

基于神经网络的铝电解混合控制模型研究^{*}

汪成亮^{a,b}, 庞 栩^a, 陆志坚^a

(重庆大学 a. 计算机学院; b. 电气工程学院, 重庆 400044)

摘要: 铝电解优化控制生产过程的实质是将可控参数尽量控制在工艺要求的目标值范围内。传统的基于神经网络的控制方法或直接判断氧化铝浓度, 缺乏对历史浓度的有效追踪, 致使判断准确率下降; 或对铝电解生产状况进行宏观识别, 并调整, 但缺乏实时性、及时性。针对上述问题, 将神经网络和关联规则库、专家知识库、控制策略相结合, 提出了一种新的氧化铝浓度识别及控制方法, 从而将神经网络上升为一种混合控制模型 HC-NN (hybrid control- neural network)。该模型以控制参数(自变量)为神经网络输入, 和其输出共同作为关联规则库部分前件, 对氧化铝浓度进行预测, 并使其能对可控参数进行自适应调整, 进而将氧化铝浓度(因变量)控制在专家知识库的目标范围内, 最终实现对铝电解生产过程的优化控制。通过实际生产运行, 验证了系统的可行性和有效性。

关键词: 神经网络; 智能控制; 铝电解; 时间序列

中图分类号: TP273.2

文献标志码: A

文章编号: 1001-3695(2010)07-2536-04

doi:10.3969/j.issn.1001-3695.2010.07.038

Research on hybrid control methods of aluminum reduction on neural network

WANG Cheng-liang^{a,b}, PANG Xu^a, LU Zhi-jian^a

(a. College of Computer Science, b. College of Electrical Engineering, Chongqing University, Chongqing 400044, China)

Abstract: Substance of control problem of optimal control in the process of aluminum electrolytic production is to control possible the controllable parameters into technological desired ranges. The traditional control method based on ANN is that judging and controlling the concentration of alumina directly. But the method can not follow efficiently historic concentration of alumina so that accuracy rating is not high. Another is that diagnosing and controlling aluminum electrolytic status. But this method is only macroscopic for recognize status and it lacks of real time. According to such problems, combining associative rule base, expert knowledge base, control strategy with ANN, this paper proposed a new method of recognizing and controlling, and it made ANN be a hybrid controlling model HC-NN. The new method used the input (controllable parameters-independent variable) and output of ANN to be one part of the front conditions of the associative rule base so that it could forecast the concentration of alumina, control the controllable parameters of the process of production self-adaptive, control dependent variables into technological desired ranges, and then realized optimal control in the process of aluminum electrolytic production. The feasibility and effectiveness of this approach has been proved by the practical production result.

Key words: neural network; intelligent control; aluminum reduction; time series

铝电解是一个非线性、多变量耦合、时变和大时滞的工业过程体系,其过程伴随着复杂的物理化学反映。因此,复杂多变的生产过程决定了电解槽运行过程中众多参数和变量具有强耦合、不确定性、不可连续测定性,难以对此建立准确的数学模型。近年来,智能控制理论得到迅速发展,为解决上述问题提供了一种新的思路。在智能控制方法中,由于神经网络方法本身所具有的非线性映射能力强,能够学习和适应不确定性系统的动态特性以及允许多输入多输出的特性,使其在求解非线性和不确定性控制问题方面具有其他方法所不具备的优势与潜力。本课题将神经网络与关联规则库、专家知识库相结合,对铝电解槽的槽电阻变化趋势进行精确预测和控制,构成一种新的对电解槽氧化铝浓度的实时预测、混合控制模型 HC-NN^[1],以达到优化铝电解生产控制过程的目的。

1 铝电解问题描述

1.1 氧化铝浓度控制

目前,铝电解的生产控制主要以氧化铝浓度控制为主,即将氧化铝浓度控制在一定目标范围内,因此氧化铝浓度的准确判断是整个浓度控制的基础,而整个铝电解过程中,惟有电解槽槽电阻变化趋势与氧化铝浓度具有特定的特征关系^[2-4],如图 1 所示。在实际生产过程中,影响氧化铝浓度的主要控制参数是氧化铝下料间隔(以下简称下料间隔),在其他条件不变的情况下,下料间隔越大,氧化铝浓度越小,反之越大。而现在铝电解生产过程的问题是:下料间隔变化能影响氧化铝浓度变化,氧化铝浓度变化引起槽电阻趋势变化。但从图 1 可知,槽电阻和氧化铝浓度的特征曲线为一抛物线,且实际生产过程有众多不确定因素,造成单从槽电阻变化趋势并不能判断出氧化

