

微风速流场数据采集与融合方法研究

刘建旭 付东翔

(上海理工大学光电信息与计算机工程学院 上海 200093)

摘要: 在微风速(0~1 m/s)空间流场测量中,对传感器精度要求高,实时在线仪表数据精度不够,数据采集滞后性大;考虑采用多个传感器测量提高精度,但也存在数据融合的问题。针对微风速流场测量,提出基于K均值-RBF神经网络的数据采集预处理软测量模型,首先选取中间变量(电流值),运用K均值聚类,用RBF网络训练得到单个传感器数据;提出基于相关性-kalman滤波的传感器数据融合算法,剔除无效数据点,并融合得到精确风速预测值。测量实验和数据结果表明该方法处理的数据结果滞后性小,处理速度快,数据精度高。

关键词: 微风速流场;软测量K均值-RBF网络;多传感器融合;相关性-kalman滤波

中图分类号: TP274+.2 **文献标识码:** A **国家标准学科分类代码:** 510

Wind velocity flow field data acquisition and fusion method research

Liu Jianxu Fu Dongxiang

(Photoelectric Information Engineering College with the Computer, Shanghai University of Science and Technology, Shanghai 200093, China)

Abstract: In the wind speed (0~1 m/s) space flow field measurement, the sensor accuracy requirement is high, the real-time online instrument data accuracy is not enough, hysteresis of data acquisition; Consider using multiple sensors measurement improve accuracy, but also has the problem of data fusion. Velocity flow field measurement, the author of this paper, based on k-means-data collection and pretreatment of RBF neural network soft measurement model, firstly, intermediate variable (current value), using the k-means clustering, use RBF network training to get a single sensor data; Based on correlation-sensor data fusion algorithm of kalman filtering, eliminate invalid data points, and get accurate fusion wind speed prediction. Measurement experiment and data results show that this method processing data results of hysteresis is small, processing speed, high precision of data.

Keywords: wind velocity flow field; soft measurement; K-means-RBF network; multiple sensor fusion; correlation-kalman filtering

0 引言

在微风速流场测量中,需要测量范围0~1 m/s的高精度传感器,当实际风速为0~0.2 m/s范围时,测量值往往偏差会变大,因此,在实际测量中直接采用实时在线仪表存在数据精度不够,数据滞后性等^[1]问题。单纯的最小二乘法建立的线性模型又不能很好的反应传感器的实际测量特性^[2]。另外,微风速流场测量中使用传感器阵列进行测量,多只传感器数据需要融合,同一测量点的微风速条件下的多个传感器测量值跳变范围大,无效数据时有出现,如何提出无效数据,融合有效数据是保证微风速流场测量值准确的关键。

本文核心在于多传感器数据准确获得以及数据的融合。基于这个核心,提出了运用相关性-卡尔曼滤波算

法^[1]进行融合。数据采集及预处理是首要问题,本文提出基于K均值-RBF神经网络建立的单个微风速传感器的软测量^[3-4]模型,通过采集传感器返回的电流数据,建立软测量模型过度得到所需微风速预测数据^[5];针对多个传感器测量的无效数据点,运用相关性判定方法,剔除测量数据中的异常点(或无效点);把通过软测量模型得出的特性曲线方程得出的数据和方差作为卡尔曼滤波的初始预估值和初始方差估计,进行多传感器数据的融合,提高了卡尔曼滤波数据融合的精确度^[6]。实验数据和处理结果表明该处理方法的有效性,为得到三维空间微风速流场分布提供了精确的数据。

1 K均值-RBF网络软测量模型

假设对单个传感器进行风洞试验,根据下述式子得到

风洞内标准风速,以此作为神经网络初始输入数据。

$$Q = v_{\text{喷}} \cdot A_{\text{喷}} \quad (1)$$

$$\Delta P = \frac{1}{2} \rho \cdot v_{\text{喷}}^2 \quad (2)$$

$$v_{\text{风洞}} = Q / A_{\text{风洞}} \quad (3)$$

式中: Q 为单位时间内通过喷嘴出的风量, $v_{\text{喷}}$ 为通过喷嘴处的风速, ρ 为大气压, ΔP 为喷嘴前后压差(气压计测得), $A_{\text{风洞}}$ 为风洞截面积, $v_{\text{风洞}}$ 为风洞内理论风速。

