

# 基于 ConvLSTM 的改进雷达回波外推方法研究

赵玉娟<sup>1</sup>, 李宗飞<sup>1</sup>, 陈凯华<sup>1</sup>, 王彦<sup>2</sup>, 朱男男<sup>3</sup>, 李祥海<sup>1</sup>, 姜罕盛<sup>1</sup>

(1. 天津市气象信息中心, 天津 300074; 2. 天津市人工影响天气办公室, 天津 300074;

3. 天津海洋中心气象台, 天津 300074)

**摘要:** 海上大风及其引发的次生灾害是导致海洋气象灾害的主要因素; 雷达观测数据是临近预报主要参考数据之一, 准确的雷达外推数据对于提升海上强对流大风临近预报能力极为关键; 面向海上大风预报需求和大风天气雷达回波特征, 从输入数据格式和损失函数两方面对 ConvLSTM 进行改进, 在损失函数中增加观测真实值作为系数提高强回波影响, 构建了基于自编码的 ConvLSTM 网络, 利用 4 年的沧州历史雷达回波数据对其进行训练, 得到了可基于历史 1 h 雷达数据预测未来 1 h 雷达回波的雷达回波外推模型; 测试集及个例检验结果表明, 改进模型在强回波预测方面具备更好效果。

**关键词:** 海洋强对流天气; 海上大风; 雷达回波外推; 自编码; ConvLSTM

## Research on Improved Radar Echo Extrapolation Method Based on ConvLSTM

ZHAO Yujuan<sup>1</sup>, LI Zongfei<sup>1</sup>, CHEN Kaihua<sup>1</sup>, WANG Yan<sup>2</sup>, ZHU Nannan<sup>3</sup>,

LI Xianghai<sup>1</sup>, JIANG Hansheng<sup>1</sup>

(1. Tianjin Meteorological Information Center, Tianjin 300074, China;

2. Tianjin Weather Modification Office, Tianjin 300074, China;

3. Tianjin Marine Meteorological Centre, Tianjin 300074, China)

**Abstract:** Strong winds at sea and the secondary disasters caused by them are the main factors leading to marine meteorological disasters. Radar observation data is one of main reference data for proximity prediction, accurate radar extrapolation data is very important for improving the ability of predicting the approaching strong convective gales at sea. Facing the demand of offshore gale forecast and radar echo characteristics of gale weather, ConvLSTM is improved from two aspects of input data format and loss function, the observed true value is added as a coefficient in the loss function to improve the strong echo effect, a ConvLSTM network based on self-coding is constructed, the model is trained by four years historical radar echo data of Cangzhou, the radar echo extrapolation model is obtained that the intensity and shape of the future 1-hour radar echo can be predicted by using the historical 1-hour radar echo data. The test set and case test results show that the improved model has better extrapolation effect in strong echo prediction.

**Keywords:** severe marine convective weather; sea gale; radar echo extrapolation; self-encoding; ConvLSTM

## 0 引言

临近预报通常指未来 0~2 h 的天气预报。强对流天气包括雷雨大风、冰雹等天气, 因其历时短、破坏性强、演变规律复杂, 是临近预报的重点和难点。海洋强对流天气临近预报在海洋气象灾害防御中具有重要地位。海上大风及其引发的次生灾害是导致海洋气象灾害的主要因素。为了提升海上大风等海上强对流天气预报能力, 气象工作者持续在开展大风天气特征及预报方法等方面的探索。多普勒天气雷达是气象部门用于大气监测的重要设备, 能够提供高时空分辨率的精细监测产品, 在灾害性、突发性天气监测预警中是极为重要的参考指标, 因此, 许多学者开展

了分析雷达回波在雷暴大风天气条件下特征的研究, 为相关领域天气预报能力提升提供支撑。王彦等<sup>[1]</sup>利用天津地区 46 次雷暴大风过程统计分析了雷达回波在雷暴大风天气过程下的特征, 得出了影响渤海西部的雷暴大风在雷达回波形态方面有弓状、带状、阵风锋等四种类型, 弓状回波对应的雷暴大风天气最强烈等结论; 郭庆利等<sup>[2]</sup>通过对烟台北部沿海 5 年的雷雨大风天气个例分析, 得到了渤海海峡雷雨大风天气下雷达反射率因子的回波强度多在 45 dbz 以上, 形状大致分带状、弓形等 5 类的结论。郭鸿鸣等<sup>[3]</sup>综合运用 6 部天气雷达拼图、WRF 模式物理场等资料分析了强对流系统入海前后的时空变化规律。王亚南等<sup>[4]</sup>利用海岛、平台、浮标等站点加密观测资料, 分析了渤海西部雷

收稿日期: 2023-02-20; 修回日期: 2023-04-07。

基金项目: 国家自然科学基金(41675046); 环海区域协同创新基金(QYXM202013); 天津市气象局科研项目(202107ybxm02)。

作者简介: 赵玉娟(1981-), 女, 硕士, 正高级工程师。

通讯作者: 王彦(1972-), 女, 大学本科, 正高级工程师。

引用格式: 赵玉娟, 李宗飞, 陈凯华, 等. 基于 ConvLSTM 的改进雷达回波外推方法研究[J]. 计算机测量与控制, 2023, 31(9): 166-173.

雨大风的统计特征。陈明轩等<sup>[5]</sup>、俞小鼎等<sup>[6]</sup>、程丛兰<sup>[7]</sup>等则论述了强对流天气临近预报方法。

雷达回波外推结果是临近预报主要参考数据之一。如何快速、准确地生成雷达回波预测数据是近年来气象领域研究热点之一。传统雷达外推方法包括交叉相关法 (CO-TREC)<sup>[8]</sup>、光流法等<sup>[9-10]</sup>。交叉相关法和光流法均是假定雷达反射率因子的运动符合拉格朗日守恒规律, 在稳定性降水预报中效果较好<sup>[11]</sup>, 但对于局地强对流天气, 因雷达回波演变快, 不满足守恒条件, 预报效果则会随着时间快速下降<sup>[12-13]</sup>。

