

DOI: 10.11830/ISSN.1000-5013.202409021



全景动态网络标志物的汽轮发电机 定子绕组热故障预警

曾思嘉, 方瑞明, 彭长青, 庄杰农, 尚荣艳

(华侨大学 信息科学与工程学院, 福建 厦门 361021)

摘要: 将汽轮发电机组的集散控制系统(DCS)的定子各槽出水口水温监测点映射为复杂网络中的节点,从而能够基于汽轮发电机 DCS 监测数据对定子绕组的热状态进行观测。根据 DCS 监测数据的时序特性,引入全景动态网络标志物(L-DNM)法计算网络中各节点的特异性皮尔逊相关系数,以构建不同采样时刻的特异性差分网络。量化网络中各节点的动态变化以进行故障预警,进而筛选出温度异常升高的关键节点,根据这些关键节点构建动态网络标志物(DNM)以识别故障位置。结果表明:文中方法能够实现对早期故障的预警和异常槽口位置的定位。

关键词: 汽轮发电机; 定子绕组; 热故障; 全景动态网络标志物; 故障检测; 故障定位

中图分类号: TM 311

文献标志码: A

文章编号: 1000-5013(2025)02-0201-08

Early Warning of Thermal Fault in Turbine Generator Stator Winding of Landscape Dynamic Network Marker

ZENG Sijia, FANG Ruiming, PENG Changqing,
ZHUANG Jienong, SHANG Rongyan

(College of Information Science and Engineering, Huaqiao University, Xiamen 361021, China)

Abstract: The outlet water temperature monitoring points for each stator slot in the steam turbine generator group distributed control system (DCS) are mapped to nodes in a complex network, the thermal state of the stator windings can be observed based on the steam turbine generator DCS monitoring data. Based on the time series characteristics of the DCS monitoring data, the landscape dynamic network marker (L-DNM) method is introduced to calculate the specific Pearson correlation coefficients of each node in the network to construct specific differential networks at different sampling times. The dynamic changes of each node in the network are quantified for the purpose of fault prediction. Subsequently, critical nodes with abnormal increasing temperature are identified to construct a dynamical network marker (DNM) for fault location identification. The results show that the proposed method can achieve early warning of faults and localization of abnormal slot positions.

Keywords: steam turbine generator; stator winding; thermal fault; landscape dynamic network marker; fault detection; fault localization

收稿日期: 2024-09-02

通信作者: 方瑞明(1972—),男,教授,博士,主要从事电气设备在线监测与故障诊断的研究。E-mail: fangrm@hqu.edu.cn。

基金项目: 国家自然科学基金资助项目(52477048);福建省高校产学研合作项目(2024H6009);福建省厦门市自然科学基金资助项目(3502Z202373952);福建省厦门市产学研项目(2023CXY0201)

水内冷系统异常造成的定子绕组热故障是大型汽轮发电机组的主要故障之一，为确保机组安全稳定工作，对定子绕组热故障预警的研究具有重要意义^[1]。由于无须安装额外的数据采集设备，基于发电机组的集散控制系统(DCS)数据的汽轮机组状态异常的检测方法具有显著的成本优势。近年来，基于DCS数据的汽轮机组的故障预警方法在发电机定子绕组热故障诊断领域应用较为广泛^[2-4]。Pietrzak等^[5]使用双谱分析结合卷积神经网络对定子绕组故障进行检测与分类，通过适当调整训练参数提高卷积神经网络模型的准确性并减少训练时间。Yang等^[6]提出了一种将滑动窗口法和自编码器-长短期记忆网络(SAE-LSTM)结合的预警方法，通过动态调整预警阈值改善预警精度和及时性。但上述方法往往忽略了汽轮发电机定子绕组热故障与DCS数据多状态信息之间的耦合性。此外，汽轮机组定子绕组热故障的故障标签数据也较为稀缺，难以满足基于人工智能的故障诊断方法对训练数据的需求。

为了解决这一问题，近年来将动态网络标志物(DNM)理论应用于复杂系统的状态临界转化^[7]，DNM能够描述带有噪声干扰的复杂多变量非线性系统在临界点附近动态特征，量化复杂系统状态临界转变可能性^[8-9]，对于及时检测类似于汽轮机组定子绕组热故障这种类型的问题具有很好的借鉴意义。金亮^[10]将DNM理论引入到汽轮发电机定子绕组热故障诊断之中，取得了较好的效果，为基于DCS数据驱动的汽轮机组热故障预警提供了一种新的思路，但该方法在确定动态网络关键节点时仍需借助于聚类算法，计算量较大，影响了预警的实时性。基于此，本文对全景动态网络标志物的汽轮发电机定子绕组热故障预警进行研究。

