

# 基于改进型支持度函数的畜禽舍温度监测数据融合方法

许佩全<sup>1,2</sup> 柳 萃<sup>2,3</sup> 唐瑜嵘<sup>2,4</sup> 刘龙申<sup>1,2</sup> 沈明霞<sup>1,2</sup>

(1. 南京农业大学人工智能学院, 南京 210031; 2. 农业农村部养殖装备重点实验室, 南京 210031;

3. 南京农业大学动物医学院, 南京 210031; 4. 南京农业大学工学院, 南京 210031)

**摘要:** 温度场动态重构精度不足是制约精准饲喂决策系统响应与调控效能的重要因素, 鉴于此, 本文提出一种基于改进型支持度函数(Fast-NF)的动态数据融合算法。通过耦合动态时间规整(FastDTW)与多层多项式衰减机制, 构建传感器数据时空权重优化模型, 有效解决传统方法在计算效率与缺失数据补偿方面的技术局限。试验结果表明, 本文融合温度算法均方根误差(RMSE)由0.4367℃降至0.3875℃, 窗口计算时间由标准DTW-NF算法14.5688s缩短至5.8394s, 与传统高斯型方法相比分别下降11.3%和提升59.9%。基于此方法的畜禽舍温度场动态重构技术, 实现了温度监测数据从离散点到连续场域的升维映射, 为精准饲喂决策系统提供了有力支撑。

**关键词:** 畜禽舍; 温度监测; 数据融合; 支持度函数; 动态时间规整

中图分类号: S828; TP391.9

文献标识码: A

文章编号: 1000-1298(2026)06-0356-12

OSID:



## Data Fusion Method for Temperature Monitoring in Livestock and Poultry Housing Based on Improved Support Function

XU Peiquan<sup>1,2</sup> LIU Luo<sup>2,3</sup> TANG Yurong<sup>2,4</sup> LIU Longshen<sup>1,2</sup> SHEN Mingxia<sup>1,2</sup>

(1. College of Artificial Intelligence, Nanjing Agricultural University, Nanjing 210031, China

2. Key Laboratory of Breeding Equipment, Ministry of Agriculture and Rural Affairs, Nanjing 210031, China

3. College of Veterinary Medicine, Nanjing Agricultural University, Nanjing 210031, China

4. College of Engineering, Nanjing Agricultural University, Nanjing 210031, China)

**Abstract:** Insufficient accuracy in dynamic temperature field reconstruction significantly constrains the responsiveness and control efficacy of precision feeding decision systems. To address this critical limitation, a novel dynamic data fusion algorithm was proposed based on an improved support function (Fast-NF). The algorithm constructed a spatio-temporal weight optimization model for sensor data by coupling dynamic time warping (FastDTW) with a multi-layer polynomial decay mechanism. This approach effectively overcame the technical limitations of traditional methods, particularly concerning computational efficiency and compensation for missing data. Experimental results demonstrated that compared with conventional Gaussian-based methods, the root mean square error (RMSE) of the fusion temperature was reduced from 0.4367°C to 0.3875°C, a decrease of 11.3%. The window calculation time was shortened from 14.5688 s of the standard DTW-NF algorithm to 5.8394 s, and the efficiency was improved by 59.9%. Consequently, the developed dynamic temperature field reconstruction technology, leveraging this method, successfully achieved dimensionality elevation from discrete monitoring points to a continuous field domain. This advancement can provide robust support for precision feeding decision systems, offering a significant improvement in reconstruction accuracy and computational efficiency for practical agricultural applications. The core innovation lied in the synergistic Fast-NF mechanism integrating FastDTW and decay weighting.

**Key words:** livestock and poultry housing; temperature monitoring; data fusion; support function; dynamic time warping (DTW)

收稿日期: 2025-06-11 修回日期: 2025-09-29

基金项目: 国家重点研发计划项目(2021YFD2000800)和科技创新2030—“新一代人工智能”重大项目(2021ZD0113800)

作者简介: 许佩全(1989—),男,博士生,主要从事精准养殖和机器视觉研究, E-mail: 634625768@qq.com

通信作者: 沈明霞(1964—),女,教授,博士生导师,主要从事机器视觉和农业信息化研究, E-mail: mingxia@njau.edu.cn

## 0 引言

面对生产效率提升、资源配置高效与绿色低碳转型的迫切需求,畜禽养殖业加速向集约化、智能化方向演进,而精准饲喂技术作为关键使能工具,正通过耦合饲料供给-环境调控-动物生长动态关系,成为破解效益增长、资源约束与福利保障协同难题的核心突破口<sup>[1-6]</sup>。当前,基于多传感器数据融合的环境感知技术正推动精准饲喂决策从传统的经验驱动向数据驱动跃迁,而温度场动态重构精度直接制约着饲喂决策系统的响应灵敏度与调控可靠性<sup>[7]</sup>。

数据融合通过协同多源传感器信息,能够显著消除数据冗余、提升系统决策可靠性<sup>[8-9]</sup>,其方法体系依据理论范式可分为以贝叶斯推理为核心的统计型融合和依托深度学习网络的人工智能型融合以及基于支持度函数的信息论型融合<sup>[10]</sup>。统计型融合往往需要依赖先验分布建模<sup>[11]</sup>,对环境突变(如通风启停导致的温度阶跃)适应性较差;神经网络虽可建模非线性热传递过程,但其训练依赖大量标注数据,在养殖场小样本条件下易产生过拟合<sup>[12]</sup>;信息论型融合基于支持度函数构建数据关联度量,因其无需先验假设且抗干扰性强<sup>[13]</sup>,近年来在养殖环境监测中逐步应用。随着多传感器部署密度提升和数据采样频率增加,传统融合算法在嵌入式平台的运行效率逐渐成为瓶颈。尤其是在畜禽舍这类资源受限的物联网环境中,系统需具备较强的实时响应与持续运行能力,对融合算法的计算复杂度和部署成本提出更高要求。当前部分支持度函数模型虽具备较好精度,但在效率与资源适配方面仍缺乏兼顾,制约了其实时应用效果。因此,在保障融合精度的同时提升算法效率,已成为养殖环境监测中亟需突破的问题之一。JOUSSELME等<sup>[14]</sup>提出了一种基于 Dempster-Shafer 理论的识别算法性能度量(MOP),通过量化集合之间的相似性定义2个基本概率分配(BPAs)之间的距离,为处理不确定性信息提供了一种系统的方法。YAGER<sup>[15]</sup>提出幂平均算子创新性引入值间支持距离,有效提升了数据融合的灵活性,并增强了对数据内在关系的捕捉能力,但该方法在支持函数选择和调整方面存在一定的复杂性。熊迎军等<sup>[16]</sup>基于灰色系统接近度思想,提出了一种无需指数运算的支持度函数,有效降低了处理器资源需求,但在数据融合过程未充分考虑传感器数据的时间序列特性。文献[17-18]分别在文献[16]基础上提出六次多项式(SN)与二次倒数型(SF)支持度函数,虽避免了指数运算,但SN函数在0~1℃温差区间因衰减过剧易过度抑制有效数据权

重,而SF函数因衰减平缓对异常值敏感性不足,制约了融合精度。宋坤等<sup>[19]</sup>基于支持度和置信距离理论构建支持矩阵,提升了温室环境参数检测的稳健性,但算法复杂度较高。现有方法仍面临环境突变响应迟滞、时序数据对齐失真及权重动态漂移等问题。

针对上述挑战,本研究提出基于改进快速动态时间规整的支持度函数加权融合算法。通过融合灰色接近关联度与高斯函数特性,重构支持度函数数学表达,在保证关联度量精度的同时可显著降低计算复杂度;引入快速动态时间规整(Fast dynamic time warping, FastDTW)算法量化传感器时序数据的动态规整距离,借助其局部路径优化能力增强异步数据对齐的鲁棒性;同步构建动态权重更新机制,通过实时感知环境参数漂移特征实现融合权重的自适应调整。从模型架构、时序对齐和权重优化3个维度协同提升融合算法性能,为畜禽养殖复杂工况下环境监测提供高精度、强适应的解决方案,为精准饲喂决策系统奠定可靠感知基础。

## 1 畜禽舍无线传感器网络系统数据融合原理

针对畜禽舍温度场空间异质性强(如通风死角、热源分布不均等)与动态演变复杂(如通风启停引发温度阶跃)的特性,构建面向单参数优化的无线传感器网络融合架构,如图1所示。通过分布式部署温度传感器节点形成空间采样矩阵,结合时间序列相关性分析与动态权重分配机制,实现温度场高精度重构。