探索雷达回波外推新方法, 高效、准确地生成雷达回波预测数据, 对提升海上强对流天气临近预报和服务能力具有重要意义。深度学习算法可自动学习海量数据中蕴含规律, 且无需较多先验知识, 因此在气象领域应用日益广泛, 诸多学者开展了相关方法在短临天气预报方面研究。郭尚瓚等<sup>[14]</sup>开展了多层感知器在短时降雨预测方面的探索。Shi 等<sup>[15]</sup>利用带卷积的长短时记忆单元构建 RNN, 将其在雷达外推预报方面应用取得了较好效果。施恩<sup>[16]</sup>提出了基于输入的动态卷积神经网络模型, 卷积核含有当前输入的特征, 网络模型测试期间还可基于输入图像变化, 输入、输出图像的强相关性得到保证, 利用南京、杭州、厦门三地雷达 CAPPI 图像数据作为样本试验的结果表明, 所提方法较传统雷达回波外推方法, 预测图像准确率和外推时效均有所提高。郭瀚阳<sup>[17]</sup>等借助基于自编码的卷积 GRU 网络, 利用雷达拼图数据训练得到了可利用历史 0.5 h 数据预测未来 1 h 回波的雷达回波外推模型。试验结果证明其所提方法在预测精度上明显优于传统方法。黄兴友<sup>[18]</sup>等采用 Causal-LSTM 单元构建神经网络模型实现雷达回波外推, 并使用带权重的损失函数进行模型训练, 测试集及个例检验表明其构建的模型在强回波预报方面优于光流法。

目前基于深度学习的雷达回波外推研究多面向降水预报, 针对海上大风天气的研究较少。本研究面向海上大风临近预报需求选取雷达数据, 并从输入数据格式、损失函数两方面进行改进, 构建了基于自编码的 ConvLSTM 网络, 利用沧州雷达站 4 年的历史观测数据对其进行训练, 得到了雷达回波外推模型, 可利用近 1 h 雷达反射率因子数据预测未来 1 h 雷达反射率因子数据。测试集及典型天气个例对模型预测效果进行检验的结果表明, 改进后模型较传统 ConvLSTM 模型在强回波预测方面效果更好。

## 1 方法

### 1.1 网络模型

本研究拟通过学习历史雷达数据时空变化规律, 预测未来雷达回波序列, 属于时间序列预测问题, 循环神经网络在相关领域应用较多。不同于一般神经网络不同层神经网络节点互相独立, 循环神经网络各隐藏层节点不仅依赖当前输入, 还依赖前一时刻中间状态, 处理新数据时, 也可记忆历史计算结果。卷积长短时记忆单元 ConvLSTM 是应用较广的循环神经网络模型之一, 通过输入门、遗忘门及

输出门实现信息流动控制, 可防止有价值信息因为预测序列长度的增大而被丢, 还能选择性地实现“更新”和“遗忘”。ConvLSTM 工作原理如式 (1) ~ (5) 所示,  $i_t$  表示输入门,  $f_t$  表示遗忘门,  $o_t$  表示输出门, 算子 ( $\circ$ ) 表示矩阵对应元素相乘, “ $*$ ”表示卷积操作, “ $\sigma$ ”表示 Sigmoid 函数,  $W_x$ —,  $W_h$ —是二维卷积核, 输入  $X_1, \dots, X_t$  和单元状态  $C_1, \dots, C_t$ , 隐藏状态  $H_1, \dots, H_t$  及  $i_t, f_t, o_t$  均为 3 维张量。

$$i_t = \sigma(W_{xi} * X_t + W_{hi} * H_{t-1} + W_{oi} \circ C_{t-1} + b_i) \quad (1)$$

$$f_t = \sigma(W_{xf} * X_t + W_{hf} * H_{t-1} + W_{of} \circ C_{t-1} + b_f) \quad (2)$$

$$O_t = \sigma(W_{xo} * X_t + W_{ho} * H_{t-1} + W_{oo} \circ C_t + b_o) \quad (3)$$

$$C_t = f_{io} \circ C_{t-1} + i_{io} \tanh(W_{xc} * X_t + W_{hc} * H_{t-1} + b_c) \quad (4)$$

$$H_t = O_t \circ \tanh(C_t) \quad (5)$$

循环神经网络还能作为基本单元构建更复杂网络。本研究借鉴了郭瀚阳等<sup>[17]</sup>研究思路, 亦采用自编码模型构建网络, 不同之处在于本文采用基于自编码的 ConvLSTM 网络进行雷达回波序列预测, 通过多层堆叠 ConvLSTM, 增强模型学习能力。自编码模型包含编码、解码两阶段。编码阶段先用最后输入的隐藏层状态代表所有输入序列信息, 再将编码最后一步隐藏层状态用于初始化解码阶段隐藏层的状态。解码阶段先用编码输入的最后一帧作为第一个输入得到第一个预测输出, 再用第一个预测输出作为输入得到第二个预测输出, 持续迭代此过程得到所有预测输出, 该方法具备可产生变长预测序列的优势。本研究的编码和解码阶段均采用三层堆叠 ConvLSTM 来学习数据特征。

### 1.2 损失函数改进

不同天气状况下, 雷达反射率因子强度具有明显差异。天气雷达实时观测到的回波强度是判断强对流天气的重要参考数据。预报经验和已有对海上强对流大风天气的雷达回波特征分析研究表明, 雷达反射率因子包含较多强回波情况下, 发生海上强对流大风天气的概率相对更高<sup>[19-22]</sup>, 王福侠等<sup>[21]</sup>利用天气雷达和自动站资料研究统计 2006 ~ 2008 年河北省中南部地区 28 次雷暴大风过程中出现地面大风的 262 个观测站上空的雷达回波特征发现, 一般雷暴大风的反射率因子都在 50 dbz 以上, 但干对流雷暴大风的反射率因子一般只有 40 dbz 左右。强回波预测准确与否对预报效果影响更大, 提高强回波预测准确率是提升预报效果的关键。

ConvLSTM 模型常规采用的是均方差损失函数 MSE, 均方差损失函数先计算真实数据与预测数据所有对应点误差平方的总和, 再计算其均值, 对于不同大小的真实值权重一样, 对于雷达回波数据则表现为对不同强度回波的权重一样。对于雷达回波预测应用而言, 希望较大的回波值能够具有更高的预测准确率, 为提升强回波预测能力, 本文改进了损失函数, 将损失函数构造为原始 MSE 损失函数和加权重的 MSE 函数两部分的组合, 两部分的系数各为 0.5, 对于加权重的 MSE 损失函数, 在利用均方差损失函数计算真实值与预测值差值基础上增加回波真实值作为权

