

DOI: 10.13382/j.jemi.B2508599

基于因果图的飞控系统故障传播路径识别方法*

张晓瑜¹ 吕亚蕊¹ 郭润夏¹ 吴 军²

(1. 中国民航大学电子信息与自动化学院 天津 300300; 2. 中国民航大学航空工程学院 天津 300300)

摘要: 民航飞行控制系统采用冗余架构保障安全性, 但该设计在提升可靠性的同时使得组件间存在耦合与非线性因果依赖, 导致单一故障在组件之间传播, 正确识别组件之间的因果关系对分析故障发生的根本原因和识别传播路径至关重要。因此, 提出一种基于因果图的飞控系统故障传播路径识别方法。首先, 构建双注意力协同机制的多通道深度可分离时序卷积网络 (dual attention-based multi-channel depthwise separable temporal convolutional network, Da-MDSTCN), 通过注意力融合机制解析组件间因果关联特征, 并结合图论构建系统结构因果图; 其次, 设计特征融合的多通道加权时序卷积网络 (multi-channel weighted temporal convolutional network, MC-WTCN), 通过特征调制策略实现多维状态特征参数的协同预测, 并建立一个基于预测残差与相对偏差分析的诊断框架, 实现故障根源诊断与传播路径识别。最后, 基于 A320 飞控系统的案例进行实验, 故障诊断准确率达到 94.8%, 同时故障传播路径识别更加准确, 验证了所提方法在故障诊断与传播路径识别方面的准确性与有效性。

关键词: 飞控系统; 时间卷积网络; 注意力机制; 因果图模型; 故障传播路径

中图分类号: V249; TN06 **文献标识码:** A **国家标准学科分类代码:** 590.35

Fault propagation path identification method for flight control systems based on causal diagrams

Zhang Xiaoyu¹ Lyu Yarui¹ Guo Runxia¹ Wu Jun²

(1. School of Electronic Information and Automation, Civil Aviation University of China, Tianjin 300300, China;

2. School of Aeronautical Engineering, Civil Aviation University of China, Tianjin 300300, China)

Abstract: Civil aircraft flight control systems adopt a multi-redundancy architecture to ensure safety. However, this design, while enhancing reliability, introduces coupling and nonlinear causal dependencies among components, leading to the propagation of single faults across components. Accurately identifying the causal relationships among components is crucial for analyzing the root causes of faults and identifying their propagation paths. Therefore, a method for identifying fault propagation paths in flight control systems based on causal graphs is proposed. Firstly, a dual attention-based multi-channel depthwise separable temporal convolutional network (Da-MDSTCN) is constructed. Through the attention fusion mechanism, the causal association features among components are analyzed, and a system structure causal graph is built in combination with graph theory. Secondly, a multi-channel weighted temporal convolutional network (MC-WTCN) is designed for feature fusion. Through a feature modulation strategy, the collaborative prediction of multi-dimensional state feature parameters is achieved, and a diagnostic framework based on prediction residuals and relative deviation analysis is established to realize the diagnosis of fault origins and the identification of propagation paths. Finally, experiments are conducted based on the A320 flight control system. The fault diagnosis accuracy reaches 94.8%, and the identification of fault propagation paths is more accurate, verifying the accuracy and effectiveness of this method in fault diagnosis and propagation path identification.

Keywords: flight control system; temporal convolutional network; attention mechanism; causal diagram; fault propagation path

收稿日期: 2025-07-25 Received Date: 2025-07-25

* 基金项目: 国家自然科学基金项目 (62173331, 52375557)、天津市自然科学基金项目 (24JCYBJC00160, 23JCYBJC00060)、民航安全能力建设项目 (2024012)、天津市教委科研项目 (2023KJ222)、中央高校基本科研业务费 (3122023PY06, 3122024052, KJZ53420210113) 资助

0 引言

民机飞行控制系统是保障飞行安全的核心系统,由机械、电子、电气及液压等部件组成^[1],其通过将飞行员或自动驾驶仪的指令精确转换为舵面控制量,实现对飞行姿态控制、俯仰轴配平、偏航控制、减速操纵和横滚操纵等重要功能。为确保极高的可靠性与安全性,该系统普遍采用冗余余架构设计^[2],然而,这种设计在引入冗余单元以保障协同与资源共享的同时,也导致系统内部形成了高度耦合的交互网络^[3]。组件间紧密的耦合关系产生了复杂的非线性依赖^[4]。一旦发生故障,此类依赖极易引发连锁反应,甚至导致次生系统性故障。因此,找到一种能够准确诊断飞行控制系统故障根源并识别其传播路径的有效方法,对于提升飞行安全具有至关重要的理论与现实意义。

当前,基于数据驱动的故障诊断方法已成为研究热点。其核心优势在于能够利用历史运行数据挖掘变量间的复杂关系,为故障诊断和路径识别构建拓扑图^[5]。格兰杰因果关系(granger causality, GC)^[6]、传递熵(transfer entropy, TE)^[7]和贝叶斯网络(Bayesian network, BN)^[8]等因果分析方法虽能理论上更深入地解析故障根源与传播机理^[9-10]。但它们在处理多变量、非线性以及存在隐藏混杂变量的复杂系统时,准确性与鲁棒性仍面临挑战。

随着深度学习技术的发展,其在非线性关系建模和异常检测领域的强大能力为因果发现提供了新途径^[11]。其优势在于能够学习复杂的非线性关系和长时间依赖^[12]。长短期记忆(long short-term memory, LSTM)网络^[13-14]、门控循环单元(gated recurrent unit, GRU)^[15-16]和时序卷积网络(temporal convolutional network, TCN)^[17]等模型因其在时序特征提取方面的卓越表现,推动了基于预测的因果发现方法的发展。Guo等^[18]提出一种可解释的多变量LSTM模型,利用混合注意力机制识别关键变量;He等^[19]设计了基于注意力的LSTM方法以识别过程变量间的因果关系,从而诊断故障根本原因,同时新的训练策略可增强鲁棒性和防止传统LSTM方法存在的过拟合问题。TCN由于引入了膨胀因果卷积与残差连接,使其能够高效训练深度网络并获得更大的感受野^[20],从而更有效地提取长期时序依赖。Nauta等^[21]提出时间因果发现框架(temporal causal discovery framework, TCDF),结合注意力权重量化了变量间因果关系强度,同时实现了多变量间非线性因果关系辨识;Li等^[22]提出可解释多尺度TCN模型,精确定位关键飞行参数,从而找到对异常贡献最大的关键参数,实现飞机飞行异常的检测;这些方法展示了TCN在多维时间序列因果关系辨识中的巨大潜力。

