



中国科技期刊卓越行动计划项目入选期刊

控制与决策

CONTROL AND DECISION

复杂时空域下多维度智能车间数据的关联网络建模

张万达, 阴艳超, 顾文娟, 唐军

引用本文:

张万达, 阴艳超, 顾文娟, 唐军. 复杂时空域下多维度智能车间数据的关联网络建模[J]. 控制与决策, 2024, 39(7): 2284–2294.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.1732>

您可能感兴趣的其他文章

Articles you may be interested in

基于WGRA-FCM样本相似性度量的转炉炼钢终点碳温软测量方法

End point carbon temperature measurement method based on WGRA-FCM for sample similarity measurement

控制与决策. 2021, 36(9): 2170–2178 <https://doi.org/10.13195/j.kzyjc.2020.0128>

基于深度时序特征迁移的轴承剩余寿命预测方法

Remaining useful life prediction of bearing based on deep temporal feature transfer

控制与决策. 2021, 36(7): 1699–1706 <https://doi.org/10.13195/j.kzyjc.2019.1809>

基于正态云模型的状态转移算法求解多目标柔性作业车间调度问题

State transition algorithm based on normal cloud model for solving multi-objective flexible job shop scheduling problem

控制与决策. 2021, 36(5): 1181–1190 <https://doi.org/10.13195/j.kzyjc.2019.1233>

基于核典型相关性-熵成分分析的工业过程质量监测方法

A quality monitoring method for industrial process based on kernel canonical correlation-entropy component analysis

控制与决策. 2021, 36(12): 2999–3006 <https://doi.org/10.13195/j.kzyjc.2020.0548>

基于模式运动的一类生产过程调节性能与聚类参数关系

Relationship between clustering parameters and regulation performance of a class of production processes based on pattern moving

控制与决策. 2020, 35(5): 1025–1038 <https://doi.org/10.13195/j.kzyjc.2018.1142>

复杂时空域下多维度智能车间数据的关联网络建模

张万达¹, 阴艳超^{1†}, 顾文娟¹, 唐军²

(1. 昆明理工大学机电工程学院, 昆明 650500;
2. 云南中烟工业有限责任公司技术中心, 昆明 650231)

摘要: 智能车间生产数据的多工序、跨流程、异构多态的特性加剧了生产过程中工艺数据关联融合问题的复杂性。面向复杂时空域下多维多尺度车间数据, 提出一种基于时序聚类-关联挖掘-复杂网络的深度融合建模方法。首先, 通过高斯核函数与一维卷积运算描述车间数据的聚类特征, 采用欧氏距离度量车间时序数据特征向量间的相似性, 并将处理后的时序特征引入聚类分析中; 其次, 通过时序数据关联规则提取各工艺参数之间蕴含的内在规律和关联关系, 采用支持度与置信度完成关联规则的深度挖掘; 然后, 依据车间跨流程多工序协同运行特点, 构建以多工序的工艺参数为节点、关联关系为边的带时间窗的生产工艺过程双权重有向多层网络模型, 为车间跨流程、多工序、异构多态的工艺指标间的复杂关联关系的描述提供依据; 最后, 以某制丝生产线质量调控为例, 对所提出方法的有效性和适用性进行验证。

关键词: 智能车间; 时序数据; 多层复杂网络; 关联网络; 时序聚类; 关联挖掘

中图分类号: TP391

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.1732

引用格式: 张万达, 阴艳超, 顾文娟, 等. 复杂时空域下多维度智能车间数据的关联网络建模[J]. 控制与决策, 2024, 39(7): 2284-2294.

Association network modeling of multi-dimensional intelligent workshop data in complex spatio-temporal domain

ZHANG Wan-da¹, YIN Yan-chao^{1†}, GU Wen-juan¹, TANG Jun²

(1. Faculty of Mechanical and Electrical Engineering, Kunming University of Science and Technology, Kunming 650500, China; 2. Technology Center, China Tobacco Yunnan Industrial Co., Ltd, Kunming 650231, China)

Abstract: The multi-process, cross-process, and heterogeneous and polymorphic characteristics of production data in smart workshops exacerbate the complexity of the process data association and fusion problem in the production process. In this study, a deep fusion modeling method that integrates time series clustering, association mining and complex network based on multi-dimensional and multi-scale workshop data in complex spatio-temporal domain is proposed. First, the Gaussian kernel function and one-dimensional convolution operation are used to describe the clustering characteristics of the workshop data, the Euclidean distance is used to calculate the similarity between the feature vectors of the workshop time series data, and the processed time series characteristics are introduced into the cluster analysis. Then, the inherent laws and correlations between the process parameters are extracted through the correlation rules of time series data, and the calculation of support and confidence are used to complete the in-depth mining of the association rules. On this basis, according to the characteristics of cross-process and multi-process collaborative operation in the workshop, a two-weight directed multi-layer network model of the production process with time windows with the process parameters of the multi-process as the node and the correlation as the edge is constructed, which provides a basis for the description of the complex relationship between the process indicators of the workshop across processes, multiple processes and heterogeneous polymorphism. Finally, a certain tobacco production line quality control is taken as an example to verify the validity and applicability of the proposed method.

Keywords: smart workshop; time series data; multi-layer complex network; association network; time series clustering; association mining

收稿日期: 2022-10-05; 录用日期: 2023-04-03.

基金项目: 国家自然科学基金项目(52065033); 云南省重大科技项目(202202AG050002).

责任编辑: 胡清华.

[†]通讯作者. E-mail: yinyc@163.com.

0 引言

智能车间融合了现代传感技术、网络技术、自动化技术等先进技术,由于大量传感器、数据采集装置等智能设备在车间投入使用,生产车间已成为信息流、物料流和控制流的汇集中心. 在产品的生产过程中,车间以前所未有的速度产生着海量的与生产、环境、状态、工艺以及设备相关的数据,且数据呈现出多任务、跨流程、异构多态的新特性. 然而,传统的制造模式中信息流、物料流、控制流在生产执行各阶段仍然相互孤立,缺乏有效的数据关联融合机制,因而难以形成合力,制约了生产效率和系统智能化水平的进一步提高^[1-2]. 因此,研究车间数据多维多尺度关联融合问题是智能制造模式在生产车间落地的核心问题之一.

近年来,国内外学者针对车间数据处理、关联分析、复杂网络建模与应用方面开展了重点研究. 在车间数据处理方面,文献[1]提出了一种两阶段无监督特征选择方法,以去除制造数据冗余性,挖掘原始数据局部结构;文献[2]提出了基于分数阶偏微分方程的离散制造系统差异性数据融合算法,以解决复杂离散制造系统中差异性数据的融合问题;文献[3]利用本体从时间、空间和属性维度对数据进行组织,以解决智能制造模式下多源异构数据建模和集成问题. 然而,上述研究多面向车间数据清洗^[1]、融合^[2]、集成^[3]等问题展开车间数据处理的相关研究. 实际上,车间数据往往具有明显的时间序列特性,但鲜有研究从时序特征的角度对车间数据进行处理,分析车间数据在时间维度上的相似模式,为面向车间时序数据的精准分析奠定基础.