重, 强回波的值较大权重会更高, 弱回波值较小则权重会更低, 从而实现提升强回波预测准确率的目标。改进后损失函数如式 (6) 所示, 其中  $pred$  代表预测值集合,  $label$  代表实际观测值集合,  $N$  代表系数, 改进后损失函数在  $label$  值较大即观测值为强回波时将产生更大影响,  $lossfunction$  为 MSE 函数, 计算公式如式 (7) 所示, 其中  $y_i$  代表实际观测值集合  $label$  中的第  $i$  个真实观测值,  $y_i^p$  代表第  $i$  个观测值在预测值集合  $pred$  中对应的预测值。基于公式 (6)、(7) 可推导出公式 (8), 由公式 (8) 可见, 改进后的损失函数增加了  $N^2 y_i^2$  作为真实值与预测值差值的权重系数, 当预测值与真实值存在差异且真实观测值较大时, 改进后损失函数计算得出的数值较改进前更大, 因此能够实现增大强回波权重, 提升强回波预测效果的目的。

$$loss = 0.5 * lossfunction(pred, label) + 0.5 * lossfunction(N * label * label, N * pred * label) \quad (6)$$

$$lossfunction(pred, label) = \frac{1}{n} \sum_{i=1}^n (y_i - y_i^p)^2 \quad (7)$$

$$loss = 0.5 * \frac{1}{n} \sum_{i=1}^n (y_i - y_i^p)^2 + 0.5 * \frac{1}{n} \sum_{i=1}^n N^2 y_i^2 (y_i - y_i^p)^2 \quad (8)$$

### 1.3 输入数据改进

气象部门长期存储的主要是二进制格式的雷达基数据, 该类数据无法直接用于深度学习训练, 已有研究多采用基数据生成图像文件方式作为输入数据, 而单个图像文件仅能保存 1 个仰角的观测数据。天气雷达是对一定空间范围内降水回波的观测, 一个体扫包含多个仰角观测数据。大气流体运动变化过程是在三维空间中进行, 每个高度层均与其附近高度层有较强相关性<sup>[23]</sup>。在每个时刻输入相邻多个仰角观测数据有助于解决单层雷达回波图像外推局限性。数组是在程序设计中, 为了处理方便, 把具有相同数据类型的若干元素按有序的形式组织起来的一种数据组织方式, 是用于储存多个相同类型数据的集合。每个观测时次, 天气雷达单个仰角对一定空间范围的观测数据可抽象为二维数组, 多个仰角的雷达观测数据可抽象为三维数组,  $numpy$  文件是 Python 语言针对多维数组 (Nddarray) 的科学计算库

NumPy 专用的二进制文件格式, 能够保存任意维度的 NumPy 数组, 可满足存储多仰角雷达观测数据的需求, 而且 NumPy 库提供了  $save$ 、 $load$  函数为便捷地将数组数据存储到  $numpy$  文件和从  $numpy$  文件读取数组内容提供了有力支撑, 因此, 本文对深度学习模型的雷达输入数据存储格式进行改进, 将同一个观测时次多个仰角的雷达反射率观测数据定义为  $(n, x, y)$  形式的三维数组进行存储,  $n$  代表观测仰角个数,  $x$  代表经度方向的观测数据点个数,  $y$  代表纬度方向的观测数据点个数, 并利用  $numpy$  库的  $save$  函数将其存储在同一个  $numpy$  文件中,  $N$  个观测时次的观测数据转化为  $N$  个  $numpy$  文件存储, 为后续实现多仰角输入数据训练打下基础, 实际训练时可按需灵活提取  $numpy$  文件中的 1 个或多个仰角的雷达观测数据用于训练。

## 2 数据集构建

深度学习雷达数据集构建主要包括雷达数据筛选、数据预处理、深度学习样本组构造三个步骤, 流程如图 1 所示。

### 2.1 雷达数据筛选

雷达数据时段选取强对流大风发生较多的 5~9 月。首先使用渤海西部有代表性的地面自动气象站、海上平台站逐小时观测资料, 根据王亚男等<sup>[4]</sup>提出的指标选取强对流天气导致的雷暴大风过程, 然后依据大风过程日期挑选雷达数据。强对流天气导致雷暴大风过程选取标准如下:

代表站瞬时风速 (或最大风速)  $\geq 17$  m/s, 相应海域出现雷电天气 (为消除系统性大风过程, 对于瞬时风速 (或最大风速)  $\geq 17$  m/s 且持续时间大于 3 小时的过程予以去除)。当多个观测站在不超过 12 小时范围内先后监测到雷雨大风并受同一天气系统影响时, 记为一次过程。

### 2.2 数据预处理

雷达基数据预处理包括数据解码、坐标转换等步骤。CINRAD-SA 型多普勒天气雷达基数据文件为二进制格式, 存储的数据采用极坐标系, 存储内容包括反射率、速度、谱宽等。数据解码步骤负责按照雷达基数据文件格式, 完成雷达观测描述信息和反射率观测数据的提取并按不同信息的数据类型完成格式转换, 坐标转换步骤首先建立极坐标和经纬度坐标的对应关系, 然后将以极坐标形式存储的

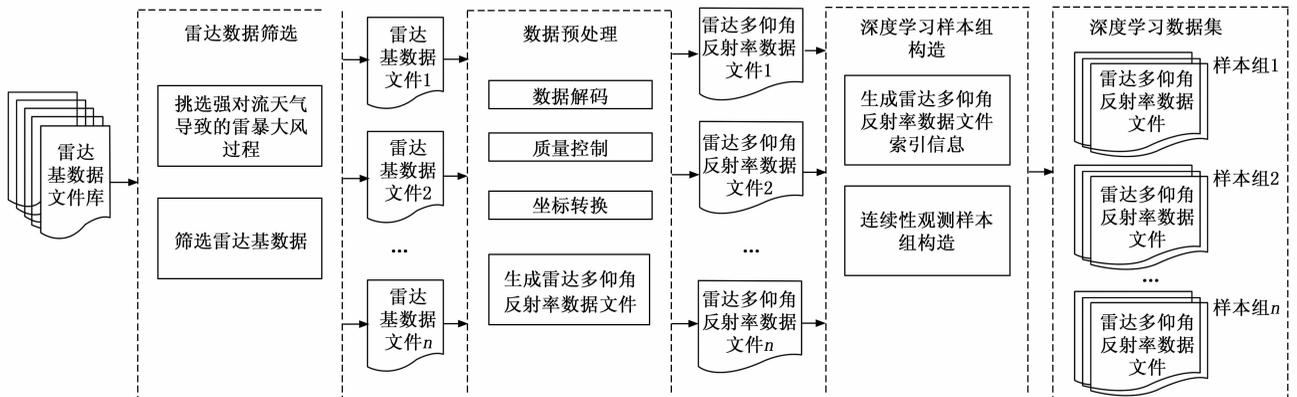


图 1 雷达数据深度学习数据集构建流程

反射率等数据, 投影到经纬度坐标系, 得到反射率数据的格点矩阵。坐标转换步骤中建立极坐标和经纬度坐标对应关系的过程如下: 雷达观测径向剖面图如图 2 所示,  $\angle\varphi$  代表雷达观测仰角,  $d$  代表雷达站点与观测位置的径向距离。建立以地球中心为原点的三维直角坐标系, 雷达站点  $r$  的坐标为  $(x_1, y_1, z_1)$ , 雷达观测任意点位置为  $p$ , 其在地球表面投影为  $p'$   $(x_2, y_2, z_2)$ ,  $\Delta lon, \Delta lat$  为投影点与雷达站点的经纬度差, 观测点  $p$  在地球表面投影  $p'$  坐标利用式 (9) 计算得到。通过式 (10), 计算得到任意  $p'$  位置  $(lon, lat)$  的极坐标值  $(\angle A, \angle\varphi, d)$ , 其中  $\angle A, d$  通过计算得到,  $\angle\varphi$  为已知值,  $\angle A$  代表雷达观测方位角。

