

粒子滤波优化的相关向量回归多步预测方法

李 勇^{1,2}, 陈俊达², 张胜满², 常 亮²

(1 63863 部队, 吉林 白城 137001; 2 63956 部队, 北京 100095)

摘 要: 为有效削弱多步回归预测中的累积误差, 提出粒子滤波优化的相关向量回归多步预测方法. 采用相关向量机建立预测对象的状态特征参数回归预测模型. 将回归模型作为系统状态方程, 预测输出的概率分布作为重要性分布, 采用粒子滤波算法对预测值进行动态修正, 逼近状态的最优估计. 对比实验验证了该方法的预测精度相比相关向量回归多步预测有较大的提高.

关键词: 相关向量机; 粒子滤波; 多步预测

中图分类号: TP206⁺. 3

文献标识码: A

文章编号: 1000-7180(2015)01-0161-04

Relevance Vector Regression Multi-step Prediction Method Optimized By Particle Filter

LI Yong^{1,2}, CHEN Jun-da², ZHANG Sheng-man², CHANG Liang²

(1 Troops No. 63863, Baicheng 137001, China;

2 Troops No. 63956, Beijing 100095, China)

Abstract: In order to weaken cumulative error in multi-step regression prediction effectively, relevance vector regression multi-step prediction method optimized by particle filter is proposed in this paper. Relevance vector machine is used to build regression prediction model of characteristic parameters of state. Regression model is acted as system state function and probability distribution of prediction output is acted as importance distribution. By using particle filter algorithm, prediction data is corrected dynamically and the optimal state is estimated. It is proved that the precision of relevance vector regression multi-step prediction method optimized by particle filter is improved by contrast experiment.

Key words: relevance vector machine; particle filter; multi-step prediction

1 引言

多步预测是指用过去的 $m(m \geq 1)$ 个观测数据去预测未来的 $k(k \geq 1)$ 个时刻的值, 即把历史上的前 m 个数据作为预测模型的输入, 预测得出 k 个输出值, 这是一个从 $R^m \rightarrow R^k$ 的映射问题^[1]. 目前常用的多步预测方法是逐步递推多步预测方法, 它是将前一次单步预测的结果作为真实值重新建立预测模型, 然后按照相同的方法逐步递推算出预测值. 在逐步递推过程中, 由于下一步的预测是在前一步预测值的基础上进行的, 因此会引入预测误差, 累积误差会随着预测步数的增加而迅速增加.

目前对多步预测方法的研究主要集中在如何提高多步预测的精度上. 刘劲松^[2]提出了灰色自适应预测模型与非平稳 ARMA 模型自校正预测模型的组合多步预测模型, 适合随机时变动态系统的多步预测问题, 具有预测精度和可靠性高的特点. 殷礼胜^[3]等提出基于混沌机理的小波神经网络快速学习算法, 并应用到交通流量的时间序列多步预测中, 取得了较好的预测效果. 王秋香^[4]等结合 BP 算法和一般多步预测算法提出了设备状态的多项式神经网络迭代多步预测算法, 在设备状态的中长期预测中具有较高的预测精度. 由于相关向量机 (Relevance Vector Machine, RVM) 通过后验分布来反映模型

中权值最优的不确定性,近年来它也逐步被用来预测建模.仕玉治^[5]等对径流时间序列进行相空间重构,并建立基于相关向量机的径流预报模型.该方法能够描述预测值的不确定度并给出相应概率下的预报区间,具有较好的泛化能力.范庚^[6]等提出了灰色相关向量机故障预测模型,并通过引入新陈代谢过程不断更新数据中的信息,克服了灰色模型在长期预测时精度不高的缺陷.预测中累积误差,本文在相关向量回归(Relevance Vector Regression, RVR)预测的基础上,采用粒子滤波算法对回归预测值进行修正,逼近状态的最优估计,可以有效制约相关向量回归预测中累积误差以提高预测精度.