1 全景动态网络标志物方法

1.1 动态网络标志物

DNM是一种基于临界慢化(CSD)和分叉理论(BT)提出的，用于检测复杂系统在发生临界转变之前的早期预警信号的方法。对于多变量复杂非线性系统，当其接近临界状态时，由于集体动力学效应，系统中至少存在一组主导性变量，这些变量之间具有高度相关性，被称为系统的关键状态变量^[11-12]。当系统逐渐逼近临界状态时，系统的关键状态变量之间的相关性会显著增加，而其余状态变量之间的相关性则会减弱。

关键状态变量要满足以下3个条件^[13]。

- 1) 关键状态变量中每个变量的标准差(σ)显著增加。
- 2) 关键状态变量中每对变量的相关性(P_{in})增加。
- 3) 关键状态变量与其余状态变量的相关性(P_{out})降低。

依据上述条件，对DNM进行量化设定，即

$$I=\sigma \cdot \frac{P_{in}}{P_{out}+\epsilon} \tag{1}$$

式(1)中： I 为DNM的量化值； ϵ 为避免分母为0的小正常数。

在识别系统状态转变过程中，DNM通过最大的 I 或大幅增加的 I 检测系统状态转变的预警信号。DNM在复杂系统的早期预警研究中展现出了显著的优势，传统的数据驱动方法依赖特定的模型框架，导致其在应用范围上受到限制，难以在多样性和复杂性较高的系统中推广。同时，传统的数据驱动方法有效性往往也依赖大量高质量的训练样本，而获取足够的训练样本在实际应用中面临诸多困难，样本不足的问题可能会导致模型的泛化能力下降，难以满足故障诊断的需求。此外，传统数据驱动方法缺乏对系统动态特性的考虑，难以捕捉到系统在临界状态下的突变行为，而DNM基于网络拓扑结构和动态变化规律，不依赖于特定的模型，能够从时间序列数据中提取系统在临界转变前的关键特征，具有较强的普适性^[14]。同时，DNM能够通过识别关键状态变量间的集体动力学效应，减少对大量训练样本的依赖，提升对系统故障早期预警的准确性和可靠性^[15-16]。

1.2 全景动态网络标志物

在使用DNM确定系统的关键状态变量的过程中，DNM通常依赖于聚类算法或其他启发式程序进行筛选。这些方法尽管能够识别出系统的关键状态变量，但往往需要大量的计算资源和时间。因此，在实时性要求较高的场景中应用时，DNM实用性会受到较大的影响，而全景动态网络标志物(L-DNM)可

通过构建特异性差分网络,快速、高效、实时筛选关键状态变量,无需提前确定,大大降低计算成本的同时,又提高了时效性。

L-DNM 算法有如下 2 个步骤。

1) 特异性差分网络的构建。选取 n 组的 k 个参考样本($\text{Sample}[i,j], i=1,\cdots,n; j=1,\cdots,k$),构建 n 组参考样本数据的特异性差分网络(SDN)。为了获得每个 SDN 中的 L-DNM 模块,需要赋予网络中每个节点一个局部得分。

首先,使用节点 x 及其一阶邻域内所有的节点(SDN 中与节点 x 有边相连的节点构成节点 x 的一阶邻域)的差分表达偏差(D_{SDE})。

其次,计算节点 x 及其一阶邻域内所有的节点的平均特异性皮尔森相关系数(C_{in}),以及节点 x 的一阶邻域的节点和二阶邻域的节点之间的平均特异性皮尔森相关系数(C_{out})。

2) 计算特异性差分网络中每个节点的局部得分,并绘制三维景观图。基于 SDN 的节点 x 局部 DNM 得分($S(x)$)为

$$S(x)=D_{\text{SDE}}\cdot\frac{C_{\text{in}}}{C_{\text{out}}}。 \tag{2}$$

同理,对于 SDN 中的每个节点都可以得到相应的 $S(x)$,将 $S(x)$ 放入坐标轴中,得到一个 x 轴为参考样本编号、 y 轴为参考样本组的组号、 z 轴为 S 的三维景观图。将三维景观图中各个网络中各节点的得分情况作为检测即将到来的临界状态的特定标识符,某一个或几个节点其 $S(x)$ 的快速上升标志着临界状态的出现。