对单个传感器用风洞进行标定。采集传感器返回电流数据(4~20 mA),假设数据向量(输入向量)为 $\mathbf{X}_n = (x_1, x_2, x_3, \dots, x_n)$;对应的标准风速数据向量为 $\mathbf{V}_m = (v_1, v_2, v_3, \dots, v_m)$ 。首先采用 K-均值聚类算法对输入向量数据进行聚类,找到 K 个聚类中心作为 RBF 网络隐含层基函数中心 $C_i = (c_1, c_2, c_3, \dots, c_i)$ 。

具体算法^[7]如下:

1) 给定各隐藏节点的初始中心 $C_i(0)$,通常取输入样本向量的前 K 个值。

计算欧式距离为

$$d_i(t) = \|x(t) - C_i(t-1)\| \quad (4)$$

$i = 1, 2, \dots, k$

求出最小距离节点为

$$d_r(t) = \min d_i(t) \quad (5)$$

2) 调整重心为

$$C_i(t) = C_i(t-1), 1 \leq i \leq k, i \neq r \quad (6)$$

$$C_r(t) = C_r(t-1) + \beta[x(t) - C_r(t-1)] \quad (7)$$

$i = r$

3) 判别。如果 $C_i(t) = C_i(t-1)$,则终止迭代;否则转 2)。

当 C_i 确定后,可采用最小二乘法求隐含层和输出层之间的权值,即:

$$w = \exp\left(\frac{M}{C_{\text{max}}^2} \|x_n - c_i\|\right), \quad p = 1, 2, \dots, P, i = 1, 2, \dots, M \quad (8)$$

式中: C_{max} 为所选取中心之间的最大距离, n 为样本数量, l 为隐含层节点数。

接下来样本输入网络,使得误差函数最小。

设有 n 组输入样本 x_n ,每组样本的期望输出值为 v_m ,因此,将目标误差函数定义为

$$E = \frac{1}{2} \sum_{p=1}^n \|v_m - y_n\|^2 \quad (9)$$

式中: y_n 为在 x_n 输入下网络的输出向量。目的是让 RBF 网络的参数足够合适,误差函数达到最小。

最终通过训练得出的预测风速数据 $Y_n = (y_1, y_2, y_3, \dots, y_n)$ 。

2 基于相关性-kalman 滤波算法的多传感器数据融合

2.1 相关性函数

用多个上述校正过的风速传感器测量同一个坐标测点

的风速数据,第 i 个传感器和第 j 个传感器测得的数据分别为 Y_i 和 Y_j 对应上节经过训练得出的风速预测数据(较准确的数据), Y_i 和 Y_j 都服从高斯分布,以他们的 pdf 曲线作为传感器的特征函数,记成 $p_i(y), p_j(y), y_i, y_j$ 分别为 Y_i 和 Y_j 的一次观测值。

为反映 x_i 和 x_j 之间的偏差大小,引进置信距离测度^[8],设

$$d_{ij} = 2 \int_{y_i}^{y_j} p_i[yy_i] dy \quad (10)$$

$$d_{ji} = 2 \int_{y_j}^{y_i} p_j[yy_j] dy \quad (11)$$

式中

$$p_i(yy_i) = \frac{1}{2\pi\sigma_i} \exp\left\{-\frac{1}{2}\left(\frac{y-y_i}{\sigma_i}\right)^2\right\} \quad (12)$$

$$p_j(yy_j) = \frac{1}{2\pi\sigma_j} \exp\left\{-\frac{1}{2}\left(\frac{y-y_j}{\sigma_j}\right)^2\right\} \quad (13)$$

其中 d_{ij} 的值为第 i 个传感器与第 j 个传感器读数的置信距离测度,可以借助误差函数 $\text{erf}(\theta)$ 直接求得,即

$$d_{ij} = \text{erf}\left(\frac{y_j - y_i}{2\sigma_i}\right) \quad (14)$$

$$d_{ji} = \text{erf}\left(\frac{y_i - y_j}{2\sigma_j}\right) \quad (15)$$

如果有 n 个风速传感器测量同一个坐标测点的风速数据,置信距离测度 $d_{ij}(i, j = 1, 2, \dots, n)$ 构成多个风速传感器数据的置信距离矩阵。

$$D_n = \begin{bmatrix} d_{11} & d_{21} & \dots & d_{n1} \\ d_{12} & d_{22} & \dots & d_{n2} \\ \vdots & \vdots & \vdots & \vdots \\ d_{1n} & d_{2n} & \dots & d_{nn} \end{bmatrix} \quad (16)$$