2 相关向量回归模型

相关向量机是一种基于贝叶斯框架的核函数方法^[7],是非线性稀疏学习建模方法的具体实现形式,它由 Tipping^[8]于 2000 年提出.

设 $\{x_i\}_{i=1}^N$ 是训练样本集, $t = [t_1, t_2, \dots, t_N]^T$ 是目标值,其模型可表示一系列核函数的线性组合形式:

$$\begin{aligned} t_i &= \sum_{j=1}^N \omega_j K(x_i, x_j) + \omega_0 + \varepsilon_i \\ &= y(x_i; \omega) + \varepsilon_i \\ &= \varphi(x_i) \omega^T \end{aligned} \quad (1)$$

式中, x_i 为输入的特征向量, ω_i 为样本权值, $\omega = [\omega_0, \omega_1, \dots, \omega_N]^T$ 为与样本对应的权值向量, $\varphi(x_i) = [1, K(x_i, x_1), K(x_i, x_2), \dots, K(x_i, x_N)]$ 为核函数向量, 内积函数 $K(\cdot)$ 为核函数, $\Phi = [\varphi(x_1), \varphi(x_2), \dots, \varphi(x_N)]^T$, t_i 为预测输出.

假设存在噪声 ε_i 服从均值为 0, 方差为 σ^2 的高斯分布, 则 $p(t_i) = N(t_i | y(x_i; \omega), \sigma^2)$, 设 t_i 独立同分布, 在已知 $\{\omega_i\}_{i=0}^N$ 与 σ^2 的条件下, 整个训练样本数据集的似然函数为

$$\begin{aligned} p(t | \omega, \sigma^2) &= \prod_{i=1}^N p(t_i | \omega, \sigma^2) \\ &= (2\pi\sigma^2)^{-N/2} \exp\left(-\frac{\|t - \Phi\omega\|^2}{2\sigma^2}\right) \end{aligned} \quad (2)$$

设 ω_i 服从零均值高斯分布: $\omega_i \sim N(0, \alpha_i^{-1})$, 则 ω 的先验概率分布可表示为

$$\begin{aligned} p(\omega | \alpha) &= \prod_{i=0}^N p(\omega_i | \alpha_i) \\ &= \prod_{i=0}^N \frac{\alpha_i}{\sqrt{2\pi}} \exp\left(-\frac{\alpha_i \omega_i^2}{2}\right) \end{aligned} \quad (3)$$

式中, $\alpha = [\alpha_0, \alpha_1, \dots, \alpha_N]^T$ 为超参数向量, 在计算过程中, 超参数值的大小决定权值 ω .

在似然函数及先验分布的基础上, 由贝叶斯公式可推出 ω 的后验概率分布为

$$p(\omega | t, \alpha, \sigma^2) = (2\pi)^{-\frac{N+1}{2}} |\Sigma|^{-\frac{1}{2}} \exp\left\{-\frac{(\omega - \mu)^T \Sigma^{-1} (\omega - \mu)}{2}\right\} \quad (4)$$

式中, $\Sigma = (\sigma^{-2} \Phi^T \Phi + A)^{-1}$ 为后验方差, $\mu = \sigma^{-2} \Sigma \Phi^T t$ 为均值, $A = \text{diag}(\alpha_0, \alpha_1, \dots, \alpha_N)$.

通过边缘积分求得超参数的边界似然度:

$$p(t | \alpha, \sigma^2) = ((2\pi)^{-N/2} / \sqrt{|\Omega|}) \exp\left\{\frac{1}{2} t^T \Omega^{-1} t\right\} \quad (5)$$

式中, $\Omega = \sigma^2 I + \Phi A^{-1} \Phi^T$. 式(5) 两边对 α 和 σ^2 求偏导并令导数为零, 有

$$\alpha_i^{\text{new}} = \frac{\gamma_i}{\mu_i^2} = \frac{1 - \alpha_i \Sigma_{ii}}{\mu_i^2} \quad (6)$$

$$(\sigma^2)^{\text{new}} = \frac{\|t - \Phi\mu\|^2}{N - \sum_{i=0}^N \gamma_i} \quad (7)$$

式中, μ_i 为 μ 中第 i 个元素, Σ_{ii} 为协方差矩阵 Σ 中的第 i 个对角元. 通过依次迭代计算进行 RVM 模型训练, 直到所有参数都收敛或达到最大迭代次数为止, 即完成 RVM 训练过程.