收稿日期: 2009-12-13; 修回日期: 2010-01-11 基金项目: 重庆市自然科学基金资助项目(CSTC,2007BB6118); 中国博士后科学基金资助项目(20080430750)

作者简介: 汪成亮(1975-),男,副教授,博士,主要研究方向为软件工程、人工智能、故障诊断; 庞栩(1981-),男,重庆人,硕士研究生,主要研究方向为数据库、数据挖掘、神经网络(lpx2007@sina.com); 陆志坚(1985-),男(布衣族),硕士研究生,主要研究方向为智能技术。

铝浓度的精确大小。

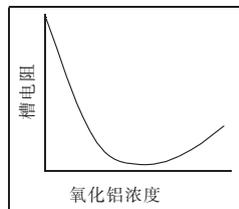


图 1 槽电阻特征曲线

1.2 铝电解过程时序分析

目标槽电阻变化趋势被视为预测事件或为控制事件。事件的预测问题可以描述为判断在不久的将来目标事件是否会发。在时间序列数据中,通常目标事件并不是孤立存在。在目标事件发生之前,时间序列的演变会呈现出一定的规律^[5,6]。因此,可以通过研究目标事件发生之前,时间序列所发生的变化,发现与目标事件相关的特征模式,进而达到预测目标事件是否会发生的目的。

目前的铝电解实际生产情况,能够实时检测、计算,具有反应氧化铝浓度大小的间接信号只有槽电阻值和氧化铝下料间隔(其中氧化铝下料间隔为控制参数)。下料间隔变化趋势决定氧化铝浓度变化趋势,进而影响槽电阻变化趋势。因此,某段时间内的槽电阻变化趋势($F_1, F_2, F_3, \dots, F_n$)、下料间隔变化趋势($G_1, G_2, G_3, \dots, G_n$)及下一时段的下料间隔变化趋势 G_{n+1} 决定了下一时段的槽电阻变化趋势 F_{n+1} 。

在此引入灰关联规则相关概念^[7],在整个监控事物拓朴空间中,属性集的元素集 Ω 包括槽电阻 X_0 、下料间隔 X_1 。

定义 1 设 X_0 是 Ω 中关于时间段 \oplus_j 的槽电阻属性序列; X_1 是 Ω 中关于时间段 \oplus_j 的下料间隔属性序列; F_j 是 \oplus_j 时间段关于 X_0 的特征(即槽电阻变化趋势), f 为特征函数; G_j 是 \oplus_j 时间段关于 X_1 的特征(即下料间隔变化趋势), g 为特征函数。

$$\begin{cases} X_0 = \{ \langle x_0(k), \oplus_j \rangle | k = 1, 2, 3, \dots, n, j = 1, 2, 3, \dots, n \} \\ X_1 = \{ \langle x_1(k), \oplus_j \rangle | k = 1, 2, 3, \dots, n, j = 1, 2, 3, \dots, n \} \\ F_j = f(X_0, \oplus_j) \\ G_j = g(X_1, \oplus_j) \end{cases} \quad (1)$$

F_j 和 G_j 是一种时间序列数据,下一时段下料间隔变化趋势 G_{j+1} 为控制参数,下一时段槽电阻变化趋势 F_{j+1} 为预测事件或控制事件。

2 混合控制模型及系统架构

2.1 系统总体设计

基于神经网络的铝电解混合控制模型主要包括数据处理模块、氧化铝浓度判断关联规则库、专家知识库、神经网络控制模型。其基本控制思想主要由以下几个步骤组成,HC-NN 控制流程如图 2 所示。