在车间数据关联分析与融合方面,文献[4]提出了基于过程质量数据的关联规则挖掘算法,结合复杂事件处理技术,以实际工序顺序为约束,挖掘对各工序质量数据进行关联分析处理,实现复杂离散制造过程的关联分析;文献[5]开展面向云制造资源服务的数据挖掘技术及应用研究,提出了一种面向制造资源服务的改进遗传算法,以实现海量多态数据的高效搜索和挖掘. 然而,上述研究主要是对车间数据进行离散处理^[4],从事件的角度对车间信息进行挖掘^[5],缺乏车间生产数据多时态多尺度属性的关联分析与融合方法,从而难以解决智能车间生产数据多维多尺度关联关系的精准分析问题.

在车间数据复杂网络建模与应用方面,文献[6]提出了基于复杂网络的制造系统脆弱性综合评估方法,通过系统复杂网络的拓扑特性评估制造系统结构

脆弱性;文献[7]通过对车间进行复杂网络建模,解决了复杂车间瓶颈识别问题;文献[8]提出了一种基于复杂网络分析的聚类方法,解决了车间产生大规模传感器网络中时间序列聚类难的问题;文献[9]利用复杂网络技术对车间物料流进行建模,实现了复杂车间物料流的分析与预测;文献[10]利用复杂网络技术对车间进行分析,解决了复杂车间调度问题.

上述研究将车间的工艺流程、物料转运流程转化为复杂网络模型,为复杂网络在制造车间的应用提供了思路,但上述模型主要基于固化的生产计划和工艺流程而建立,因此,所提模型在对车间生产情况的动态描述方面有所欠缺,导致现有成果难以简单推广到智能制造模式下的智能车间,实现车间生产指标关系的动态描述,而且鲜有研究将车间在线数据蕴含的信息融入复杂网络模型中,难以通过现有模型实时揭示车间生产工艺数据之间蕴含的动态规律.

本文针对智能车间生产数据时序聚类与关联发掘利用的难题,提出一种基于时序聚类-关联挖掘-复杂网络的深度融合建模方法,以揭示车间多维时序生产数据的关联融合机理,厘清生产数据深度融合的关键影响因素. 首先,通过分析智能车间生产数据多维度时序特性,研究车间海量数据的时序聚类机理,为车间制造大数据的分析与挖掘奠定基础;其次,提出面向车间时序数据的关联规则挖掘算法,深入挖掘车间数据间复杂影响规律;最后,构建数据驱动下的多维多尺度智能车间关联网络模型,探索面向智能车间数据的多层网络与相依存网络模型的融合方法,定义智能车间关联网络模型的结构化描述机制,揭示智能车间制造过程中的演化规律与复杂关联,为智能车间分析与决策提供关联信息.

1 智能车间制造数据的关联关系挖掘

1.1 智能车间制造数据的多维度时序特性分析

随着智能车间数据中结构化、非结构化数据所占的比例越来越高,海量高维数据难以实现有效分类与重复利用,并且数据的时变规律呈现多尺度特征,数据之间的关联关系愈发复杂多样. 本文通过数据关联关系建模,根据生产数据的时变特性探究车间性能的演化规律,进一步深入分析车间生产数据的多工序、多尺度、多维时序特征.

1) 多工序特征. 如图1所示,智能车间生产过程具有加工工序多、工艺复杂、质量影响因素多等特点,其生产执行过程中蕴含着来自多道工序生成的大规模多元数据,反映了加工设备与工艺过程实时运行的状态信息,同时,每道工序都会对相邻工序和产品最

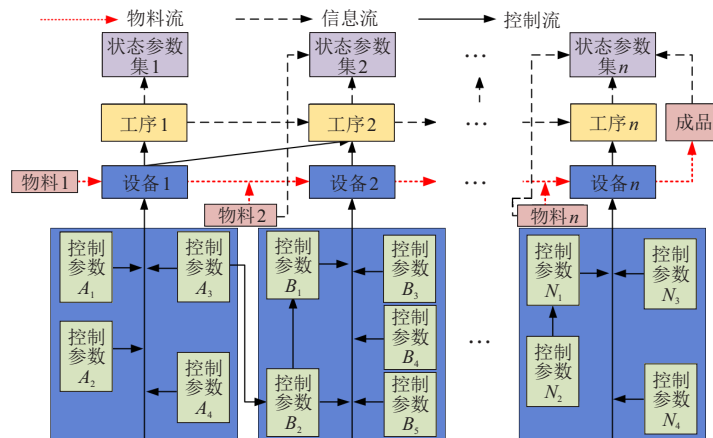


图1 典型智能车间生产工艺流程

终质量产生影响。在涉及多工序的复杂生成过程中必须考虑工序之间质量传递与相互影响,重点分析每一道工序的加工运行、工艺参数、质量特征与最终产品质量指标之间的关系。

2) 跨流程特征. 智能车间生产过程是由人、设备、物料、环境等因素组成的一个多因素、多流程的复杂系统,如图1所示。在这个系统中,生产数据在不同的生产流程和环节中交互产生,不同生产环节受到工艺参数、设备状态等多个因素的相互影响,不同流程不同环节间的工艺参数也相互影响。这种因素与因素间以及不同流程与生产环节间的相互影响使得整个车间生产过程中的各个流程都不能独立存在,因此,智能车间生产质量波动追溯需要深入发掘多流程、多环节生产数据间复杂影响规律。

3) 多维时序特征. 如图1所示,智能车间生产过程中通过传感器、控制系统、智能设备获得多维度、多数据源、多时序的设备运行参数、状态参数和生产信息数据。随着物料在车间中经由不同控制参数的作用,其状态参数也在不断改变。为了提高某些感知数据的可靠性,车间数据采集系统往往会对生产数据进行多维度测量,而同一设备的运行参数又包括流量、阀门开度和物料比例等典型参数,因此,生产过程中产生的原始数据的维度可以达到成百维甚至上千维。从智能车间生产过程中数据流的时空交互看,其物料流、信息流、控制流呈现有序流动,上一时刻的设备状态会影响下一时刻的设备状态,生产数据的多维时序性特征明显。

综上所述,智能车间生产执行过程中,物料按照工艺流程沿着不同工序和生产流程流转,海量数据在物料流转过程中实时产生,对应的数据采集点将海量车间数据按采集时序反馈到信息系统,不同工序的工艺指标和质量指标相互影响,车间参数的波动导致最

终车间生产质量的波动。通过对多维车间数据进行关联分析和挖掘,能够全面且准确地得到丰富的领域知识,实现车间大数据从局部到整体的全方位表达,进而支撑智能车间的运行状态分析、控制、决策和规划。

1.2 智能车间制造数据时序特征提取

针对车间数据的多维时序特性,本文通过时序聚类算法挖掘车间数据的时空相似模式,为实现车间数据间关联关系的精准挖掘奠定基础。首先借鉴图像特征提取思路^[11],引入一维高斯核函数和一维卷积运算,构建高斯差分金字塔,提取车间数据关键子序列;然后设计面向车间数据关键子序列的特征提取方法,建立时序聚类特征向量,通过相似度计算,实现智能车间跨流程、多工序制造数据时序聚类,支撑关联规则挖掘。