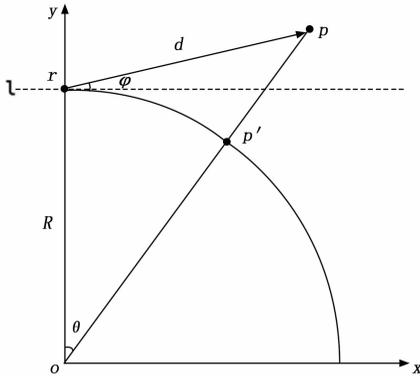


图 2 雷达观测径向剖面图

$$\begin{cases} x_2 = R \cdot \cos\Delta lat \cdot \sin\Delta lon \\ y_2 = R \cdot \cos\Delta lat \cdot \cos\Delta lon \\ z_2 = R \cdot \sin\Delta lat \end{cases} \quad (9)$$

$$\left. \begin{cases} \angle\theta = \arccos\left(\frac{x_1 \cdot x_2 + y_1 \cdot y_2 + z_1 \cdot z_2}{\sqrt{x_1^2 + y_1^2 + z_1^2} \cdot \sqrt{x_2^2 + y_2^2 + z_2^2}}\right) = \arccos(\cos(\Delta lat)\cos(\Delta lon)) \\ \angle A = \arcsin\left(\frac{x_2}{\sqrt{x_2^2 + z_2^2}}\right) \\ d = \frac{R \cdot \sin(\angle\theta)}{\cos(\angle\theta + \angle\varphi)} \end{cases} \right\} \quad (10)$$

坐标转换后单个仰角的观测数据为  $400 \times 400$  的格点矩阵, 直接用于训练计算开销较大, 为提高处理效率, 本研究对数据进行了抽样处理, 提取以雷达站点为中心  $\pm 2$  度经纬度范围的格点数据, 抽样处理后单个仰角观测数据的格点分辨率为  $100 \times 100$ , 数据量降低为抽样前的  $1/16$ 。

在特定环境下, 雷达观测受地物杂波、晴空回波等诸多因素影响, 将产生非降水回波干扰。地物杂波已在雷达 RPG 中进行了处理, 为进一步去除无效回波干扰, 质量控制方面, 本研究主要通过去除  $10 \text{ dbz}$  以下晴空回波以保障模型训练效果。

### 2.3 深度学习样本组构造

雷达数据因观测设备故障、维护等原因存在缺测, 导致数据存在时间间隔不等的问题, 为去除时间不连续数据, 按以下步骤构造观测数据文件时间间隔相同的深度学习数

据集:

1) 针对预处理得到的文件生成其文件名、观测时间索引信息。

2) 利用索引信息, 按照时间连续原则, 筛选构造深度学习样本组。对符合时间连续性检查的数据文件使用长度为 20 的滑动窗口以步长为 1 进行滑动采样, 得到所有样本组。每组样本包含 20 个观测时间连续的雷达数据文件  $\{x_1, x_2, x_3, \dots, x_{10}, y_1, y_2, y_3, \dots, y_{10}\}$ ,  $x_1$  到  $x_{10}$  为输入数据, 对应近一小时 10 个观测时间的雷达回波,  $y_1$  到  $y_{10}$  为输出数据, 代表下一小时 10 个观测时间的雷达回波, 每个文件时间间隔为  $6 \text{ min}$ 。

### 3 实验设计及结果分析

为验证本文方法有效性, 利用 Pytorch 实现了深度学习模型, 按照本研究方法, 基于沧州雷达站 2016~2019 年 5~9 月观测数据, 利用 Python 语言开发软件构建了雷达数据深度学习数据集, 构建的训练集包含 10 640 个样本, 测试集包含 2 000 个样本。激活函数是深度学习神经网络模型的重要组成部分, 旨在使神经网络模型能更好地拟合数据分布, 输出更准确的结果, 其选择对神经网络性能、模型收敛速度有很大影响, 本研究激活函数使用 LeakyReLU。LeakyReLU 是神经网络常用激活函数 ReLU 的变体。对于 ReLU 函数, 当输入  $x > 0$  时, 输出为  $x$ , 当输入  $x \leq 0$  时, 输出始终为 0, 导致神经元不能更新。为了解决 ReLU 函数这一问题, 在 ReLU 函数的负半区引入一个非常小的常数 *leak*, 即当  $x \leq 0$  时, 输出为  $leak * x$ , 使得输入信息小于 0 时, 信息没有被完全丢掉, 仍有很小的梯度。由于导数总是不为零, 能减少静默神经元的出现, 允许基于梯度的学习, 解决了 ReLU 函数进入负区间后, 导致神经元不学习的问题。训练过程采用反向传播算法计算误差, 网络参数利用 Adam 算法更新, Adam 算法本质上是带有动量项的 RMSprop, 它利用梯度的一阶矩估计和二阶矩估计动态调整每个参数的学习率, 该算法的优点主要在于经过偏置校正后, 每一次迭代学习率都有确定的范围, 参数比较平稳, 对内存需求少, 适用于大数据集和高维空间。学习率参数的设置很重要, 学习率取值过小会使网络收敛缓慢, 过大则又会使训练易陷入局部最优解。本研究通过引入动量项加快网络收敛速度, 减少震荡, 使网络训练不易陷入局部最优解。损失函数采用原始 MSE 函数和带权重的 MSE 函数组合的方式, 详见 1.2 节, 实验过程对比了  $N$  设置为 2、3、4 情况下和输入数据为 1 个仰角、2 个仰角时的模型预测效果, 对比结果表明输入为 1 个仰角、 $N=2$  时预测效果最优, 最终选定的损失函数参式 (11)。其他训练参数如表 1 所示, 初始学习率采用 0.000 1, 模型的训练采用批训练方式, `batch_size` 设置为 20。训练采用早停策略 (Early Stop) 方式停止以避免过拟合。最大迭代次数设置为 400 次, 当 10 次循环迭代后训练集精度提高不超过 0.000 1, 则训练结束。训练完成后, 模型能够根据雷达近 1