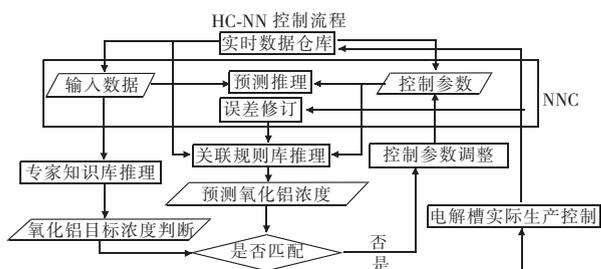


图 2 模型控制流程

a) 通过数据处理模块将铝电解实时数据库数据存入数据

仓库,并用数据挖掘技术形成以某时段内槽电阻和下料间隔变化趋势为主要前件的氧化铝浓度判断关联规则库。

b) 根据工艺思想中的最佳氧化铝浓度变化过程,形成氧化铝目标浓度专家知识库。

c) 控制参数和与之对应的神经网络输出同时作为关联规则的输入以推测氧化铝目标浓度,不断调整控制参数直到预测浓度和专家知识库的目标浓度达到最佳匹配。

d) 将确定好的控制参数传输给实时数据库,供生产使用,并以实际生产输出进行误差修订。

2.2 数据处理

本文的研究基于精确的时序分析,分别采用过滤、均值填充、继承三种 ETL 技术对数据进行处理,以确保实时数据的完整性和准确性。用时间序列光滑中的 n 阶加权移动平均方法^[8]以消除原始数据中不必要的波动。

$$v_i = \frac{1}{n} \sum_{k=i-n}^{i+n} w_k \times v_k, \sum w_k = 1 \quad (2)$$

数据处理程序通过最大—最小规范化方法对式(1)中各时序特征作归一化处理:

$$v'_i = (v_i - \min) / (\max - \min) \quad (3)$$

2.3 浓度判断关联规则库及推理专家知识库

氧化铝浓度(以下简称浓度)判断、控制是铝电解过程的一大难题,本课题的最终目标也是精确控制槽电阻变化趋势而实现对浓度的精确控制。在离线测试氧化铝浓度后,本文采用基于 Apriori 算法和 OLAP 的关联规则数据挖掘模型^[9-11]对该关联规则库进行建模,归为维度的时序特征有电解槽序号、槽电阻变化趋势、下料间隔变化趋势、上一时刻浓度、当前浓度、时间序列。

各特征概念分层后,不同的层次用不同的数字代替,部分关联规则如下:

槽电阻变化趋势 = 4, 下料间隔变化趋势 = 5, 上一时刻浓度 = 5 → 当前浓度 = 6

根据特定时间单位内浓度的时序特征及最佳工艺控制思想,氧化铝浓度推理专家知识库确定下一时刻浓度的目标值,在此不作过多阐述。

2.4 神经网络控制模型

本课题主要是将神经网络强大的预测能力应用于实际控制的应用性研究,在实时数据、历史数据的时序分析基础上,利用神经网络建立系统的预测模型,并将训练好的神经网络上升为控制模型。首先用属性集的实际输入、输出数据建立神经网络预测模型;然后将某输入数据作为控制参数,通过调整控制参数以得到不同的预测值,通过关联规则库推算预测浓度值,并将该值与专家知识库得出的最佳控制目标值进行匹配;最后推理出控制参数并运用于生产,以实际生产数据和预测值对神经网络进行修正。改进后的控制模型如图 3 所示。

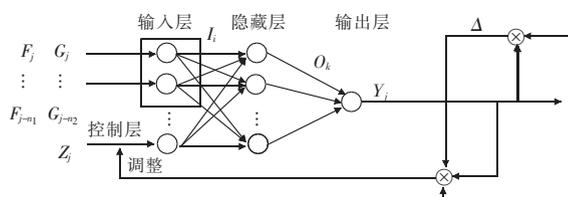


图 3 神经网络控制模型

本文采用时延神经网络对槽电阻变化趋势建模。时延序

神经网络是指具有时间序列输入的神经网络,网络有时延及反馈的存在,网络中神经元的输入—输出不是简单的输入输出映射关系,对神经网络的训练及输出具有复杂网络的动态特征^[12]。就本文所提的下料间隔,其既是时间序列数据,又是控制参数。

定义 2 设 j 为当前时间标志, net 为训练好的神经网络, Z_j 为控制参数, Δ 为误差修订值, 则 BP 控制网络的预测输出为

$$\begin{cases} Y_j = \text{net}(F_j, \dots, F_{j-n_1}, G_j, \dots, G_{j-n_2}, Z_j) + \Delta \\ F_{j+1} = Y_j \\ Z_j = G_{j+1} \end{cases} \quad (4)$$

其中: Y_j 表示生产中的实际输出; n_1 表示 Y_j 与 F_j 的 $n_1 + 1$ 个时刻相关; n_2 表示 Y_j 与 G_j 的 $n_2 + 1$ 个时刻相关。