(1)温度数据预处理 针对温度传感器易受局部气流扰动、设备热惯性等因素导致异常波动,建立多

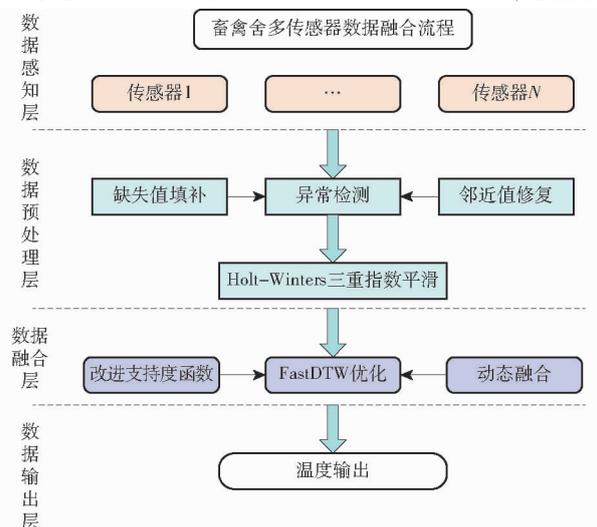


图1 畜禽舍多传感器数据融合流程

Fig. 1 Flowchart of multi-sensor data fusion in livestock sheds

级清洗策略:首先,采用时间窗约束线性插值法快速填补温度缺失值,保持时间序列的连续性。其次,采用四分位距(Interquartile range, IQR)方法进行异常值检测,识别出显著偏离正常范围的数据<sup>[20]</sup>。最后,通过基于邻近值的修复方法,用前后邻近值的平均值替换异常值,快速对原始数据进行一致性检测,构建新的数据集。

(2) 温度序列特征解耦 采用 Holt - Winters 算法将原始时间序列分解为水平项、趋势项及季节项,分离长期趋势与短期波动,消除传感器热惯性噪声,增强时序数据的可解释性与融合鲁棒性<sup>[21-22]</sup>,为融合提供更稳定的数据。

(3) 改进型支持度函数设计 根据灰色关联度思想和多项式衰减特性对高斯型支持度函数改进,提出新型支持度函数  $NF(x, y, K, \beta)$ ,在避免指数运算的同时实现与传统高斯函数的高度拟合,显著降低计算复杂度至  $O(1)$ 。

(4) 动态时间规整距离优化 引入 FastDTW 算法,通过多尺度粗化与局部路径优化,将时序对齐复杂度由  $O(nm)$  降至  $O(n)$ ,并结合滑动窗口机制实现高精度、低延迟的权重分配与融合<sup>[23-24]</sup>。

## 1.1 传感器数据预处理

畜禽舍环境复杂,传感器易受粉尘污染、硫化氢等腐蚀性气体及设备热惯性等因素影响,导致传感器数据缺失、异常波动或噪声污染。为实现高精度温度场重构,须对原始数据进行预处理,提升传感器数据质量与一致性。预处理流程包括数据一致性检测与季节性平滑 2 个核心环节。

### 1.1.1 原始数据的一致性检测

数据一致性检测旨在解决数据缺失与异常值问题,为数据融合提供高质量输入。针对传感器网络传输丢包或短暂故障导致的数据缺失,利用缺失数据前后临近数据,采用线性插值法进行填补,保持时间序列的连续性。采用 IQR 算法识别异常值,避免局部气流扰动或传感器瞬时故障导致的野值干扰,设  $n$  个彼此独立的传感器在同一时刻对参数(如温度)进行测量,并将测量的数据按照升序排列,定义第 1 四分位数  $Q_1$  和第 3 四分位数  $Q_3$ ,计算式为

$$Q_1 = \frac{x_{\frac{n}{4}} + x_{(\frac{n}{4} + 1)}}{2} \quad (1)$$

$$Q_3 = \frac{x_{\frac{3n}{4}} + x_{(\frac{3n}{4} + 1)}}{2} \quad (2)$$

式中  $x_{\frac{n}{4}}$ ——第  $\frac{n}{4}$  个最小测量值,其余依此类推

四分位间距计算式为

$$IQR = Q_3 - Q_1 \quad (3)$$

$(Q_1 - 1.5IQR, Q_3 + 1.5IQR)$  区间以外的值视为数据集异常值。为避免异常值剔除后导致信息损失,采用邻近均值替换法修复异常数据,能够在保障数据连续性的同时,抑制突发噪声对后续融合数据的干扰。

### 1.1.2 传感器数据序列 Holt - Winters 季节性平滑

畜禽舍温度变化具有周期性(如昼夜温差)与趋势性(如通风启停导致的阶跃变化),需通过平滑算法提取稳定特征。Holt - Winters 季节性平滑算法是一种典型的时间序列预测方法,特别适用于具有趋势和季节性的数据,其核心在于将时间序列数据分解为水平项(Level)、趋势项(Trend)和季节项(Seasonality),考虑到猪舍参数相对稳定,变化幅度较固定,采用加法模型简化计算。水平值、趋势值和季节性指数趋势更新公式为

$$L_i(t) = \alpha(x_i(t) - S_i(t-s)) + (1-\alpha) \cdot (L_i(t-1) + T_i(t-1)) \quad (4)$$

$$T_i(t) = \lambda(L_i(t) - L_i(t-1)) + (1-\lambda)T_i(t-1) \quad (5)$$

$$S_i(t) = \gamma(x_i(t) - L_i(t)) + (1-\gamma)S_i(t-s) \quad (6)$$

式中  $L_i(t)$ —— $t$  时刻传感器  $i$  采集数据的水平值,反映当前数据水平

$T_i(t)$ ——趋势值,体现数据变化趋势

$S_i(t)$ ——季节性因子,描述数据季节性特征

$\alpha, \lambda, \gamma$ ——水平项、趋势项和季节项平滑系数,取  $0 \sim 1$

若时间序列季节性特征稳定,相应平滑系数可适当取小,更多依赖历史信息;若季节性波动大,则可适当增大平滑系数,增强对近期数据变化的跟踪能力。考虑到时间序列数据持续增长,初始值对后续预测值影响逐渐减小。利用时间序列前几个完整季节周期数据计算初值,例如选取前 2 s 数据,通过合适计算方法(如求平均值)得到合理初值。经 Holt - Winters 加法模型季节性平滑处理后,能有效捕捉温室环境数据的季节性变化规律,为数据融合和分析提供可靠数据支持。

## 1.2 改进支持度函数

### 1.2.1 支持度函数设计

在多传感器数据融合领域,支持度函数(Support function)作为评估异构数据源置信水平的关键技术,基于数学建模方法量化多源传感器数据间的置信度与一致性特征。该函数通过构建数据间的支持度测度,实现高置信度数据源与潜在异常数据的有效辨识。其核心机制在于检测受噪声干扰、设备故障或异常因素影响的观测值,进而为异质数

据赋权提供量化依据,最终优化多传感器系统的信息融合效果。

文献[15]采用支持度函数  $\text{sup}(x, y)$  表示  $x$  和  $y$  元素间接近程度,即  $x$  和  $y$  间支持度。支持度函数  $\text{sup}(x, y)$  满足:①对称性: $\text{sup}(x, y) = \text{sup}(y, x)$ 。②单调性:如果  $|x_1 - y_1| < |x_2 - y_2|$ , 则有  $\text{sup}(x_1, y_1) > \text{sup}(x_2, y_2)$ 。其中  $x_1, x_2, y_1, y_2$  均大于 0。③归一性: $\text{sup}(x, y) \in [0, 1]$ , 其中 1 表示完全支持, 0 表示完全不支持。

在基于数值距离的权重计算方面,指数衰减型支持度函数(Gaussian support function, 也称作高斯型支持度函数)更为常见<sup>[16]</sup>, 其表达式为

$$\text{sup}(x, y) = G(x, y, K, \beta) = Ke^{-\beta(x-y)^2} \quad (K \in [0, 1], \beta \geq 0) \quad (7)$$

式中  $K$ ——支持度函数幅度

$\beta$ ——支持度函数衰减系数

其中,当  $x = y$  时,支持度函数取得最大值  $\text{sup}(x, y) = \text{sup}(y, x) = K$ ; 当  $(x - y)^2 \rightarrow \infty$  时,支持度函数取得最小值  $\text{sup}(x, y) = \text{sup}(y, x) = 0$ 。

指数衰减型支持度函数虽能有效表征数据相似性,但其指数运算复杂度为  $O(2^n)$ , 难以适应畜禽舍无线传感网络的低算力要求。刘思峰等<sup>[25-26]</sup>通过引入相似关联度和接近关联度 2 个概念,提出一种基于相似性和接近性视角的新型灰色关联分析模型,根据该思想,本文在指数衰减型支持度函数基础上融合多项式衰减特性,提出一种无指数运算的新型支持度函数,计算式为

$$\text{sup}(x, y) = \text{NF}(x, y, K, \beta) = K \left[ \frac{0.4}{1 + 2\beta(x-y)^2} + \frac{0.2}{1 + 3\beta(x-y)^4} + \frac{0.4}{1 + \beta(x-y)^6} \right] \quad (8)$$