一般的融合方法是给出一个融合上限 β_{ij} ,对于 d_{ij} ,令

$$r_{ij} = \begin{cases} 1, & d_{ij} \leq \beta_{ij} \\ 0, & d_{ij} > \beta_{ij} \end{cases} \quad (17)$$

若 $r_{ij} = 0$,则认为第 i 个风速传感器与第 j 个风速传感器相融性差,或称它们相互不支持,如 $r_{ij} = 1$,则认为第 i 个风速传感器与第 j 个风速传感器相融性好,称第 i 个风速传感器支持第 j 个风速传感器。若 $r_{ij} = r_{ji} = 1$,称第 i 个风速传感器与第 j 个风速传感器互相支持,如果一个风速传感器被一组风速传感器所支持,这个传感器的读数是有效的。若一个风速传感器不被其他风速传感器所支持,或只被少数风速传感器所支持,则这个风速传感器的读数是无效的。进行数据融合时,这样的数据要删掉。这样做固然能排除掉一些无效数据,但是 β_{ij} 的选取过于绝对化和经验化,不利于对实际情况作出客观判断,融合结果受主观因素影响较大。

对于这个问题,可以采用下面的方法^[9]:

由 d_{ij} 的运算可知 $0 \leq d_{ij} \leq 1$,且由运算公式可知, d_{ij} 越小说明第 i 个风速传感器被第 j 个风速传感器支持程度

越高。因此,由模糊理论中的相关性函数定义可令

$$f(ij) = 1 - d_{ij}, i, j = 1, 2, \dots, n \quad (18)$$

相关性函数 $f(ij)$ 的大小表示第 i 个风速传感器被第 j 个风速传感器支持程度,相关性函数定义为

$$f(ij) = f(ij) / \max[f(ij), f(ji)] \quad (19)$$

构造 $f(ij)$ 的矩阵,此矩阵为方阵且秩为 n , 记为 J , 这里 $i, j = 1, 2, \dots, n$ 。

为确定各个风速传感器被其他传感器支持的程度,令 $\tilde{J}_i = \min(f(iA)), A = 1, 2, \dots, n$, \tilde{J}_i 为第 i 个风速传感器被其他风速传感器支持的程度。通过计算得出, \tilde{J}_i 支持度矩阵^[10], 排除掉支持度为 0 或支持程度低的传感器数据,得到新的多个传感器的测量训练数据矩阵 $Y_{k,n}$ 。

2.2 基于 kalman 滤波算法的多传感器数据融合

设有 m 个风速传感器,通过风洞试验及 K 均值-RBF 网络训练得到的较为准确的单个传感器风速数据 $Y_k = (y_1, y_2, y_3, \dots, y_k)$, 对 m 个风速传感器风速数据进行融合^[11]。当前时刻有 m 个风速传感器测量训练数据: $Y_{k,m} = Y_{k,1}, Y_{k,2}, \dots, Y_{k,m}$ 。随机噪声和测量噪声这里取高斯噪声,其测量噪声协方差分别为: $Q_{k,n}, R_{k,n}$ 。用 $\hat{X}_{k,n|j}$ 表示根据 j 时刻及 j 以前时刻的传感器测量值对 k 时刻状态 $X_{k,n}$ 做出的估计,得出 n 个估计输出,可得到风速传感器数据融合的 kalman 滤波方程^[12]:

首先是估计状态的更新, $\mathbf{O}_{k,n|k-1}$ 为状态转移矩阵;

$$\hat{X}_{k,n|k-1,n} = \mathbf{O}_{k,n|k-1} \hat{X}_{k-1,n} \quad (20)$$

多次更新之后得到最终的估计数据 $\hat{X}_{k,n}$;

$$\hat{X}_{k,n} = \hat{X}_{k,n|k-1,n} + K_{k,n} \epsilon_{k,n} \quad (21)$$

上式中 $\epsilon_{k,n}$ 为每次状态更新产生的新息^[13], 以及增益矩阵 $K_{k,n}$; $H_{k,m}$ 为 $n \times m$ 为风速测量数据。

$$\epsilon_{k,n} = Y_{k,m} - H_{k,m} \hat{X}_{k,n|k-1,n} \quad (22)$$

$$K_{k,n} = P_{k,n|k-1,n} H_{k,m}^T (H_{k,m} P_{k,n|k-1,n} H_{k,m}^T + R_{k,n})^{-1} \quad (23)$$