尽管上述方法在故障定位和状态判别方面取得了显著进展,但它们大多缺乏对故障定位与传播路径识别的一体化诊断能力。现有研究中,因果分析与路径推断往往是分离的步骤。例如,Dong等^[23-24]在对系统进行因果关系分析后利用预测值的最小二乘线性拟合并对斜率进行分析,从而进行故障传播路径推理;Dong等^[25]提出两步分布式故障诊断方法,定义区块贡献指数识别故障子块和变量,再根据全局和局部因果有向图搜索传播路径。这些推理与搜索的方法与因果关系分析的结合为系统故障诊断方法提供了较好的思路。

综上所述,提出一种基于因果图的飞行控制系统故障诊断与传播路径一体化识别方法。其核心在于构建一个“因果发现-预测-诊断”的协同诊断方法,该方法通过3个关键技术环节的有机结合实现:首先,设计双注意力协同的TCN网络,结合静态与动态注意力机制从时序数据中自动辨识因果关系,构建系统结构因果图;然后,以所得因果图为先验,利用多通道加权TCN及基于因果强度的特征调制策略,建立关键组件状态的精准预测模型;最后,基于预测残差与节点间相对偏差,融合根源定位算法与路径搜索策略,自动实现故障根源识别与传播路径追溯。

1 基于因果图的故障传播路径识别

1.1 故障传播路径识别方法

本文基于因果图模型的飞控系统故障传播路径识别方法的整体流程如图1所示,具体包含3个步骤:

首先,针对飞行控制系统多变量强耦合及非线性的时序特性,设计了基于双注意力协同机制的多通道深度可分离时序卷积网络(dual attention-based multi-channel depthwise separable temporal convolutional network, Da-MDSTCN),用于精准辨识该系统内部组件间的结构因果关系,构建系统结构因果图;然后,利用上述取得的飞行控制系统组件间因果依赖强度数据,利用多通道加权时序卷积网络(multi-channel weighted temporal convolutional network, MC-WTCN)对关键节点的状态特征进行预测,该设计能有效建模系统中由因果强度决定的信号传播权重;最后,结合飞行控制系统故障传播的物理逻辑,设计了一套基于预测残差分析与节点间相对偏差对比的联合诊断策略,从而实现对飞控系统的故障根源定位与传播路径追溯。

1.2 基于Da-MDSTCN的系统结构因果关系识别

为揭示A320飞行控制系统内部组件间的因果关系,设飞行控制系统因果图模型为 $G = (P, E, \Phi)$,其中 $P = [p_1, p_2, \dots, p_n]$ 为节点的有限集合,代表系统中的所




图1 基于因果图模型的飞控系统故障传播路径识别方法

Fig. 1 A fault propagation path identification method for flight control systems based on causal graph models

有关键组件, n 为节点总数。 $E = [e_1, e_2, \dots, e_n]$ 为连接节点的有向边集合, 且 $e_i = [e_{i,1}, e_{i,2}, \dots, e_{i,n}]$ 为节点 i 与所有节点的有向边集合, $\Phi = [\varphi_1, \varphi_2, \dots, \varphi_n]$ 为节点间的连接权重集合, 且 $\varphi_i = [\varphi_{i,1}, \varphi_{i,2}, \dots, \varphi_{i,n}]$ 为节点 i 与所有节点的连接权重集合, 其中 $\varphi_{i,j}$ 为节点 j 对节点 i 的因果影响强度。将组件与传感器采集的时间序列数据进行一对一关联, 构建成一个特征矩阵 $X = [x_1, x_2, \dots, x_n] = [x^1, x^2, \dots, x^T]^T \in \mathbf{R}^{T \times n}$, 其中 T 为时间序列的采样点数。利用 Da-MDSTCN 网络对特征矩阵 X 进行分析, 以推断并量化节点间的因果关系 (即确定边集合 E 和权重集合 Φ), 进而完成飞行控制系统因果图的构建。

1) Da-MDSTCN 的架构

Da-MDSTCN 模型由 n 个并行的子网络 $\{\text{Da-MDSTCN}_i\}_{i=1}^n$ 构成, 整体架构如图2所示, 其核心改进在于将双重注意力机制嵌入深度可分离 TCN 骨干, 并通过因果关系量化模块实现对变量间因果关系强度的表征。该网络的结构设计主要围绕3个核心改进展开: 静态输入注意力层 (图2虚线框)、动态通道注意力层 (图2点划线框) 及因果关系量化模块 (图2双点划线框)。

在子网络 Da-MDSTCN_i 中, 输入数据 $X \in \mathbf{R}^{T \times n}$ 需要经过针对目标节点 i 的预处理。具体而言, 对于所有非目标节点 $j (j \neq i)$, 其输入序列 $x_j = [x_j^1, x_j^2, \dots, x_j^T]^T$ 保持不变, 对于目标节点 i , 为了防止在预测时发生信息泄露, 其输入序列 x_i 会向右平移一个时间步, 并在起始位置

以0填充, 记为 $x_i' = [0, x_i^1, x_i^2, \dots, x_i^{T-1}]^T$, 预处理后的输入矩阵记为 $X_i' \in \mathbf{R}^{T \times n}$ 。Da-MDSTCN_{*i*} 对于节点 i 的特征数据的预测值记为 $\hat{y}_i$ 。

(1) 静态输入注意力层

Da-MDSTCN_{*i*} 的第一步是通过一个可训练的注意力向量 α_i , 对预处理后的输入矩阵 X_i' 进行静态重要性加权, 以评估每个输入序列对预测的全局因果影响。该过程的数学表达式为:

$$H_i = X_i' \odot \alpha_i \quad (1)$$

式中: $\alpha_i = [\alpha_{i,1}, \alpha_{i,2}, \dots, \alpha_{i,n}] \in \mathbf{R}^{1 \times n}$ 为输入注意力权重向量, 是可训练参数; $\odot$ 为 Hadamard 积^[26] 运算, 它将 α_i 通过广播机制作用于 X_i' 的每个时间步; $H_i = [h_{i,1}, h_{i,2}, \dots, h_{i,n}] \in \mathbf{R}^{T \times n}$ 为经输入注意力加权后的初始特征矩阵。