小时 10 个观测时次的回波数据作为输入，预测出未来 1 小时 10 个时次的雷达回波数据。

$$loss = 0.5 * lossfunction(pred, label) + 0.5 * lossfunction(2 * label * label, 2 * pred * label) \quad (11)$$

表 1 雷达数据深度学习训练参数

参数名称	参数值
初始学习率	0.000 1
学习率惩罚因子	0.5
batch_size	20

### 3.1 模型评价指标

采用分阈值评估方式对测试集进行检验，阈值分别选取 15、20、30、40 dbz，预测时长包括 0.5 h 和 1 h，预报时间间隔为 6 min，评价指标采用气象领域常用指标临界成功指数 (CSI)、命中率 (POD) 和虚警率 (FAR)。通过逐点对比预测值与观测值，得出各预测点所属分类 (分类标准参见表 2)，进而计算得出评估指标。 $a$ 、 $b$ 、 $c$  分别代表预测数据命中数、空报数和漏报数，评估指标公式如式 (12) ~ (14)：

$$CSI = \frac{a}{a + b + c} \quad (12)$$

$$POD = \frac{a}{a + c} \quad (13)$$

$$FAR = \frac{b}{a + b} \quad (14)$$

表 2 雷达回波像素点分类标准

分类	判定标准
命中点	预测值与真实值均大于判别阈值
空报点	预测值大于判别阈值而真实值小于判别阈值
漏报点	预测值小于判别阈值而真实值大于判别阈值

### 3.2 测试集检验

表 3 对比了原模型和本文改进模型对于测试集在 15、20、30、40 dBz 共 4 个反射率阈值 0.5 h 和 1 h 的预测结果。由表 3 可知，本文改进模型在 4 个阈值的 CSI、POD 指标均明显优于改进前，FAR 指标在阈值较小时略有增长，但在阈值较高时优于改进前。

表 3 模型改进前后在测试集检验指标

预测时间	回波阈值/dBz	命中率(POD)		临届成功指数(CSI)		虚警率(FAR)	
		原始 ConvLSTM	改进 ConvLSTM	原始 ConvLSTM	改进 ConvLSTM	原始 ConvLSTM	改进 ConvLSTM
0.5 h	15	0.61	0.70	0.52	0.56	0.22	0.27
	20	0.50	0.62	0.44	0.51	0.23	0.29
	30	0.26	0.43	0.22	0.34	0.36	0.41
	40	0.06	0.14	0.05	0.11	0.49	0.49
1 h	15	0.50	0.63	0.42	0.49	0.28	0.31
	20	0.36	0.53	0.32	0.42	0.29	0.33
	30	0.13	0.27	0.11	0.21	0.49	0.48
	40	0.01	0.03	0.01	0.02	0.73	0.60

POD 指标方面，阈值为 30 dbz 及以下时，0.5 h、1 h 的预测较改进前分别提高了 9%~17% 和 13%~17%；阈值为 40 dbz 时，0.5 h、1 h 的预测分别提高了 8% 和 2%。CSI 指标方面，阈值为 30 dbz 及以下时，0.5 h、1 h 的预测较改进前分别提高了 4%~12% 和 7%~10%；阈值为 40 dbz 时，0.5 h、1 h 的预测较改进前分别提高了 6% 和 1%。FAR 指标方面，0.5 h 的预测较改进前略有增长，1 h 的预测在 30、40 dbz 较改进前降低。0.5 h 的预测在阈值为 30 dbz 及以下时，较改进前增幅不超过 6%，阈值为 40 dbz 的预测和改进前相当；1 h 的预测在阈值为 20 dbz 及以下时，较改进前增幅不超过 4%，在阈值为 30、40 dbz 时的预测较改进前分别降低 1% 和 13%，优于改进前。

### 3.3 个例分析

文献 [21] 研究表明，产生雷暴大风的回波主要为弓形回波、带状回波和块状回波，其中带状回波是产生雷暴大风的主要回波。为更直观分析预测效果，从测试集和非测试集共选取 2019 年 7 月 29 日、2020 年 05 月 21 日、2022 年 06 月 12 日 3 组发生强对流大风的个例日期进行雷达回波外推分析，通过回波图像和预测指标两方面对比原始 ConvLSTM 模型和本文改进模型未来 1 h 雷达回波预测效果，对比图形包括四行，每行图像之间的时间间隔为 6 分钟，第一行为输入的近 1 小时雷达观测真实回波图像，第二行为未来 1 小时雷达实际观测的真实回波图像，第三、四行分别为原始 ConvLSTM 模型和改进模型基于第一行真实雷达观测预测的未来 1 小时雷达回波图像。

图 3 为测试集 2019 年 07 月 29 日 09 点 06 分到 10 点 00 分雷达回波个例预测效果对比，该个例是一次强带状回波引发的海上大风过程。带状回波通常是由多个对流回波单元相连排列成带状的回波，回波长度远大于回波宽度，有强回波时，传播方向与回波带垂直<sup>[22]</sup>。由图 3 可见，未来 1 h 的真实回波图像中在右下方一直存在一条形态较为明显、强度较高的带状回波，原始模型的预测，尤其在 35 min 之后的预测，对于带状回波的覆盖区域、强度方面均与实况有较大差异，而改进后模型预测的回波图像则整体上与观测实况更为相似，而且对带状强回波的预测效果有更为明显的提升，能较准确地预测出右下角带状回波形态、强度和移动位置，尤其是后 30 分钟的预测效果相比原始模型改进

