	5 492	90.00	60.00		52.93
GDF-001 式 35 mm 双管高炮	4 000.00	3 000.00	1 175	1 100	550	6 210	120.00	60.00	59.00	59.00
Breda 式 30 mm 双管高炮	3 500.00	2 500.00	1 044	1 600	369	5 000	120.00	80.00		55.43
Breda 式 40 mm 高炮	4 000.00	3 000.00	1 200	300	960	5 300	85.00	45.00		52.93
“狩猎女神”式 30 mm-双管高炮	3 500.00	2 500.00	1 040	1 600	369	7 400	100.00	75.00		56.35
74 式 37 mm 双管高炮	3 500.00	3 000.00	866	480	732	2 960	50.00	30.00		42.67

6 结束语

对于本文所涉及的武器装备水平年代的划分问题,BP 网络可以较好地实现。在网络的训练过程中,除了网络自身的参数设置外,典型年代(即训练样本)和装备性能参数的选择是对水平年代的形成起决定作用的,而这一部分也正是领域专家所起的作用。应当引起注意的是,为了保证评估结果的有效性,专家选择的典型型号数最少不应低于 3 个。当这两者都确定以后,可以通过调节网络自身的参数,改善网络性能,以尽可能获得理想输出。

参考文献:

- [1] 阎平凡. 对多层前向神经网络研究的几点看法[J]. 自动化学报,1997,23(1):25-27.
- [2] 李明国,郁文贤. 神经网络的函数逼近理论[J]. 国防科技大学学报,1998,5(4):22-24.
- [3] Hecht-Nielsen R. Theory of the Backpropagation Neural Network[J]. UCNN,1989,18(22):593-605.

A Study of Weapon Level Year's Evaluation Based on the Forward Neural Network

LI Fei, GU Qi-ping, ZHANG Wen-ming

(The Missile Institute, Air Force Engineering University, Sanyuan 713800, China)

Abstract: The paper discusses the problems of weapon level year's evaluation, presents a weapon level year's evaluation model based on the back-propagation neural network, and pre-processes the performance parameters of the weapons concerned. The results of simulation show that the model is effective and promising.

Key words: level year; neural network; BP algorithm

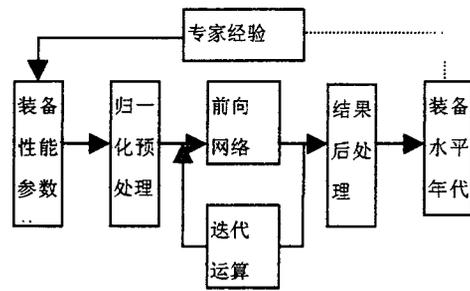


图 1 神经网络的武器装备水平年代评估模型