随后, 采用堆叠多层膨胀因果卷积的 TCN 网络对 H_i 进行分通道深度特征提取, 发掘深层时序依赖关系:

$$F_i = \text{TCN}_i(H_i) \quad (2)$$

式中: $\text{TCN}_i(\cdot)$ 为带残差连接的深度可分离 TCN^[27] 单元; 对每个通道进行独立的运算; $F_i = [f_{i,1}, f_{i,2}, \dots, f_{i,n}] \in \mathbf{R}^{T \times n}$ 为提取的深度特征矩阵。

(2) 动态通道注意力层

为捕捉特征层面的动态依赖关系, 引入一个通道注意力模块 (channel attention module, CAM)^[28], 它根据深度特

图2 用于因果分析的 Da-MDSTCN_i 网络结构图Fig. 2 The Da-MDSTCN_i network structure diagram for causal analysis

征 F_i 动态地为每个特征通道分配一个重要性权重,其计算过程如下:

$$\beta_i = \sigma(\text{MLP}(\text{Avgpool}(F_i)) + \text{MLP}(\text{Maxpool}(F_i))) \quad (3)$$

式中: $\text{Avgpool}(\cdot)$ 和 $\text{Maxpool}(\cdot)$ 分别为沿时间维度的全局平均池化和全局最大池化; $\text{MLP}(\cdot)$ 为一个共享权重的多层感知机(multilayer perceptron, MLP); $\sigma(\cdot)$ 为 sigmoid 激活函数; $\beta_i = [\beta_{i,1}, \beta_{i,2}, \dots, \beta_{i,n}] \in \mathbf{R}^{1 \times n}$ 为通道注意力权重向量。

随后,将该权重应用于深度特征矩阵 F_i , 实现特征的动态校准:

$$Z_i = F_i \odot \beta_i \quad (4)$$

式中: $Z_i = [z_{i,1}, z_{i,2}, \dots, z_{i,n}] \in \mathbf{R}^{T \times n}$ 为经 CAM 重加权后的新特征数据。

最后,将经过双重注意力加权的特征矩阵 Z_i , 通过一个 1×1 逐点卷积层^[29]进行通道融合,并映射到最终的单通道预测结果 $\hat{y}_i$ 。该预测值将用于计算网络损失并驱动模型训练。

$$\hat{y}_i = \text{Conv}_{1 \times 1}(Z_i) \quad (5)$$

(3) 因果关系量化模块

为了实现对因果关系的量化,设计了一个独立于预测网络之外的因果量化模块。该模块在网络训练完成后,融合静态因果重要性和动态特征贡献度,得到一个综合的因果强度分数,用于量化每个输入序列 x_j 对目标序列 x_i 的因果影响,其计算方法为:

$$\gamma_i = g \times \alpha_i + (1 - g) \times \beta_i \quad (6)$$

式中: $\gamma_i = [\gamma_{i,1}, \gamma_{i,2}, \dots, \gamma_{i,n}] \in \mathbf{R}^{1 \times n}$ 为融合注意力得分向

量,用于量化因果影响; g 为一个介于 0~1 之间的超参数,它代表了在最终评估中,对于静态全局因果信号 α_i 的信任程度。

2) 基于因果关系的系统结构因果图构建

通过 Da-MDSTCN 模型,为每个目标节点 i 得到一个融合注意力得分向量 $\gamma_i = [\gamma_{i,1}, \gamma_{i,2}, \dots, \gamma_{i,n}]$, 其元素 $\gamma_{i,j}$ 表示节点 j 对节点 i 的注意力强度,该向量为量化节点间的因果关系提供了初步依据。然而,由于模型训练的随机性与数据分布的复杂性,直接使用这些注意力得分可能导致虚假的因果连接。因此,提出一种结合自适应阈值与显著性检验的因果关系确认策略,用以精简并确认最终的因果关系向量,生成因果图 G 。该过程具体流程如下:

(1) 注意力得分排序。对每个向量 γ_i , 按其元素值降序排列,得到排序后的向量 η_i 。

$$\eta_i = \text{Sort}_{\text{desc}}(\gamma_i) = [\eta_{i,1}, \eta_{i,2}, \dots, \eta_{i,n}] \quad (7)$$

(2) 最大间隔索引识别。在排序后的向量 η_i 中,寻找相邻元素间绝对差值最大的位置索引 q_i , 用于区分显著与非显著的注意力得分:

$$q_i = \underset{1 \leq j \leq n-1}{\text{argmax}} (\eta_{i,j} - \eta_{i,j+1}) \quad (8)$$

(3) 自适应阈值确定。基于索引 q_i , 定义节点 i 的自适应因果阈值 τ_i 为该最大间隔位置对应的注意力值,该阈值 τ_i 作为筛选潜在因果关系的初步标准:

$$\tau_i = \eta_{i,q_i} \quad (9)$$

(4) 因果图构建。对于每个目标节点 i , 构建一个面向它的因果图 $G_i = (P, e_i, \varphi_i)$ 。其中,从 p_j 到 p_i 的边 $e_{i,j}$ 的存在性及其权重 $\varphi_{i,j}$ 定义如下:

$$e_{i,j} = \begin{cases} 1, & \gamma_{i,j} \geq \tau_i \wedge \text{PI}(p_j \rightarrow p_i) = 1 \\ 0, & \text{其他} \end{cases} \quad (10)$$

$$\varphi_{i,j} = \begin{cases} \gamma_{i,j}, e_{i,j} = 1 \\ 0, e_{i,j} = 0 \end{cases} \quad (11)$$

式中:PI(permutation importance)为排列重要性^[30]显著性检验。

(5)通过对所有 n 个目标节点重复上述步骤,得到一个因果图集合 $\{G_1, G_2, \dots, G_n\}$ 。最终,完整的系统因果图 $G=(P, E, \Phi)$ 通过合并所有子图的边集与权重集而构成。