从式(8)形式上可验证,该函数满足文献[15]对支持度函数的定义,且通过多项式衰减结构替代指数运算,将算法复杂度由传统高斯型函数的  $O(2^n)$  降为  $O(1)$ , 从而显著减少对嵌入式系统计算资源的占用。针对畜禽舍温度场空间分布特性,假设同一平面温差不超过  $3^\circ\text{C}$ , 即  $(x - y) \in [-3, 3]$ 。为了验证新型支持度函数性能,设定参数  $K, \beta$  为 1, 对比分析高斯型  $G(x, y, 1, 1)$ 、文献[17]中  $\text{SN}(x, y, 1, 1)$  型、文献[18]中  $\text{SF}(x, y, 1, 1)$  型以及本文  $\text{NF}(x, y, 1, 1)$  型支持度函数的特征曲线,不同支持度函数特性曲线如图 2 所示。由图 2 可知,  $\text{SN}$  函数在中心区域的支持度较分散, 衰减速度比  $G$  函数稍慢;  $\text{SF}$  函数温差分布范围更为广泛, 衰减速度更慢;  $\text{NF}$  函数的曲线形状与  $G$  函数非常接近, 且在中心区域的支持度更集中, 衰减速度更快, 对温度差异更

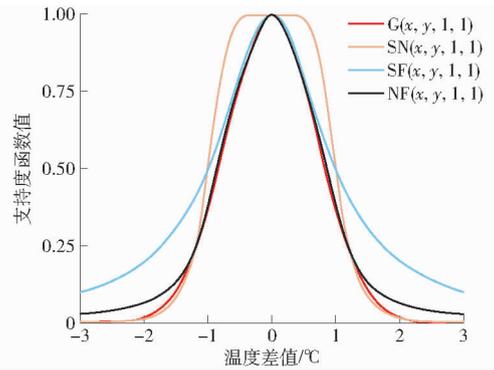


图 2 不同支持度函数特性曲线

Fig. 2 Different support function characteristic curves

为敏感。由式(7)可知,  $K$  控制支持度函数峰值,  $\beta$  控制支持度函数的衰减速度,  $K$  值一定(设  $K = 1$ ) 时, 支持度函数  $\text{NF}$  的衰减速度与  $\beta$  间的关系如图 3 所示。

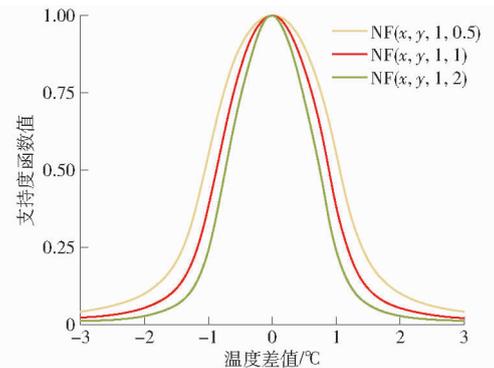


图 3 不同  $\beta$  值新型支持度函数特性曲线

Fig. 3 New support function characteristic curves with different  $\beta$  values

### 1.2.2 基于 FastDTW 的支持度函数建模与融合方法

传统高斯支持度函数以欧氏距离的指数衰减为基础, 借助高斯核函数将传感器瞬时差异映射为归一化支持度值, 进而为多源数据融合提供权重分配。高斯核函数主要用于衡量向量或数据点间的相似度, 在分类或聚类任务中针对静态数据有较好的表现, 但难以捕捉传感器数据的动态时序特征, 并且对时间轴偏移缺乏鲁棒性, 当传感器存在响应延迟或采样率差异时, 容易出现支持度估计偏差。

为有效解决上述问题, 动态时间规整(Dynamic time warping, DTW) 算法提供了一种可行方案。DTW 算法最初由 SAKOE 和 CHIBA 提出, 用于语音识别场景时间序列比对, 通过动态规划寻找时间序列间最优非线性对齐路径, 使累积的路径代价最小化, 从而实现对序列距离的精准度量<sup>[27]</sup>。给定 2 个时间序列  $X = \{x_1, x_2, \dots, x_n\}$  和  $Y = \{y_1, y_2, \dots, y_m\}$ , 目标找到最优对齐路径  $P$ , 使得整条路径上所有点的局部距离之和最小, 满足:①边界条件: $p = \{p_1, p_2, \dots, p_k\}$ , 其中  $p_k = (i_k, j_k)$ , 且  $p_1 = (1, 1), p_k = (n, m)$ 。

②单调性:  $i_{t+1} \geq i_t, j_{t+1} \geq j_t$ 。③连续性:  $i_{t+1} - i_t \leq 1, j_{t+1} - j_t \leq 1$ 。④最小累积距离:  $\min \sum_{(i,j) \in P} d(x_i - y_j)$ 。

构建矩阵  $D \in \mathbf{R}^{n \times m}$ , 元素  $D(i, j)$  表示从起点  $(1, 1)$  到点  $(i, j)$  的最小累积距离, 对  $\forall i \in \{2, 3, \dots, n\}$  和  $\forall j \in \{2, 3, \dots, m\}$ , 最小累积距离为

$$D(i, j) = d(x_i, y_j) + \min \begin{cases} D(i-1, j) \\ D(i, j-1) \\ D(i-1, j-1) \end{cases} \quad (9)$$

特别地, 当  $(i, j) = (n, m)$  时

$$D(n, m) = \min \sum_{(i,j) \in P} d(x_i - y_j) = DTW \quad (10)$$

$D(n, m)$  即时间序列  $X$  和  $Y$  在经过最优非线性对齐后的最小累积距离, 又称为动态规整距离。

传统 DTW 算法计算累积距离矩阵需填充  $n \times m$  个元素, 时间复杂度为  $O(nm)$ , 对处理器资源消耗过大<sup>[28-29]</sup>。为进一步提升支持度函数在处理时序异步性与动态变化数据的适应能力, 本研究将 FastDTW 动态时间规整算法引入支持度函数, 通过多尺度粗化、投影和局部路径优化 3 阶段将 DTW 算法复杂度降低至线性阶  $O(n)$ , 使其适用于实时性要求较高的嵌入式系统<sup>[24]</sup>。通过建立时序感知的改进支持度函数模型, 并基于一致性权重实现多传感器数据融合, 主要包括构建滑动窗口下的子序列提取与动态规整距离计算、构建时序感知支持度函数以及支持度矩阵构建与一致性加权融合。

(1) 滑动窗口下的子序列提取与动态规整距离计算

考虑到传感器响应延迟差异与异步采样问题, 将连续时间序列分割为可处理的局部片段, 并量化传感器间的时序相似性。设定原始时间序列长度  $L$ 、滑动窗口长度  $T$  和滑动步长  $\Delta t$ 。第  $i$  个窗口覆盖的时间范围为  $[t_{i-start}, t_{i-end}]$ , 计算式为

$$\begin{cases} t_{i-start} = (i-1)\Delta t + 1 \\ t_{i-end} = (i-1)\Delta t + T \end{cases} \quad (11)$$

其中  $i \in \left\{1, 2, \dots, \left\lfloor \frac{L-T}{\Delta t} \right\rfloor + 1\right\}$

传感器  $k$  在第  $i$  个窗口内的时间子序列记为

$$X_k^{(i)} = \{x_k(t_{i-start}), x_k(t_{i-start} + 1), \dots, x_k(t_{i-end})\}$$

采用 FastDTW 算法计算任意 2 个传感器  $k, l$  的子序列进行动态时间规整, 其规整距离为

$$DTW_{kl}^{(i)} = \text{FastDTW}(X_k^{(i)}, X_l^{(i)}) \quad (12)$$

(2) Fast - NF 时序感知支持度函数构建

在动态规整距离  $DTW_{kl}^{(i)}$  基础上, 引入 FastDTW 动态时间规整距离作为传感器间的相似度量, 结合多项式衰减型支持度函数  $\text{NF}(x, y, K, \beta)$  增强对不同幅度差异的敏感性, 构建时序感知的支持度函数

Fast - NF (Fast dynamic time warping optimized new-type support function), 计算式为

$$\text{Fast - NF}(k, l) = K \left( \frac{0.4}{1 + 2\beta (DTW_{kl}^{(i)})^2} + \frac{0.2}{1 + 3\beta (DTW_{kl}^{(i)})^4} + \frac{0.4}{1 + \beta (DTW_{kl}^{(i)})^6} \right) \quad (13)$$

(3) 基于 Fast - NF 的一致性权重计算与数据融合

为了有效修正局部漂移或异常观测, 基于 Fast - NF 支持度函数引入目标驱动的加权策略。在滑动窗口  $i$  内, 构建支持度矩阵  $S^{(i)} \in \mathbf{R}^{N \times N}$ , 其中  $N$  为传感器数量,  $s_{kl}^{(i)}$  为传感器  $k$  和  $l$  间的相互支持度, 对每个传感器  $k$  的观测值为  $x_k(t_i)$ , 计算式为

$$S^{(i)} = \begin{bmatrix} s_{11}^{(i)} & s_{12}^{(i)} & \dots & s_{1N}^{(i)} \\ \vdots & \vdots & & \vdots \\ s_{N1}^{(i)} & s_{N2}^{(i)} & \dots & s_{NN}^{(i)} \end{bmatrix} \quad (14)$$

