

数据驱动的高速铁路强风报警自适应解除策略

刘昊侯¹ 贺诗波¹ 陈积明¹

摘 要 高速铁路在中国发展迅速,带来了全新的交通变革.较快的运行速度在带来效率提升的同时也增加了沿线强风对其运行安全的威胁.为了安全运行,铁路沿线部署了大量风速监测传感器,一旦监测到强风,将通过调度中心发出信号,调度沿线列车减速慢行甚至停车.在报警过程中,如何确定报警保持时间极具挑战.如果保持过短,则可能发生重复报警,增加处置次数,加重工作人员负担;若取消过晚,则影响轨道通过能力,带来不必要的效率损失.为此,本文提出一种高速铁路强风报警解除时间调整策略,用于改善这一问题.该策略通过轨道沿线部署的风速计装置,结合时空信息对短时未来强风情况进行预测,基于预测情况,自适应调整报警解除时间.该策略能够有效减少报警冗余时长,提高列车运行效率.

关键词 高速铁路, 风速监测, 强风报警, 报警解除时间

引用格式 刘昊侯, 贺诗波, 陈积明. 数据驱动的高速铁路强风报警自适应解除策略. 自动化学报, 2019, 45(12): 2242–2250

DOI 10.16383/j.aas.c190227

Data-driven Adaptive Adjustment Strategy for Strong Wind Alarm in High-speed Railway

LIU Hao-Yu¹ HE Shi-Bo¹ CHEN Ji-Ming¹

Abstract The rapid development of high-speed railways in China has changed the way people travel. The faster speed induces a growing threat of strong wind on safety. A large number of anemometers have been deployed alongside the railway for monitoring the strong wind. Dispatchers in the dispatch centers issue the scheduling instructions to the train drivers according to the measured wind speed. It is not trivial for the dispatchers to decide when to stop an alarm. If the alarm lasts too short, repeated alarms may occur, increasing the number of treatments and the burden on the staff. If it is stopped too late, track passing capacity will be affected and unnecessary efficiency loss may be caused. In this paper, an adjustment strategy for the stop time of high-speed railway alarm based on wind speed prediction is proposed to solve this emerged challenge. The strategy can effectively reduce the alarm redundancy time and improve operational efficiency.

Key words High-speed railway, wind speed prediction, strong wind prediction, alarm duration adjustment

Citation Liu Hao-Yu, He Shi-Bo, Chen Ji-Ming. Data-driven adaptive adjustment strategy for strong wind alarm in high-speed railway. *Acta Automatica Sinica*, 2019, 45(12): 2242–2250

高速铁路作为国民经济的重要推力,近年来发展迅速.截止 2018 年,中国高铁运营总里程已达到 2.9 万公里,全年发送旅客量占铁路总发送量的 60.4%.尽管高速铁路已经采取了非常充分的安全防范措施,但是由于列车行驶速度较快,运行过程气动升力较大,因而环境中的风速对高速列车造成的影响仍然较大,直接威胁列车正常运行.历史上曾发生过多起强风环境下铁路列车出轨事件,譬如 2005 年日本“稻穗 14 号”的脱轨倾覆,造成了严重的经济损失及人员伤亡^[1].因此,在高速列车速度越来越

快的今天,对风况的实时监测以及基于风况的及时调整显得愈发重要.

为了适应复杂多变的环境,保证列车的安全运行,我国高速铁路建造过程中,在轨道沿线部署了大量风速监测传感器,建造了风速监测及强风报警系统^[2].当检测到强风时,调度指挥中心的调度人员通过防灾系统报警指示,严格按照规定通报各有关列车进行减速或禁行操作.这种方式大大提高了列车安全运行保障,但同时也投入了较多人力来进行报警处置,对列车运行效率也会造成影响.除此之外,由于风速的难预测性,当强风报警发生时,报警解除时间如何确定成了新的挑战.由于报警处置的繁琐及处置过程中减速及禁行操作对列车正常运行的影响,对于报警解除时间的确定往往需要一定权衡.一方面,若报警时间保持太短,虽然列车能够较快恢复到正常运行状态,但是若在同一地点短时间内重复刮起强风,出现重复报警,则需要所有相关人员再次

收稿日期 2019-03-21 录用日期 2019-06-02

Manuscript received March 21, 2019; accepted June 2, 2019

国家自然科学基金(61790571)资助

Supported by National Natural Science Foundation of China (61790571)

本文责任编辑 董海荣

Recommended by Associate Editor DONG Hai Rong

1. 浙江大学工业控制技术国家重点实验室 杭州 310027

1. State Key Laboratory of Industrial Control Technology, Zhejiang University, Hangzhou 310027

完成处置流程。另一方面,报警时间若保持太长,虽然有效降低了重复处置次数,但列车运行效率显然会受到较大影响,导致铁路区间通过能力下降。因此,如何解决报警停止时间问题,对于进一步优化强风报警系统以及提高高速铁路整体运行效率有着重要意义。