定义 3 设 Δ_i 为各时间段实际输出和预测输出误差值, Y'_i 为实际输出, 则

$$\Delta_i = Y'_i - Y_i \quad (5)$$

用存储器存储各时间段的误差。由于铝电解存在异常情况, 如加料器堵塞、铝电解发生效应, 从而造成预测值和实际值相差过大且失真。滤掉这些突变点后, 以当前时间为基准, 采用逼近加权平均的方法推导出 Δ 误差修订值:

$$\begin{cases} \phi = \Delta_{j-n} \cup \Delta_{j-n}, \dots, \Delta_j \\ \phi = \phi - \text{突变点} \\ \Delta = \frac{\sum_{k=j-n}^j w_k \Delta_k}{(j-n+1)} \\ \Delta_k \in \phi, w_k > w_{k-1} > w_{k-2}, \dots, \sum w_k = 1 \end{cases} \quad (6)$$

其中: n 表示 Δ 所基于的时间范围。

3 HC-NN 模型的建立

铝电解过程中, 下料间隔变化趋势只能决定氧化铝浓度变化方向, 但对电解槽浓度的绝对大小缺乏准确的解释。由于槽电阻变化趋势和下料间隔变化趋势蕴涵有氧化铝浓度变化大小的特征, BP 控制模型的基本思想是结合槽电阻变化趋势、下料间隔变化趋势、前—时刻浓度及氧化铝浓度规则准确判断当前氧化铝浓度大小并加以控制。

3.1 神经网络输入层、控制层、输出层确定

输入层、控制层、输出层节点数完全根据使用者要求来设计。本文的研究中, 研究对象是槽电阻变化趋势。根据实际情况的特征, 取输入层为前—时刻下料间隔变化趋势、槽电阻变化趋势, 时间阶次为 2, 时间段以 10 min 为一单位^[13]; 控制层为下一时刻下料间隔变化趋势, 输出层为下一时刻槽电阻变化趋势。因此神经网络模型输入节点数为 5, 表示为

$$Y_j = \text{net}(F_j, F_{j-1}, G_j, G_{j-1}, Z_j) \quad (7)$$

参照图 3, 神经网络隐藏层输出和输出层输出函数采用:

$O_i = R(\sum_{k=1}^n w_{ki} I_i + \theta_{ki})$, $Y_j = R(\sum_{i=1}^p w_i O_i + \theta_j)$ 。其中: R 采用 logsig 传递函数; n, p 分别为输入层和隐藏层节点数; BP 神经网络的学习函数采用 Levenberg-Marquardt 优化算法 (trainlm 函数)。

训练好的 BP 网络进入实际生产后上升为神经网络控制模型, 输出层的预测输出实际为: $Y_j = Y_j + \Delta$ 。

3.2 隐藏层确定

隐含层单元数目的问题至今没有一个完全统一的方法来解决, 常用的解决办法就是使隐含层单元数目可变, 开始放入比较少的隐含层单元, 学习一定次数后, 还不成功就要增加隐含单元个数, 一直达到比较合理的隐含单元数目为止。对三层

神经网络而言, 经验上可得到隐含层单元数 h 的几个公式^[14,15]: $h = \sqrt{n+m} + a$, $h = \sqrt{n \cdot m}$, a 为 0~10 的常数。本文经过实验取隐藏层节点数 11。

3.3 神经网络算法学习

本文的神经网络模型为 $5 \times 11 \times 1$ 结构, 三层 BP 神经网络的学习算法如下^[15]:

a) 设定学习次数 $t = 0$, 对网络权值和阈值赋予小的随机数, $w_{ik}(t) \in [-1, 1]$, $w_k(t) \in [-1, 1]$, $\theta_k(t) \in [-1, 1]$, $\theta_j(t) \in [-1, 1]$ 。

b) 输入一个学习样本 (X_K, T_K) 。其中: $K \in \{1, 2, \dots, N\}$; N 为样本数; $X_K \in R^5$, $T_K \in R^1$ 。

c) 计算隐含层各节点的输出值:

$$O_k = R(\sum_{i=1}^5 w_{ik} I_i + \theta_k) = R(\sum_{i=1}^5 w_{ik} X_{Ki} + \theta_k), k \in \{1, 2, \dots, 11\}$$

d) 计算输出节点的输出:

$$Y_j = R(\sum_{k=1}^{11} w_k O_k + \theta_j)$$

e) 输出层节点和隐含层节点之间权值修正量计算:

$$\delta = (T_K - Y_j) \times Y_j \times (1 - Y_j)$$

f) 隐含层节点和输入层节点间连接权值修正量的计算:

$$\delta_k = O_k \times (1 - O_k) \times \sum_{k=1}^{11} w_k \delta$$

g) 用 e) 求出的误差修正量 δ 来修正输出层和隐含层间连接权值和阈值:

$$w_k(t+1) = w_k(t) + \alpha \times \delta \times O_k$$

$$\delta(t+1) = \delta(t) + \alpha \times \delta$$

h) 用 f) 求出的误差修正量 δ_k 来修正隐含层和输入层间连接权值和阈值:

$$w_{ik}(t+1) = w_{ik}(t) + \alpha \times \delta_k \times X_{Ki}$$

$$\delta_k(t+1) = \delta_k(t) + \alpha \times \delta_k$$

i) 如果全部学习样本未取完, 则返回步骤 b); 否则, 转 j)。

j) 计算误差函数 E , 并判断 E 是否小于规定的误差上限。如果 E 小于误差上限, 则算法结束; 否则, 学习次数到算法结束; 否则更新学习次数 $t = t + 1$, 返回步骤 b)。

3.4 HC-NN 模型控制参数的确定

神经网络训练好后, 控制参数的确定将直接影响对浓度的精确控制, 算法将模型各部分有机结合起来以形成自适应的混合控制模型。根据关联规则库, 下一时刻目标浓度判断的前置条件为: 当前浓度、下一时刻下料间隔变化趋势 NB 、下一时刻槽电阻变化趋势 R , 其中 NB 为控制参数。算法基本思想为: 根据当前浓度、下一时刻目标浓度确定由 NB 和 R 组成的所有项集集合 L , 再从 L 中确定最佳控制策略, 即最终使预测值和控制目标值误差最小。具体算法如下:

now_c: 当前氧化铝浓度

next_c: 由专家知识库推理出的下一时刻氧化铝目标浓度

nb: 下一时刻下料间隔变化趋势(可控参数)

r: 下一时刻槽电阻变化趋势(因变量)

g(): nb 的概念分层函数

f(): r 的概念分层函数

NB_K: 概念分层后的下一时刻槽电阻变化趋势, 即 $NB_K = g(nb)$

R_K: 概念分层后的下一时刻下料间隔变化趋势, 即 $R_K = f(r)$

L: 数据仓库中, 前置条件是 now_c、next_c, 后置条件为 NB_K、R_K 的所有项集集合;

Err: 误差集合;

begin

```

ERR = Ø //先赋予误差集合为空集
while(L ≠ Ø) //当 L 集合不为空时
{
l = max_confidence L( now_c, next_c, NB_K, R_K)
//取 L 中置信度最大的项集
NB_K = l. NB_K;
R_K = l. R_K; //取 l 集合中的 NB_K, R_K 值
If( next_c = rule( now_c, NB_K, R_K)
//rule 是关联规则库中氧化铝浓度推理规则
{
for j = 1 to N
{
nbk = min(NB_K) + (( max(NB_K) - min(NB_K) ) / N) × j // * N
为调整速率。由于 NB_K 是概念分层后的 nb 值,以 min(NB_K)、max
(NB_K) 表示包含于 NB_K 中的最小、最大 nb 值 * /
rj = net( ...nbj ) // * 以逐步调整的控制参数 nbj、HC-BP 网络得到相
应的下一时刻槽电阻变化趋势 rj 值, ... 表示其他输入参数 * /
R' = f(rj) //将 rj 概念分层
if( R' = R_K ) // * rj 和 R_K 相等,表明与 rj 对应的控制值 nbj 能够
使氧化铝生产达到下一时刻的目标浓度 * /
{
Errj = (nbj - NB_K中心)2 + (rj - R_K中心)2
Err = Err ∪ Errk //计算 rj、nbj 与之对应的概念分层中心值的误差
} //结束 If
} //结束 for 循环
} //结束 If
if( Err = Ø ) // * 检查 Err 是否为空集。若为空,表明 l 中没有满足
控制要求的 nbj, 需要进一步在 L 中寻找控制值 * /
{
L = L - 1
}
else
{
nb = min( Err1, Err2, ..., Errk ). nb
//若 Err 不为空,取 Err 中与最小误差对应的 nb 值作为控制值
L = Ø //将 L 设为空集,结束 While 循环
}
} //while
Return nb
end