定义车间数据特征点附近的数据序列为关键子序列,涵盖了车间数据的代表性特征。对于时序数据 $S(t)$,本文利用逐层递减降采样的方式建立 k 组高斯差分金字塔,实现车间时序数据关键子序列的选择。引入一维卷积运算

$$y(n) = x(n) * h(n) = \sum_{i=0}^N x(i)h(n-i), \quad (1)$$

其中 $y(n)$ 表示两个长度为 n 的输入数据序列 $x(n)$ 与卷积核 $h(n)$ 的卷积运算结果。引入一维高斯核函数

$$G(x, \sigma) = \frac{1}{2\pi\sigma^2} e^{-(x^2)/\sigma^2}. \quad (2)$$

其中: x 为车间数据输入序列 $S(t)$ 中的点, σ 为方差。高斯金字塔第 k 组第 j 个一维卷积输出数据序列可通过下式求得:

$$I_k^j(x, \sigma) = G(x, kn^j\sigma) * S(t). \quad (3)$$

对高斯金字塔中组间相邻序列做差,构建高斯差分金字塔,采用密集提取的方式提取差分空间中的

特征点. 对于不同高斯差分空间中不同参数的序列 X_1, X_2, \dots, X_s , 若 x_i 是 X_{i-1}, X_i, X_{i+1} 三个序列中坐标为 $i-1, i, i+1$ 处共9个值的极值点, 则 x_i 为 X_i 的特征点, 放入集合 S_x 中. 特征集中的特征点坐标为 t , 且所有坐标的集合为 S_t , N 为特征长度, 构建车间数据关键子序列 KS, 即

$$KS = \{x_i | t - N/2 < i < t + N/2, t \in S_t\}. \quad (4)$$

如图2所示, A点为车间数据特征点, 可得到 DBACE 车间数据关键子序列, 将关键子序列内的数据划分为 DB、BA、AC、CE 四段, 各段计算均值、方差、坡度比值、cos 值和空间位置以反映数据的特征. 其中: 均值与方差揭示了数据的统计信息, 坡度比值表达了车间指标序列增长率的波动, 余弦值刻画了序列特征点两侧数据变化的情况, 空间位置描述了数据的空间特征, 最终得到车间时序数据的特征向量 F , 即

$$F = [m_{DB}, v_{DB}, s_{DB}, m_{BA}, v_{BA}, s_{BA}, \dots, m_{CE}, v_{CE}, S_{DB}/s_{BA}, S_{BA}/s_{AC}, S_{AC}/s_{CE}, \cos(BAC), \cos(DAE), SC_{DBACE}]. \quad (5)$$

其中: m_{DB} 为 DB 段序列的均值, v_{DB} 为方差, s_{DB} 为坡度, $\cos(BAC)$ 为 BAC 段序列的 cos 值, SC_{DBACE} 表示关键子序列所属工序, 以此类推.




图2 车间数据关键子序列的特征提取

特征向量的相似度蕴含了车间数据序列的时空相似模式, 本文采用欧氏距离计算车间时序数据的特征向量 F_i 与 F_j 间的距离 $d(F_i, F_j)$, 引入如下相似度计算公式, 快速计算车间数据间的聚类依据:

$$r_{ij} = \frac{1}{1 + d(F_i, F_j)}. \quad (6)$$

欧氏距离越小, 相似度 r_{ij} 越大. 在此基础上进行聚类分析, 将整个车间的指标依据特征划分为 k 个类, 通过特征聚类的方式打破智能车间数据的跨流程、多工序特性, 从而挖掘车间时空数据间有价值的时空关联模式.

1.3 智能车间制造数据动态波动关联分析

智能车间制造数据时序聚类将众多工艺指标按照时序特征聚成 k 个类, 而每个监测维度蕴含的指标变量众多, 变量间影响关系错综复杂. 在智能车间制

造数据时序聚类的基础上, 本文构建面向车间关联分析的数据转换规则, 实现多维度、多数据源、多时序的设备运行参数、状态参数和生产信息数据的有效统一与处理; 设计面向智能车间数据的关联分析算法, 挖掘各大类车间数据间的动态波动关联模式, 捕捉车间指标间的复杂影响规律.

车间指标波动规律是关联关系的时序表达, 针对车间生产多维度、多数据源、多时序的设备运行参数、状态参数和生产信息数据的多维多源异构特性, 本文设计以下数据转换规则: 对于某一指标数据, 通过 $[-1, 0, 1]$ 来表征数据的相对波动规律, 对于非浮动的衡增数据, 利用增量矩阵反映衡增数据的波动情况, 实现多维多源数据的统一.

针对车间不同工序之间数据的关联性、波动性和传递性, 本文引入关联规则挖掘算法发掘车间多流程、多环节生产数据间复杂影响规律. 车间指标 A 与指标 B 之间的关联规则可表示为 $A- > B$, 支持度 $s(A, B)$ 表示指标 A 和指标 B 同时变化的概率, 设 N 是包含指标 A 和 B 的事务数据库中事务的总数, 则支持度可由下式^[4]计算求得:

$$S(A, B) = \frac{\sigma(A \cup B)}{N}. \quad (7)$$

置信度 $C(A- > B)$ 表示当 A 发生波动的情况下, B 也发生波动的概率, 可通过下式^[4]求得:

$$C(A- > B) = \frac{\sigma(A \cup B)}{\sigma A}. \quad (8)$$

若聚类结果的第 u 个类包含 v 个指标, 形成集合 $U^v = \{u_1, u_2, \dots, u_v\}$, U^v 内任一指标 u_o 构成集合 $U^o = \{u_o\}$, 则 u_o 与其余指标的关联规则为 $u_o- > (U^v - U^o)$, 第 u 个类元素需进行 $v-1$ 次关联计算. 引入 $v \times w$ 的关联矩阵 A' 存储指标之间的波动情况, w 为时间序列长度, A' 内元素 a'_{ij} 为 u_i 指标对应的第 j 个时间点的数据转换结果.

针对车间时序关联挖掘, 定义关联矩阵 A' 的更新规则: 令 $i = n_i - k$, 其中 $i \in N^+$, 若同一时刻下, 矩阵 A' 中 i 个指标波动, 但 k 个指标未波动, 则波动指标的数据转换结果是非全为0的组合, 对这些指标进行过滤. 根据关联规则矩阵 A' 内的情况, 定义集合 $S^+(i)$ 为 i 个指标正相关的支持度集, 即判定 i 个指标波动规律相似的支持度集, 定义集合 $C^+(i)$ 为 i 个指标正相关的置信度集, 对式(7)和(8)进行更新, 有

$$S(i) = \begin{cases} \sum_{l=1}^j S^+(1), \\ \sum_{l=1}^k S^-(1); \end{cases} \quad (9)$$

$$C(i) = \begin{cases} \sum_{l=1}^j C^+(1), \\ \sum_{l=1}^k C^-(1). \end{cases} \quad (10)$$

其中 $j+k=i$. 集合中元素间关联关系的支持度与置信度越高, 对应指标间的影响关系越明显.

2 复杂时空域下多维度智能车间数据的关联网络建模

2.1 复杂时空域下智能车间数据的关联网络建模

在关联规则挖掘的基础上, 本文利用复杂网络理论描述并融合车间数据间的复杂关联, 通过对智能车间生产过程不同工序的加工运行、工艺参数、质量特征与最终产品质量指标之间的关联关系进行建模, 以网络的形式直观、全面地揭示智能车间的内在关联规律, 提高关联规则的易用性.