本文在现有研究的基础上,通过充分利用安装于高铁沿线的风速传感器所包含的时间空间信息,提出了一个新颖的依靠风速预测的风速报警解除时间调整方案,并最终在实际数据上进行了实验验证。本文的主要贡献总结如下:

1) 充分利用已部署的风速传感器,首次提出基于时空注意力循环神经网络的风速预测方案,在短时预测上达到了较高准确度。

2) 在风速预测基础上,提出了以多步预测为基础的强风判断方案,实现了强风预测。

3) 提出了基于强风预测的高速铁路风速报警解除时间调整策略,最多可减少 10 分钟的冗余报警时长。相关结果通过实验得到了验证。

本文结构为:第 1 节介绍了高速铁路强风报警解除问题及风速预测的相关工作;第 2 节展示了设计的模型和方法,并对相关技术进行了说明;第 3 节进行了实验验证,说明了方案的有效性;第 4 节对本文工作进行了总结,并明确了下阶段的研究方向。

1 相关工作

铁路列车的防风减灾工作已具有一定的现实基础,对风速的研究历史则更长。本节将对高速铁路风速报警及报警解除现状、风速预测现状及相关预测方法进行整理总结。

1.1 高速铁路强风报警解除时间

为了应对高速铁路运行环境变化多样带来的负面影响,我国已在铁路沿线部署了大量传感器,用于对周边环境的实时感知,其中包含了对风速的监测。为了防止强风导致列车脱轨甚至倾覆,基于风速的限制,对于高速铁路运行速度已经制定并出台了如表 1 所示的操作规定。

表 1 高速铁路不同风速下行驶速度规定

Table 1 Speed constraints for the high-speed train at different wind speeds

风速 (m/s)	列车运行规定 (km/h)
15 ~ 20	限速 300
20 ~ 25	限速 200
25 ~ 30	限速 120
> 30	禁止通行

为了能够在强风报警处置次数较少的情况下让报警总时长尽可能短,文献 [3] 基于历史报警数据,提出了大风报警影响时长增长率与调度员报警处置次数减少率比值量化分析方法,对不同线路大风报警解除时间进行优化调整,并将京沪线的报警保持时长设定为 10 分钟。该方法虽然基于长时间的数据统计结果,然而,影响局部风速情况的因素众多,过去长期的历史数据作为参考样本虽然有着很高价值,但间隔时间较长时,不一定能够很好地表示当前情况。而另一方面,对于同一条线路的各个区段,该方法并没有独立分析建模,因而总体上存在较大优化空间。

日本作为高速铁路的先发国家,地处海岛多风地区,对于报警解除时限也有着大量研究。东日本旅客铁路公司目前对于强风报警解除时间问题设定了两种规定,其一是当实际风速低于限速值 30 分钟后解除,另一种规定是,当前实测风速和当前预测的最大风速均低于限制值时解除报警。在实际运行测试过程中,第二种方案相较于第一种方案,缩减了约 30% 的列车限速时间和驾驶中止时间^[1]。在本文中,我们借鉴该报警解除时间方案,对短时未来风速进行准确预测,动态调整报警解除时限,实现处置次数及报警总时长两个值均尽可能小。

1.2 风速预测

风速预测相关研究工作普遍集中于新能源发电领域。为了能够更精准地实现预测,研究者已经发展出多类型的预测模型。物理预测方法是基于自然规律以及相关数学模型进行的风速预测方法,在其模型中考虑了土地状况、障碍物情况以及气压、温度等环境变量,综合对环境各类信息的准确感知,结合 NWP (Numerical weather prediction) 对气象变化的预测,最终得到风速及风向的预测信息。文献 [4] 将物理方法用于风电站的风速预测,文献 [5] 结合天气信息实现了提前 2.5 分钟的超短时风速预测并用于对风电产能的估计,文献 [6] 通过结合一个自适应神经模糊系统提高了短时预测的准确度。此类物理模型通常可以较准确地描述风速的变化规律,但是需要对环境进行充分感知,导致感知成本高昂。另外该模型局限也较大,不同地域需重新建模^[7],对于只含有初步风速监测传感器件的高速铁路场景并不完全适用。

基于统计模型的方法广泛应用于各类时间序列建模中,同样也被应用于风速建模^[8]。经典的时间序列模型包括有自回归 (Auto regression, AR) 模型、移动平均 (Moving average, MA) 模型、自回归滑动平均 (Autoregressive moving average, ARMA) 模型和差分整合移动平均自回归 (Autoregressive in-

tegrated moving average, ARIMA) 模型. 将一个随机时间序列定义为如下的 ARMA 模型

$$x_t = \sum_{i=1}^n \phi_i x_{t-i} + \alpha_t - \sum_{j=1}^m \theta_j \alpha_{t-j} \quad (1)$$