最终得到估计方差矩阵 $P_{k,n}, P_{k,n|k-1,n}$ 为预测方差矩阵^[14]。

$$P_{k,n} = (I - K_{k,n} H_{k,m}) P_{k,n|k-1,n} \quad (24)$$

$$P_{k,n|k-1,n} = \mathbf{O}_{k,n|k-1} P_{k-1,n} \mathbf{O}_{k,n|k-1}^T + Q_{k,n} \quad (25)$$

经过上述 kalman 滤波方程融合之后得到新的预测融合传感器数据输出 $\hat{X}_{k,n} = (\hat{X}_{k,1}, \hat{X}_{k,2}, \dots, \hat{X}_{k,n})$ 。融合后最终估计方差 $P_{k,n} = (p_{k,1}, p_{k,2}, \dots, p_{k,n})$ 。

3 实验结果与分析

实验选取量程在 0~1 m/s 的风速传感器;首先进行风洞标定实验,通过标定理论风速下数据采集卡采集到的电流数据(4~20 mA),每个传感器标定 20 组,每组 100 个电流数据,对应 20 组理论风速值,以此作为 K 均值-RBF 网络训练的样本,通过 K 均值-RBF 网络算法得到软测量模型。先通过对每个传感器 20 组 2 000 个电流数据进行 K 均值聚类,再结合 RBF 神经网络训练预测得到单个风速传

感器标准电流值对应的实际风速 20 组。实验仿真结果如图 1 所示。

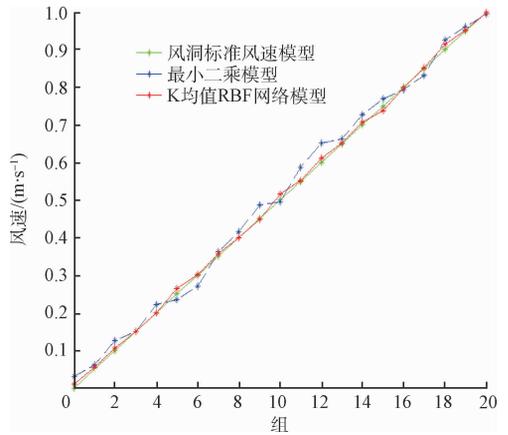


图 1 K 均值-RBF 网络建立软测量模型与标准风速及最小二乘模型对比

从图 1 明显可以看出,经过 K 均值-RBF 网络训练后的预测风速模型得到的数据更接近风洞实验的理论标定风速(即更接近实际风速)。对比单纯的最小二乘线性模型^[15]数据波动小,有良好的优越性,对于微风速流场测定能够得到较为准确的风速数据。

得到单个传感器数据后,选取 3 个同型号的 TSI 风速传感器在风洞中进行实验,选取风洞理论风速 0.6 m/s 作为标准风速数据。每个风速传感器在每个测点不同标准风速下同时采集 10 组,每组 10 个数据,10 s 完成采集,3 个传感器得到 30 组测点的风速数据。以 30 组测点风速数据作为样板,先对风速数据经行相关性判定,提出部分无效数据点(支持程度低的传感器数据点),再对余下的有效数据点运用 kalman 滤波进行数据融合。得到融合后数据的风速对比图和数据均方根误差(RMSE)对比图仿真结果如图 2 和图 3 所示:

