

## 基于神经网络的汽油干点软测量

包 健, 曾文华, 严 义

(杭州电子工业学信息工程分院, 浙江 杭州 310037)

**摘要:** 针对常压蒸馏塔产品质量(汽油干点)测量困难的特点, 建立质量指标(汽油干点)与其影响因素的多层前馈神经网络, 应用神经网络的输入输出非线性函数逼近原理, 将易于测量的温度压力等参数作为网络的输入, 使经过 BP 算法学习的神经网络输出与实际化验的质量指标(汽油干点)值逼近。以此方法来实现常压蒸馏塔产品质量的在线软测量, 以获得控制与优化所需的实时质量测量信号。这种软测量为实现常压塔的质量优化控制奠定了基础。

**关键词:** BP 算法; 软测量; 实时测量信号; 质量优化控制

中图分类号: TP183      文献标识码: A      文章编号: 1001- 9146(2000) 01- 0072- 04

### 0 引 言

在常压塔控制系统中, 产品质量控制需要将各产品质量如汽油干点作为被控变量加以测量控制。目前, 在汽油干点的控制中, 离线化验分析值因其采样周期长、实时性差, 无法直接实现质量闭环控制。而在线质量分析仪表虽然运行稳定、精度较高, 但由于其价格昂贵、测量滞后大、在线维护保养困难, 因此也很少用于闭环控制。

在工业控制界, 一般有二种方法来实现软测量, 一种是以工艺机理为基础的软测量计算, 另一种就是本文所介绍的基于神经网络的计算模型。前者要求对工艺机理有非常深入的了解, 以得到软测量计算公式。神经网络方法的实质是一种非线性函数逼近的方法, 用较易测量的并且对输出影响较大的工艺参数值与输出的非线性关系, 建立一个神经网络的模型, 用输入输出样本集对网络进行学习训练使其逼近实际的输入输出关系。目前神经网络方法在处理复杂系统的建模问题上具有优越性。它应用于非线性对象动态或静态辨识的软测量技术正成为研究的热点, 这方面已发表的文章如文献[4]。本文是以常压蒸馏塔的质量控制为对象, 并且在算法实现上与前者也有较大不同。

### 1 建立软仪表的方法

首先从工艺机理出发, 定性分析与汽油干点有关的因素, 同时根据实际装置的特点, 筛选出影响较

收稿日期: 1999- 11- 25

作者简介: 包健(1962-), 女, 浙江温州人, 讲师, 硕士, 智能控制。

大的变量, 建立相应的函数。影响汽油干点的因素很多。根据炼油厂实际装置的特点和操作经验可初步确定主要影响因素有:

- 常压塔塔顶温度:  $T_{top}$
- 常压塔塔顶压力:  $P_{top}$
- 常压塔顶循环量:  $F_{top}$
- 常压塔顶循环抽出温度:  $T_1$
- 常压塔顶循环返塔温度:  $T_2$
- 常一中抽出温度:  $T_3$
- 常一中流量:  $F_1$

基于该装置现场采样分析发现, 不仅塔顶循环量的波动较少, 而且常一中抽出温度和常一中流量变化对汽油干点的影响不明显, 因而决定选取塔顶温度  $T_{top}$ 、塔顶压力  $P_{top}$ 、塔顶循环抽出温度  $T_1$  和塔顶循环返塔温度  $T_2$  作为辅助变量。进一步研究发现, 塔顶循环的目的主要是取热, 因而抽出温度与返塔温度之差更能代表其对干点产生的影响。因此最终决定采用  $T_{top}$ 、 $P_{top}$  和  $\Delta T = T_2 - T_1$  作为辅助变量。这样, 汽油干点的质量模型可以描述为:

$$y(k) = f[T_{top}(k), P_{top}, \Delta T(k), O(k)] \tag{1}$$

式中:  $y(k)$  ——汽油干点;  $O(k)$  ——其他影响汽油干点的因素;  
 $f(\cdot)$  ——它们之间的非线性函数关系;  $k$  ——采样次数。