```

4 应用实例

4.1 神经网络的训练

本系统于 2008 年 10 月 ~ 2009 年 1 月在某电解铝厂进行调试。训练样本为 834 条,其中包括某台电解槽 15 天的实时数据及铝电解专家给出的、符合工艺思想的弥补数据。训练过程中,网络训练目标精度只有 0.323%,并未达到预设精度 0.1%。考虑到铝电解实际情况,0.3% 左右的精度误差完全符合工艺控制要求。BP 神经网络精度收敛曲线和训练样本拟合情况如图 4 和 5 所示。

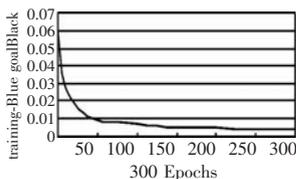


图 4 BP 网络精度收敛曲线

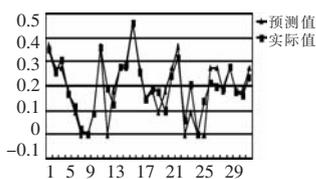


图 5 训练样本拟合曲线

4.2 实际生产效果及经济效益

本系统于 2009 年 1 月在 26 台电解槽上投入生产,计划于 2011 年 9 月前完成所有电解槽的调试。

HC-NN 模型对铝电解生产过程进行了有效的优化,取得了明显效果。目前该系统平均每 10 min 就会自动调整氧化铝下料间隔,有效、准确地控制了氧化铝浓度。以某台电解槽 10 天数据,1 063 条测试样本为例:归一化处理后,槽电阻变化趋势目标控制值和生产实际数据拟合曲线如图 6 所示,槽电阻变化趋势控制目标和实际生产误差均方差为 0.007 4,方差为 7.858 5,精度达到 90% 和 85% 的样本比例分别为 84.8% 和 91.8%。虽然期望输出的槽电阻变化趋势和实际值有一定误差,但基于该精度所得的氧化铝浓度控制和判断精度均在 90% 以上。期望输出、HC-NN 预测输出和生产实际输出值部分结果如表 1 所示,实际生产数据中的控制目标和实际值误差均方差为 0.294 3。

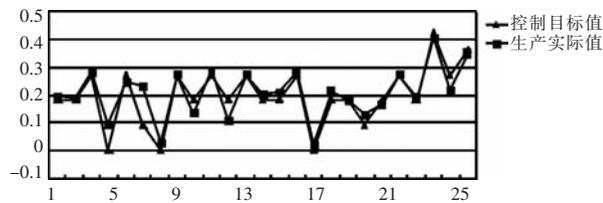


图 6 目标控制值和生产实际数据拟合曲线

使用本系统电解槽的直流电耗降低 100 ~ 150 kwh/t-Al 不等,达到了节能降耗的目的,为企业增加了经济效益。若按某电解铝单位年产量 65 万吨铝、电耗降低 100 ~ 150 kwh/t-Al 计算,一年累计节约用电 100 kwh/t × 650 000 t ≈ 6 千万 kwh。

5 结束语

本文将关联规则库、专家知识库、BP 神经网络、控制技术相结合,提出了一种新的铝电解优化控制系统,充分发挥了神经网络高度的非线性处理能力和强大的自适应、自学习、容错能力,对铝电解槽电阻、下料间隔进行了有效的预测和控制以达到精确控制氧化铝浓度变化的目的,实际效果明显。但从实际生产过程中的抽取样本数据看,本系统的预测控制目标和实际值间的误差精度并非很高,还有待对该系统进一步完善。同时,本系统在铝电解过程的个别异常情况(尤为铝电解效应过程)中的预测控制精度较低,但对这种异常情况能作出提前辨识,进而给出警告使系统转入其他控制策略。如何解决这些异常情况以及如何进一步提高准确性是笔者下一步工作的目标。