对于训练好的 RVM 模型, 输入新样本 x_* , 其输出 t_* 的预测分布满足高斯分布:

$$p(t_* | t, \alpha_{\text{op}}, \sigma_{\text{op}}^2) = N(t_* | y_*, \sigma_*^2) \quad (8)$$

其中,

$$y_* = \Phi(x_*) \mu \quad (9)$$

$$\sigma_*^2 = \sigma_{\text{op}}^2 + [\Phi(x_*)]^T \Sigma \Phi(x_*) \quad (10)$$

RVM 回归模型结构如图 1 所示.




图 1 RVM 回归模型

RVM 回归模型中的模型权值的估计值由后验分布的均值给出, 同时它也反映出权值最优的不确定性, 因此可以表示模型的不确定性^[6].

3 粒子滤波优化的相关向量回归多步预测

相关向量回归预测是将过去时刻的数据 $\{x(i), i = m, m-1, \dots, m-l+2, m-l+1\}$ 作为输入, 未来时刻的数据 $x(m+1)$ 作为输出, 建立 $x(m+1)$ 关于 $\{x(i), i = m, m-1, \dots, m-l+2, m-l+1\}$ 的时间序列映射关系 $R^l \rightarrow R$, 其中 l 为嵌入维数. 根据 l 个数据训练出相关向量回归模型:

$$x(m) = f(x(m-1)) = \sum_{j=m-l}^{m-1} \omega_j K(x(m-1), x(j)) + \omega_0 \quad (11)$$

根据回归模型, 得到单步预测值:

$$\hat{x}(m+1) = f(x(m)) = \sum_{j=m-l+1}^m \omega_j K(x(m), x(j)) + \omega_0 \quad (12)$$

相关向量回归多步预测是将单步预测值 $\hat{x}(m+1)$ 作为新数据, 加入到原始数据序列中构造出新的数据序列 $\{\hat{x}(m+1), x(m), \dots, x(m-l+2)\}$, 然后应用式递推得到未来 2 步预测值 $\hat{x}(m+2)$. 后续各步预测依此类推.

逐步递推多步预测的精度取决于每一步的预测精度, 如果递推过程中存在预测精度不高的预测步, 则预测误差会逐步累积, 为解决此问题, 本文提出粒子滤波优化的相关向量多步回归预测方法, 算法采用相关向量回归算法对预测对象的状态特征参数的时间序列进行建模, 得到特征参数的回归预测模型. 将回归模型作为系统状态方程, 预测输出的概率分布作为粒子滤波的重要性分布, 从重要性分布中采集粒子, 并加以一定的扰动, 得到粒子集. 采用粒子滤波算法对预测值进行修正, 逼近预测值的最优估计, 再将修正的预测值用于下一步预测.

算法描述如下:

步骤 1 相关向量回归单步预测

采用相关向量回归算法对 $0 \sim m$ 时刻数据进行回归建模, 在此基础上进行 1 步预测, 即预测出 $m+1$ 时刻的数据.

步骤 2 粒子滤波优化预测值

步骤 2.1: 采样粒子

在 m 时刻依据重要性采样, 从 $x(m)$ 时刻采样 N_s 个粒子构成初始粒子集 $\{x_m^i, i = 1, 2, \dots, N_s\}$, 并初始化每个粒子权值 $1/N_s$.

步骤 2.2: 粒子更新

由系统状态方程及 $x(m)$ 时刻采样粒子, 计算

$m+1$ 时刻 N_s 个粒子的状态 x_{m+1}^i , 由观测方程计算 $m+1$ 时刻观测值 y_{m+1}^i .