其中  $s_{kl}^{(i)} = \text{Fast - NF}(k, l)$

第  $i$  个滑动窗口中传感器  $l$  对  $k$  的加权系数  $\omega_l^{(i,k)}$  定义为

$$\omega_l^{(i,k)} = \frac{s_{lk}^{(i)}}{\sum_{j=1}^N s_{jk}^{(i)}} \quad (15)$$

通过所有传感器对传感器  $k$  的支持度值进行加权修正, 得到融合值  $\hat{x}_k(t_i)$  为

$$\hat{x}_k(t_i) = \sum_{l=1}^N \omega_l^{(i,k)} x_l(t_i) \quad (16)$$

## 2 试验与分析

### 2.1 数据来源

数据来源于南京农业大学淮安研究院养殖基地的温度传感数据(时间为 2024 年 6 月 30 日—7 月 4 日)。如图 4 所示, 猪舍南北长 40 m, 东西跨度 4 m, 6 个温度传感器分别部署在边点和中间点, 距离地面高度 2 m。温度传感器采样周期为 10 min, 理论上应采集 4 320 个数据, 实际成功采集 4 229 个, 对 91 个缺失值采用线性插值法进行补全。此外, 数据预处理阶段使用 IQR 算法识别出 4 个明显异常值, 并通过邻近均值替换法进行修复。后续所有性能验证试验均采用完整预处理后的 4 320 个有效数据。

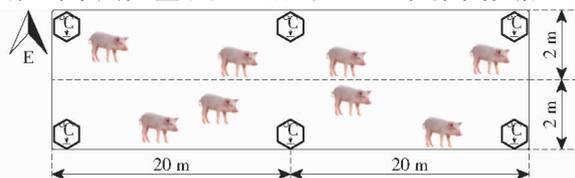


图 4 畜离舍温度传感器部署图

Fig. 4 Deployment of temperature sensors in livestock sheds

所有程序均在 pyCharm Community Edition 2022.2.2 上运行,计算机操作系统为 64 位 Windows 11 操作系统,处理器 12th Gen Intel(R) Core(TM) i7-1260P 2.10 GHz,运行内存 16 GB。

### 2.2 Holt-Winters 季节性平滑效果

为验证 Holt-Winters 算法对畜禽舍温度数据的降噪与趋势提取能力,选取畜禽舍南北侧中间位置传感器连续 5 d(共 720 组数据)数据进行季节性

平滑分析。基于网格搜索与交叉验证,确定最优平滑系数  $\alpha$  为 0.2、 $\lambda$  为 0.05、 $\gamma$  为 0.3, Holt-Winters 温度数据平滑效果如图 5 所示,平滑后曲线(红色实线)能精准捕捉温度日期活动,有效抑制因通风启停导致的瞬时阶跃噪声,且对极端异常值的修复效果显著,图 5b、5c 为 2 个最为明显的异常值放大图,7 月 3 日 16:50 异常值 24.5℃ 被修正为 29.6℃,7 月 4 日 01:20 异常值 32.4℃ 被修正为 27.9℃。

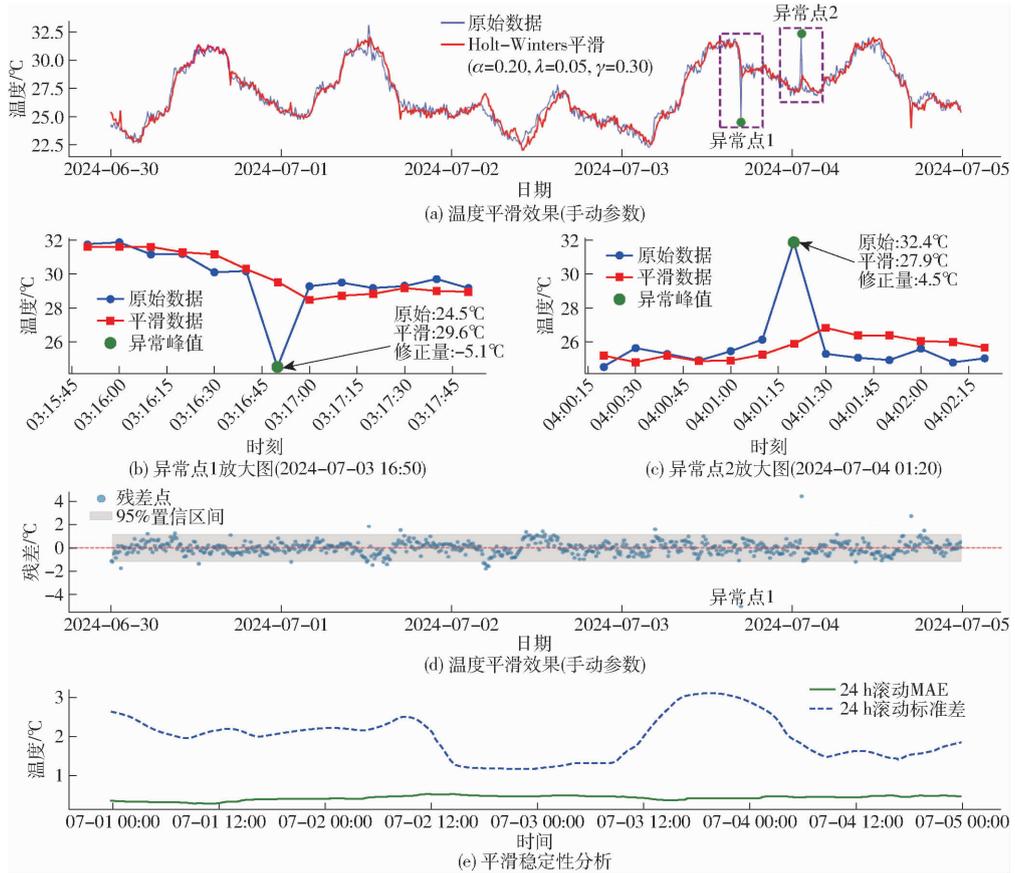


图 5 Holt-Winters 温度平滑效果

Fig. 5 Holt-Winters temperature data smoothing effect

为全面评估算法在数据预处理中的准确性与鲁棒性,引入 4 类常用误差评价指标进行定量分析,包括平均绝对误差 (Mean absolute error, MAE)、均方根误差 (Root mean square error, RMSE)、平均绝对百分比误差 (Mean absolute percentage error, MAPE)、标准残差 (Std Residuals), Holt-Winters 算法评估指标结果如表 1 所示。