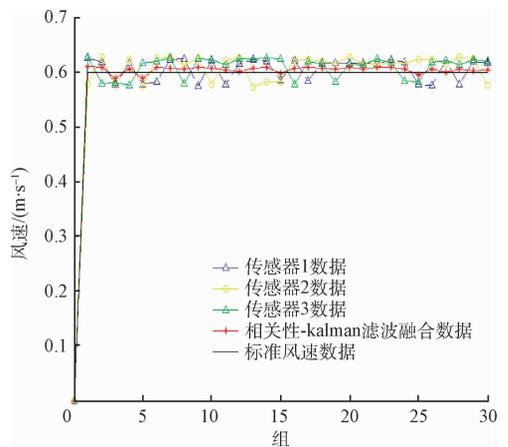


图 2 3 个传感器风速数据与相关性-kalman 滤波融合后数据对比

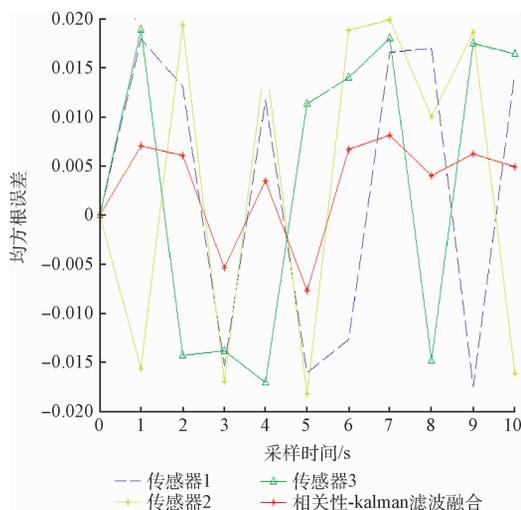


图3 3个传感器同一采样时刻均方根误差与相关性-kalman滤波融合后对比

从图2和图3的结果可以看出,融合后的数据均方根误差明显波动较小;对比单个传感器对数据测量的准确度,进行数据处理与融合后得到的测定结果更符合实际的风速,采用相关性-kalman滤波算法对风速数据进行融合有明显的优越性。

4 结 论

本文针对微风速流场测量在数据采集与处理方法应用上的研究,提出了基于 k 均值-RBF网络算法软测量模型建立方法;以及基于相关性-kalman滤波算法的后续多传感器数据融合方法。组合完成一套较为完善的微风速流场测量系统数据采集与处理方法。通过对比一般的最小二乘法模型和与单个传感器数据采集均方误差,通过 k 均值-RBF网络完成的软测量模型和相关性-kalman滤波算法完成的传感器数据融合体现出明显的优越性。结合设计好的测量方案可以很好的完成封闭空间微风速流场的测量项目。

参考文献

- [1] SHIVASHANKARAPPA N, ADIGA S, AVINAS R A. Kalman filter based Multiple Sensor Data Fusion in systems with time delayed state[C]. India: 3rd International Conference on Signal Processing and Integrated Networks (SPIN), 2016: 375-381.
- [2] 王贺,胡志坚,张翌晖,等.基于聚类经验模态分解和最小二乘支持向量机的短期风速组合预测[J].电

工技术学报,2014,29(4):237-245.

- [3] 张英,苏宏业,褚健.基于模糊最小二乘支持向量机的软测量建模[J].控制与决策,2005,20(6):621-624.
- [4] 王锡淮,李少远,席裕庚.基于自适应模糊聚类的神经网络软测量建模方法[J].控制与决策,2004,19(8):951-953.
- [5] 梁岚珍,邵璠.时序神经网络算法的短期风速预测研究[J].控制工程,2011,18(1):43-45,50.
- [6] 黎蓉.卡尔曼滤波在组合导航数据处理中的应用[J].电子测量技术,2017,40(3):158-162.
- [7] 庞振,徐蔚鸿.一种基于改进k-means的RBF神经网络学习方法[J].计算机工程与应用,2012,48(11):161-163,184.
- [8] 张龙,黄家栋,王莉莉.风速相关性对电力系统暂态稳定的影响[J].电力系统保护与控制,2014,42(6):77-83.
- [9] 刘建书,李人厚,常宏.基于相关性函数和最小二乘的多传感器数据融合[J].控制与决策,2006(6):714-716,720.
- [10] 周尧,姜礼平,刘杨.复杂环境下基于支持度的多传感器数据融合算法[J].火力与指挥控制,2014,39(3):12-14,19.
- [11] 胡振涛,曹志伟,李松,等.基于容积卡尔曼滤波的异质多传感器融合算法[J].光电子.激光,2014,25(4):697-703.
- [12] 焉晓贞,罗清华.基于卡尔曼滤波的动态传感数据流估计方法[J].仪器仪表学报,2013,34(8):1847-1854.
- [13] 王宏健,李村,么洪飞,等.基于高斯混合容积卡尔曼滤波的UUV自主导航定位算法[J].仪器仪表学报,2015,36(2):254-261.
- [14] 陈雷,杨丽娟.基于可信度的多传感器火灾报警系统的设计与仿真[J].国外电子测量技术,2016,35(4):67-70.
- [15] 鲁铁定,陶本藻,周世健.基于整体最小二乘法的线性回归建模和解法[J].武汉大学学报:信息科学版,2008(5):504-507.

作者简介

刘建旭,1990年出生,硕士研究生,研究方向为智能信息融合与自动化控制。

E-mail:18801732440@139.com

付东翔,副教授,研究方向为工业自动化。