步骤 2.3: 权值更新

计算 N_s 个粒子 x_{m+1}^i 的权值 ω_{m+1}^i :

$$\omega_{m+1}^i = \omega_m^i \cdot p(y_{m+1}^i | x_{m+1}^i) \quad (13)$$

$$p(z_{m+1}^i | y_{k+1}^i) = \sum_{i=1}^{N_s} \omega_{m+1}^i N(x_{m+1}^i, v P_{m+1}^i) \quad (14)$$

$$v = 0.5 N_s^{-2/d} \quad (15)$$

$p(y_{m+1}^i | x_{m+1}^i)$ 表示粒子值为 x_{m+1}^i 的条件下的分布密度, P_{m+1}^i 表示样本方差. 由于任意连续随机变量的分布密度均可用一组高斯混合模型近似描述, 即对于变量 x_{m+1}^i 的一组随机测度 $< x_{m+1}^i$,

$\omega_{m+1}^i > x_{m+1}^i$ 的样本均值 $\bar{x}^i$ 和方差 P_{m+1}^i 可表示为

$$\bar{x}^i = \sum_{i=1}^{N_s} x_{m+1}^i \cdot \omega_{m+1}^i \quad (16)$$

$$P_{m+1}^i = \sum_{i=1}^{N_s} \omega_{m+1}^i (x_{m+1}^i - \bar{x}^i) (x_{m+1}^i - \bar{x}^i)^T \quad (17)$$

$N(\cdot)$ 表示函数, 形如:

$$N(X, B) = \frac{1}{(2\pi)^{N_s/2} |B|^{1/2}} e^{-\frac{1}{2} X^T B^{-1} X} \quad (18)$$

式中, N_s 为粒子数, d 为状态变量 x_m 的维数.

步骤 2.4: 权值归一化

$$\hat{\omega}_{m+1}^i = \frac{\omega_{m+1}^i}{\sum_{j=1}^{N_s} \omega_{m+1}^j} \quad (19)$$

步骤 2.5: 重采样

判断是否需要重采样, 如果需要重采样, 则对粒子进行重采样, 得到重采样粒子 $\hat{x}_{m+1}^i$.

步骤 2.6: 估计 $m+1$ 时刻状态

$$\tilde{x}(m+1) = \sum_{i=1}^{N_s} \hat{\omega}_{m+1}^i \cdot \hat{x}_{m+1}^i \quad (20)$$

将 $\tilde{x}(m+1)$ 作为相关向量回归预测的修正值.

步骤 3 步数更新

更新预测步数, 如果达到指定的多步预测, 则输出预测值; 否则, 将步骤 2.6 得到的预测值加入到特征参数序列中, 并转入步骤 1, 执行下一步预测.

4 实验及分析

4.1 数据来源及参数设置

本文采用文献[9]中雷达发射机高压电源测试数据来验证预测方法的有效性. 由于发射机发射的脉冲功率高, 对高压电源提出了苛刻要求, 并且高压电源也是易损模块, 因此对其状态进行预测可以有效保证雷达发射机系统的射频质量和寿命. 选择纹

波电压作为高压电源的特征信号,在雷达修理厂等间隔采集 40 个测量数据,其中前 30 个测量数据作为训练样本训练预测模型,后 10 个测量数据作为参考值对比不同预测方法得到的预测值的差异。

相关向量回归模型的性能很大程度上受核函数的影响,本文选择径向基核函数作为 RVR 的核函数:

$$K(x_i, x_j) = \exp(-\|x_i - x_j\|^2 / r^2) \quad (21)$$

式中, $r = 0.05$ 。

初始化超参数: $\alpha(0) = (0.25, 0.25, \dots, 0.25)$, $\sigma_0^2 = \text{var}(y) \times 0.01$, 设置最大循环次数 $iter_{\max} = 50$, $\alpha_{\max} = 1 \times 10^5$ 。