表 1 Holt-Winters 季节性平滑效果评估指标

Tab.1 Holt-Winters seasonal smoothing effect evaluation

参数	MAE/℃	RMSE/℃	MAPE/%	标准残差/℃
数值	0.428 1	0.593 0	1.594 5	0.593 0

### 2.3 基于改进的动态时间规整距离优化支持度函数性能

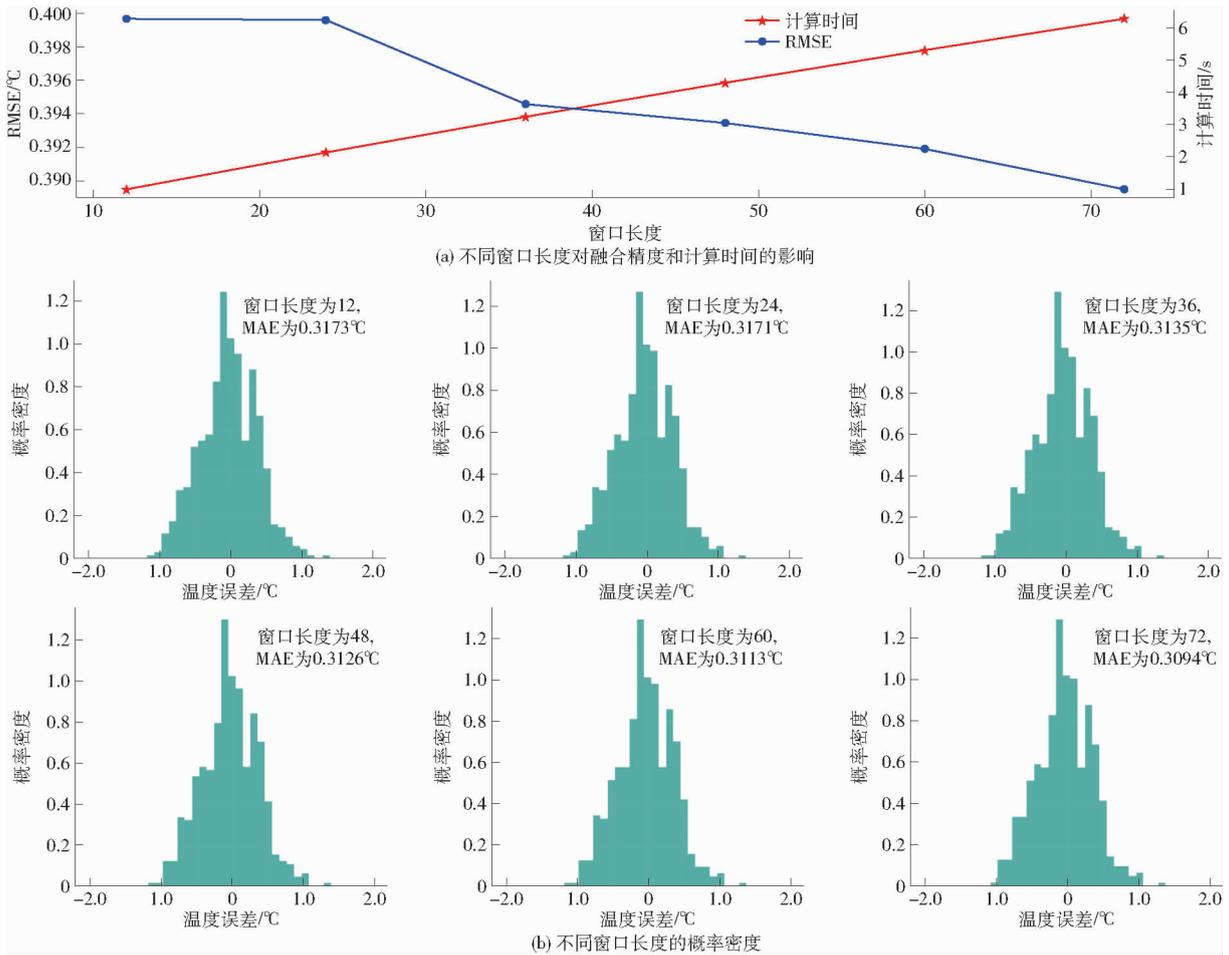
为验证改进 Fast-NF 支持度函数在畜禽舍温

度监测中的融合性能,从参数敏感性、融合精度以及鲁棒性 3 个维度展开分析。

#### 2.3.1 窗口参数优化

通过网格搜索法探究滑动窗口长度  $T$  与步长  $\Delta t$  对融合性能的影响,图 6 为滑动步长  $\Delta t = 1$  时,不同窗口长度  $T$  对融合性能的影响,具体指标如表 2,窗口长度  $T$  为 36 时,模型相关性系数最高 ( $R^2$  为 0.974 6),同时平均绝对误差 MAE 相对较低 (0.313 5℃),比最低值 ( $T$  为 72) 降低约 1.3%,但计算时间却提升 51.2%。

图 7 为窗口长度  $T$  为 36 时,不同滑动步长  $\Delta t$  对融合性能的影响,具体指标如表 3,滑动步长  $\Delta t$  为 3 时,MAE (0.302 4℃) 和 RMSE (0.387 0℃) 均为最低,决定系数  $R^2$  (0.975 2) 最高,表明预测误差最小且模型解释力最强。

图6 滑动步长  $\Delta t = 1$  时不同窗口长度性能分析Fig. 6 Performance analysis of different window lengths ( $\Delta t = 1$ )表2 滑动步长  $\Delta t = 1$  时不同窗口长度性能评估指标Tab. 2 Performance evaluation at different window lengths ( $\Delta t = 1$ )

$T$	MAE/°C	RMSE/°C	$R^2$	计算时间/s
72	0.309 4	0.389 5	0.974 0	8.4
60	0.311 3	0.391 9	0.973 8	7.1
48	0.312 6	0.393 5	0.974 2	5.6
36	0.313 5	0.394 6	0.974 6	4.1
24	0.317 1	0.399 6	0.973 9	2.5
12	0.317 3	0.399 7	0.973 6	1.2

综合考虑实际场景对精度和实时性要求,设定  $T$  为 36、 $\Delta t$  为 3 时,融合效果如图 8 所示。Fast-NF 支持度函数融合后温度数据曲线与真实温度高度一致,平均绝对误差为 0.302 4°C,决定系数  $R^2$  达 0.975 2,表明模型具有较强的拟合能力,能够有效还原真实温度趋势。

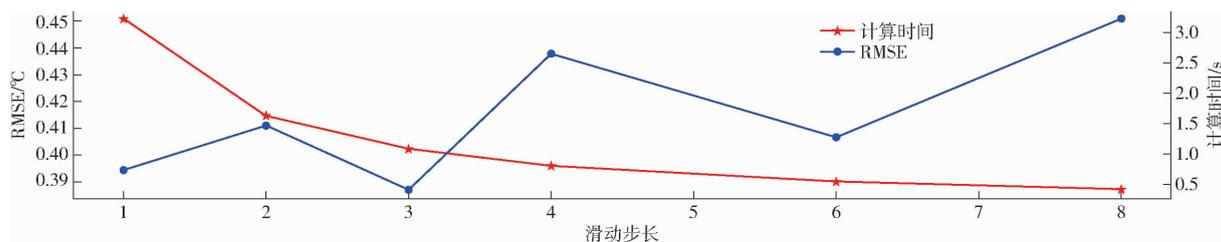
### 2.3.2 改进支持度函数融合结果

为评估本研究提出的 Fast-NF 支持度函数算法的优越性,对 5 种经典支持度函数(高斯型 G 函数、新型 D 函数、SN 函数、SF 函数及 NF 函数)的融合结果与误差进行分析。图 9 为不同支持度函数衰减特性,可以看出 NF 支持度函数在衰减特性上与

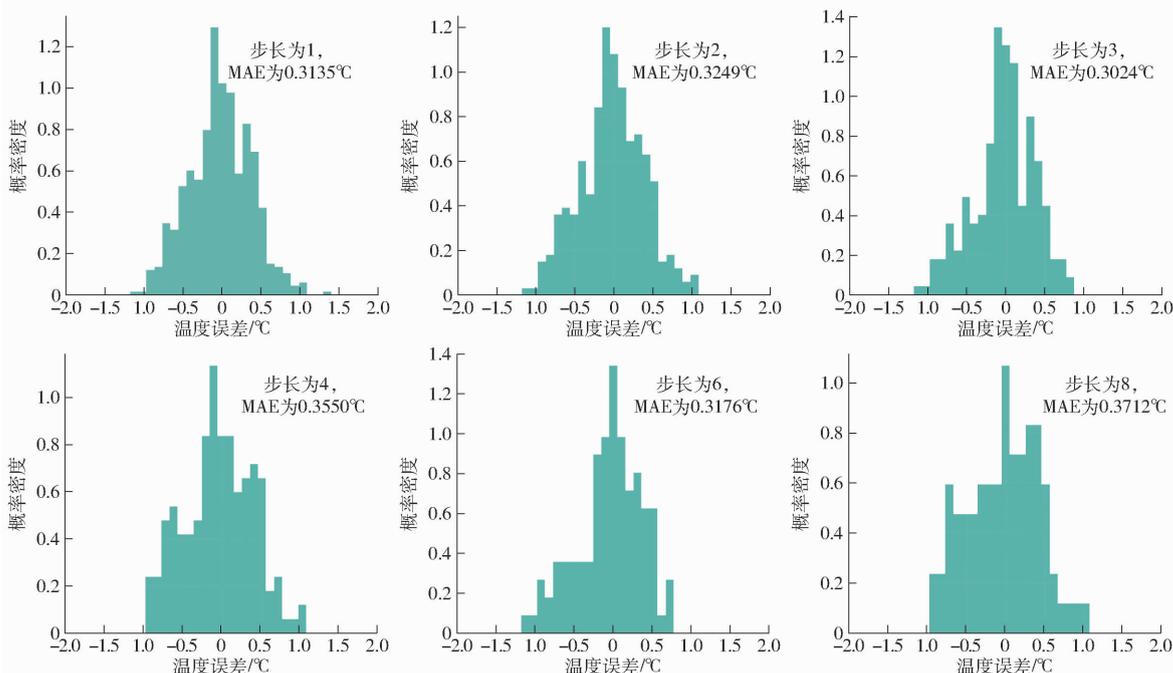
高斯支持度函数呈现出高度一致性,特别是温度差值在 1.5°C 核心区间内,2 条函数曲线几乎完全重合,表明二者对传感器间微小差异具有等效的敏感性,随着温度差值的增大,NF 支持度函数虽略高于高斯支持度函数,但仍保持相似的平滑衰减趋势,这种特性使 NF 函数既保留了高斯函数对细微差异的高敏感性优势,又通过多项式组合增强了对异常值的鲁棒性,为多传感器数据融合提供了更均衡的支持度度量基准。

图 10 为不同支持度函数融合温度,6 种融合算法均能准确地捕捉真实温度变化趋势,但在局部存在明显差异,特别是在突变、转折或波动区域(Fast-NF 优势区域放大图)Fast-NF 函数具有更低的平均绝对误差。

图 11 为不同支持度函数融合温度误差分布,误差均呈正态分布且 Fast-NF 函数的平均绝对误差最低。图 12 展示了不同支持度函数在时间序列中的融合权重动态演化对比,用以分析各支持度函数在多源感知环境下稳定性与权重响应特性,G、D、SN 3 种方法的权重分布相对平稳,权重波动幅度小,缺乏对突发异常或漂移趋势的敏感



(a) 不同滑动步长对融合精度和计算时间的影响



(b) 不同滑动步长的概率密度

图7 窗口长度  $T = 36$  时不同滑动步长性能分析

Fig. 7 Performance analysis of different sliding step sizes ( $T = 36$ )

