arXiv:2303.10183v1 [cs.LG] 17 Mar 2023

文章

一种用于预测空间物体非受控再入的机器学习与特征工程方法

Francesco Salmaso 1、Mirko Trisolini [1]* 和 Camilla Colombo [1]

[1] 米兰理工大学空间科学与技术系，La Masa 路 34 号，10156，米兰，意大利 ly
* 通讯作者：mirko.trisolini@polimi.it

摘要： 预计，环绕地球运行的空间物体数量持续增长，也将伴随再入地球大气层的物体越来越频繁。这些再入事件中有许多将是非受控的，因此难以预测，且存在多种不确定性。传统上，再入预测基于采用针对作用于物体的力的先进建模技术，对物体动力学进行传播。然而，建模误差，尤其是与大气阻力预测相关的误差，可能导致预测精度较差。在此背景下，我们探讨从基于物理的方法转向数据驱动方法的范式转变的可能性。为此，我们介绍一种深度学习模型的开发，用于预测低地球轨道（LEO）非受控物体的再入。该模型基于改进版的序列到序列架构，并利用来自 400 多个天体的一组两行根数（TLE）数据推导出的平均高度剖面进行训练。本研究的创新之处在于，在深度学习模型中，除平均高度外，还引入了三个新的输入特征：类阻力系数（B^*）、平均太阳指数以及物体的面积质比。我们使用机构间空间碎片协调委员会（IADC）活动中研究的一组物体对该模型进行测试。结果表明，对于类阻力系数和偏心率分布与训练集相同的天体，模型表现最佳。

关键词： 再入预测；机器学习；深度学习；特征工程；非受控再入

check for updates

C引文： Salmaso, F.; Trisolini, M.; Colombo, C. 一种机器学习与feature工程方法，用于p预测失控re -太空物体再入。预印本**022**, **2***1*, 0。https://doi.org/

P

出版商说明： MDPI在已发表地图和机构附属关系中涉及的管辖权主张方面保持中立。

版权声明： © 2022 作者所有。许可方MDPI，瑞士巴塞尔。本文为开放获取文章，依据知识共享署名（CC BY）许可协议（https://creativecommons.org/licenses/by/ 4.0/）的条款和条件发布。

1. 引言

自1957年10月 4^{th} 首次发射人造卫星以来，绕地球运行的天体数量持续增长，呈指数趋势[1]。此外，近年来，为电信、导航和全球互联网覆盖而建立的大型星座使这一增长进一步加剧。为保护低地球轨道（LEO）区域并鼓励尽早处置卫星，相关方制定了任务后处置指南 [2,3]，以免卫星对已经受到污染的轨道环境造成影响。聚焦于再入问题，截至2022年3月，共有26135个天体再入大气层[1]。根据Pardini等人 [5], 的数据，自2013年4月以来，完整物体的再入事件中只有五分之一受到控制，其总质量约为11000公吨，主要涉及火箭箭体和航天器。因此，轨道物体数量持续增长，预计也会导致受控和非受控物体的再入数量增加。然而，预测非受控物体的再入时刻和地点仍然至关重要，因为这受到多种不确定性影响，可能导致地面人员伤亡风险 [5]。

在典型的基于动力学的方法中，为解决再入预测问题，会对航天器的轨迹进行传播，直至其到达解体发生时的高度。这

[1] www.space-track.org

种方法包括确定物体的初始位置，并准确地对作用于其上的力进行建模，以预测其轨迹的演变。然而，通常很难准确地对作用于航天器的力进行建模，也难以精确了解其物理特性和状态。事实上，对于再入预测，通常建议采用的相对不确定性值为±20% [6,7]。 [5] 对再入预测中的各种不确定性来源进行了深入综述，其中最重要的是阻力加速度的建模。太阳辐射压和日月引力等其他力也会影响再入动力学。不过，在这项工作中，我们聚焦于低偏心率轨道再入预测的最后阶段；因此，主要作用力是大气阻力，主要不确定性则与大气密度有关。大气密度通过经验模型进行建模，这些模型描述了密度在空间和时间尺度上的变化 [8–12]。然而，这些模型受到两类不确定性的影响 [11]：一是其所依据的简化物理建模；二是空间天气预测中的不确定性和复杂性，尤其是太阳指数。低偏心率轨道预测中的另一个重要变量是研究对象的弹道系数。弹道系数取决于物体的形状、方向和姿态；对于非受控物体，这些特征可能难以准确获知。