根据 1.3 节对车间数据关联规则挖掘的情况, 本文提出有向加权双权重网络模型 $G^1 = (N, E, W^1, W^2)$ 来描述车间数据间的关联规则. 将智能车间各个指标作为网络的节点, 对复杂网络进行映射, 则有 $N = \{n_i | i = 1, 2, \dots, n\}$, 其中 n 为车间指标个数. 对节点进行编码后, 进行关联规则的拆分, 构建一个 $n \times n$ 的邻接矩阵 GR^1 . 定义边集合为 $E = \{gr_{pq} | p, q \in (1, 2, \dots, n)\}$, 若指标 p 与 q 存在关联关系, 则 $gr_{pq} = 1$; 否则 $gr_{pq} = 0$. 有

$$GR^1 = \begin{bmatrix} 0 & gr_{12} & \dots & gr_{1n} \\ gr_{21} & 0 & \dots & gr_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ gr_{n1} & gr_{n2} & \dots & 0 \end{bmatrix}. \quad (11)$$

在构建节点与边的基础上, 建立双权重 W^1 和 W^2 来描述各个节点间的相互影响关系. 若节点 p 与

q 存在关联关系, 则它们存在相应的函数关系. 考虑到实际生产情况, 针对智能车间数据的分析与决策问题, 根据式 (10) 构建权重 $W^1 = \{w_{pq}^1 | p, q \in (1, 2, \dots, n)\}$ 反映节点之间关联规则的可信度, W^1 表征了指标间的时序关联, w_{pq}^1 越大, 指标 p 对指标 q 的可控度越高. 通过对 p 与 q 对应的数据序列进行多项式拟合^[12], 可快速得到相应的函数关系 $q = f(p)$, 对所得函数关系式进行编码, 构建权重 $W^2 = \{w_{pq}^2 | p, q \in (1, 2, \dots, n)\}$. 其中: w_{pq}^2 蕴含了 p 对 q 的控制方式, W^2 刻画了指标间的因果关联.

2.2 复杂时空域下多层智能车间数据的关联网络建模

2.1 节通过 $G^1 = (N, E, W^1, W^2)$ 描述车间数据间的关联规则, 利用双权重的方式刻画各指标间的复杂关联, 而车间生产具有强烈的周期性, 参数调整、生产波动体现为复杂网络在时间尺度上的变动. 针对车间关联规则的多维时序特性, 本节构建基于时间窗的多层网络, 融合相互依存网络理论, 设计与多层网络相互依存的工序网络, 实现智能车间多维时序生产数据关联关系的多尺度深度融合与精准描述.

复杂制造过程往往涉及多个生产周期, 针对车间生产的周期性, 引入时间变量 $t_i, i \in \{1, 2, \dots, k\}$, t_i 为第 i 个制造小周期, 可根据实际生产情况进行划分, 则 $T = \sum_{i=1}^k t_i$ 为制造大周期, 即车间从生产到结束的时间. 基于多层网络的思想, 引入时间窗对不同周期的车间复杂网络进行建模, 如图 3 所示. 更新 $G^1 = (N, E, W^1, W^2)$ 为 $G_{t_i}^1 = (N_{t_i}, E_{t_i}, W_{t_i}^1, W_{t_i}^2)$, 构建复杂时空域下多层智能车间数据的关联网络 $G_T^1 = \{G_{t_i}^1 | i = 1, 2, \dots, k\}$, 形成智能车间指标数据的多层关联网络, 从而揭示了智能车间关联规则的周期性规律.




图 3 基于时间窗的多层网络叠加

智能车间制造数据在不同的生产流程和环节中交互产生, 车间生产波动体现为复杂网络在时间尺度

上的变动. 为探究车间生产中的稳定关联, 支撑智能车间分析与决策, 对多时间窗复杂网络进行叠加^[13],

完成各个小周期网络内关联规则的融合. 定义模型 $G_T^1(V) = (N_T(V), E_T^1(V), W_T^1(V), W_T^2(V), e_T^1(V))$ 为车间关联叠加网络, 其中 $e_T^1(V)$ 为边叠加的计数, 反映了规则的稳定性以及系统的稳定性, 即某工艺指标与某质量指标在多周期融合下 $e_T^1(V)$ 的值越高, 该关联规则稳定性越强.

工艺指标关联网络 G_T^1 反映了多周期下各指标间的关联信息, 针对车间生产多工序跨流程特性, 为深入分析车间生产中工序间的关联, 本文基于 G_T^1 提出其相互依存工序网络 G_T^2 , 通过聚合低层次关联的方式对 G_T^1 进行抽象, 刻画工序间的关联关系. 定义 $G^2 = (N, W, E)$. 其中: N 为工序节点, E 为工序节点间连边, W 为工序节点间权重. 同样地, 引入时间变量 t_i , 则有 $G_{T_i}^2 = (N_T, W_T, E_T)$. 对 G_T^1 网络参数进行分析, 若两个工序间的指标存在关联, 则判定工序间存在关联, 而工序间的指标连边的数量构成了 W_T . 以 M_1 与 M_2 两个工序在 t_1 周期内的情况为例 (见图4), 构建相互依存网络 $G_T^* = (G_T^1, G_T^2, E_T^*)$, 其中 E_T^* 为某工序对应指标节点指向该节点的连边, 即层间边, 在图4中用虚线表示, 刻画了指标与工序间相互依存的关系.

在分析与决策过程中, 可根据实际需求, 利用 G_T 网络分析智能车间整体的运行情况; 通过 G_T^1 多层网络分析智能车间多工序、跨流程生产下多维车间指




图4 智能车间工序-指标相互依存网络

标时序数据间的关联关系, 通过 $G_{T_i}^1$ 精准辨识 t_i 周期内车间关键节点, 依据叠加网络 $G_T^1(V)$ 探讨全生产周期 T 内车间生产过程中稳定的关联规则, 支撑生产车间的分析与调控; 利用 G_T^2 网络表征车间各生产指标与工序间的相互依存关系, 描述智能车间多工序间的影响规律, 降低分析与决策的复杂度.

3 实例验证

为验证所提出方法的有效性, 采用 Python3.6 在基于 Xeon E5-2609V2 处理器和 RAM64G 的浪潮英信服务器上进行车间数据关联挖掘, 通过 Gephi0.9.7 实现智能车间数据的关联网络建模与分析. 以某制丝生产线为例进行方法验证, 该制丝生产线生产工艺过程包含 61 个工艺指标, 11 个质量指标. 本案例以该制丝生产线 112 587 条数据为样本进行方法验证, 车间参数指标及部分数据如图5所示. 对数据进行编号后, 依次基于统计特征、空间信息与形状信息进行特征提取, 提取各指标数据的关键特征点.