表3 窗口长度  $T = 36$  时不同滑动步长性能评估指标

Tab.3 Performance evaluation with different sliding step sizes ( $T = 36$ )

$\Delta t$	MAE/°C	RMSE/°C	$R^2$	计算时间/s
1	0.3135	0.3946	0.9746	4.1000
2	0.3249	0.4109	0.9714	1.9000
3	0.3024	0.3870	0.9752	1.3000
4	0.3550	0.4377	0.9675	0.9703
6	0.3176	0.4064	0.9722	0.6487
8	0.3712	0.4508	0.9639	0.5220

响应,易导致对低质量数据赋予稳定性偏高的权重;SF采用二次多项式形式,在一定程度上改善了G的过度平滑问题,但仍存在适应性不足的问题;NF通过多项式组合形式对不同程度的差异实现分层加权,具有一定的非线性调节能力,表现出中等程度的权重变动性,在保持稳定性的同时,能对部分变化做出有限响应;Fast-NF引入滑动窗口机制与动态支持度函数,呈现出权重随时间动态变化的趋势,尤其在传感器数据波动或突变时段,权重能迅速调整,明显区别于其他函数。Fast-NF支持度函数权重曲线变化相对平缓,表明其动态

规整距离机制通过全局时序对齐有效抑制了局部噪声干扰,对温度动态特征的捕捉能力更强。由表4可知,Fast-NF支持度函数算法的MAE、RMSE最低, $R^2$ 最高。相较于高斯型函数,Fast-NF支持度函数的RMSE由 $0.4367^\circ\text{C}$ 降为 $0.3875^\circ\text{C}$ ,降低11.3%,同时模型决定系数 $R^2$ 略有提高。

### 2.3.3 不同动态规整距离对支持度函数改进效果

为评估FastDTW算法对支持度函数NF优化效果,对比标准DTW、FastDTW和SparseDTW3种动态规整距离对NF支持度函数的改进性能。图13为不同DTW方法改进支持度函数的温度拟合效果,3种方法改进的NF支持度函数均能准确反映真实温度变化趋势,与DTW-NF函数相比,FastDTW和SparseDTW对应的温度变化趋势更为缓和。

图14为不同DTW策略改进支持度函数的温度误差分布,3个算法的频数呈正态分布且主要集中在 $\pm 0.5^\circ\text{C}$ 区间,但SparseDTW-NF算法误差分布相对较为分散且分布形状不如前2个模

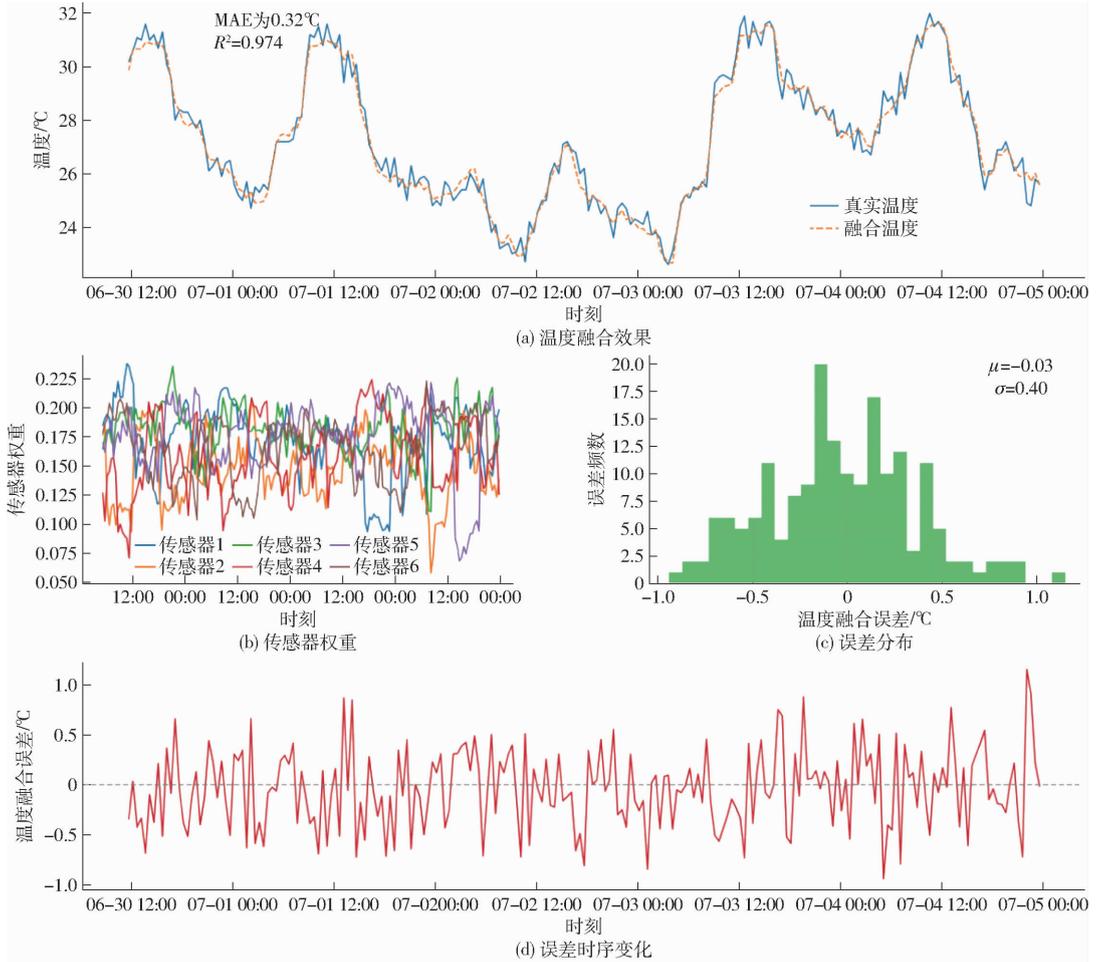


图8 窗口长度  $T=36$  和  $\Delta t=3$  时融合效果

Fig. 8 Fusion effect performance ( $T=36, \Delta t=3$ )

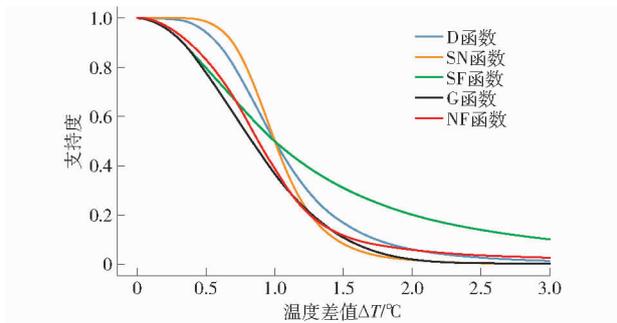


图9 不同支持度函数衰减特性

Fig. 9 Different support function attenuation characteristics

型对称。表5为不同改进支持度函数性能评估指标。由表5可知,与DTW-NF函数相比, Fast-NF函数在MAE、RMSE和 $R^2$ 上基本一致,但在计算时间上由14.5688 s降至5.8394 s,效率提升59.9%;与SparseDTW-NF函数相比, Fast-NF函数除计算时间外,其余指标均优于SparseDTW-NF函数,MAE和RMSE均提升7%以上。综合来看, Fast-NF算法在精度、效率上取得最优平衡,其动态带宽调整机制更适配畜禽舍复杂工况,能够为农业物联网嵌入式系统提供高效可靠的解决方案。