1.3 基于 MC-WTCN 的节点状态特征数据预测

在构建系统因果图 G 后,为图中每个节点 i 设计并构建一个 MC-WTCN _{i} 模型,用于对该节点的状态特征进行预测。

传统的时间序列预测模型通常仅利用目标变量自身的历史数据,而忽略了系统中变量间复杂的因果依赖关系。为解决此问题,本模型的核心思想是构建融合了因果信息的特征序列作为网络输入。具体而言,对于任意待预测的目标节点 i ,首先根据因果图 G_i 确定其所有直接原因节点,记为集合 $\{pa_j(i)\}_{j=1}^m$,随后,将目标节点 i 自身及其 m 个原因节点在 t 时刻的状态值整合,构成一个 $m+1$ 维的因果特征向量 $\mathbf{X}_i^t = [x_i^t, x_{pa_1(i)}^t, x_{pa_2(i)}^t, \dots, x_{pa_m(i)}^t]^T$ 。随后,采用长度为 ω 的滑动窗口,截取连续 ω 个时刻的因果特征向量,构成输入序列 $\mathbf{S}_i^t = [\mathbf{X}_i^{t-\omega+1}, \mathbf{X}_i^{t-\omega+1}, \dots, \mathbf{X}_i^t] \in \mathbf{R}^{(m+1) \times \omega}$ 。同时,将窗口后下一时刻的目标变量真实值 x_i^{t+1} 作为监督学习的输出标签。通过上述变换,原始时序数据被重构为适用于监督学习的样本对 $(\mathbf{S}_i^t, x_i^{t+1})$ 。

1) 特征调制层

为实现对不同原因变量的差异化关注,设计了一个特征调制层,利用从因果图 G_i 中得到的边权重 $\varphi_{i,j}$,对输入的多元时间序列进行加权。采用 softmax 函数将影响强度转化为归一化的调制权重:

$$\psi_{i,j} = \frac{\exp(\varphi_{i,j})}{\sum_{k \in D(i) \cup \{i\}} \exp(\varphi_{i,k})} \quad (12)$$

式中: $D(i)$ 为因果图 G_i 中的上游原因节点集合;由此得到包含自身节点在内的、完整的 $m+1$ 维权重向量 $\boldsymbol{\psi}_i = [\psi_{i,i}, \psi_{i,pa_1(i)}, \dots, \psi_{i,pa_m(i)}]^T$ 。随后,将权重向量应用到输入序列 $\mathbf{S}_i^t$ 的每一个时间步上,得到调制后的特征序列 $\mathbf{U}_i^t \in \mathbf{R}^{(m+1) \times \omega}$:

$$\mathbf{U}_i^t = \mathbf{S}_i^t \odot \boldsymbol{\psi}_i \quad (13)$$

2) 深度可分离 TCN 计算

该层利用深度可分离时序卷积网络,从加权后的特征序列 $\mathbf{U}_i^t$ 中提取高维时序特征。计算过程如下:

$$\mathbf{V}_i^t = \text{TCN}_i^t(\mathbf{U}_i^t) \quad (14)$$

式中: $\text{TCN}_i^t(\cdot)$ 表示深度可分离 TCN;其输出 $\mathbf{V}_i^t \in \mathbf{R}^{(m+1) \times \omega}$ 是一个高维特征序列,为了进行最终预测,提取该输出序列在最后一个时间步的特征向量 $\mathbf{A}_{\text{final},i}^t$,它融合了整个历史窗口的信息:

$$\mathbf{A}_{\text{final},i}^t = \mathbf{V}_i^t[:, t] \quad (15)$$

最后,将该特征向量 $\mathbf{A}_{\text{final},i}^t$ 通过一个全连接输出层,得到最终的预测值:

$$\hat{x}_i^{t+1} = \mathbf{W}_{\text{final}} \times \mathbf{A}_{\text{final},i}^t + b_{\text{final}} \quad (16)$$

式中: $\mathbf{W}_{\text{final}} \in \mathbf{R}^{1 \times (m+1)}$ 和 $b_{\text{final}} \in \mathbf{R}^{1 \times 1}$ 分别为输出层的权重和偏置项,为模型训练学习的参数; $\hat{x}_i^{t+1}$ 为模型对节点 i 在 $t+1$ 时刻的预测值。

1.4 基于残差分析与相对偏差对比的故障根源诊断与传播路径识别

1) 基于残差分析的故障根源诊断

利用 MC-WTCN 对因果图中每个节点的特征值进行实时预测,基于预测残差分析的故障定位方法,通过阈值优先触发准则进行故障节点定位,其故障根源诊断算法如下:

$$k = \underset{i}{\text{argmin}} (\min \{t \mid \hat{x}_i^t - x_i^t > \bar{\lambda} \text{ or } \hat{x}_i^t - x_i^t < \underline{\lambda}\}) \quad (17)$$

$$\bar{\lambda} = \mu + 3\delta \quad (18)$$

$$\underline{\lambda} = \mu - 3\delta \quad (19)$$

式中: k 为最早触发异常阈值上界或者下界的节点; $\hat{x}_i^t$ 和 x_i^t 分别为节点 i 在时间步 t 的特征预测值和真实值,二者差值为异常分数; $\bar{\lambda}$ 为异常阈值上界; $\underline{\lambda}$ 为异常阈值下界; μ 和 δ 分别为模型在正常数据集上利用 MC-WTCN 预测得到的残差的均值和标准差。

2) 基于相对偏差对比的传播路径识别

在定位到故障根源节点后,下一目标是揭示故障在系统内的传播机制,提出一种基于因果图的搜索策略,其核心准则为:故障倾向于沿着对其下游节点造成最大“序列累积相对偏差”的路径进行传播。

(1) 偏差度量:为量化故障对下游节点的影响程度,定义节点 p_i 在一个时间段内的时序累积相对偏差 θ_i 为:

$$\theta_i = \frac{1}{|\Gamma|} \sum_{t \in \Gamma} \frac{2 \|\hat{x}_i^t - x_i^t\|}{\|\hat{x}_i^t\| + \|x_i^t\|} \quad (20)$$