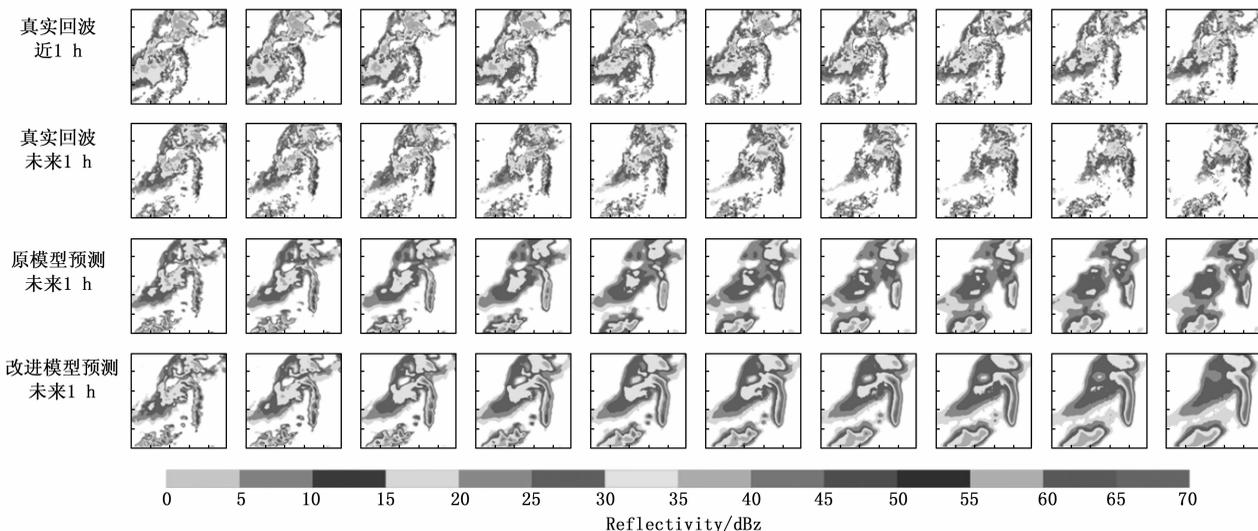


图 3 模型改进前后 2019 年 07 月 29 日 09 点 06 分至 10 点 00 分预测效果对比

更为明显,较改进前更完整、清晰地预测了强回波形态、强度。该个例在阈值为 30 dbz 时,0.5 h、1 h 的预测命中率为 73%和 62%,较改进前分别提升 29%、32%;阈值为 40 dbz 时,0.5 h、1 h 的预测命中率为 37%和 17%,较改进前分别提升 36%、17%,虚警率皆低于改进前。不过也应注意到,改进后模型虽然在回波细节预测上优于改进前,但与观测实况仍有一定差距,而且预测细节与实际图像的差异随着预测时间的变长逐渐加大,外推时间越长,细节丢失也越来越多。

图 4 展示了非测试集个例 2020 年 05 月 21 日 07 点 00 分到 07 点 54 分雷达回波预测效果对比情况,该个例是一次小弓形回波引发的海上大风过程。弓形回波是指快速移动的向着运动方向凸起的,形如弓的强对流回波。弓形回波的空间尺度大小不一,小的弓形回波长度仅几十公里,有的可达上百公里。弓形回波是由后侧强烈的下沉气流造成的。显著弓形回波在低层反射率因子图上除了形如弓形外,

弓形回波前沿存在高的反射率因子梯度,在较强回波带后侧有弱回波通道或者后侧入流缺口<sup>[21-22]</sup>。由图 4 中未来 1 h 的真实回波可见,图像上方持续存在一小弓形回波,并逐渐自左向右移动,改进后模型对回波整体形态预测更为准确,对于图像上部的回波强度、形态和移动趋势预测效果更优,能够更为明显地呈现出小弓形回波的形态特征和强度。该个例在阈值为 30 dbz 时,0.5 h、1 h 的预测命中率为 41%和 29%,较改进前分别提升 13%、11%;阈值为 40 dbz 时,0.5 h、1 h 的预测命中率为 27%和 18%,较改进前分别提升 15%、13%,虚警率皆低于改进前。

图 5 为非测试集个例 2022 年 06 月 12 日 15 点 00 分至 15 点 54 分雷达回波预测效果对比,该个例在未来 1 h 的真实雷达回波中存在两个小带状回波。由图 5 中可见,未来 1 h 的真实雷达回波中左侧带状回波形态较为稳定,且维持了较高的强度,右侧的带状回波则逐渐变弱、消散,原始模型预测左侧带状回波逐渐消散、右侧回波维持,而改进