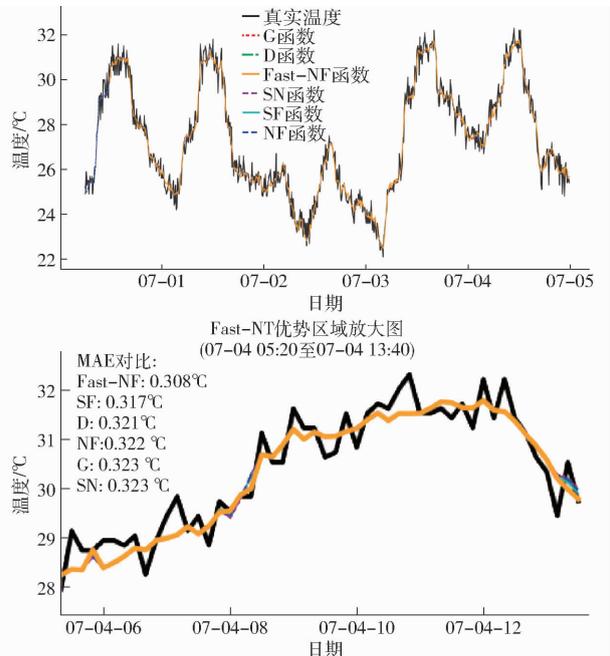


图10 不同支持度函数融合温度

Fig. 10 Different support function fusion temperature

### 3 结论

(1) 针对畜禽舍温度监测中多传感器数据存在

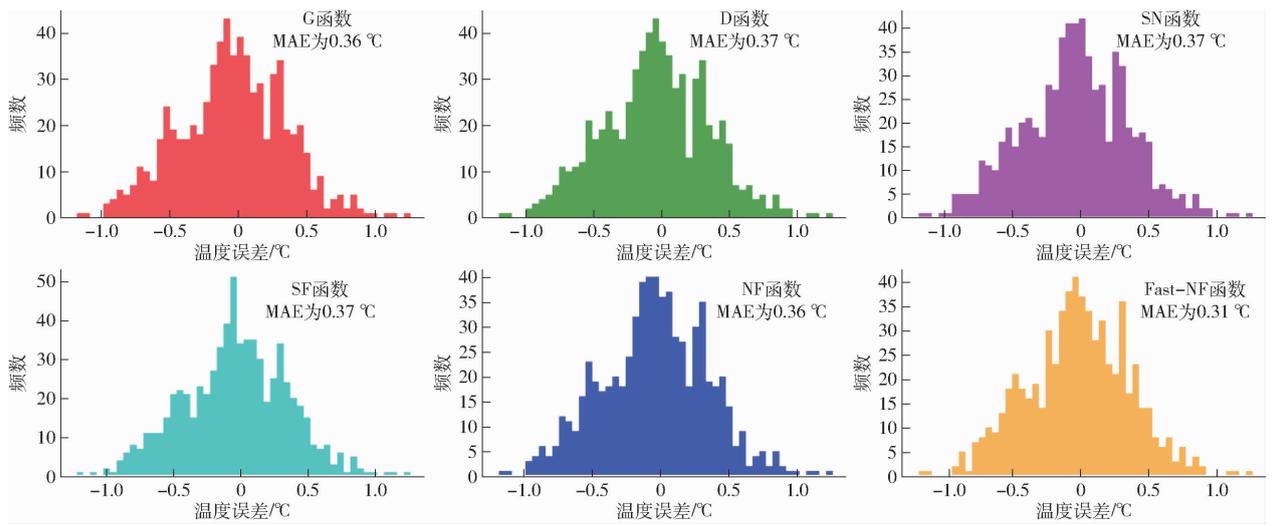


图 11 不同支持度函数融合温度误差

Fig. 11 Different support function fusion temperature error

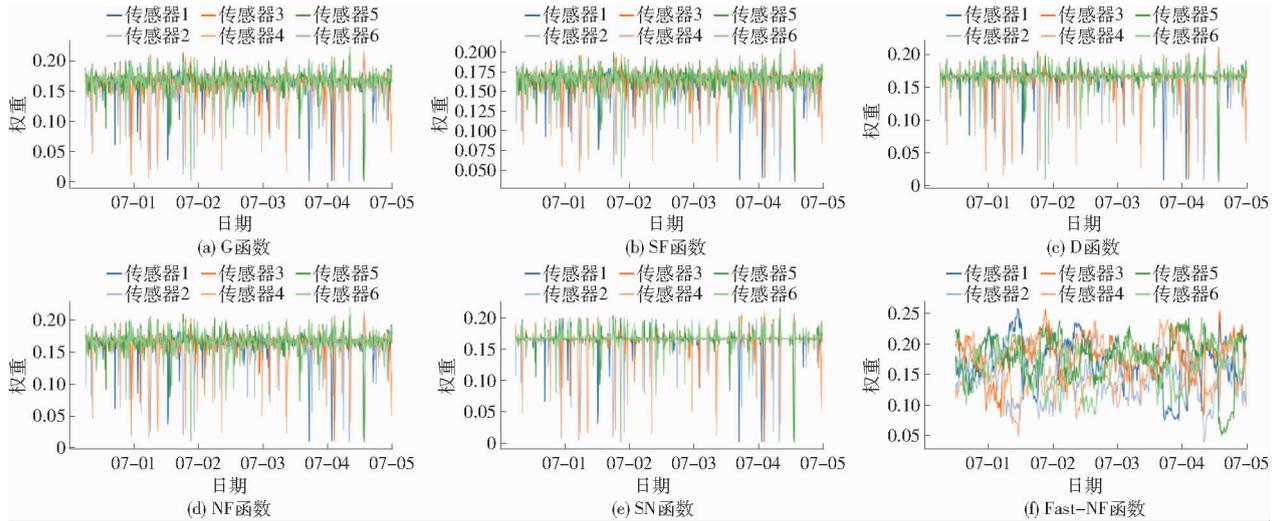


图 12 不同支持度函数权重变化

Fig. 12 Different weight support function evolution

表 4 不同支持度函数性能评估指标

Tab. 4 Performance evaluation of different support functions

函数	MAE/°C	$R^2$	RMSE/°C
G	0.363 9	0.974 3	0.436 7
D	0.367 2	0.974 6	0.440 6
SN	0.372 1	0.975 1	0.446 5
SF	0.366 8	0.974 4	0.440 2
NF	0.364 1	0.974 3	0.436 9
Fast - NF	0.307 1	0.975 5	0.387 5

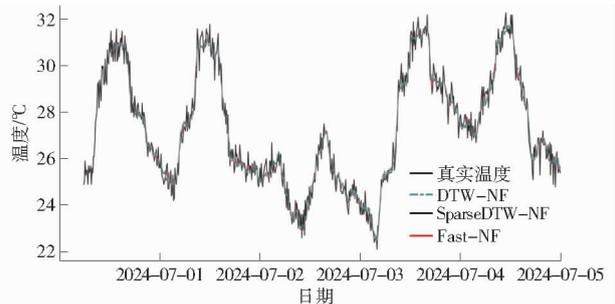


图 13 不同 DTW 方法 NF 函数温度拟合效果

Fig. 13 Temperature fitting effect of NF function under different DTW strategies

噪声干扰、漂移变化及局部异常等问题,本文提出了一种基于改进型支持度函数的高效动态数据融合方法 Fast - NF。基于快速动态时间规整距离 (Fast DTW),引入多项式分层衰减结构,构建改进型相似度函数,并结合滑动窗口机制生成局部一致性权重。在保留传统高斯函数拟合精度的同时,将算法复杂度由  $O(nm)$  降为  $O(n)$ ,显著提升

温度监测数据的融合精度与计算效率。

(2) 依据猪舍 5 d 实测数据对不同支持度函数进行验证,结果表明 Fast - NF 方法表现出更优性能:相较传统高斯型方法,融合温度均方根误差 (RMSE) 由  $0.4367^{\circ}\text{C}$  降至  $0.3875^{\circ}\text{C}$ ,下降 11.3%;同时,得益于窗口级缓存和快速权重估计机制,窗

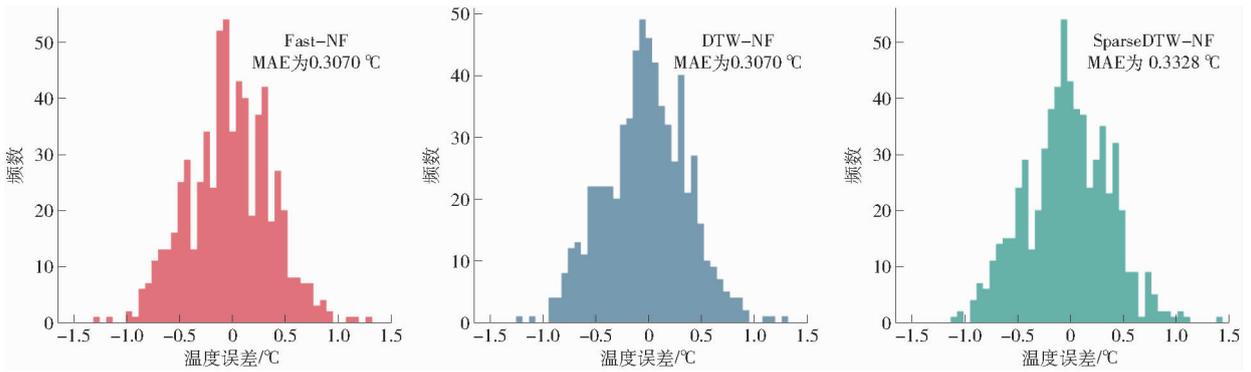


图 14 不同 DTW 方法 NF 函数温度误差分布

Fig. 14 Temperature error distribution of NF functions by different DTW methods

表 5 不同改进支持度函数性能评估指标

Tab.5 Performance evaluation of different improved support functions

函数	MAE/°C	RMSE/°C	$R^2$	计算时间/s
Fast - NF	0.307 1	0.387 5	0.975 6	5.839 4
DTW - NF	0.307 0	0.387 2	0.975 5	14.568 8
SparseDTW - NF	0.332 8	0.416 9	0.973 6	4.924 4

口计算时间由标准 DTW - NF 算法的 14.568 8 s 降至 5.839 4 s, 提升 59.9%。Fast - NF 方法在应对突变、漂移、局部异常等干扰时表现出更强的稳定性与鲁棒性。本研究为养殖环境中多源感知数据的鲁棒融合提供了一种轻量化、高效率、易部署的解决方案。