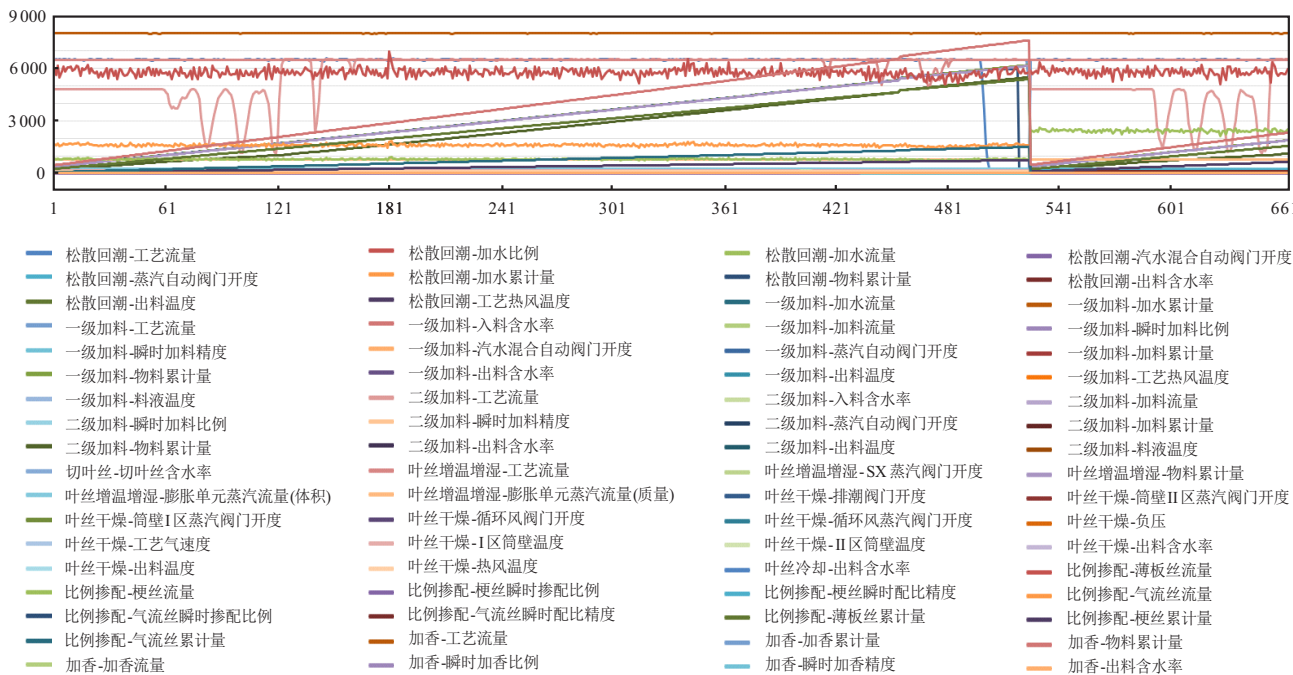


图5 部分实验数据

在制丝数据特征提取的基础上, 按照式(5)计算特征向量, 根据特征向量对工艺指标进行聚类分析,

再对所有指标数据按1.3节进行数据转换, 进而对每个类内的工艺指标及其对应的质量指标进行关联

规则挖掘,形成226条关联规则,部分关联规则如表1所示.根据式(11)构建邻接矩阵 GR^1 以存储各指标间的关联关系,支撑复杂网络模型中边的构建.基于邻接矩阵 GR^1 构建 E ,按2.1节进行权重计算,通过表1中的置信度构建 W^1 ,如图6所示.根据权重与关联规则矩阵构建制丝数据单层关联规则网络 $G^1 = (N, E, W^1, W^2)$,由于篇幅限制,对图内权重进行省略.

表1 部分关联规则

源节点	目标节点	置信度	支持度
松散回潮-工艺流量	松散回潮-加水累计量	0.61	正相关
一级加料-入料含水率	一级加料-出料含水率	0.65	正相关
一级加料-入料含水率	一级加料-出料温度	0.63	负相关
叶丝干燥-工艺气速度	叶丝干燥-出料含水率	0.51	负相关
叶丝干燥-负压	叶丝干燥-出料含水率	0.65	负相关
加香-工艺流量	加香-出料含水率	0.54	负相关

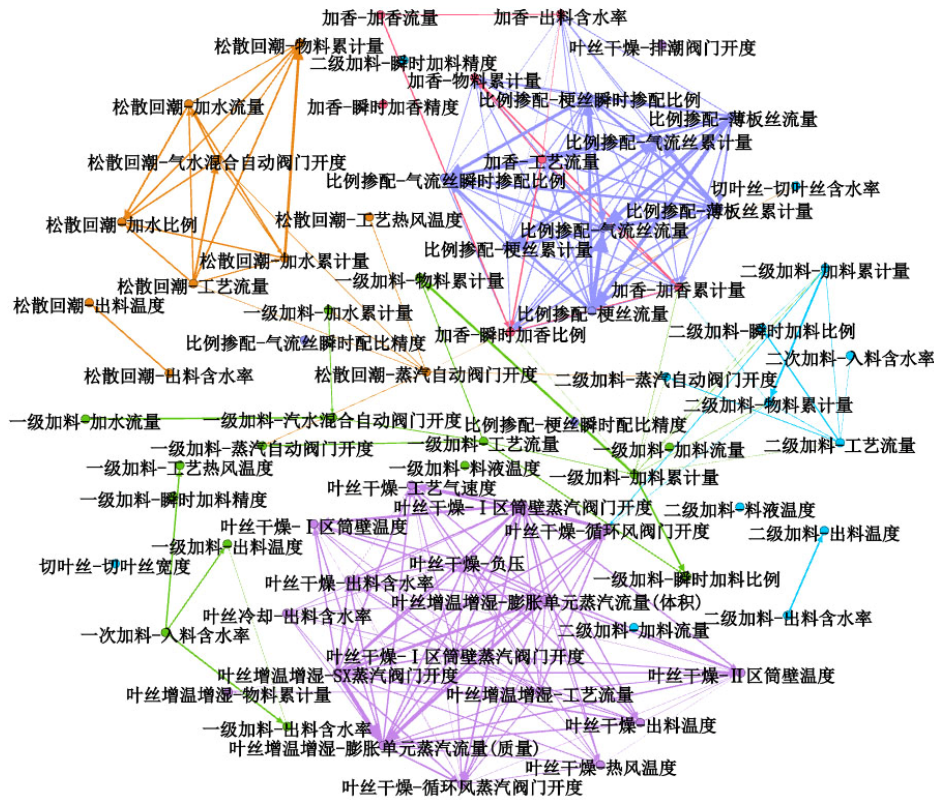


图6 基于制丝数据的单层关联网络

从整体上看,制丝数据单层关联规则网络具有明显的小世界^[14]特性,即相邻工序的车间指标间存在聚集现象,而不属于同一聚集区域的节点也存在关联影响,且这些节点在车间中的物理位置跨度较大.上述现象往往由网络中的重要节点所决定,为实现制丝数据单层关联规则网络内在知识的挖掘,以 G^1 网络为例,本文利用复杂网络理论经典参数对制丝数据单层关联规则网络进行分析.

1) 制丝关联网络度分布,某节点的度^[15]反映了与该节点相连的边的个数.在制丝数据单层关联规则网络中,“切叶丝-切叶丝宽度”等指标与网络内其余节点不存在关联影响,因此,这类不存在连边节点的度为0,属于非重要节点.

2) 制丝关联网络HITS, Authority值与指向该节点的边数量呈正相关, hub与指向该节点的边数量呈

正相关.在制丝数据单层关联规则网络中,“一级加料-工艺热风温度”等指标与网络内其余节点的关联较小,因此,这类连边较少的节点所对应的 Authority与hub值均为0,属于非重要节点.