L-DNM 算法示意图,如图 1 所示。

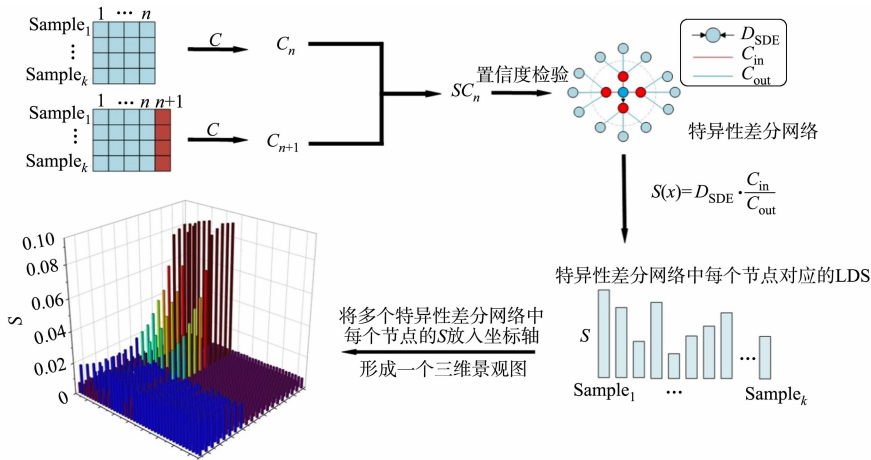


图 1 L-DNM 算法示意图

Fig. 1 Sketch diagram of L-DNM algorithm

2 基于 L-DNM 故障预警方法

作为发电机定子结构的重要组成部分,汽轮发电机的定子绕组是常见故障的主要部分。发电机定子绕组故障按故障类型包含了电气故障、机械故障和冷却系统故障。其中,电气故障造成的绝缘损坏及冷却系统水内冷出现异常都会造成发电机定子绕组热故障。据不完全统计,近年来,全国含有的 100 MW 及以上发电机中,定子绕组热故障的次数占发电机故障的 60% 以上。为此,使用 L-DNM 对汽轮发电机定子绕组热故障进行及时预警。

根据节 1.2 中介绍的方法即可利用发电机自身 DCS 系统中对于发电机定子绕组各槽出水口的温度监测节点,建立可反映发电机定子绕组温升变化情况的复杂网络。通过量化网络中各个节点的动态变化对故障进行预警,并筛选出温度异常升高的关键节点,构建基于关键节点的动态网络标志物对故障位置进行辨识。

基于 L-DNM 的汽轮发电机定子绕组热故障预警具体有如下 8 个步骤。

1) 选取连续的 k 个采样时刻的实时 DCS 监测数据,将其中第 $i+1\sim n+i$ 个采样时刻的监测数据作为参考变量组,其中, n 表示参考变量组中所包含的采样时刻的总数。

2) 初始状态令 $i=0$, i 作为后续检测流程完成的标志,计算参考变量组内各个变量间的 C_n ,再加入第 $n+i+1$ 个采样时刻的监测数据,计算新变量组内各个变量间的 C_{n+1} ,将 C_{n+1} 减去 C_n 得到 SC_n ,即

$$C_n(x,y)=\frac{\sum_{i=1}^n(x_{i+1}-\bar{x})(y_{i+1}-\bar{y})}{\sqrt{\sum_{i=1}^n(x_i-\bar{x})^2\sum_{i=1}^n(y_i-\bar{y})^2}},\tag{3}$$

$$SC_n(x,y)=C_{n+1}(x,y)-C_n(x,y).\tag{4}$$

式(3),(4)中: x_{i+1} 和 y_{i+1} 为参考样本组中 x 和 y ; \bar{x} 和 \bar{y} 分别为 x 和 y 在参考样本组中的均值。

3) 使用置信度检验法对每一个 SC 进行检验,保留置信度水平高于 0.95 的 SC (两个变量存在边),有边相连的样本构成即为某个样本的一阶邻域,与一阶邻域内的样本有边相连的样本的为二阶邻域,建立该采样时刻下的 SDN。