其中, ϕ_i 为自回归系数, θ_j 为移动平均系数, α_t 为白噪声, x_t 是时间序列在 t 时刻的值. 当 n 为 0 时, 式 (1) 成为典型的 MA 模型, 当 m 为 0 时, 式 (1) 为 AR 模型, 而当 x_t 是在原时间序列上差分得到的稳定序列时, 则称式 (1) 为 ARIMA 模型^[9]. 风速预测中大量工作使用了基于统计模型发展出来的相关方法. 文献 [10] 通过 ARIMA 模型对墨西哥境内两处风速数据进行了建模, 并通过误差的分布情况, 说明所建模型已充分挖掘了风速数据包含的趋势、周期等特征信息. 文献 [11] 中对三个地点的 10 分钟风速均值的时间序列及高频低频信息进行建模, 通过模型实现对无测量点地区的风速仿真. 文献 [12] 通过结合小波变换对高频部分进行建模, 用于改善预测的准确度.

近年来, 随着人工智能技术的发展, 大量新的建模及预测方法得以产生^[13-15]. 文献 [16] 使用不定层的神经网络对单一地点 10 分钟风速进行建模, 通过计算得到的均方根误差来对网络层数等参数进行调整, 并展示了最佳的参数选择结果. 文献 [17] 利用径向基函数神经网络结构建立风速预测模型, 通过对过去 24 小时风速数据的训练, 实现了对未来 72 小时的预测. 文献 [18] 使用了一个共享隐层的深度神经网络结构, 依靠多个风场的风速数据, 训练模型进行风速预测, 其可以进行一定程度的迁移学习, 对于训练数据较少的风电场也可以达到较好的风速预测效果. 另一方面, 循环神经网络 (Recurrent neural network, RNN) 在近年也获得了很大发展, 衍生出来的长短期记忆 (Long short-term memory, LSTM) 网络可以记忆更长时间的时序特征, 弥补了 RNN 网路中梯度消失的问题^[19]. 基于 LSTM 的递归神经网络, 作为一种处理序列数据的典型网络结构, 被大量应用于风速预测场景. 文献 [20] 通过 LSTM 及时间窗口的组合, 对未来一段时间内各个时刻的风速值进行了预测, 其预测结果相较于传统统计学模型有了很大提高. 文献 [21] 先使用主成分分析 (Principal component analysis, PCA) 对空气密度、气压、温度等参数进行选择, 再结合 LSTM 网络, 对风速进行短时预测, 其结果相较于单纯使用 LSTM 有了一定提升. 文献 [22] 通过对总卷积神经网络 (Convolutional neural network, CNN) 及 LSTM 网络的组合使用, 对于空间及时间特征进行建模, 来提高模型对短时风速的预测准确度.

在使用 LSTM 结构的神经网络中, 基于编码

器-解码器循环神经网络广泛应用于时间序列数据的处理, 例如机器翻译^[23-25]. 但是在实际使用时, 随着输入历史序列时间长度的增长, 网络效果会快速变差^[26]. 为了能够保持对长时间历史信息的提取, 又不至于影响网络效果, 基于注意力的编解码网络得到发展. 文献 [27] 提出了一种新颖的双阶段注意力循环神经网络 (Dual-stage attention-based RNN, DA-RNN), 针对多条时间序列数据场景下, 基于注意力编解码器来建立时序模型并进行预测. 该模型首先由一层注意力机制来适应性地从多条驱动数据中提取信息并编码, 之后再通过一层注意力机制, 对所有历史时间段的隐状态进行处理, 提取时间上有关联的信息, 最后从解码层输出.

值得注意的是, 高速铁路沿线风速预测的形式和 DA-RNN 非常相似. 图 1 所示为当前高速铁路沿线风速监测传感器部署情况示意图, y 及 x_1, x_2, x_3, x_4 分别为目标风速监测点及周边风速监测点.




图 1 风速传感器部署示意图

Fig. 1 The deployment of anemometers

目前在京沪线上, 风速传感器的部署密度大约有 10 公里左右的间隔. 各测风点下一时刻的风速既和该测风点历史数据有关, 也存在受周边风速环境影响的可能. 为了更好地挖掘其中的时间空间信息, 本文基于双阶段注意力循环神经网络, 提出时空注意力循环神经网络 (Spatial-temporal attention-based RNN, STA-RNN), 分别对目标风速计和周边风速计的时序信息进行赋权提取, 实现对高速铁路沿线风速的准确预测. 基于预测结果, 本文进一步探讨并实现了强风预测, 以此来对高速铁路报警时间进行调节.