3) 制丝关联网络重要度计算.针对不同应用对象,节点重要性有多种衡量方式.中介中心性^[15]以经过某个节点的最短路径数目来刻画节点的重要性,即制丝数据单层关联网络 G^1 中,节点间影响关系以某节点为核心的聚集现象较为明显,则该节点的中介中心性较大,中介中心性从整个网络节点间链路上体现了节点的重要性,记为全局重要性 IM_1 .特征向量中心性^[15]通过聚集邻居节点的度值来衡量节点的重要性,制丝数据单层关联网络 G^1 中,某个节点的度越大,越说明该节点为“小世界”的核心节点之一.特征向量中心性从节点局部连接上体现了节点的重要性,记

为局部重要性IM₂. 为消除量纲差异,对IM₁和IM₂进行归一化处理,制丝数据单层关联网络节点重要度计算公式如下所示:

$$IM^i = [Nomalize(IM_1^i) + Nomalize(IM_2^i)]/2, \quad (12)$$

其中Nomalize为归一化操作. 本文选取G¹网络中排序前10个节点为重要节点,利用Gephi软件对重要节点的一阶邻居节点进行渲染,形成如图7所示的重要节点影响力图.

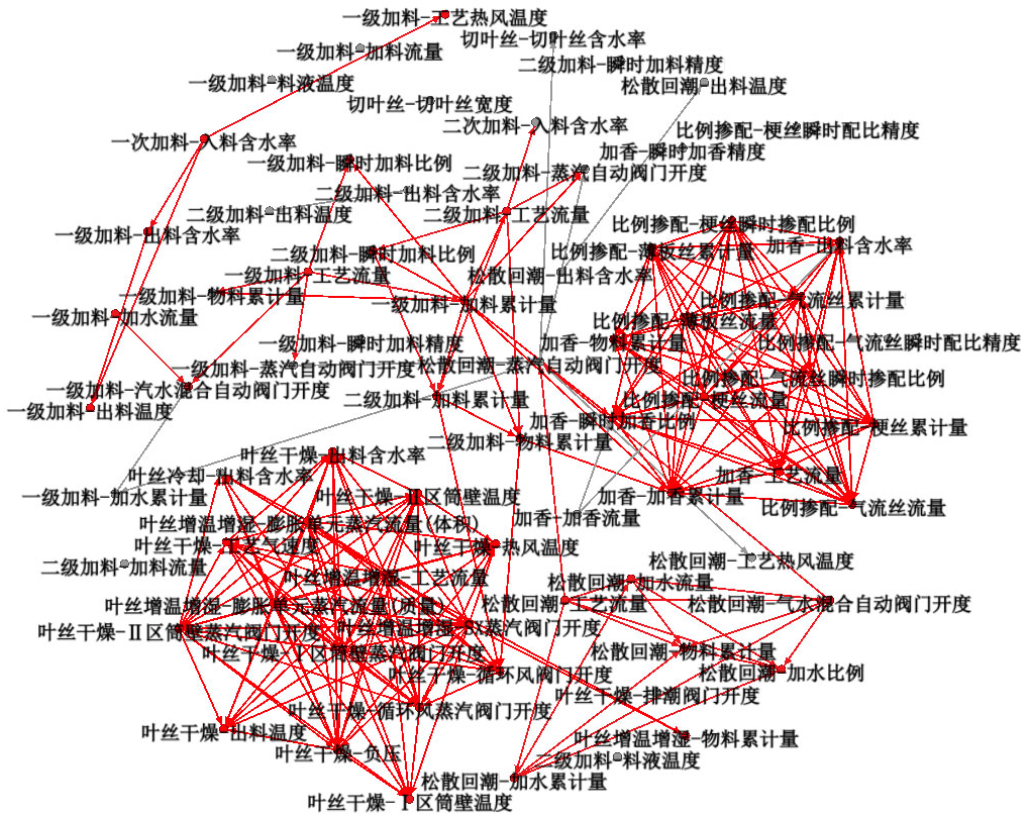


图7 重要节点影响力图

由图7可知,相邻重要节点间相互影响,重要节点的影响路径贯穿了制丝生产车间的全部工序,最终指向末端工序的质量指标“加香-出料含水率”。“叶丝冷却-出料含水率”等车间生产质量指标主要被其余节点所影响,在影响力图中属于被影响节点,从车间生产工艺角度看,这类节点是车间产品质量的表征,属于重要节点,但从车间生产调控的角度看,这类节点对其余节点影响力较小,因此,最终G¹网络中高影响力重要节点如表2所示.

由图7可知,表2所示节点作为G¹网络中的重要枢纽,决定了网络内节点的连接关系,从车间生产的角度看,保证高影响力重要节点在相关工艺范围有利于促进车间生产的稳定性,因此,定义表2所示的高影响力重要节点为车间调控与决策过程中的一级调控参数,通过调整一级调控参数可以支撑车间质量的直接调控. 由图6可知,对某个一级调控参数进行调整,可能会导致其余一级调控参数发生变化,进而对其他工序的生产造成连锁反应,因此,对车间一级调控参数进行调整属于车间生产的全局调控. 实际车

表2 高影响力重要节点

节点序号	节点名称
46	叶丝干燥-循环风阀门开度
47	叶丝干燥-循环风蒸汽阀门开度
67	加香-加香累计量
31	二级加料-加料累计量
32	二级加料-物料累计量
5	松散回潮-物料累计量
51	叶丝干燥-II区筒壁温度
17	一级加料-瞬时加料比例
54	叶丝干燥-出料温度
49	叶丝干燥-工艺气速度
66	加香-工艺流量
64	比例掺配-气流丝瞬时掺配比例

间生产中,车间质量波动源往往最先出现在某个故障工序,为降低调控行为对生产稳定性的影响,本文定义影响一级调控参数的指标为二级调控参数,通过故障工序内二级调控参数对一级调控参数进行微调,实现对质量参数的间接调整. 以一级调控参数“叶丝干燥-循环风阀门开度”节点为例,影响该节点的指标众

多,而“叶丝增温增湿-工艺流量”影响“叶丝干燥-循环风阀门开度”的权重 $w_{38,46}^1 = 0.661$,该关联规则的置信度相对较高,可采用 $w_{38,46}^2$ 对“叶丝干燥-循环风阀门开度”进行微调;同理,可对表2中其余高影响力重要节点进行调整,保证故障工序内加工质量的参数范围。

如图8所示,以半年作为制造小周期,全年为制造大周期,利用某制丝线下半年数据构建单层网络 $G_{t_2}^1$,设置叠加网络参数 $\max(e_T^1(V)) = 2$,综合 $G_{t_1}^1$ 与

$G_{t_2}^2$ 形成全年叠加网络 $G_T^1(v)$ 。根据2.2节构建制丝数据多层关联规则网络,由于篇幅限制,对图8内权重 W 进行省略,其中 G_T^2 与 $G_{t_1}^1$ 、 $G_{t_2}^1$ 、 $G_T^1(v)$ 为相互依存网络, $G_T^1(v)$ 为 $G_{t_1}^1$ 与 $G_{t_2}^1$ 的叠加网络,进而可分析出不同时间粒度下制丝生产的关键节点并支撑优化调控。为验证调控的有效性,在制丝车间质量指标出现超限趋势时,根据各层内的高影响力重要节点对某制丝生产线分别进行产线调控验证,制丝车间生产过程智能决策系统反馈结果如图9所示。