式中: $\Gamma = \{t+1, t+2, \dots, t+\Delta t\}$ 为累积观测时间点集合; $|\Gamma|$ 为累积时间长度。

(2) 路径推断算法的计算流程如下:

(a) 初始化:将故障根源节点 k 作为当前节点;

(b) 迭代步骤:在当前节点的直接下游节点集合(例如第 m 层下游节点集合 B_m)中,选择具有最大时序累积相对偏差 θ_i 的节点 k_m 作为下一个故障传播节点:

$$k_m = \underset{k \in B_m}{\text{argmax}} (\theta_i) \quad (21)$$

(c) 更新:将 k_m 设为新的当前节点,并继续在其下游节点中进行选择;

(d) 终止:当当前节点无下游节点,或所有下游节点的偏差均不显著时,迭代终止。

2 实验验证

以 A320 飞机飞控系统 中的方向舵子系统为例进行验证,相关变量数据是在航空器快速存取记录器 (quick access recorder, QAR) 中采集的飞行参数数据。实验平台的计算机配置如下: Intel Xeon W-2133, 主频为 3.6 GHz, RAM 为 16 GB。

2.1 飞控数据集介绍

随着民用航空业的不断发展,飞机飞控系统集成化程度不断提高。飞控系统主要包括方向舵子系统、升降舵子系统、可配平水平安定面子系统、副翼子系统和扰流板子系统^[31]。方向舵子系统可通过电动/机械复合操纵实现作动,其动力执行机构采用 3 套并联液压伺服作动器,集成偏航阻尼、转弯协调、行程限制及配平控制等核心功能。

根据方向舵子系统拓扑架构,通过分析系统间的物理耦合与功能关联,从控制器、作动器、液压执行单元及位移传感器等关键组件中,遴选出 23 个具备显著状态表征能力的动态参数构成输入特征集,选取的参数如表 1 所示。所选参数在时域表现出良好的故障敏感性,能有效表征系统运行状态的非线性动态特征。

表 1 选取的飞控系统变量及变量说明
Table 1 Selected flight control system variables and variable descriptions

变量	节点	变量说明
x_1	p_1	方向舵配平复位按钮
x_2	p_2	方向舵配平旋扭角度
x_3, x_4	p_3, p_4	飞行增稳计算机 1, 2
x_5, x_8	p_5, p_8	方向舵配平作动器 1, 2 压力
x_6, x_9	p_6, p_9	偏航阻尼器 1, 2 压力
x_7, x_{10}	p_7, p_{10}	行程限制马达 1, 2 扭矩
x_{11}	p_{11}	人工感觉组件位移
x_{12}	p_{12}	偏航阻尼伺服控制器位移
x_{13}	p_{13}	行程限制作动器位移
x_{14}	p_{14}	方向舵脚蹬压力
x_{15}	p_{15}	脚蹬伺服控制器位移
x_{16}	p_{16}	方向舵伺服作动器位置
x_{17}, x_{18}, x_{19}	p_{17}, p_{18}, p_{19}	方向舵伺服控制器蓝/绿/黄液压压力
x_{20}	p_{20}	方向舵机械连杆位移
x_{21}	p_{21}	方向舵舵面偏转角度
x_{22}	p_{22}	方向舵位置传感器反馈角度
x_{23}	p_{23}	偏航阻尼传输组件位移

首先使用 3 000 个正常运行数据进行离线训练,以捕获方向舵子系统组件间的因果关系,实现系统结构因果图构建。随后,针对各特征变量截取连续 5 250 个采样点数据,并对数据进行预处理操作,包括 K-最近邻算法填补缺失值和标准化处理,K 取值为 3,预处理后数据

集按 6 : 2 : 2 比例划分为训练集、验证集和测试集。其中,训练集用于 MC-WTCN 的模型训练;验证集用于优化网络超参数与结构配置,并通过预测残差计算确定故障检测阈值;测试集用于最终评估模型的性能与故障诊断精度。

2.2 实验过程及结果分析

1) 系统结构因果关系识别

基于方向舵子系统正常运行状态下的参数数据集,构建并分析了多变量系统间的因果关系模型。所采用的 Da-MDSTCN 核心参数设置如下:训练采用 Adam 优化器^[32],卷积核大小为 4;特征通道维度匹配系统变量规模,设定为 23;深度膨胀因果卷积采用 2 层隐藏结构;初始学习率设置为 0.001;损失函数采用均方误差函数 (mean squared error, MSE);超参数 $g = 0.6$,该参数配置经过实验验证可有效提升模型性能。

为确保所构建因果图的物理意义和工程可信度,采用数据驱动与机理知识的双重验证方法。该框架在通过 PI 进行统计学显著性检验的基础上,进一步引入领域知识进行校准。具体而言,任何由 PI 初步确认的因果关系 $p_j \rightarrow p_i$,都必须与飞行手册中的技术规范及领域专家的经验知识相符。只有同时满足统计显著性和机理一致性两个标准的因果关系,才被最终采纳。

每个 Da-MDSTCN_i 子模型均能生成一个面向特定目标节点 i 的因果图 G_i ,该子图精确表征了 p_i 与其所有上游原因节点之间的因果依赖关系。通过合并所有独立的因果图,构建系统的完整因果图 G ,该合并过程保留了每个节点的局部因果结构。考虑到在单个视图中完整展示所有节点的因果关系会使图结构异常复杂,为此,本文选取 7 个具有代表性的关键节点 $\{p_{11}, p_{12}, p_{13}, p_{15}, p_{16}, p_{20}, p_{22}\}$,对其各自的因果图在完整因果图进行可视化呈现,最终构建的系统结构因果图如图 3 所示。以节点 16 的因果图 G_{16} 为例,其上游原因节点集合为 $\{p_{11}, p_{12}, p_{13}, p_{15}\}$,从而构成一个包含 5 个节点的局部因果结构,图中各条有向边的权重值 $\varphi_{16,j}$ 量化了相应变量间的因果关系强度。因果图中具体数值分析结果如表 2 所示。