4.2 实验结果及分析

采用相关向量回归多步预测(RVR)和粒子滤波优化的相关向量回归多步预测(PFRVR)两种方法对实验数据进行多步预测,其对比结果如图 2 所示。




图 2 RVR 和 PFRVR 多步预测结果

图中给出了根据前 30 个纹波电压值建立预测模型,预测得出的后 10 个纹波电压值,从图中可以看出, RVR 多步预测也能较准确地跟踪特征参数的变化趋势,但由于前一步的预测误差进入到下一步的预测中,因此,随着预测步长的增加,其预测误差越来越大。PFRVR 考虑到了预测过程中的扰动因素,采用粒子滤波算法对 RVR 的预测值进行修正,因此它的预测精度较 RVR 预测有了明显提高。

为了比较不同预测方法的预测性能,采用均方根误差(RMSE),平均绝对误差(MAE)及相关系数(R)等指标来评价预测模型的性能,其定义如下:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n [(x_i - p_i)/x_i]^2} \times 100\% \quad (22)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |x_i - p_i| / x_i \times 100\% \quad (23)$$

$$R = \left[\sum_{i=1}^n (x_i \times p_i) \right] / \left(\sqrt{\sum_{i=1}^n x_i^2} \times \sqrt{\sum_{i=1}^n p_i^2} \right) \quad (24)$$

以上各式中, n 为样本量, x_i 为实际值, p_i 为预测值。

分别计算文献[6]中提出的灰色相关向量机(GRVM)预测方法、RVR 多步预测方法和 PFRVR 多步预测方法的评价指标值,其结果如表 1 所示。

表 1 预测方法的性能比较

评价标准	GRVM	RVR	PFRVR
RMSE/%	1.17	3.46	0.9
MAE/%	1.06	3.15	0.813
R	0.999 98	0.999 91	0.999 99

从表中可以看出,各种预测值与实际值的相关度均比较高。从预测效果来看, RVR 的精度较低, PFRVR 相比 GRVM 的精度有进一步的提高。GRVM 采用灰色预测模型,并引入新陈代谢过程,也能够弱化预测过程中的扰动因素。而 PFRVR 采用粒子滤波算法还能对预测过程中的非线性非高斯扰动进行估计,能进一步削弱预测误差带来的影响,因此其预测精度得到了进一步提高。

5 结束语

本文在相关向量多步回归预测的基础上,采用粒子滤波算法对预测值进行修正,有效削弱了预测过程中的扰动因素带来的误差。对比实验发现,本文方法的预测精度比单纯的相关向量多步回归预测有明显的提高,也优于灰色相关向量预测方法。

参考文献:

- [1] 刘芳. 基于小波分析和相关向量机的非线性径流预报模型研究[D]. 武汉:华中科技大学, 2007.
- [2] 刘劲松. 多步自适应组合预测及其应用[J]. 佳木斯大学学报:自然科学版, 2009, 27(4): 535-537.
- [3] 殷礼胜, 鲁照权, 董学平. 交通流量小波神经网络多步预测研究[J]. 自动化仪表, 2011, 32(8): 7-10.
- [4] 王秋香, 于德介. 设备状态的多项式神经网络迭代多步预测法[J]. 计算机仿真, 2010, 27(3): 179-181.
- [5] 仕玉治, 彭勇, 周慧成. 基于相关向量机的中长期径流预报模型研究[J]. 大连理工大学学报, 2012, 52(1): 79-84.

(下转第 168 页)

播电台、公众短信、网站、微博、可变情报板、固定式多媒体终端、内部 OA 系统等形式将各类交通实时信息对外发布。该系统平台由信息获取子系统、综合信息服务子系统、信息发布子系统构成。信息获取子系统负责交通实时状态信息的获取,主要来源于各类监测系统的安全状态信息;信息综合服务子系统平台完成所获取交通信息的处理、分析、存储和传输;信息发布子系统将路网运行信息按照工作规范要求以各种手段或渠道对外发布。