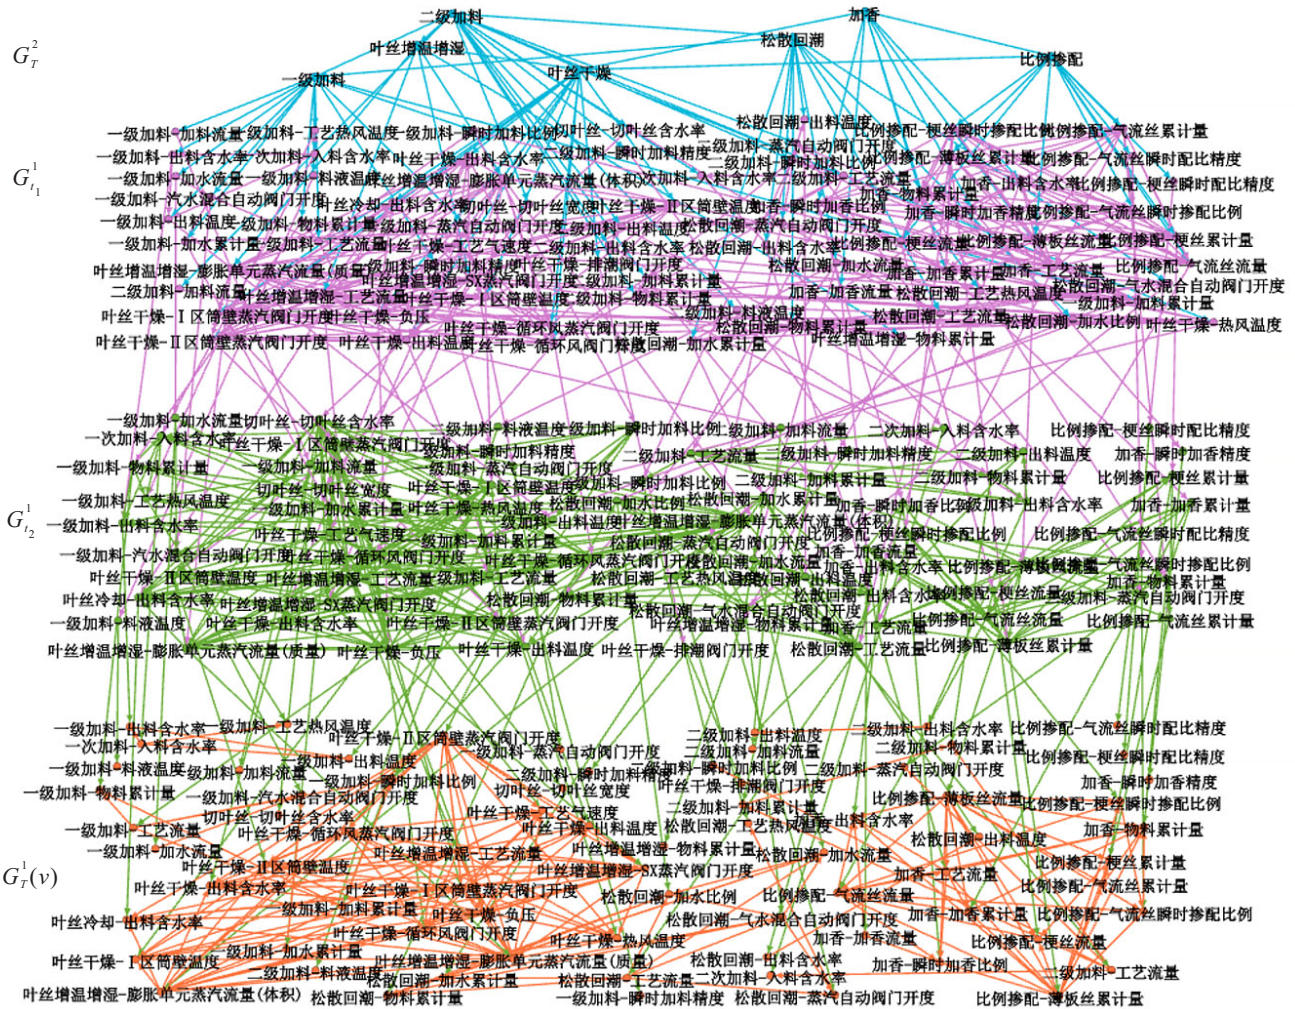


图8 基于制丝数据的多层复杂网络

制丝车间生产过程智能决策系统中,生产过程监控模块与在线数据库连接,对关键工艺参数进行实时监控,并通过工艺质量预测模块的算法对生产质量进行基于关联规则的预测,工艺质量预测算法的问题定义如下式所示:

$$X; Y' \xrightarrow{f(\cdot)} Y. \tag{13}$$

定义 $X \in R^{N \times S}$ 与 $Y' \in R^{M \times S}$ 为预测模型的时间序列输入,即将 S 个时间点的 N 个工艺参数数据与

M 个加工质量数据作为算法 $f(\cdot)$ 的输入,预测第 $S + 1$ 个时间点的加工质量数据 $Y \in R^{M \times 1}$ 。由图8所示的多层复杂网络图数据可知,影响“松散回潮-出料含水率”的一级调控参数为“松散回潮-物料累计量”,二级调控参数为松散回潮工序的“工艺流量”“工艺热风温度”“蒸汽自动阀门开度”和“加水流量”,则通过上述参数的时序数据对“松散回潮-出料含水率”进行预测;同理,可实现对“松散回潮-出料温度”的预测。