2) 故障诊断实验

对于因果图中各节点对应的特征数据,滑动窗口长度设置为 $\omega = 10$,滑动步长为 1。针对 MC-WTCN 的深度优化问题,通过比较 1~4 层隐藏结构的预测性能,采用 MSE 和平均绝对误差 (mean absolute error, MAE) 为评价指标,比较其预测性能。如图 4 所示,当隐藏层数 $m = 2$ 时,模型达到最低误差水平,故采用双层隐藏结构作为最终架构。故障检测方面,基于阈值优先触发准则进行故障节点定位,若节点异常分数最先超过阈值,则判定为系统故障根源节点。




图 3 系统结构因果图
Fig. 3 System structure causal diagram

表 2 边权重值
Table 2 Side weight value

$e_{i,j}$	$\varphi_{i,j}$	$e_{i,j}$	$\varphi_{i,j}$
(3, 1)	0.280 5	(13, 7)	0.416 3
(3, 2)	0.304 6	(13, 10)	0.496 8
(3, 23)	0.368 4	(15, 14)	0.675 1
(4, 1)	0.231 4	(16, 11)	0.255 2
(4, 2)	0.244 1	(16, 12)	0.242 3
(4, 23)	0.463 2	(16, 13)	0.217 2
(5, 3)	0.540 5	(16, 15)	0.257 5
(6, 3)	0.548 0	(17, 16)	0.510 6
(7, 3)	0.547 4	(18, 16)	0.583 4
(8, 4)	0.540 1	(19, 16)	0.535 5
(9, 4)	0.535 1	(20, 17)	0.288 1
(10, 4)	0.542 7	(20, 18)	0.365 0
(11, 5)	0.403 4	(20, 19)	0.342 3
(11, 8)	0.402 7	(21, 20)	0.647 2
(12, 6)	0.460 5	(22, 21)	0.688 8
(12, 9)	0.420 5	(23, 12)	0.333 4




图 4 MC-WTCN 的预测误差
Fig. 4 The prediction error of MC-WTCN

故障设置为方向舵伺服作动器卡阻异常,该异常会引发液压伺服控制器压力波动,液压压力会迅速升高来

推动作动器工作,当作动器卡阻时导致液压压力保持在一个比较高的数值,进而导致方向舵位置偏差。在因果图中方向舵伺服作动器对应节点 16,在测试集的第 500~800 个时间步引入故障,图 5 监测结果表明:模型在第 500 时间步捕获到节点 16 的数值越界现象,其异常分数值在该时段持续高于阈值水平,表明在这一时间段内节点 16 对应组件发生了故障,验证了所提出的故障检测方法的有效性。




图 5 故障诊断结果
Fig. 5 Fault diagnosis result

为评估本方法的诊断性能,以方向舵伺服作动器卡阻异常为典型故障案例,与相关向量机 (relevance vector machine, RVM) [33]、支持向量回归 (support vector regression, SVR) [34]、LSTM [35] 和 TCN [36] 4 类基准模型进行对比实验。以准确率 (accuracy, ACC)、虚警率 (false alarm rate, FAR) 和 F1 分数 (F1-score) 作为评价指标。实验参数参照文献设置:RVM 相关系数阈值为 0.75;SVR 模型基于已建立的因果图边权重参数构建回归基准;LSTM 采用 3 层网络结构,滑动窗口长度为 40;TCN 卷积核大小设置为 3。实验结果如表 3 所示。从表中可以看出,本方法在 A320 飞控系统故障诊断中展现出显著优势:相较于对比模型,其准确率分别提升 3.8、7.6、2.1 和 2.0 个百分点;虚警率降低 5.6、12.0、4.2 和 3.2 个百分点;F1 分数提高了 4.1、8.5、2.3 和 2.1 个百分点,多维评估指标综合分析表明,本文方法融合了因果图结构与 TCN 的时序建模优势,在维持较低虚警率的同时,实现了故障的精准识别。

表 3 不同方法的故障诊断性能

Table 3 Fault diagnosis performance of different methods (%)

模型	ACC	FAR	F1 分数
RVM	91.0	14.0	90.5
SVR	87.2	20.4	86.1
LSTM	92.7	12.6	92.3
TCN	92.8	11.6	92.5
本文方法	94.8	8.4	94.6

3) 故障传播路径识别

本研究基于阈值优先触发准则,将节点 16 识别为初始故障源节点。依据结构因果图的拓扑关系解析,其直接下游影响节点为 17、18、19。为确定故障传播路径,采用式(20)定义的时序累积相对偏差,对故障发生后 100 个样本点数据进行分析。表 4 的实验数据显示,节点 18 的时序累积相对偏差值 θ_{18} 达到 0.126,显著高于其他相邻节点,判定其为次级故障传播节点。通过迭代计算连续追踪故障传播过程,最终构建的传播路径为: $p_{16} \rightarrow p_{18} \rightarrow p_{20} \rightarrow p_{21} \rightarrow p_{22}$, 如图 6 所示。该传播路径与已知机理相符,因此故障传播路径识别算法可以准确找出故障路径。

表 4 故障传播路径识别

Table 4 Identification of fault propagation path			
上游节点	下游节点	θ_i	传播方向
P16	P17P18	0.093	P18
	P19	0.126	
		0.101	
P18	P20	0.142	P20
P20	P21	0.139	P21
P21	P22	0.128	P22




图 6 故障传播路径
Fig. 6 Fault propagation path

为验证本方法的优越性,将其与 SGC 算法^[37]和 TE 算法^[38]进行对比,结果如图 7 所示。从表 5 和图 7 的综合性评估可以看出,本文方法性能显著优于对比算法。具体而言,SGC 算法经最大生成树优化后,虽然能正确识别节点 16 为根节点,但其拓扑简化过程导致节点 22 的传播路径丢失。而 TE 方法由于无法区分直接与间接因果关系,错误地将节点 13 和 15 归入故障关联变量集,且在互信息特征提取过程中存在关联过度的问题。

表 5 不同方法的比较

Table 5 Comparison of different methods			
方法	根本原因	故障相关变量	边数量
SGC	16	16~21	5
TE	13, 16	13, 15~20, 22	14
本文方法	16	16, 18, 20~22	4




图 7 不同方法得到的故障传播路径
Fig. 7 Fault propagation paths obtained by different methods

本研究所提出的故障传播路径识别方法通过引入结构因果图和时序累积相对偏差,实现了对 A320 飞控系统多冗余、非线性耦合结构的故障传播辨识,为复杂航空机电系统的故障诊断提供了新的解决方案。