表 1 期望输出、HC-NN 预测输出和生产实际输出值

| 控制值 | 期望输出值 | 期望浓度 | HC-NN 预测值 | 生产实际输出值 | 实际浓度 | 是否达到期望 | 时间序列 | 均方差 | |
|-------|---------|------|-----------|---------|-------|--------|---------|-----|----|
| nb | r | R_K | next_c | r' | r'' | R_K' | next_c' | | |
| 31.34 | -6 ~ -4 | 1 | 2 | -4.10 | -4.96 | 1 | 2 | 是 | 1 |
| 35.29 | -4 ~ -3 | 2 | 3 | -3.65 | -3.11 | 2 | 3 | 是 | 2 |
| 35.56 | -4 ~ -3 | 2 | 5 | -3.44 | -3.69 | 2 | 5 | 是 | 3 |
| 43.73 | -2 ~ -1 | 4 | 7 | -1.23 | -1.71 | 4 | 7 | 是 | 4 |
| 51.65 | 0 ~ 0.5 | 7 | 6 | 0.78 | -0.43 | 6 | 7 | 否 | 5 |
| 62.90 | 1 ~ 2 | 9 | 5 | 1.39 | 1.67 | 9 | 5 | 是 | 6 |
| 57.27 | 1 ~ 2 | 9 | 4 | 1.56 | 1.32 | 9 | 4 | 是 | 7 |
| 62.18 | 2 ~ 3 | 10 | 2 | 2.47 | 2.84 | 10 | 2 | 是 | 8 |
| 65.56 | 2 ~ 3 | 10 | 2 | 2.51 | 2.48 | 10 | 2 | 是 | 9 |
| 68.21 | 3 ~ 4 | 11 | 1 | 3.88 | 3.62 | 11 | 1 | 是 | 10 |

参考文献:

[1] 柴天佑,丁进良,王宏,等.复杂工业过程运行的混合智能优化控制方法[J].自动化学报,2008,34(5):505-515.

$$\text{SemMatch} = w_1 \times \text{Match}(\text{ReqOutputs}, \text{AdvOutputs}) + w_2 \times \text{Match}(\text{ReqInputs}, \text{AdvInputs}) \quad (11)$$

其中: $w_1 + w_2 = 1$, 分别表示输出集和输入集在 Web 服务功能匹配中的权重。

3 应用实例

以供应链中产品销售领域本体作为知识服务的领域本体, 存在以下五个知识服务:

Req: ServiceCategory = (需求预测)
 Inputs(0.4) = {价格(0.3), 市场占有率(0.3), 前期销售量(0.2), 经济增长率(0.1), 季节指数(0.1)};
 Outputs(0.6) = {需求量(0.4), 需求波动范围(0.2), 最优库存量(0.4)};
 (括号内数字为用户输入的相应权重值)
 Adv1: ServiceCategory = (需求预测)
 Inputs = {价格, 竞争对手平均价格, 前期销售量, CPI 指数};
 Outputs = {需求量, 需求波动范围, 最优价格};
 Adv2: ServiceCategory = (订单预测)
 Inputs = {价格水平, 前期销售量, 季节指数};
 Outputs = {订单期望数量, 最大订单数量, 最低订单数量};
 Adv3: ServiceCategory = (库存预测)
 Inputs = {上期产量, 需求量, 当期库存};
 Outputs = {库存水平, 安全库存};
 Adv4: ServiceCategory = (订单预测)
 Inputs = {价格, 市场份额, 前期销售量, 季节指数};
 Outputs = {订单量, 最优库存量};

其中: Adv1~4 为已注册的广告服务, 即可提供的服务; Req 为请求服务; ServiceCategory 为其服务类别描述; Inputs、Outputs 为其输入输出概念集, 这些均是从服务描述中提取的与功能匹配有关的信息, 其他与此无关的信息并没提取。功能性匹配过程如下:

a) 计算服务功能类别匹配度。结果显示, $S_{\text{sim}}(\text{Req}, \text{ServiceCategory}, \text{Adv3}, \text{ServiceCategory})$ 小于阈值, 类别筛选后的服务集为 (Adv1, Adv2, Adv4)。

b) 计算服务功能语义匹配度。结果显示, $\text{SemMatch}(\text{Req}, \text{Adv2})$ 小于阈值, 功能性筛选后的服务集为 (Adv1, Adv4)。此服务集用于以后的基于服务质量的筛选。

从这个例子可以看出, 输入、输出集权重完全是用户请求

服务的描述信息, 对于其他描述信息相同而输入、输出集权重不同的服务, 此匹配算法得到的是完全不同的结果。例如将 Req 中输入、输出集权重改为 0.6、0.4 后, 功能性筛选后的服务集改变为 (Adv1, Adv2, Adv4)。因此该算法充分利用了请求服务的描述信息, 即用户的需求信息。