用  $T_{top}$ 、 $P_{top}$ 、 $\Delta T$  三个辅助变量作为输入, 汽油干点作为输出, 用神经网络来拟合它们之间的非线性关系  $f[\cdot]$ 。

## 2 网络结构和算法

选取在石油化工领域中普遍适用的多层前馈网络。在多层前馈网络的实际应用中, 不但只能使用有限的节点, 而且只有有限的训练集。在确定网络结构时, 为了使网络尽量简单, 首先确定采用三层前馈网络, 若能达到输入输出的映射要求即可以, 否则再增加网络的隐层数。另外, 当网络的隐层节点增加时, 一方面神经网络逼近目标函数的最小误差减小, 但另一方面网络的泛化指标随之增大。所以神经网络选择过大或过小的隐层节点都无法得到很好的应用效果。当训练样本非常大的时候, 可以选取较多隐层节点, 但当神经网络的训练集合较小时, 就要选取适当的隐层节点, 或者在网络中结合先验知识, 从而提高网络的泛化性能。因此, 本文采用三层前馈网络建立干点的软测量模型。由于训练集较小, 所以采用较少的网络隐层节点。网络结构如图 1 所示。其输入、输出关系为:

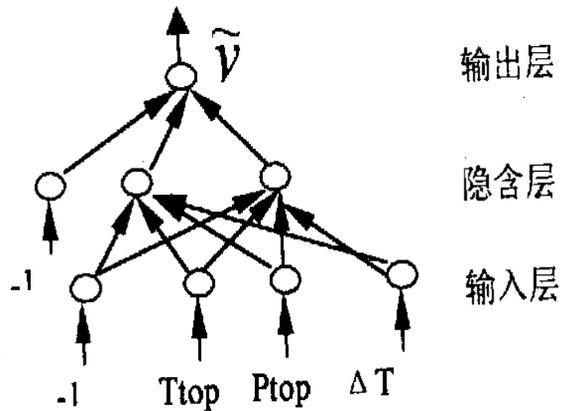


图 1 汽油干点的神经网络模型结构

$$\tilde{y}(k) = f_2\left[\sum_{i=1}^m v_i z_i(k) + v_0\right] \tag{2}$$

$$z_i(k) = f_1\left[\sum_{j=1}^n \omega_{ij} x_j(k) + \omega_{i0}\right] \quad i = 1, \dots, m; j = 1, \dots, n; k = 1, \dots, N \tag{3}$$

式中:  $m$  ——隐节点数为 2;  $n$  ——输入节点数为 3;  $N$  ——样本数为 30;  $\omega_{ij}$  ——隐含层权值, 为  $\omega_{11}, \omega_{12}, \omega_{13}, \omega_{21}, \omega_{22}, \omega_{23}$ ;  $v_i$  ——输出层权值, 为  $v_1, v_2$ ;  $x_j(k)$  —— $x_1, x_2, x_3$  分别为辅助变量  $T_{top}, P_{top}, \Delta T$ ;  $z_i(k)$  ——第  $i$  个隐节点的输出;  $\tilde{y}(k)$  ——汽油干点的估计值;  $f_1, f_2$  ——节点作用函数。

取  $f_1(x) = \frac{1}{1 + e^{-x}}, f_2(x) = x$ 。

网络学习过程是网络中各权值的不断调整过程。在图 1 所示的三层前馈网络中, 第一层为输入层, 第二层为隐层, 第三层为输出层。设给定  $N$  组输入输出样本  $X_1, X_2, X_3, Y$ , 利用该样本集首先对 BP 网络进行训练, 也即对网络的连接权系数进行学习和调整, 以使该网络实现给定的输入输出映射关系。