2 模型描述

2.1 强风预测模型

以京沪的风速监测系统为例, 设定一个测风点为目标点, 其相邻总计 4 个测风传感器处采集到的风速数据为驱动序列, 在给定的时间窗口 T 下, 有 $X = (x^1, x^2, x^3, x^4)^T = (x_1, x_2, \dots, x_T) \in \mathbf{R}^{4 \times T}$, 其中任意一条时间序列表示为 $x^n = (x_1^n, x_2^n, \dots, x_T^n)^T \in \mathbf{R}^T$, 而在一个时刻的输入向量表示为 $x_t = (x_t^1, x_t^2, x_t^3, x_t^4)^T$. 我们设定在时刻 t 时, 需要预测的风速监测点处的历史风速为 $(y_1, y_2, \dots, y_t)$, 而需要

预测的下一时刻风速为 y_{t+1} , 因此, 我们所需要的建立的风速预测模型为 $\hat{y}_{t+1} = F(y_1, \dots, y_T, x_1, \dots, x_T)$.

本风速预测模型为基于 DA-RNN 的时空注意力循环神经网络模型 (STA-RNN), 模型主体架构为 LSTM 组成的编解码器结构. 一个典型的 LSTM 单元内部计算过程由下式共同完成

$$\begin{cases} f_t = \sigma(W_{xf} \times x_t + W_{hf} \times h_{t-1} + b_f) \\ i_t = \sigma(W_{xi} \times x_t + W_{hi} \times h_{t-1} + b_i) \\ \tilde{c}_t = \tanh(W_{xc} \times x_t + W_{hc} \times h_{t-1} + b_c) \\ c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \\ o_t = \sigma(W_{xo} \times x_t + W_{ho} \times h_{t-1} + b_o) \\ h_t = o_t \odot \tanh(c_t) \end{cases} \quad (2)$$

在编码器部分, 如图 2 所示, 对于给定的序列, 通过训练可以得到一个从 x_t 到 h_t 的转换式

$$h_t = f_1(h_{t-1}, x_t) \quad (3)$$

其中, h_t 是 t 时刻所产生的隐状态. 邻近地理位置的风速测量结果经常呈现出一定的相关性, 依靠注意力机制来自适应地选择相关邻近监测点. 对于任一序列 x^n 及时刻 t , 本文采用如下注意力机制:

$$e_t^n = v_e^T \tanh(W_e[h_{t-1}; s_{t-1} + U_e x^n]) \quad (4)$$

$$\alpha_t^n = \frac{\exp(e_t^n)}{\sum_{i=1}^4 \exp(e_i^n)} \quad (5)$$

最终得到的 α_t^n 即为时刻 t 该监测点测得的风速对需要预测的监测点风速的注意力权重. 基于得到的权重值, 动态提取各监测点数据为

$$\tilde{x}_t = (\alpha_t^1 x_t^1, \alpha_t^2 x_t^2, \alpha_t^3 x_t^3, \alpha_t^4 x_t^4)^T \quad (6)$$

由此产生的 $\tilde{x}_t$ 再输入到 LSTM 单元中, 更新隐状态, 完成编码器部分. 而在解码器部分, 为了选择在时间上与待预测监测点风速值最相关的信息, 一个相同结构的注意力机制设置为

$$l_t^m = v_d^T \tanh(W_d[I_{t-1}; s'_{t-1} + U_d h_m]) \quad (7)$$

$$\beta_t^m = \frac{\exp(l_t^m)}{\sum_{i=1}^T \exp(l_i^m)} \quad (8)$$

$$c_t = \sum_{i=1}^T \beta_t^m h_i \quad (9)$$

由此得到对解码器的输入向量 c_t , 之后结合循环神经网络计算过程 (2), 得到建立风速预测模型所需的 $\hat{y}_{t+1}$ 值.

本文通过使用上述基于 STA-RNN, 分别对从当前时刻 t 开始的 $t+1, t+2, \dots, t+10$ 建立预测模型, 得到未来 10 个点的风速预测值 $\hat{y}_{t+1}, \dots, \hat{y}_{t+10}$. 为了能够在风速预测值的基础上判断强风情况, 本文在得到 10 步风速预测值后, 接入了一个支持向量机 (Support vector machine, SVM) 作为分类器^[28], 用于判断是否有强风出现. SVM 是以统计学习为基础的分类器, 其旨在线性可分情况下寻找最优超平




图 2 时空注意力循环神经网络结构

Fig. 2 Structure of STA-RNN

面来对样本进行分类, 过去已有大量研究将其应用于时间序列分类^[29-31]. 为了实现线性分类, 首先需要使用核函数将输入变量投射到高维空间中. 常用的核函数包含有线性核函数、多项式核函数及径向基核函数. 本文选定径向基核函数作为分类函数, 分类器结构为

$$K(x, x_i) = \exp(-\gamma|x - x_i|) \quad (10)$$

$$f(x) = \text{sign} \left(\sum_{i=1}^l (\alpha_i y_i K(x, x_i) + b) \right) \quad (11)$$

通过预测的多步风速值来判断是否可能发生强风.

综上所述, 本文所提的强风预测模型整体流程如图 3 所示.