4) 根据相关公式计算该采样时刻下的 SDN 的各个节点的 D_{SDE} 、 C_{in} 、 C_{out} ,进而得到各个节点在对应采样时刻下的 S ,即

$$D_{SDE}=\frac{1}{1+n_x}\left(\frac{\sigma_x}{\mu_x}+\sum_{y\in N_x}\frac{\sigma_y}{\mu_y}\right),\tag{5}$$

$$C_{in}=\frac{1}{n_x}\sum_{y\in N_x}|sC_n(x,y)|,\tag{6}$$

$$C_{out}=\frac{1}{n_xm_{xx'}}\sum_{x'\in N_x,y'\in M_x}|sC_n(x',y')|.\tag{7}$$

式(5)~(7)中: N_x 为特异性差分网络中与节点 x 有边相连的节点构成的一阶邻域; n_x 为一阶邻域中节点的个数; σ_x 为节点 x 的标准差; μ_x 为节点 x 的平均值; σ_y 为节点 x 的一阶邻域中的节点 y 的标准差; μ_y 为节点 y 的平均值; M_x 为特异性差分网络中与节点 x 的一阶邻域中节点有边相连的节点构成的二阶邻域; m_x 表示二阶邻域中节点的个数; x' 为一阶邻域中的节点 x' ; y' 为一阶邻域中的节点 y' 。

5) 判断 $n+i+1$ 是否等于 k ,若不满足,令 $i=i+1$,返回步骤 2),继续得到不同采样时刻下的 SDN 内各节点的 S ;若满足,则进入步骤 6);

6) 计算各采样时刻内各变量的 S 的标准差,即

$$\sigma_{S_{i+1}}=\sqrt{\frac{\sum[S_i(j)-\mu_{S_i}]^2}{L}}.\tag{8}$$

式(8)中: $\sigma_{S_{i+1}}$ 为除去参考变量组的第 $1\sim n+1$ 个采样时刻后,剩余的第 i 个采样时刻的各节点的 S 的标准差; L 为第 i 个采样时刻的特异性差分网络中的节点个数; $S_i(j)$ 为 k 个采样时刻中除去变量组的第 $1\sim n+1$ 个采样时刻后,剩余的第 i 个采样时刻的第 j 个节点的 S , $j=1,2,3,\cdots,L$; μ_{S_i} 为除去作为参考变量组的第 $1\sim n+1$ 个采样时刻后,剩余第 i 个采样时刻的各节点的 S 的平均值。

7) 以两个相邻采样时刻构成一个采样时间组,在该组中计算两个相邻采样时刻的 $\sigma_{S_{i+1}}$ 的偏差 a ,其中, $a=\frac{|\sigma_{S_{i+1}}-\sigma_{S_i}|}{\sigma_{S_i}}$ 。

8) 若 $a\leq 0.05$,表明各槽 S 处于相对平稳的状态,判断发电机处于正常运行状态;若 $a>0.05$,表明某一个或多个槽的 S 突然上升,说明出水口温度出现了异常变化,发电机到达临界状态,此时生成预警信号,确定三维景观图中 S 发生突然上升的槽口为检修的关键节点,结合检修结果确定局部得分发生突然上升的槽口是否为所述故障位置。

3 实例分析

为了验证提出的方法能够实现对定子绕组热故障的早期预警和异常槽口位置的定位,案例采用某发电机 3 号机组 DCS 采集的 2020 年度监测数据进行验证,型号为 QFSN-1000-2-27,冷却方式为水氢

氢,即定子绕组水内冷。DCS 每 10 min 进行一次采样。

3.1 正常运行情况分析

对汽轮发电机处于正常运行状态时的 DCS 历史监测数据进行分析,选取 2020 年 7 月 18 日—7 月 22 日的定子冷却出水口温度数据进行测试,任意选取一个时刻,分别向前、后截取 29,20 个采样时刻数据。正常样本各采样时刻的 σ_s 和各采样时间组的偏差 a ,如图 2 所示。




图 2 正常样本各采样时刻的 σ_s 和各采样时间组的偏差 a

Fig. 2 σ_s at each sampling time and deviation a at each sampling time group of normal sample

由图 2 可知:正常样本中各采样时间组的 a 均小于 0.05,而且各采样时刻的 σ_s 差异较小。正常样本三维景观图,如图 3 所示。




图 3 正常样本三维景观图

Fig. 3 Three-dimensional landscape map of normal sample

由图 3 可知:在正常情况下,42 个定子冷却出水口温度的 S 均处于 $2.5 \times 10^{-3} \sim 7.0 \times 10^{-3}$ 的范围内,没有出现某一个或几个定子槽出水口温度的 S 明显高于其他定子槽出水口温度,说明无异常情况,符合检修记录。