交通执法单兵工作系统:该系统是按照“强化一线综合执行能力、方便后端指挥调度管理”的发展思路,为满足高速公路网一线移动式路政、运政、安全管理等业务工作需求,以及后端现场信息获取和指挥调度管理平台应用需求的一项重要的管理措施。交通执法单兵工作系统以无线宽带技术、视频技术和全球定位技术为基础,由移动式前端业务终端子系统和后台管理子系统组成。

6 结束语

设计了一种基于物联网框架的高速公路网运行管理信息系统平台体系架构。

系统的创新之处体现在它综合利用先进的物联网与云计算技术的应用优势,不但具备高速公路管理系统的基本信息管理功能,而且整合了现有的和即将建设的交通设施,并从路网运行管理数据的实时采集和综合利用、交通状态的全面感知和监测、按需使用的资源共享和信息交换等多个方面入手,保证了海量交通状态数据准确、及时地采集、传输、加工和处理,实现了对路网运行状态信息的实时感知与全程监测、综合分析与决策支持,加强了路网管理机构之间的资源共享、信息交换和联动协作合力,提高了高速公路网运行管理服务的效率和突发事件应急指挥处置能力。

目前本系统建设方案的主要功能已经在重庆市公路运行状态监测与效率提升示范工程陆续试用过

程中。

参考文献:

- [1] 蒋新华,陈宇,朱铨,等. 交通物联网的发展现状及趋势研究[J]. 计算机应用研究, 2013, 30(8): 2256-2261.
- [2] 邓爱民,毛浪,田丰,等. 我国 ITS 物联网发展策略研究[J]. 中国工程科学, 2012, 14(3): 83-91.
- [3] 张国伍. 智能交通物联网与综合交通信息服务——“交通 7+1 论坛”第三十次会议纪实[J]. 交通运输系统工程与信息, 2013, 13(2): 1-8.
- [4] 段宗涛,李莹,康军,等. 基于车联网的行车安全预警信息服务系统设计[J]. 微电子学与计算机, 2014, 31(3): 66-69, 73.
- [5] 吴磊,侯忠伟,许登元. 城市交通公众出行服务系统设计[J]. 微电子学与计算机, 2012, 29(3): 89-92, 97.
- [6] Atzori L, Iera A, Morabito G. The internet of things: a survey[J]. Computer Networks, 2010, 54(15): 2787-2805.
- [7] Miorandi D, Sicari S, De Pellegrini F, et al. Internet of things: vision, applications and research challenges[J]. Ad Hoc Networks, 2012, 10(7): 1497-1516.
- [8] Atzori L, Iera A, Morabito G. The internet of things: a survey[J]. Computer Networks, 2010, 54(15): 2787-2805.
- [9] 罗军舟,金嘉晖,宋爱波,等. 云计算:体系架构与关键技术[J]. 通信学报, 2011, 32(7): 3-21.

作者简介:

刘永男, (1983-), 博士研究生. 研究方向为交通物联网技术及管理信息化. E-mail: liuevery@gmail.com.

林鹰男, (1962-), 博士, 教授. 研究方向为计算机系统、信息工程、智能自动化.

蒋山男, (1972-). 研究方向为高速公路执法信息化建设与管理.

苏小军男, (1976-), 硕士, 高级工程师. 研究方向为综合交通运输规划与管理.

(上接第 164 页)

- [6] 范庚,马登武,邓力,等. 基于灰色相关向量机的故障预测模型[J]. 系统工程与电子技术, 2012, 34(2): 424-428.
- [7] 吴良海. 基于粒子群优化相关向量机的网络入侵检测[J]. 微电子学与计算机, 2010, 27(5): 181-184.
- [8] M Tipping. The relevance vector machine[J]. Advances in Neural Information Processing Systems,

2000(12): 652-658.

- [9] 许丽佳. 电子系统的故障预测与健康管理工作研究[D]. 成都: 电子科技大学, 2009.

作者简介:

李勇男, (1983-), 博士, 工程师. 研究方向为装备智能故障诊断、预测与健康管理工作. E-mail: Liyong169@aliyun.cn.