图3 强风预测整体流程

Fig. 3 Overall procedure of the strong wind prediction

对于待预测目标监测点, 基于其自身和邻近 4 个监测点的历史风速数据, 获得 10 步预测值. 之后, 通过 SVM 分类器对预测结果进行分类, 实现对大风的预测. 在训练过程中, 本文首先基于历史数据对风速模型进行训练. 其后使用训练好的预测模型对历史数据进行预测处理, 基于预测值及历史数据中的强风值, 对 SVM 分类器进行训练.

2.2 报警保持时间调整流程

基于第 2.1 节所建立的强风预测框架, 本文对未来 10 分钟的强风情况进行实时预测, 以此作为报警保持与否的重要衡量标准. 系统在实际运行中的流程图如图 4 所示.

发生强风报警后, 当前风速值通过高速铁路系统部署的通信网络实时传输至调度中心, 报警系统首先基于实际测量的风速情况, 对当前风速进行监

控. 当前风速保持在报警阈值以上时, 强风报警继续保持. 之后, 当实测风速低于报警阈值时, 则检查强风预测结果, 若强风预测结果判断未来仍存在短时强风, 则报警信号继续由调度人员保持. 若实测风速低于报警阈值且强风预测系统的输出不认为短时内存在强风, 则调度人员取消报警, 相关高速列车恢复正常运行, 铁路区间通过能力恢复正常. 基于该方案, 报警解除时间不再是一个固定值, 而是由强风预测系统进行动态判断. 这为高速铁路运行效率带来了提高空间.




图4 报警保持时间调整流程

Fig. 4 Strong wind alarm duration adjustment procedure

3 实验验证

本节通过在实际数据上进行的相关实验, 对 STA-RNN 在高速铁路沿线风速预测及报警解除时限调整的各部分效果进行验证. 本文所收集的数据集为京沪线上 200 公里前后连续 5 个测风点的每秒久采样数据, 时间范围从 2017 年 1 月 1 日至 2017 年 12 月 13 日. 从数据集中选取了有大风报警的时间段, 最终使用的数据集时间范围从 2017 年 6 月 24 日至 2017 年 7 月 7 日. 选取前一周数据作为训练集, 后一周数据作为测试集. 数据集描述见表 2.

首先对数据进行了预处理. 由于数据包含超出风速计正常范围的负值, 本文对每个测量点测得的风速数据进行调零操作:

$$X_{aa} = X_{ba} - X_{\min} \quad (12)$$

表 2 实验数据集

Table 2 Dataset for experiments

测量点	数量	均值 (m/s)	最大值 (m/s)	最小值 (m/s)
测量点 1	1 209 600	3.64	20.0	-0.7
测量点 2	1 209 600	3.63	24.9	-0.4
测量点 3	1 209 600	3.63	29.9	-1.0
测量点 4	1 209 600	3.63	29.5	-1.2
测量点 5	1 209 600	3.62	22.7	-0.3

其中, X_{ba} 为调零前的时间序列, $X_{\min}$ 为时间序列中的最小值, X_{aa} 为调零后的时间序列值. 考虑到实际环境中计算时间及通信时间成本, 本文预测模型基于时间粒度为 1 分钟的数据进行

$$X_c = \left[\underbrace{(X_{aa}(0), \dots, X_{aa}(59))}_{60}, \dots \right] \quad (13)$$

$$X_m = \max(X_c) \quad (14)$$

最终, 本文用每分钟最大风速 X_m 来表示每条风速时间序列. 后续实验均基于该预处理后的结果.

3.1 STA-RNN 风速预测效果

本文对风速预测模型的准确度进行比较. 作为对比, 在过去风速预测中使用较多的 ARIMA 模型^[11-12] 及 LSTM^[20-21] 用来作为对比试验. 本文对从单步到多步的预测效果均进行了测试. 为了对预测效果进行衡量, 本文采用平均绝对误差 (Mean absolute error, MAE)、均方根误差 (Root mean squared error, RMSE) 及相对百分比误差 (Mean absolute percentage error, MAPE) 来对误差进行衡量. 在实验过程中, 本文提供了单步的结果对比, 同时还分别提供了 5 步及 10 步的预测结果, 注意此处多步的实现方法同本文前述方案一致, 并非将预测得到的前序值作为历史值再预测多步的风速, 而是直接跳过前序值进行 5 步及 10 步的预测. 实验结果展示于表 3 中.

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_t^i - \hat{y}_t^i|$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_t^i - \hat{y}_t^i)^2}$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_t^i - \hat{y}_t^i}{y_t^i} \right| \times 100\%$$

表 3 风速预测准确度

Table 3 Performances of the wind prediction

模型		MAE (m/s)	RMSE (m/s)	MAPE (%)
ARIMA	1-step	2.02	3.46	1.35
	5-step	2.14	3.50	1.36
	10-step	2.24	3.57	1.37
LSTM(128)	1-step	1.21	1.60	0.65
	5-step	1.39	1.87	0.69
	10-step	1.51	2.25	0.75
STA-RNN	1-step	0.98	1.25	0.20
	5-step	1.11	1.40	0.22
	10-step	1.21	1.80	0.25

从测试结果可以看出, ARIMA 方法下的预测效果最不理想, LSTM 及 STD-RNN 两个方法结果接近, 但 STD-RNN 在单步及多步的预测效果上均更优.