3.2 故障情况分析

采用汽轮发电机处于故障状态时的 DCS 历史监测数据进行分析,选取 11 月 10 日—14 日的定子冷却出水口温度数据进行测试,根据系统报警时刻,分别向前、后截取 29、20 个采样时刻数据,故障样本各采样时刻的 σ_s 和各采样时间组的偏差 a ,如图 4 所示。

由图 4 可知: a 大于 0.05 的采样时间组是第 9 组,采样时刻 90、100 内的 σ_s 差异较大,采样时刻 100 内某一个或多个槽的 S 突然上升。

故障样本三维景观图,如图 5 所示。单槽故障样本不同采样时刻各槽口的 S ,如图 6 所示。

由图 6 可知: S 可以分为 3 类,第 1 类为正常状态,42 个槽口的 S 基本稳定在 $5 \times 10^{-3} \sim 25 \times 10^{-3}$ 的范围内;第 2 类为临界状态,5、10、18 号定子槽出水口温度的 S 变化为所有数值中最高位,且远大于其他 41 个槽口;第 3 类为故障状态,42 个槽口的 S 基本稳定在 $2 \times 10^{-3} \sim 3 \times 10^{-3}$ 的范围内;各槽口的




图 4 故障样本各采样时刻的 σ_s 和和各采样时间组的偏差 a

Fig. 4 σ_s at each sampling time and deviation a at each sampling time group of fault sample





图 5 故障样本三维景观图


Fig. 5 Three-dimensional landscape diagram of fault sample

S 在第 10 个采样时刻发生突变,一直持续到第 32 个采样时刻,42 个槽口的 S 重新恢复稳定;图 6(b)发出的预警信号比图 6(d)提前了 210 min。


正常样本下,L-DNM 检测结果为正常,DNM 检测结果为未见异常,检修结果为未见异常;故障样本下,L-DNM检测结果为故障,在采样时刻 9 发出预警,DNM 检测结果为在采样时刻 20 发出预警,检修结果为在 5、10、18 号槽口出现异常。因此,在故障样本中,L-DNM 比传统 DNM 提前发出预警,同时,传统 DNM 的有效性往往取决于输入特征量的筛选的准备,而 L-DNM 可事



(a) 正常状态下



(b) 由正常状态转变到临界状态



(c) 临界状态下




图 6 单槽故障样本不同采样时刻各槽口的 S

Fig. 6 S at each slot outlet of fault sample at different sampling time

先对 DNM 成员进行选择, 无需使用以往研究中的常用的聚类算法或者其他启发式程序。

以上实例分析结果表明, 以两个相邻采样时刻构成一个采样时间组, 计算两个相邻采样时刻的标准差 α , 当发电机从正常状态进入临界状态时, 该采样时间组内 α 与对应采样时间点的故障定子绕组槽口温度 S 会发生变化。当 $\alpha \leq 0.05$, 各槽口的 S 处于相对平稳的状态, 判断发电机处于正常运行状态; 若 $\alpha > 0.05$, 某一个或多个槽口的 S 突然上升, 说明某一个或多个槽口的出水口温度出现了异常变化, 发电机到达临界状态, 发生变化的槽口即为关键变量, 而发生变化的采样时刻表示发电机在该时间由正常状态转化为临界状态, 此时发出预警信号; 由临界状态转换至故障状态后, 各槽口的 S 重新回到相对平稳的状态。建立的基于 L-DNM 的汽轮发电机定子绕组热故障预警模型能够在故障出现前发出预警信号, 对运行状态变化的临界进行定时定点的检测, 验证了其具有一定的工程实用价值。

4 结论

鉴于目前汽轮发电机定子绕组热故障诊断存在的风险和挑战, 提出一种基于机组定子各槽出水口 DCS 监测水温时序数据的定子绕组热故障预警方法, 只需使用各槽口水温监测数据构建特异性差分网络, 无需建立特定模型。通过评估各个采样时刻的特异性差分网络中各节点的偏差和相关性, 计算各节点的局部得分, 根据各节点的局部得分的动态变化进行故障预警, 并根据绘制的三维景观图进一步确定故障位置。

1) 基于动态网络标志物理论, 仅使用少量数据构建特异性差分网络就可以在汽轮发电机定子绕组热故障发生之前及时识别出临界点。

2) 采用三维景观图中各个节点的 S 可视化地筛选 DNM 成员, 计算成本低、时效性较好。

3) 文中方法属于一种免模型预警方法, 仅需采用机组自身 DCS 数据即可实现缺陷临界状态的提前预测。然而, 文中方法仅验证了在连续的时序监测数据中具有良好的预警效果, 当数据由于某些原因出现缺失而导致不连续时, 文中方法是否同样能够准确地对故障进行预警是今后需要继续研究的工作。

参考文献:

[1] 赵洪森, 戈宝军, 陶大军, 等. 大型核电汽轮发电机定子内部短路故障时局部电磁力分布研究[J]. 电工技术学报, 2018, 33(7): 1497-1507. DOI: 10.19595/j.cnki.1000-6753.tces.170163.