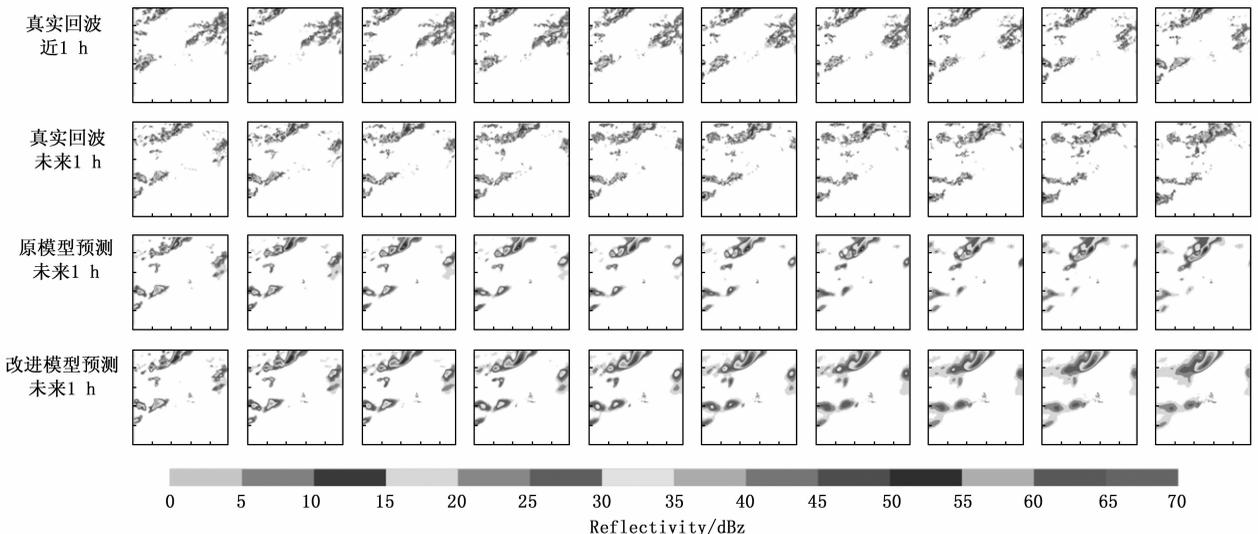


图 4 模型改进前后 2020 年 05 月 21 日 07 点 00 分至 07 点 54 分预测效果对比

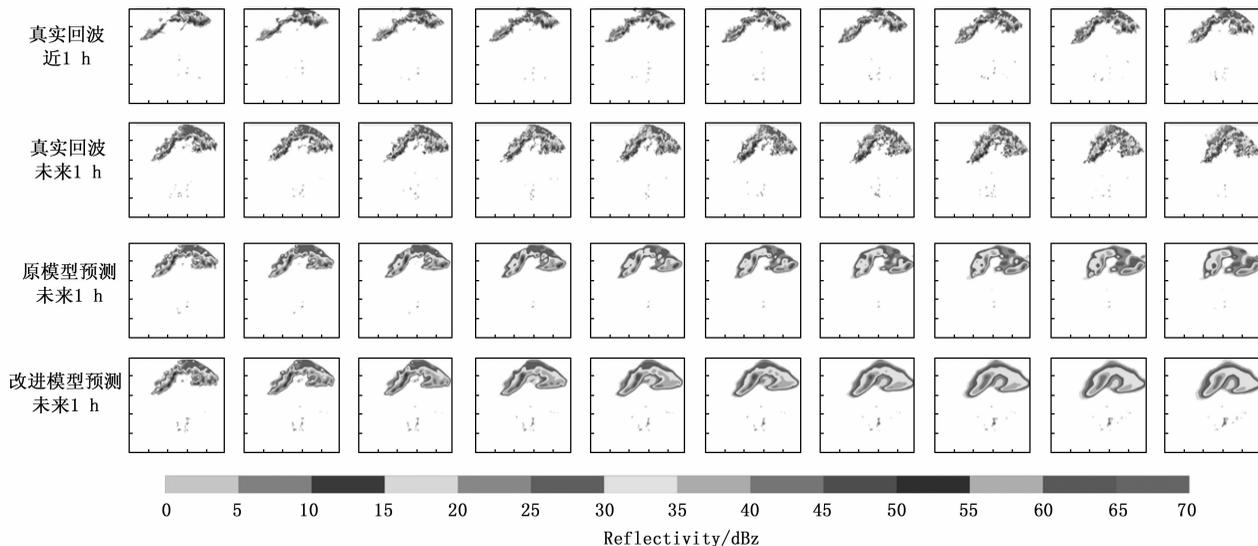


图 5 模型改进前后 2022 年 06 月 12 日 15 点 00 分至 15 点 54 分预测效果对比

后模型则较准确地预测了未来 1 h 左下角回波一直保持较高强度、右下角回波逐渐减弱的变化趋势，与实况更为一致。该个例在阈值为 30 dbz 时，0.5 h、1 h 的预测命中率分别为 76% 和 73%，较改进前分别提升 18%、36%；阈值为 40 dbz 时，0.5 h、1 h 的预测命中率分别为 30% 和 14%，较改进前皆提升 6%，0.5 h 预测的虚警率与改进前相当，1 h 预测的虚警率较改进前分别降低 18%、19%。

#### 4 结束语

本文基于深度学习模型 ConvLSTM，提出了从输入数据格式和损失函数两方面改进的雷达回波外推模型构建思路，通过沧州雷达观测站 4 年的历史数据对模型进行训练得到了可利用近 1 h 雷达观测数据预测未来 1 h 雷达回波的模型。测试集和非测试集典型个例检验结果表明，改进模型对于强回波的预测能力明显提升，预测的雷达强回波形态、强度、位置相比改进前与实况具有更高的相似性，能够为临近预报提供一定的参考。但改进模型在回波强度最大值、形态细节等方面的预测结果距离雷达真实观测仍有一定差距，同时，随着预测时间的增长，预测值与真实观测值的差异也逐渐加大，而且在外推预报的雷达数据产品方面，本研究仅探索了对反射率因子数据的预测，对于雷达观测数据中对大风预报也有较好指示意义的径向速度数据的预测尚未涉及。训练数据的质量和用于预测的模型均会对预测效果的提升产生影响，更丰富的预报产品也将为预报能力提升提供更好支撑，因此，下一步将继续开展基于更丰富和更高质量训练数据、增加注意力机制的深度学习模型以及关于雷达径向速度观测数据产品预测等方面的研究，进一步优化预测模型设计，丰富预测产品种类，提升预测效果，以便为大风临近预报提供更好支撑。

#### 参考文献:

[1] 王彦, 唐熠, 赵金霞, 等. 天津地区雷暴大风天气雷达产

品特征分析 [J]. 气象, 2009, 35 (5): 91-96.  
 [2] 郭庆利, 薛龚波, 党英娜. 渤海海峡雷雨大风的多普勒雷达回波特征 [J]. 海洋预报, 2011, 28 (1): 13-18.  
 [3] 郭鸿鸣, 费杰, 李燕, 等. 一次渤海“切变线”诱发强对流天气监测及可预报性探讨 [J]. 海洋预报, 2016, 33 (6): 93-102.  
 [4] 王亚男, 刘一玮, 易笑园. 渤海西部雷雨大风统计特征及对流参数指标分析 [J]. 气象, 2020, 46 (3): 325-335.  
 [5] 陈明轩, 俞小鼎, 谭晓光, 等. 对流天气临近预报技术的发展与研究进展 [J]. 应用气象学报, 2004, 15 (6): 754-766.  
 [6] 俞小鼎, 周小刚, 王秀明. 雷暴与强对流天气临近预报技术进展 [J]. 气象学报, 2012, 70 (3): 311-337.  
 [7] 程丛兰, 陈明轩, 王建捷, 等. 基于雷达外推临近预报和中尺度数值预报融合技术的短时定量降水预报试验 [J]. 气象学报, 2013, 71 (3): 397-415.  
 [8] 陈雷, 戴建华, 陶岚. 一种改进后的交叉相关法 (CO-TREC) 在降水临近预报中的应用 [J]. 热带气象学报, 2009, 25 (1): 117-122.  
 [9] 张蕾, 魏鸣, 李南, 等. 改进的光流法在回波外推预报中的应用 [J]. 科学技术与工程, 2014, 14 (32): 133-137, 148.  
 [10] 郑永光, 周康辉, 盛杰, 等. 强对流天气监测预报预警技术进展 [J]. 应用气象学报, 2015, 26 (6): 641-657.  
 [11] 韩丰, 龙明盛, 李月安, 等. 循环神经网络在雷达临近预报中的应用 [J]. 应用气象学报, 2019, 30 (1): 61-69.  
 [12] 王改利, 赵翠光, 刘翠平, 等. 雷达回波外推预报的误差分析 [J]. 高原气象, 2013, 32 (3): 874-883.  
 [13] 陈明轩, 王迎春, 俞小鼎. 交叉相关外推算法的改进及其在对流临近预报中的应用 [J]. 应用气象学报, 2007, 18 (5): 690-701.  
 [14] 郭尚贇, 肖达, 袁行远. 基于神经网络和模型集成的短时降雨预测方法 [J]. 气象科技进展, 2017, 7 (1): 107-113.  
 [15] SHI X J, CHEN Z R, WANG H, et al. Convolutional LSTM Network: A Machine Learning Approach for Precipita-

tion Nowcasting [C] //Proceedings of the 28th International Conference on Neural Information Processing Systems. Cambridge, MA: MIT Press, 2015, 1: 802-810.

[16] 施恩, 李骞, 顾大权, 等. 基于卷积神经网络的雷达回波外推方法 [J]. 计算机应用, 2018, 38 (3): 661-665.