3 结 论

针对飞行控制系统中存在的复杂非线性依赖问题,本文基于因果图模型构建了故障诊断的理论体系,为从数据中辨识系统结构间的因果关系并准确识别故障传播路径提供了系统性解决方案。首先,将双重注意力机制引入 TCN,设计了 Da-MDSTCN 模型。该模型能够高量化多维时序数据间的非线性耦合关系,为因果图的自动构建奠定了坚实的数学基础。接着,构建 MC-WTCN 网络,将已发现的因果关系作为先验知识指导预测过程,显著增强了对多源数据的特征提取与融合能力。进而,将该预测模型与基于因果图的路径推理算法相融合,形成了一套完整的故障诊断与传播分析流程。基于 A320 飞行控制系统数据,从故障诊断准确率和传播路径识别效果两个维度,将所提方法与多种基线模型进行了全面对比。实验结果表明,本文方法在各项性能指标上均显著优于传统模型,表明了其在复杂航空电子系统故障诊断领域的先进性与适用性。

未来可将本文方法应用于其他复杂机电系统,验证其不同故障模式与数据特性下的适用性与鲁棒性。同时可进一步探索如何将领域知识更紧密地融入因果发现与推理过程,提升诊断结果的可解释性与可信度,并与领域专家经验形成有效闭环。

参考文献

[1] 莊露,陆中,宋海靖,等. 基于故障注入模型的电传飞

- 控系统安全性分析[J]. 航空学报, 2023, 44(9): 277-290.
- ZHUANG L, LU ZH, SONG H J, et al. Safety analysis for fly-by-wire system based on fault injection model[J]. *Acta Aeronautica et Astronautica Sinica*, 2023, 44(9): 277-290.
- [2] 马立群, 孙晓哲, 杨士斌, 等. 民用飞机飞控系统传感器故障诊断研究综述[J]. 电光与控制, 2022, 29(1): 56-60.
- MA L Q, SUN X ZH, YANG SH B, et al. Review on sensor fault diagnosis of civil aircraft flight control system[J]. *Electronics Optics & Control*, 2022, 29(1): 56-60.
- [3] 康文文, 李浩敏. 基于模型的飞机系统架构多视图表达方法[J]. 系统工程与电子技术, 2021, 43(11): 3266-3277.
- KANG W W, LI H M. Multi-view representation method of aircraft system architecture based on mode[J]. *Systems Engineering and Electronics*, 2021, 43(11): 3266-3277.
- [4] 张晓瑜, 张凤琪, 郭润夏, 等. 基于改进 FPPN 的飞控系统故障传播路径分析方法[J]. 北京航空航天大学学报. 2024, 50(6): 1829-1841.
- ZHANG X Y, ZHANG F Q, GUO R X, et al. A fault propagation path analysis method for flight control system based on improved FPPN [J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2024, 50(6): 1829-1841.
- [5] 马亮, 彭开香, 董洁. 工业过程故障根源诊断与传播路径识别技术综述[J]. 自动化学报, 2022, 48(7): 1650-1663.
- MA L, PENG K X, DONG J. Review of root cause diagnosis and propagation path identification techniques for faults in industrial processes[J]. *Acta Automatica Sinica*, 2022, 48(7): 1650-1663.
- [6] 尹进田, 谢永芳, 陈志文, 等. 基于故障传播与因果关系的故障溯源方法及其在牵引传动控制系统中的应用[J]. 自动化学报, 2020, 46(1): 47-57.
- YIN J T, XIE Y F, CHEN ZH W, et al. Fault tracing method based on fault propagation and causality with its application to the traction drive control system[J]. *Acta Automatica Sinica*, 2020, 46(1): 47-57.
- [7] DUAN S, ZHAO C, WU M. Multiscale partial symbolic transfer entropy for time-delay root cause diagnosis in nonstationary industrial processes[J]. *IEEE Transactions on Industrial Electronics*, 2022, 70(2): 2015-2025.
- [8] CHU K, LIU R, DUAN G. A gray correlation based Bayesian network model for fault source diagnosis of multistage process-Small sample manufacturing system[J]. *Advanced Engineering Informatics*, 2023, 56: 101918.
- [9] 任俊杰, 韩敏. 多元时间序列因果关系分析研究综述[J]. 自动化学报, 2021, 47(1): 64-78.
- REN W J, HAN M. Survey on causality analysis of multivariate time series [J]. *Acta Automatica Sinica*, 2021, 47(1): 64-78.
- [10] CHEN J, ZHAO C. Multi-lag and multi-type temporal causality inference and analysis for industrial process fault diagnosis [J]. *Control Engineering Practice*, 2022, 124: 105174.
- [11] 杨挺, 王媛, 王瑛琪, 等. 基于时空关联的飞控传感器数据异常检测[J]. 仪器仪表学报, 2024, 45(8): 21-31.
- YANG T, WANG Y, WANG Y Q, et al. A spatio-temporal correlation method for flight control sensor data anomaly detection [J]. *Chinese Journal of Scientific Instrument*, 2024, 45(8): 21-31.
- [12] BI X, WU D, XIE D, et al. Large-scale chemical process causal discovery from big data with transformer-based deep learning [J]. *Process Safety and Environmental Protection*, 2023, 173: 163-177.
- [13] 郝洪涛, 王凯, 张炳建, 等. 多尺度特征自适应融合的气动控制阀故障诊断[J]. 仪器仪表学报, 2023, 44(10): 167-178.
- HAO H T, WANG K, ZHANG B J, et al. Fault diagnosis of pneumatic control valves with multi-scale features adaptive fusion [J]. *Chinese Journal of Scientific Instrument*, 2023, 44(10): 167-178.
- [14] 张晓瑜, 邓佐青, 唐黎伟, 等. 基于 DaLSTM 组合模型的电动舵机故障诊断方法[J]. 电子测量与仪器学报, 2022, 36(11): 70-78.
- ZHANG X Y, DENG Z Q, TANG L W, et al. Fault diagnosis method of electro-mechanical actuators based on DaLSTM combined model [J]. *Journal of Electronic Measurement and Instrumentation*, 2022, 36(11): 70-78.
- [15] 高凯悦, 牟莉. 基于二次分解和 GRU-attention 的时间序列预测研究[J]. 国外电子测量技术, 2023, 42(2): 80-87.
- GAO K Y, MU L. Research on time series forecasting based on quadratic decomposition and GRU-attention[J]. *Foreign Electronic Measurement Technology*, 2023, 42(2): 80-87.
- [16] 杨晓岗, 夏涛. 基于多尺度融合模型的化工故障诊断[J]. 电子测量技术, 2023, 46(13): 8-16.