3.2 强风报警效果

利用预测的 10 分钟风速情况, 本文设置了一组对比实验: 当实测风速低于报警阈值且当前时刻所有预测的值均低于报警阈值, 取消报警^[1]. 为了量化的进行比较, 本文对强风预测的精确度 (Precision)、召回率 (Recall) 和 F 分数值进行比较.

$$\text{Precision} = \frac{TP}{TP + FP} \quad (15)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (16)$$

$$F_{\text{score}} = \frac{2TP}{2TP + FN + FP} \quad (17)$$

其中, TP 为正检值, FP 为误检值, FN 为漏检值. 所得结果展示于表 4 中.

表 4 强风预测效果

Table 4 Performances of the strong wind prediction

模型	精确度	召回率	F_{score}
STA-RNN	1.0	0.65	0.79
STA-RNN+SVM	1.0	0.73	0.84

根据实验结果, 可以看出基于 STA-RNN 的两种方法在进行强风报警时均可以达到百分百的精确度, 其中使用 SVM 作为强风分类器的方法在召回率及 F 分数上更高, 说明采用此方法所带来的漏报会更少, 处置频率会更低, 更符合实际的高速铁路运营

需要. 造成该情况的原因为, 当风速预测值均刚好低于阈值时, 仍可能在之后短时间内发生强风, 这种情况通过再训练一层 SVM 分类器可以进行补充, 但是通过比较预测值与阈值的大小无法直接识别出来.

3.3 报警保持时间调节效果

本节通过一个实际案例对比, 来说明本方案对高铁运行中报警保持时间的调节效果. 现有运行的高速铁路系统中, 京沪线上的报警解除时限为 10 分钟. 本文以此作为标准, 来与所提方案产生的结果进行对比, 对比结果展示于图 5 中. 图中实线为所提方法产生的报警解除时间示意图, 虚线为现有实际系统在运行过程中产生的报警解除时间示意图. 两者值为 30 时, 均表示报警, 为 0 时, 均表示无报警.

图 5 为一个典型的风速报警解除过程. 显然, 实测风速 (点划线) 分别在 $x = 16810$ 及 $x = 17500$ 处跌出报警阈值 20. 但是, 在第 1 次跌出阈值后, 于 $x = 16970$ 处快速回升, 在短时间内出现了重复强风. 如果仅依靠实测风速来进行报警, 则此处必然出现重复报警, 增加了操作人员处置次数. 按照现有设计标准, 风速报警将在实测风速低于阈值后保持 10 分钟时间, 因此可以较好地保证出现如图 5 所示情况时不出现重复报警. 但是另一方面, 在实测风速第 2 次跌出阈值后, 由于固定的 10 分钟保持标准, 强风报警将继续持续 10 分钟, 即如图 5 中虚线所示. 在实际操作中, 报警发出后, 铁路区间通过能力会受

到直接影响, 因此冗余的报警时间会使强风造成的运输效率损失进一步扩大. 与之相对应, 实线为本文提出的报警解除策略调整下的报警保持时间, 其不仅依靠对实测风速的监测, 同时还监测单步到 10 步的风速预测值 (图 5 中仅展示 1-step 及 10-step 预测值) 来调整报警保持时间. 在本案例中, 黑实线报警信号在实测风速值第 1 次跌出阈值后, 基于预测的结果选择了继续报警, 保证了尽量少的重复处置次数. 同时, 当第 2 次跌出阈值后, 报警没有继续保持, 保证了整体的运行效率.

4 结论

高速铁路强风报警解除问题是一个随着列车运行速度越来越快而逐渐形成的新问题, 对其的研究充满挑战. 良好的报警解除机制要求其既满足人员处置次数投入的需要, 又符合高速铁路运行效率的需求. 目前, 随着人工智能领域的发展, 对风速预测的相关技术得到了极大提高. 本文首次将时空注意力循环神经网络运用到高速铁路沿线风速预测上, 充分利用现有的监测系统及所采集的数据, 得到了准确的风速预测结果, 并依此提出了强风预测及强风报警时间调整方案, 达到了提高高速铁路运行效率的效果.