[17] 郭瀚阳, 陈明轩, 韩雷, 等. 基于深度学习的强对流高分辨率临近预报试验 [J]. 气象学报, 2019, 77 (4): 715-727.

[18] 黄兴友, 马玉蓉, 胡苏蔓, 等. 基于深度学习的天气雷达回波序列外推及效果分析 [J]. 气象学报, 2021, 79 (5): 817-827.

[19] 于志明, 周艳军, 王驹. 渤海西岸两次强对流天气特征分

析 [J]. 海洋预报, 2017, 34 (1): 57-65.

[20] 李延江, 陈小雷, 景华, 等. 渤海强对流天气监测及概念模型初建 [J]. 海洋预报, 2013, 30 (4): 45-53.

[21] 王福侠, 俞小鼎, 裴宇杰, 等. 河北省雷暴大风的雷达回波特征及预报关键点 [J]. 应用气象学报, 2016, 27 (3): 342-351.

[22] 杨璐, 陈明轩, 孟金平, 等. 北京地区雷暴大风不同生命周期内的雷达统计特征及预警提前量分析 [J]. 气象, 2018, 44 (6): 802-813.

[23] 尹麒名, 甘建红, 漆慧, 等. 一种改进的循环神经网络雷达图像外推算法 [J]. 气象科技, 2021, 49 (1): 18-24.

(上接第 149 页)

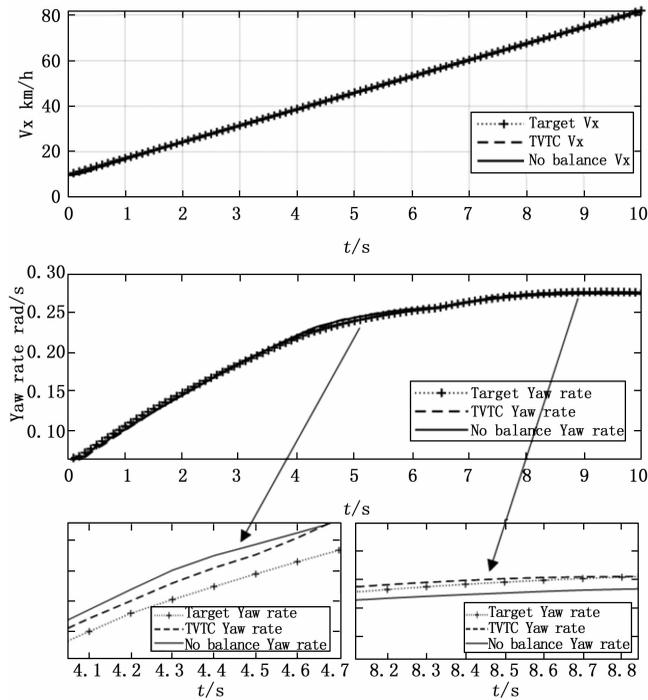


图 14 有无扭矩调整车响应对比

3) 前馈环节有利用减小横摆响应时间, 反馈环节有利于减小目标跟踪误差, 提高控制跟踪精度及抗干扰能力;

4) 左右侧电机扭矩受限时, 可通过建立合理的左右扭矩协调机制, 可在适当降低总驱动力的同时使附加横摆力矩保持在误差范围内, 保证整车的横摆响应, 提高车辆的安全性能。

参考文献:

[1] 余卓平, 冯源, 熊璐. 分布式驱动电动汽车动力学控制发展现状综述 [J]. 机械工程学报, 2013, 49 (8): 105-114.

[2] GLASER H. Electronic Stability Program ESP [R]. Lycksele: Audi Press Presentation, 1996.

[3] PACEJKA H. Tire and vehicle dynamics (3rd Edition) [M]. Elsevier, 2012: 103-105.

[4] 郭孔辉. 汽车操纵动力学原理 [M]. 南京: 江苏科学技术出版社, 2011.

[5] 张琳. 分布式驱动电动汽车状态估计与力矩矢量控制研究 [D]. 长春: 吉林大学, 2020.

[6] 李小雨. 复合工况下分布式驱动电动汽车失稳机理及操纵稳定性控制研究 [D]. 长春: 吉林大学, 2020.

[7] 陈禹行. 分布式驱动电动汽车直接横摆力矩控制研究 [D]. 长春: 吉林大学, 2013.

[8] MIRZAEI M. A new strategy for minimum usage of external yaw moment in vehicle dynamic control system [J]. Transport Res Part C: Emerg Technol, 2010, 18 (2): 213-224.

[9] BREDTHAUER LANCE, LYNCH DAVID. Use of Active Rear Steering to Achieve Desired Vehicle Transient Lateral Dynamics [J]. SAE Technical Paper 2018-01-0565, 2018: 100-103.

[10] 余志生. 汽车理论 [M]. 北京: 机械工业出版社, 2000.

[11] 周佳. 四轮转向系统控制策略对比研究 [D]. 北京: 北京理工大学, 2015.

[12] 赵立军, 邓宁宁, 罗念宁, 等. 基于直接横摆力矩的四轮转向/驱动滑模控制 [J]. 华南理工大学学报, 2015, 43 (8): 69-74, 81.

[13] ZHU T, JIN X J, YIN G D, et al. Coordinated Control for Active 4WS Vehicle Based on Linear Quadratic Differential Game [C] // 第 31 届中国控制与决策会议论文集 (5), 南昌: 第 31 届中国控制与决策会议, 2019, 5551-5555.

[14] 余卓平, 高晓杰, 张立军. 用于车辆稳定性控制的直接横摆力矩及车轮变滑移率控制 [J]. 汽车工程, 2006 (9): 844-848.

[15] 丁海涛. 轮胎附着极限下汽车稳定性控制的仿真研究 [D]. 长春: 吉林大学, 2003.

[16] 许男. 复合工况下轮胎稳态模型研究 [D]. 长春: 吉林大学, 2012.

[17] 邹广才, 罗禹贡, 李克强. 四轮独立电驱车辆全轮纵向力优化分配方法 [J]. 清华大学学报: 自然科学版, 2009, 49 (5): 719-722.

[18] 李志魁. 基于 CarSim 的整车动力学建模与操纵稳定性仿真分析 [D]. 吉林大学, 2007.

[19] 熊焱飞, 凌和平, 文婷, 等. 分布式驱动电动汽车扭矩矢量控制仿真与验证 [J]. 汽车工程师, 2016, 10: 33-37.

[20] 杨鄂川, 王滕, 张勇, 等. 汽车转向盘角阶跃输入下的瞬态响应仿真分析与优化 [J]. 西南大学学报 (自然科学版), 2016, 38 (6): 165-171.