[2] 孙磊. 大型发电机组定子水路堵塞故障分析[J]. 中国高新技术企业, 2016(22): 55-57. DOI: 10.13535/j.cnki.11-4406/n.2016.22.027.

[3] FANG Ruiming, LIU Zilin, PENG Changqing, et al. Fault diagnosis of inter-turn short circuit in turbogenerator rotor windings based on vibration-current signal fusion[J]. Energy Reports, 2023, 9: 316-323. DOI: 10.1016/j.egy.2023.03.019.

[4] LI Xingshuo, LIU Jinfu, BAI Mingliang, et al. An LSTM based method for stage performance degradation early warning with consideration of time-series information[J]. Energy, 2021, 226: 120398. DOI: 10.1016/j.energy.2021.120398.

[5] PIETRZAK P,WOLKIEWICZ M,ORLOWSKA-KOWALSKA T. PMSM stator winding fault detection and classification based on bispectrum analysis and convolutional neural network[J]. IEEE Transactions on Industrial Electronics,2022,70(5):5192-5202. DOI:10.1109/TIE.2022.3189076.

[6] YANG Yulei,ZHANG Shuming,SU Kaisen,*et al.* Early warning of stator winding overheating fault of water-cooled turbogenerator based on SAE-LSTM and sliding window method[J]. Energy Reports,2023,9:199-207. DOI:10.1016/j.egy.2023.02.076.

[7] CHEN Luonan,LIU Rui,LIU Zhiping,*et al.* Detecting early-warning signals for sudden deterioration of complex diseases by dynamical network biomarkers[J]. Scientific Reports,2012,2(1):342. DOI:10.1038/srep00342.

[8] FANG Ruiming,WU Minling,SHANG Rongyan,*et al.* Identifying early defects of wind turbine based on SCADA data and dynamical network marker[J]. Renewable Energy,2020,154:625-635. DOI:10.1016/j.renene.2020.03.036.

[9] 张燕,方瑞明. 基于油中溶解气体动态网络标志物模型的变压器缺陷预警与辨识[J]. 电工技术学报,2020,35(9):2032-2041. DOI:10.19595/j.cnki.1000-6753.tces.190295.

[10] 金亮. 基于 DCS 的发电机定子绕组热故障诊断研究[D]. 厦门: 华侨大学,2021.

[11] ORMAN G K,TÜRE N,BALCISOY S,*et al.* Finding proper time intervals for dynamic network extraction[J]. Journal of Statistical Mechanics: Theory and Experiment,2021,2021(3):033414. DOI 10.1088/1742-5468/abed45.

[12] MATSUMORI T,SAKAI H,AIHARA K. Early-warning signals using dynamical network markers selected by covariance[J]. Physical Review E,2019,100(5):052303. DOI:10.1103/PhysRevE.100.052303.

[13] CHEN Pei,CHEN E,CHEN Luonan,*et al.* Detecting early-warning signals of influenza outbreak based on dynamic network marker[J]. Journal of Cellular and Molecular Medicine,2019,23(1):395-404. DOI:10.1111/jcmm.13943.

[14] KAMAL M A S,OKU M,HAYAKAWA T,*et al.* Early detection of a traffic flow breakdown in the freeway based on dynamical network markers[J]. International Journal of Intelligent Transportation Systems Research,2020,18:422-435. DOI:10.1007/s13177-019-00199-1.

[15] YANG Kun,XIE Jialiu,XIE Rong,*et al.* Real-time forecast of influenza outbreak using dynamic network marker based on minimum spanning tree[J]. BioMed Research International,2020,2020(1):7351398. DOI:10.1155/2020/7351398.

[16] HUANG Xiaoqi,HAN Chongyin,ZHONG Jiayuan,*et al.* Low expression of the dynamic network markers FOS/JUN in pre-deteriorated epithelial cells is associated with the progression of colorectal adenoma to carcinoma[J]. Journal of Translational Medicine,2023,21(1):45. DOI:10.1186/s12967-023-03890-5.

(责任编辑: 陈志贤 英文审校: 吴跃勤)