4 结束语

本文在总结和分析相关服务发现和匹配算法的基础上, 提出了一个面向敏捷供应链的基于扩展 OWL-S 和 QoS 知识服务描述模型, 此模型对知识服务的服务质量信息进行了描述, 并在此基础上总结和分析了传统匹配算法及其不足, 提出了一种语义相似度计算方法, 并将此方法引入到服务功能类别匹配和输入输出匹配中。在此算法中, 计算概念集相似度时, 利用用户设定的各个概念的权重计算加权平均值与简单的算术平均值方法相比, 加强了服务描述信息的机器可理解性, 即更大程度上匹配了用户的需求。

此服务匹配不仅实现了用户需求和服务能力之间的功能性匹配, 而且支持基于服务质量匹配的服务筛选, 具体的基于服务质量的筛选将是以后的重点研究内容。

参考文献:

- [1] 杨敏才, 凌超, 王槐林. 供应链的知识管理系统[J]. 研究与发展管理, 2004, 16(1): 44-48.
- [2] 臧志, 金葆弘, 李玉明. 服务描述和服务匹配研究[J]. 计算机科学, 2008, 35(10): 266-287.
- [3] 胡建强, 邹鹏, 王怀民, 等. Web 服务描述语言 QWSDL 和服务匹配模型研究[J]. 计算机学报, 2005, 28(4): 505-513.
- [4] 韩涛, 郭荷清, 高英. 基于 QoWS 的 Web 服务评估算法[J]. 计算机科学, 2006, 33(5): 60-62.
- [5] 吴健, 吴朝晖, 李莹. 基于本体论和词汇语义相似度的 Web 服务发现[J]. 计算机学报, 2005, 28(4): 595-602.
- [6] 吴海鹏, 饶若楠. 一种基于服务本体及其词汇语义的 Web 服务匹配算法[J]. 计算机应用与软件, 2008, 25(5): 151-153.
- [7] MARTA S, PAN J. Towards semantically enhanced Web service repositories[J]. Journal of Web Semantics, 2007, 5(2): 142-150.
- [8] 谢琪, 张振兴. 基于 Apriori 算法和 OLAP 的关联规则挖掘模型设计[J]. 计算机应用, 2007, 27(6): 4-9.
- [9] 吴军. 铝电解过程控制智能算法的研究[J]. 工业控制计算机, 2004(5): 31-32.
- [10] BOGDANOVA G, GEORGIEVA T. Discovering the association rules in OLAP data cube with daily downloads of folklore materials[C]// Proc of International Conference on Computer Systems and Technologies. 2005: 1-6.
- [11] 文蓉. 数据挖掘中关联规则算法及其应用研究[D]. 长沙: 湖南大学, 2007.
- [12] 刘杰, 黄亚楼. 基于 BP 神经网络的非线性网络流量预测[J]. 计算机应用, 2007, 27(7): 1770-1772.
- [13] LI Jie-jia, WU Cheng-dong, LI Meng-xin. The application of distributed neural network fault diagnosis technique in process control[C]// Proc of the 6th World Congress on Intelligent Control and Automation. 2006: 5553-5556.
- [14] LEE S C, HEINBUCH D V. Training a neural-net-work base intrusion detector to recognize novel attacks[J]. IEEE Trans on SMC, 2001, 31(4): 294-299.
- [15] 韩力群. 人工神经网络理论、设计及应用[M]. 北京: 化学工业出版社, 2005.
- [16] MEGHAOUI A, THIBAUT J, BUI R T. Neural networks for the identification of the aluminium electrolysis process[J]. Computers Chem Engng, 1998, 22(10): 1419-1428.
- [17] BEREZIN A I, POLIAKOV P V, RODNOV O. Neural network qualifier of noises of aluminum reduction cell[EB/OL]. (2003). http://www.mayak-pkf.ru/articles/neuralnetworkqualifierofnois.
- [18] 闫相斌, 李一军, 崔广斌. 事件预测的时间序列数据挖掘方法[J]. 计算机工程, 2006, 32(5): 29-31.
- [19] PERLMAN E, JAVA A. Predictive mining of time series data in astronomy[C]//Proc of Astronomical Data Analysis Software and Systems XII ASP Conference Series. 2003: 431-434.
- [20] 刘思峰, 党耀国, 方志耕, 等. 灰色系统理论及应用[M]. 2 版. 北京: 科学出版社, 2007.
- [21] HAN Jia-wei, KAMBER M. Data mining: concepts and techniques[M]. 2nd ed. Beijing: China Machine Press, 2007.

(上接第 2539 页)