设取拟和误差的代价函数为:

$$E = \frac{1}{2} \sum_{k=1}^N (y(k) - \tilde{y}(k))^2 \quad (4)$$

问题是如何调整权值以使代价函数  $E$  最小。在实用中 BP 算法存在两个重要问题: 收敛速度慢, 目标函数存在局部极小。本文为了改进收敛速度慢的问题采用变步长法来选择学习率, 该算法是步长在迭代过程中自适应进行调整, 因此对于不同的连接权系数实际采用了不同的学习率, 也就是说误差代价函数  $E$  在超曲面上在不同的方向按照各自比较合理的步长向极小点逼近。具体算法如下:

Step1: 初始化,  $v_1, v_2, \omega_{11}, \omega_{12}, \omega_{13}, \omega_{21}, \omega_{22}, \omega_{23}$ , 允许误差  $\varepsilon$ , 迭代次数  $q$ , 整体误差  $E$ 。

Step2: 取  $N$  组样本集, 从  $k=1$  到  $N$  计算输出层节点误差  $\delta^*(k)$ 、隐层节点误差  $\delta_1(k), \delta_2(k)$ 。

Step3: 调整权值  $v_1, v_2, \omega_{11}, \omega_{12}, \omega_{13}, \omega_{21}, \omega_{22}, \omega_{23}$ , 权值算式中学习率用变步长法计算。

Step: 计算整体误差:  $E_{\text{总}} < \sum_{k=1}^N (E(k))$ , 若  $E_{\text{总}} < \varepsilon$  则结束, 否则判权值是否改变, 若不变则结束, 否则若  $q >$  最大迭代次数, 则结束, 否则继续 Step2。

### 3 结论

如前所述, 以塔顶温度、塔顶压力、顶循温差作为神经网络的输入, 以汽油干点作为网络的输出, 并采用 30 组具有代表性的实际工况作为学习样本, 其数据见附表。该表中的 30 组数据用于网络训练, 另外再选 40 组数据用于泛化性试验。

附表 生产记录数据表(样本点)

序号	塔顶温度 ℃	塔顶压力 kpa	顶循温 差℃	汽油干点 化验值℃	序号	塔顶温度 ℃	塔顶压力 kpa	顶循温 差℃	汽油干点 化验值℃
1	131.392	82	31.104	165	16	133.677	85	29.880	165
2	131.497	91	28.267	164	17	132.501	85	28.550	170
3	132.039	100	25.794	166	18	132.788	93	28.866	171
4	133.700	91	29.123	165	19	133.338	87	30.478	168
5	134.416	90	28.445	164	20	134.224	86	29.784	168
6	132.953	76	31.085	162	21	133.401	90	28.772	171
7	133.219	83	29.860	172	22	133.102	94	28.429	169
8	132.756	78	31.365	171	23	133.984	90	28.707	164
9	133.694	86	30.418	166	24	132.926	86	30.701	166
10	133.064	80	31.512	162	25	129.155	75	33.146	168
11	132.742	79	30.087	166	26	129.425	75	32.745	166
12	133.501	85	28.552	165	27	128.441	71	34.532	166
13	132.080	75	30.127	168	28	129.494	79	31.760	158
14	133.162	89	29.603	169	29	129.815	68	32.717	158
15	131.698	80	30.828	166	30	131.552	75	30.251	161

结果见图 2 所示, 经过 10 轮左右训练后, 网络模型的估计值与实际化验值基本能满足误差要求。该经过训练的 BP 网络, 再将 40 组数据送入其中, 从图 2 中可看出对于不是样本集中的输入, 已经显示

它也能给出合适的输出, 因此证明该网络具有较好的泛化功能。经测试得出网络输出的绝对值最大误差为  $1.256^{\circ}\text{C}$ , 绝对值平均误差为  $0.322^{\circ}\text{C}$ , 满足了控制的精度要求。