本文在实验中也发现, 在召回率没有达到 100% 之前, 均意味着处置次数会有一定上升, 因此强风预测中召回率仍然有待进一步提高. 对此, 本文下一步




图 5 报警解除时间调整案例

Fig. 5 A case for the strong wind alarm duration adjustment

将从两方面展开研究: 一方面将对模型进行改进, 例如采用 GeoMAN^[32] 等在空间信息挖掘上表现优秀的网络结构; 另一方面, 将结合更多更广范围的数据, 例如考虑地区气象预报、区域气压等信息, 来进一步提高模型精确度和召回率。除此之外, 近年来随着物联网技术的快速发展^[33-35], 风速传感器部署有望采用更加优化节能的方案, 从而增大部署密度, 获取更多细粒度数据, 进而提高模型性能, 并支撑在更大规模数据集上对算法效果的验证。

References

- Wang Rui, Chen Ran, Bao Yun. The study on JR-East monitoring technology of strong wind. *China Railway*, 2018, **07**: 96–102
(王瑞, 陈冉, 包云. JR 东日本铁路大风监测技术研究, 中国铁路, 2018, **07**: 96–102)
- Dou Ya-Xi, Lin Wei, Liu Chang. A research on the scheme of the real-time wind alarm transmission system of high-speed railway. *Railway Transport and Economy*, 2018, **40**(9): 57–61, 85
(窦亚锡, 蔺伟, 刘畅. 高速铁路大风报警信息实时传输系统方案研究. 铁道运输与经济, 2018, **40**(9): 57–61, 85)
- Wang Rui. A study on the application rules of high-speed railway wind monitoring system. *Railway Transport and Economy*, 2018, **40**(4): 48–51, 57
(王瑞. 高速铁路大风监测系统运用规则优化研究. 铁道运输与经济, 2018, **40**(4): 48–51, 57)
- Landberg L. Short-term prediction of the power production from wind farms. *Journal of Wind Engineering and Industrial Aerodynamics*, 1999, **80**(1–2): 207–220
- Negnevitsky M, Johnson P, Santoso S. Short term wind power forecasting using hybrid intelligent systems. In: Proceedings of the 2007 IEEE Power Engineering Society General Meeting. Tampa, FL, USA: IEEE, 2007. 1–4
- Negnevitsky M, Potter C W. Innovative short-term wind generation prediction techniques. In: Proceedings of the 2006 Power Systems Conference and Exposition. Atlanta, GA, USA: IEEE, 2006. 60–65
- Ma L, Luan S Y, Jiang C W, Liu H L, Zhang Y. A review on the forecasting of wind speed and generated power. *Renewable and Sustainable Energy Reviews*, 2009, **13**(4): 915–920
- Kiplangat D C, Asokan K, Kumar K S. Improved week-ahead predictions of wind speed using simple linear models with wavelet decomposition. *Renewable Energy*, 2016, **93**: 38–44
- Box G E P, Jenkins G M, Reinsel G C, Ljung, G M. *Time Series Analysis: Forecasting and Control*. John Wiley & Sons, 2015
- Cadenas E, Rivera W, Campos-Amezcuca R, Heard C. Wind speed prediction using a univariate ARIMA model and a multivariate NARX model. *Energies*, 2016, **9**(2): 109
- Yunus K, Thiringer T, Chen P. ARIMA-based frequency-decomposed modeling of wind speed time series. *IEEE Transactions on Power Systems*, 2016, **31**(4): 2546–2556
- Singh S N, Mohapatra A. Repeated wavelet transform based ARIMA model for very short-term wind speed forecasting. *Renewable Energy*, 2019, **136**: 758–768.
- Li L, Ota K, Dong M. Deep learning for smart industry: efficient manufacture inspection system with fog computing. *IEEE Transactions on Industrial Informatics*, 2018, **14**(10): 4665–4673
- Li H, Ota K, Dong M. Learning IoT in edge: deep learning for the internet of things with edge computing. *IEEE Network*, 2018, **32**(1): 96–101
- Ota K, Dao M S, Mezaris V, Mezaris V, De Natale F G. Deep learning for mobile multimedia: a survey. *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, 2017, **13**(3s): 34: 1–34: 22
- Kaur T, Kumar S, Segal R. Application of artificial neural network for short term wind speed forecasting, In: Proceedings of the 2016 Biennial International Conference On Power and Energy Systems: Towards Sustainable Energy. Bengaluru, India: IEEE, 2016. 1–5
- Chang G W, Lu H J, Chang Y R, Lee Y D. An improved neural network-based approach for short-term wind speed and power forecast. *Renewable Energy*, 2017, **105**: 301–311
- Hu Q, Zhang R, Zhou Y. Transfer learning for short-term wind speed prediction with deep neural networks. *Renewable Energy*, 2016, **85**: 83–95
- Tang Peng-Jie, Wang Han-Li, Xu Kai-Sheng. Multi-objective layer-wise optimization and multi-level probability fusion for image description generation using LSTM. *Acta Automatica Sinica*, 2018, **44**(7): 1237–1249
(汤鹏杰, 王瀚漓, 许恺晟. LSTM 逐层多目标优化及多层概率融合的图像描述. 自动化学报, 2018, **44**(7): 1237–1249)
- Dong D, Sheng Z, Yang T. Wind power prediction based on recurrent neural network with long short-term memory units. In: Proceedings of the 2018 International Conference on Renewable Energy and Power Engineering. Toronto, Canada: IEEE, 2018. 34–38
- Qu X Y, Kang X N, Zhang C, Jiang S, Ma X D. Short-term prediction of wind power based on deep long short-term memory. In: Proceedings of the 2016 IEEE PES Asia-Pacific Power and Energy Engineering Conference. Xi'an, China: IEEE, 2016. 1148–1152
- Zhu Q M, Chen J F, Shi D Y, Zhu L, Bai X, Duan X Z, Liu Y L. Learning temporal and spatial correlations jointly: a unified framework for wind speed prediction. *IEEE Transactions on Sustainable Energy*, 2019, DOI: 10.1109/TSTE.2019.2897136
- Kalchbrenner N, Blunsom P. Recurrent continuous translation models. In: Proceedings of the 2013 Conference on Empirical Methods in Natural Language Processing. Seattle, WA, USA: ACL, 2013. 1700–1709
- Venugopalan S, Rohrbach M, Donahue J, Mooney R, Darrell T, Saenko K. Sequence to sequence-video to text. In: Proceedings of the 2015 IEEE International Conference on Computer Vision. Santiago, Chile: IEEE, 2015. 4534–4542
- Sutskever I, Vinyals O, Le Q V. Sequence to sequence learning with neural networks. In: Proceedings of the 2014 Advances in Neural Information Processing Systems. Montreal, Canada: MIT Press, 2014. 3104–3112