- YANG X G, XIA T. Chemical fault diagnosis based on multi-scale fusion model [J]. *Electronic Measurement Technology*, 2023, 46(13): 8-16.
- [17] 陈银超, 王涛, 闫泓宇, 等. 飞控系统多元数据融合虚拟试验仿真模型验证[J]. *国外电子测量技术*, 2024, 43(9): 8-15.
- CHEN Y CH, WANG T, YAN H Y, et al. Multivariate data fusion virtual test simulation model validation in flight control systems [J]. *Foreign Electronic Measurement Technology*, 2024, 43(9): 8-15.
- [18] GUO T, LIN T, ANTULOV-FANTULIN N. Exploring interpretable LSTM neural networks over multi-variable data[C]. *International Conference on Machine Learning*. PMLR, 2019: 2494-2504.
- [19] HE R, CHEN G, SUN S, et al. Attention-based long short-term memory method for alarm root-cause diagnosis in chemical processes [J]. *Industrial & Engineering Chemistry Research*, 2020, 59(25): 11559-11569.
- [20] HE Y D, ZHAO J B. Temporal convolutional networks for anomaly detection in time series[J]. *Journal of Physics: Conference Series*, 2019, 1213(4): 042050.
- [21] NAUTA M, BUCUR D, SEIFERT C. Causal discovery with attention-based convolutional neural networks [J]. *Machine Learning and Knowledge Extraction*, 2019, 1(1): 312-340.
- [22] LI X, SHANG J X, ZHENG L J, et al. IMTCN: An interpretable flight safety analysis and prediction model based on multi-scale temporal convolutional networks[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2024, 25(1): 289-302.
- [23] DONG J, CAO K R, PENG K X. Hierarchical causal graph-based fault root cause diagnosis and propagation path identification for complex industrial process monitoring[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 1-11.
- [24] QIAO L, LI X T, WANG X, et al. Root cause diagnosis and fault propagation path identification for complex industrial processes based on data space [J]. *Measurement*, 2024, 226: 114219.
- [25] DONG J, LI D Y, WEI Y M, et al. A novel process monitoring and root cause diagnosis strategy based on knowledge-data integrated causal digraph for complex industrial processes [J]. *IEEE Transactions on Instrumentation and Measurement*, 2025, 74: 1-12.
- [26] ASHISH V, NOAM S, NIKI P, et al. Attention is all you need [J]. *Advances in Neural Information Processing Systems*, 2017, 30.
- [27] BAI S J, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling [J]. *ArXiv preprint arXiv: 1803.01271*, 2018.
- [28] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]. *Proceedings of the European Conference on Computer Vision (ECCV)*, 2018: 3-19.
- [29] HOWARD A G, ZHU M, CHEN B, et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications [J]. *ArXiv preprint arXiv: 1704.04861*, 2017.
- [30] ANDRE A, LAURA T, OLIVER S, et al. Permutation importance: A corrected feature importance measure[J]. *Bioinformatics*, 2010, 26(10): 1340-1347.
- [31] 管庭筠, 张睿, 刘程. 典型民机电传飞控系统架构分析[J]. *机电信息*, 2024(19): 75-80.
- GUAN T J, ZHANG R, LIU CH. Analysis of the architecture of typical civil aircraft fly-by-wire flight control system [J]. *Mechanical and Electrical Information*, 2024(19): 75-80.
- [32] KINGMA D P, BA J. Adam: A method for stochastic optimization[J]. *ArXiv preprint arXiv: 1412.6980*, 2014.
- [33] WANG B, LIU D, PENG X, et al. Data-driven anomaly detection of UAV based on multimodal regression model [C]. *2019 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*. IEEE, 2019: 1-6.
- [34] WEI L, QIAN Z, ZAREIPOUR H. Wind turbine pitch system condition monitoring and fault detection based on optimized relevance vector machine regression[J]. *IEEE Transactions on Sustainable Energy*, 2019, 11(4): 2326-2336.
- [35] WANG B, WANG Z, LIU L, et al. Data-driven anomaly detection for UAV sensor data based on deep learning prediction model [C]. *2019 Prognostics and System Health Management Conference (PHM-Paris)*. IEEE, 2019: 286-290.
- [36] YOU J, LIANG J, LIU D. An adaptable UAV sensor data anomaly detection method based on TCN model transferring [C]. *2022 Prognostics and Health Management Conference (PHM-2022 London)*. IEEE, 2022: 73-76.
- [37] LIU Y, CHEN H S, WU H, et al. Simplified granger causality map for data-driven root cause diagnosis of process disturbances [J]. *Journal of Process Control*,

2020,95:45-54.

[38] GUO L J, KANG J X, HUANG X. Fault diagnosis combining information entropy with transfer entropy for chemical processes [J]. IFAC-PapersOnLine, 2022, 55(6):458-464.

作者简介



张晓瑜(通信作者),2003 年于中国民用航空学院获得学士学位,2008 年于中国民航大学获得硕士学位,现为中国民航大学教授,主要研究方向为机载设备故障诊断与健康管理。

E-mail:xy_zhang@cauc.edu.cn

Zhang Xiaoyu(Corresponding author) received her B. Sc.

degree from Civil Aviation University of China in 2003, M. Sc. degree from Civil Aviation University of China in 2008, respectively. Now she is professor in Civil Aviation University of China. Her main research interests include fault diagnosis, Prognostics and Health Management of airborne equipment.



吕亚蕊,2023 年于大连民族大学获得学士学位,现为中国民航大学在读研究生,主要研究方向为机载设备故障诊断。

E-mail:1330399658@qq.com

Lyu Yarui received her B. Sc. degree from Dalian Minzu University in 2023. Now she is a M. Sc. candidate in Civil Aviation University of China. Her main research interests include fault diagnosis of airborne equipment.