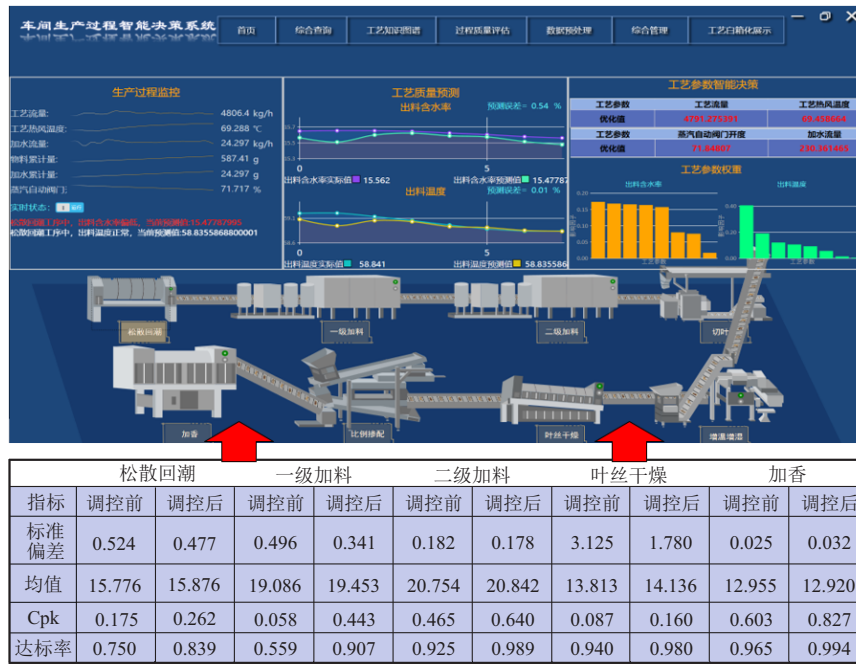


图9 基于制丝数据的多层复杂网络

如图9所示,当“松散回潮-出料含水率”工序工艺质量预测模块预测出质量指标参数值低于工艺范围时,生产过程监控模块实时预警,工艺参数智能决策模块将选取与质量指标相关的重要工艺参数进行优化调控,从权重集中挑选上述4个调控参数与“松散回潮-出料含水率”的相关权重进行依次调控。如图9所示,为评价调控的有效性,本文采用标准差^[16]、均值^[16]、Cpk^[16]和达标率对制丝车间120次调控结果进行评价,本文定义达标率为制丝过程质量达标数据占该指标总数据量的比率。由于切叶丝、增温增湿、比例掺配等工序涉及物料发酵和箱储等过程,实际生产过程不进行直接质量控制,本实验对120批次制丝生产过程中松散回潮、一级加料、二级加料、叶丝干燥和加香工序进行质量调控。采用本文方法进行级联调控后,制丝线多批次加工产品最终质量“加香-出料含水率”达标率平均值由96.5%提升到99.4%,从各工序加工质量的标准差、均值、Cpk等数据来看,产品生产过程质量的稳定性明显提高。

4 结论

针对车间数据多维多尺度关联融合问题,为支撑智能车间复杂生产模式下的分析与决策,本文提出了一种面向车间多工序、跨流程生产的多维数据关联网络建模方法,得出如下结论:

1) 本文所提出的智能车间制造数据的关联挖掘方法能有效挖掘复杂生产过程中各指标数据间的复杂关联关系;

2) 本文构建的复杂时空域下多维度智能车间数据的关联网络能全面刻画复杂生产过程中数据间的关联关系,以复杂网络的形式描述智能车间中多周期多维度下的关联规则,既实现了多制造周期下关联关系的融合,又实现了多流程、多环节生产数据间复杂影响规律的全面描述;

3) 通过实例验证了本文所提出的模型,结果表明本文方法能有效挖掘智能车间生产数据的内在规律,能够较好地支撑复杂生产模式下智能车间的分析与决策。

今后将进一步考虑调整优化多层网络模型的规模,研究相应的动态调整策略,使其更加高效准确地支撑多工序跨流程生产车间的分析决策问题。

参考文献(References)

[1] 张洁, 盛夏, 张朋, 等. 面向制造过程数据的两阶段无监督特征选择方法[J]. 机械工程学报, 2019, 55(17): 133-144.
(Zhang J, Sheng X, Zhang P, et al. Two-stage unsupervised feature selection method oriented to manufacturing procedural data[J]. Journal of Mechanical Engineering, 2019, 55(17): 133-144.)

[2] 左延红, 程桦, 张克仁. 基于分数阶偏微分的离散制造系统检测数据融合算法[J]. 计算机集成制造系统, 2015, 21(12): 3256-3262.
(Zuo Y H, Cheng H, Zhang K R. Fusion algorithm of discrete manufacturing system detection data based on fractional partial differential[J]. Computer Integrated

- Manufacturing Systems, 2015, 21(12): 3256-3262.)
- [3] Fang W G, Guo Y, Liao W H, et al. The spatio-temporal modeling and integration of manufacturing big data in job shop: An ontology-based approach[C]. IEEE the 7th International Conference on Industrial Engineering and Applications. Bangkok, 2020: 394-398.
- [4] 璩晶磊, 李少波, 陈金坤. 基于质量数据融合及规则挖掘的离散制造过程监控方法[J]. 计算机集成制造系统, 2017, 23(9): 1962-1971.
(Qu J L, Li S B, Chen J K. Process monitoring method in discrete manufacturing based on quality data fusion and rule mining[J]. Computer Integrated Manufacturing Systems, 2017, 23(9): 1962-1971.)
- [5] Yuan M H, Deng K, Chaovalitwongse W A, et al. Research on technologies and application of data mining for cloud manufacturing resource services[J]. The International Journal of Advanced Manufacturing Technology, 2018, 99(5): 1061-1075.
- [6] 高贵兵, 荣涛, 岳文辉. 基于复杂网络的制造系统脆弱性综合评估方法[J]. 计算机集成制造系统, 2018, 24(9): 2288-2296.
(Gao G B, Rong T, Yue W H. Vulnerability assessment method for manufacturing system based on complex network[J]. Computer Integrated Manufacturing Systems, 2018, 24(9): 2288-2296.)
- [7] Zhu F, Wang R G, Wang C. Intelligent workshop bottleneck prediction based on complex network[C]. 2019 IEEE International Conference on Mechatronics and Automation. Tianjin, 2019: 1682-1686.
- [8] Bonacina F, Miele E S, Corsini A. Time series clustering: A complex network-based approach for feature selection in multi-sensor data[J]. Modelling, 2020, 1(1): 1-21.
- [9] Funke T, Becker T. Complex networks of material flow in manufacturing and logistics: Modeling, analysis, and prediction using stochastic block models[J]. Journal of Manufacturing Systems, 2020, 56: 296-311.
- [10] Shi X Q, Long W, Li Y Y, et al. Research on the performance of multi-population genetic algorithms with different complex network structures[J]. Soft Computing, 2020, 24(17): 13441-13459.
- [11] Lowe D G. Distinctive image features from scale-invariant keypoints[J]. International Journal of Computer Vision, 2004, 60(2): 91-110.
- [12] Gao J H, Ji W X, Zhang L L, et al. Fast piecewise polynomial fitting of time-series data for streaming computing[J]. IEEE Access, 2020, 8: 43764-43775.
- [13] Wang D J, Yu W, Zou X F. Tensor-based mathematical framework and new centralities for temporal multilayer networks[J]. Information Sciences, 2020, 512: 563-580.
- [14] Watts D J, Strogatz S H. Collective dynamics of 'small-world' networks[J]. Nature, 1998, 393(6684): 440-442.
- [15] 陈超洋, 周勇, 池明, 等. 基于复杂网络理论的大电网脆弱性研究综述[J]. 控制与决策, 2022, 37(4): 782-798.
(Chen C Y, Zhou Y, Chi M, et al. Review of large power grid vulnerability based on complex network theory[J]. Control and Decision, 2022, 37(4): 782-798.)
- [16] 李明慧, 卢鹤. 尺寸公差的工艺能力指数评价方法[J]. 南京航空航天大学学报, 2012, 44(B04): 42-47.
(Li M H, Lu H. Process capability index of dimension tolerance evaluation[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2012, 44(B04): 42-47.)

作者简介

张万达(1997—), 男, 博士生, 从事工业大数据、知识图谱等研究, E-mail: zhangwanda1997@foxmail.com;

阴艳超(1977—), 女, 教授, 博士生导师, 从事智能制造、工业大数据等研究, E-mail: yinyc@163.com;

顾文娟(1985—), 女, 讲师, 硕士生导师, 博士, 从事工业工程及智能制造等研究, E-mail: guwenjuan001@163.com;

唐军(1984—), 男, 高级工程师, 博士, 从事加工工艺与装备、数据挖掘等研究, E-mail: juntang2013@163.com.