## 参 考 文 献

- [1] 赵春江. 智慧农业现状与未来[J]. 山东农机化, 2024(1): 9 - 10.
- [2] 杨亮, 熊本海, 王辉, 等. 人工智能养猪在我国的发展现状与研究展望[J]. 猪业科学, 2022, 39(11): 41 - 44.
- [3] 李保明, 王阳, 郑炜超, 等. 畜禽养殖智能装备与信息化技术研究进展[J]. 华南农业大学学报, 2021, 42(6): 18 - 26.  
LI Baoming, WANG Yang, ZHENG Weichao, et al. Research progress on intelligent equipment and information technology for livestock and poultry breeding[J]. Journal of South China Agricultural University, 2021, 42(6): 18 - 26. (in Chinese)
- [4] 杨飞云, 曾雅琼, 冯泽猛, 等. 畜禽养殖环境调控与智能养殖装备技术研究进展[J]. 中国科学院院刊, 2019, 34(2): 163 - 173.  
YANG Feiyun, ZENG Yaqiong, FENG Zemeng, et al. Research status on environmental control technologies and intelligent equipment for livestock and poultry production[J]. Bulletin of Chinese Academy of Sciences, 2019, 34(2): 163 - 173. (in Chinese)
- [5] 孟蕊, 崔晓东, 余礼根, 等. 畜禽精准饲喂管理技术发展现状与展望[J]. 家畜生态学报, 2021, 42(2): 1 - 7.  
MENG Rui, CUI Xiaodong, YU Ligen, et al. The development status and prospects of livestock and poultry precise feeding management technologies[J]. Journal of Domestic Animal Ecology, 2021, 42(2): 1 - 7. (in Chinese)
- [6] 吴继成, 单东林, 杨晓文, 等. 规模化畜禽养殖场数字农业规划方案综合评价[J]. 中国农机化学报, 2022, 43(1): 128 - 134, 157.  
WU Jicheng, SHAN Donglin, YANG Xiaowen, et al. Comprehensive evaluation of digital agriculture planning scheme for large-scale livestock and poultry farms[J]. Journal of Chinese Agricultural Mechanization, 2022, 43(1): 128 - 134, 157. (in Chinese)
- [7] 李春雷, 杜祥, 王刚毅. 畜牧业高质量发展: 内涵、攻坚要点与政策设计[J]. 中国农业大学学报, 2023, 28(8): 296 - 305.  
LI Chunlei, DU Xiang, WANG Gangyi. High-quality development of animal husbandry: framework, key points and policy design [J]. Journal of China Agricultural University, 2023, 28(8): 296 - 305. (in Chinese)
- [8] AIELLO G, GIOVINO I, VALLONE M, et al. A decision support system based on multisensor data fusion for sustainable greenhouse management[J]. Journal of Cleaner Production, 2018, 172: 4057 - 4065.
- [9] CHELOTTI J O, MARTINEZ-RAU L S, FERRERO M, et al. Livestock feeding behaviour: a review on automated systems for ruminant monitoring[J]. Biosystems Engineering, 2024, 246: 150 - 177.
- [10] 王华东, 王大羽. 一种改进的多无线传感器数据分批估计自适应加权融合算法[J]. 传感技术学报, 2015, 28(8): 1239 - 1243.  
WANG Huadong, WANG Dayu. An improved multiple wireless sensor data batch estimation adaptive weighted fusion algorithm [J]. Chinese Journal of Sensors and Actuators, 2015, 28(8): 1239 - 1243. (in Chinese)
- [11] DADDABBO A, REFICE A, LOVERGINE F P, et al. DAFNE: a Matlab toolbox for Bayesian multi-source remote sensing and ancillary data fusion, with application to flood mapping[J]. Computers & Geosciences, 2018, 112: 64 - 75.
- [12] JHA S K R, JOSHESKI F, MARINA N, et al. GC - MS characterization of body odour for identification using artificial neural network classifiers fusion[J]. International Journal of Mass Spectrometry, 2016, 406: 35 - 47.

- [13] 祝小钧. 多源感知网络中数据融合方法研究与应用[D]. 重庆:重庆邮电大学, 2022.  
ZHU Xiaojun. Research and application of data fusion method in multi-source sensing network[D]. Chongqing: Chongqing University of Posts and Telecommunications, 2022. (in Chinese)
- [14] JOUSSELME A L, GRENIER D, BOSSÉ É. A new distance between two bodies of evidence[J]. *Information Fusion*, 2001, 2(2): 91 – 101.
- [15] YAGER R R. The power average operator[J]. *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, 2001, 31(6): 724 – 731.
- [16] 熊迎军, 沈明霞, 陆明洲, 等. 温室无线传感器网络系统实时数据融合算法[J]. *农业工程学报*, 2012, 28(23): 160 – 166.  
XIONG Yingjun, SHEN Mingxia, LU Mingzhou, et al. Algorithm of real time data fusion for greenhouse WSN system[J]. *Transactions of the CSAE*, 2012, 28(23): 160 – 166. (in Chinese)
- [17] 段青玲, 肖晓琰, 刘怡然, 等. 基于改进型支持度函数的畜禽养殖物联网数据融合方法[J]. *农业工程学报*, 2017, 33(增刊1): 239 – 245.  
DUAN Qingling, XIAO Xiaoyan, LIU Yiran, et al. Data fusion method of livestock and poultry breeding internet of things based on improved support function[J]. *Transactions of the CSAE*, 2017, 33(Supp. 1): 239 – 245. (in Chinese)
- [18] 匡亮, 施珮, 季云峰, 等. 改进型支持度函数的 WSN 水质监测数据融合方法[J]. *农业工程学报*, 2020, 36(16): 192 – 200.  
KUANG Liang, SHI Pei, JI Yunfeng, et al. Data fusion method for water quality monitoring using WSN based on improved support function[J]. *Transactions of the CSAE*, 2020, 36(16): 192 – 200. (in Chinese)
- [19] 宋坤, 李雨婷, 张钰颖, 等. 基于改进多传感器数据融合算法的温室环境检测研究[J]. *现代电子技术*, 2023, 46(20): 178 – 182.  
SONG Kun, LI Yuting, ZHANG Yuying, et al. Research on greenhouse environment detection based on improved multi-sensor data fusion algorithm[J]. *Modern Electronic Technique*, 2023, 46(20): 178 – 182. (in Chinese)
- [20] 孙力帆, 张雅媛, 郑国强, 等. 基于 D – S 证据理论的智能温室环境控制决策融合方法[J]. *农业机械学报*, 2018, 49(1): 268 – 275.  
SUN Lifan, ZHANG Yayuan, ZHENG Guoqiang, et al. Approach to decision fusion for intelligent greenhouse environmental control based on D – S evidence theory[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2018, 49(1): 268 – 275. (in Chinese)
- [21] KUMAR L, KHEDLEKAR S, KHEDLEKAR U K. A comparative assessment of holt winter exponential smoothing and autoregressive integrated moving average for inventory optimization in supply chains[J]. *Supply Chain Analytics*, 2024, 8: 100084.
- [22] GEORGE R, MOHAMMAD H, SAHAR A. A comparison of holt-winter and artificial neural network approach in forecasting: a case study for tent manufacturing industry[J]. *Results in Engineering*, 2024, 21: 101899.
- [23] WU R, KEOGH E J. FastDTW is approximate and generally slower than the algorithm it approximates[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2022, 34(8): 3779 – 3785.
- [24] SALVADOR S, CHAN P. Toward accurate dynamic time warping in linear time and space[J]. *Intelligent Data Analysis*, 2007, 11(5): 561 – 580.
- [25] 刘思峰, 蔡华, 杨英杰, 等. 灰色关联分析模型研究进展[J]. *系统工程理论与实践*, 2013, 33(8): 2041 – 2046.  
LIU Sifeng, CAI Hua, YANG Yingjie, et al. Advance in grey incidence analysis modelling[J]. *Systems Engineering-Theory & Practice*, 2013, 33(8): 2041 – 2046. (in Chinese)
- [26] 刘思峰, 谢乃明, JEFFERY F. 基于相似性和接近性视角的新型灰色关联分析模型[J]. *系统工程理论与实践*, 2010, 30(5): 881 – 887.  
LIU Sifeng, XIE Naiming, JEFFERY F. On new models of grey incidence analysis based on visual angle of similarity and nearness[J]. *Systems Engineering-Theory & Practice*, 2010, 30(5): 881 – 887. (in Chinese)
- [27] SAKOE H, CHIBA S. Dynamic programming algorithm optimization for spoken word recognition[J]. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 1978, 26(1): 43 – 49.
- [28] QU X, ZHOU J, GU X, et al. Monitoring maize lodging severity based on multi-temporal Sentinel – 1 images using time-weighted dynamic time warping[J]. *Computers and Electronics in Agriculture*, 2023, 215: 108365.
- [29] XU J, WANG R, ZHANG Y, et al. Adaptive sequential three-way decisions for dynamic time warping[J]. *Information Sciences*, 2025, 690: 121541.