- 26 Cho K, Van Merriënboer B, Bahdanau D, Bengio Y. On the properties of neural machine translation: encoder-decoder approaches [Online], available: <https://arxiv.org/pdf/1409.1259.pdf>. October 7, 2014
- 27 Qin Y, Song D, Chen H, Cheng W, Jiang G, Cottrell G. A dual-stage attention-based recurrent neural network for time series prediction. In: Proceedings of the 26th International Joint Conference on Artificial Intelligence. San Francisco, CA, USA: AAAI Press, 2017. 2627–2633
- 28 Vapnik V N. An overview of statistical learning theory. *IEEE Transactions on Neural Networks*, 1999, **10**(5): 988–999
- 29 Du P, Wang J, Yang W, Niu T. Multi-step ahead forecasting in electrical power system using a hybrid forecasting system. *Renewable Energy*, 2018, **122**: 533–550
- 30 Xing Z, Pei J, Keogh E. A brief survey on sequence classification. *ACM SIGKDD Explorations Newsletter*, 2010, **12**(1): 40–48
- 31 He Y, Pei J, Chu X, Wang Y, Jin Z, Peng G. Characteristic subspace learning for time series classification. In: Proceedings of the 2018 IEEE International Conference on Data Mining. Singapore, Singapore: IEEE, 2018: 1019–1024
- 32 Liang Y, Ke S, Zhang J, Yi X, Zheng Y. GeoMAN: multi-level attention networks for geo-sensory time series prediction. In: Proceedings of the 2018 International Joint Conference on Artificial Intelligence. Stockholm, Sweden: Morgan Kaufmann, 2018. 3428–3434
- 33 Chen J, Hu K, Wang Q, Sun Y, Shi Z, He S. Narrowband internet of things: implementations and applications. *IEEE Internet of Things Journal*, 2017, **4**(6): 2309–2314
- 34 Zhou C, Gu Y, He S, Shi Z. A robust and efficient algorithm for coprime array adaptive beamforming. *IEEE Transactions on Vehicular Technology*, 2017, **67**(2): 1099–1112
- 35 Li C, He S, Shi Z, Chen J. Efficient antenna allocation algorithms in millimetre wave wireless communications. *IET Communications*, 2017, **12**(5): 543–551




刘昊侯 浙江大学控制科学与工程学院博士研究生。2015 年获得浙江大学控制科学与工程学士学位。主要研究方向为信息感知及异常检测。本文通信作者。

E-mail: haoyu.liu@zju.edu.cn

(**LIU Hao-Yu** Ph.D. candidate at the College of Control Science and Engineering, Zhejiang University. He re-

ceived his bachelor degree from Zhejiang University in 2015. His research interest covers information sensing and outlier detection. Corresponding author of this paper.)



贺诗波 2012 年获得浙江大学控制科学与工程博士学位。浙江大学控制科学与工程学院研究员。主要研究方向为物联网, 数据分析, 网络科学。

E-mail: s18he@zju.edu.cn

(**HE Shi-Bo** Received his Ph.D. degree in control science and engineering from Zhejiang University in 2012. He is

currently a professor with the College of Control Science and Engineering at Zhejiang University. His research interest covers internet of things, data analysis, and network science.)



陈积明 2005 年获得浙江大学控制科学与工程博士学位。浙江大学控制科学与工程学院教授。主要研究方向为网络优化与控制, 控制系统安全, 工业大数据与物联网。E-mail: cjm@zju.edu.cn

(**CHEN Ji-Ming** Received his Ph.D. degree in control science and engineering from Zhejiang University

in 2005. He is currently a full professor at the College of Control Science and Engineering, Zhejiang University. His research interest covers network optimization and control, cyber security, IoT and big data for industry.)