常压蒸馏塔的侧线质量控制是整个蒸馏过程控制任务的核心。因为蒸馏塔是直接出产品的装置, 而油品收率的提高、能耗的降低都必须以产品质量合格为前提。侧线产品的质量指标很多, 利用软测量技术解决了常压塔的优化控制系统中产品质量在线控制问题, 因此具有很好的应用前景。

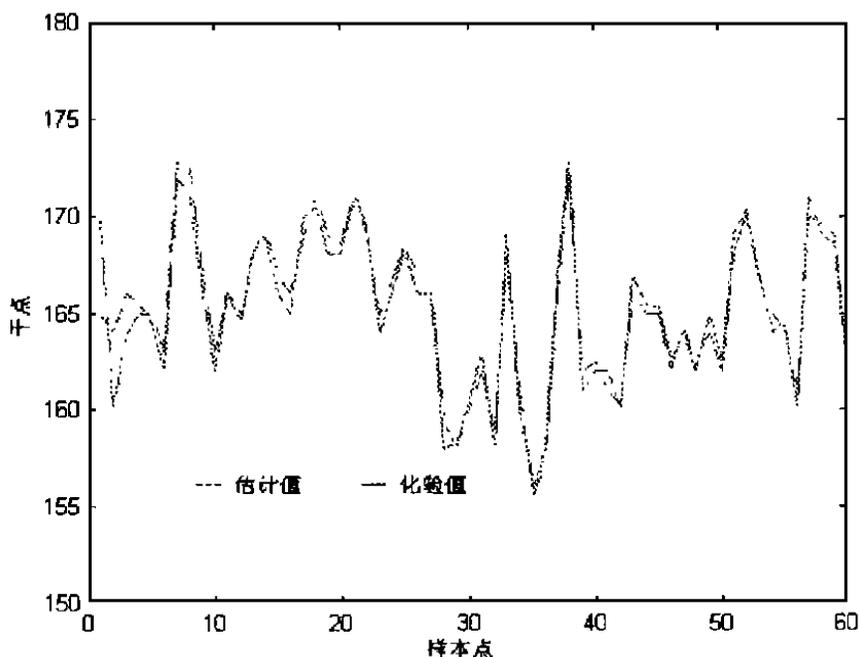


图 2 神经网络软测量估计值与实际化验值的比较

## 参考文献

- [1] 丁云, 于静江, 周春晖. 原油蒸馏塔的质量估计与优化管理[J]. 石油炼制及化工, 1994, (5). 23.
- [2] 孙增圻. 智能控制理论与技术[M]. 北京: 清华大学出版社; 南宁: 广西科学技术出版社, 1992. 129136.
- [3] Sayama H. Modelling and stage-to-stage computation of multicomponent distillation process as a multistage optimization problem[J]. Journal of Chem. Engng. Of Jpn., 1990, 23(4), 413.
- [4] 孙欣, 王金春, 何声亮. 基于神经网络的粗汽油干点的实时估计[J]. 炼油化工自动化, 1996, (5). 17.
- [5] 魏克新, 王云亮, 陈志敏. MATLAB 语言与自动控制系统设计[M]. 北京: 机械工业出版社, 1997, 1858.

## Soft-Measurement of Petrol End Point Based on Artificial Neural Network

BAO Jian, ZENG Wen-hua, YAN Yi

(Department of Computer Science and Technology, Hangzhou Institute of Electronic Engineering, Hangzhou zhejiang, 310037, China)

**Abstract:** Since product quality (petrol end point) of crude tower is not easy to be measured, a neural network and model about product quality (petrol end point) is presented. In this neural network, temperature and press variable are taken as input and product quality (petrol end point) value is taken as output. Using Non-linear function approximation principle of neural networks and BP algorithm, the network output is approached the value measured in practice. Using this way, soft-measurement estimation is realized, which provides real-time measurement for control and optimization. This lays a foundation for realizing quality control of crude tower.

**Keywords:** BP algorithm soft-measurement real-time measurement signal quality optimization control