在这种情况下，采用范式转变，从物理视角转向数据驱动视角来建模这一问题，便显得颇有意义。在此背景下，机器学习代表了一种新方法：它不再试图精确建模空间环境、环境中的作用力及航天器与这些作用力的相互作用，而是基于数据自主构建知识，并自主应对这一现象的复杂性与不确定性。Jung 等人 [13] 提出了一种基于循环神经网络（RNN）的机器学习方法，用于预测失控卫星的再入时刻。他们的研究使用一组两行根数集训练 RNN，唯一采用的特征是目标平均高度的变化过程。两行根数集除了其他信息外，还提供了在轨编目目标位置随时间变化的信息。然而，正如 Lidtke 等人 [14], 也指出的那样，两行根数存在一些必须考虑的误差。最值得注意的是，同一目标的两行根数并不一致；它们可能以不规则的时间步提供，也可能包含错误观测或属于其他目标的观测（离群值）。此外，两行根数并不直接提供目标的物理特性信息（例如弹道系数），而是将所有不确定性和建模误差综合到一个单一的类阻力系数中，记作 B^* [9,10]。最后，两行根数不包含其所提供测量值的精度信息，也就是说，它们不提供协方差信息。然而，目前两行根数集是唯一可用于再入预测的公开数据来源。因此，尽管存在局限和误差，本研究仍使用这些数据来评估采用多种输入特征的机器学习方法的能力。正如 [15],所示，可利用伪观测值估计初始协方差信息；而两行根数数据的精度也可以得到提升，如 [16,17]所示。尽管本研究着重于将机器学习技术应用于原始两行根数数据，但未来的研究可以通过纳入此类信息来提高再入预测的精度。

基于 Jung 等人 [13], 的研究，我们扩展了机器学习模型，并引入了额外特征，即类阻力系数 B^* 和太阳指数。第一项特征使机器学习模型能够考虑物体的物理特性，而第二项特征则为模型提供时间维度，使其能够考虑不同的太阳活动水平及其对物体寿命的影响。所开发的模型使用数百组属于非受控物体（如废弃有效载荷、火箭箭体和碎片）的两行根数集进行训练。因此，同一模型可用于测试不同的物体，以获得输出序列并评估其准确性。

本文结构如下。第 2 节介绍所采用的深度学习模型架构，第 3 节介绍深度学习模型所需数据的预处理和筛选流程，第 4 节分析模型输入特征的特性，第 5 节展示模型在选定测试案例上取得的结果，以及模型超参数的优化流程。

2. 深度学习模型

从机器学习的角度来看，预测物体再入是一项时间序列问题。模型旨在根据一组初始条件预测轨迹的演变，从而确定再入时刻。换句话说，这是一个回归问题。时间序列是离散时间数据，可视为序列数据的一种特殊案例，其中每个值都与一个时间戳相关联。因此，序列的顺序由时间维度决定，必须予以保留。设长度为 T_x 的输入序列为 [18]:

$$\boldsymbol{x} = \{\boldsymbol{x}^{<1>}, \boldsymbol{x}^{<2>}, ..., \boldsymbol{x}^{<T_x>}\} \tag{1}$$

其中，向量 $\boldsymbol{x}^{<t>} \in \mathbb{R}^p$ 包含时间步 t 的输入特征。此外，设长度为 T_y 的目标序列为 [18]:

$$\boldsymbol{y} = \{y^{<1>}, y^{<2>}, ..., y^{<T_y>}\} \tag{2}$$

其中，$y^{<t>} \in \mathbb{R}$ 是目标特征。我们将预测序列定义为 [18]:

$$\hat{\boldsymbol{y}} = \{\hat{y}^{<1>}, \hat{y}^{<2>}, ..., \hat{y}^{<T_y>}\} \tag{3}$$

深度学习问题的目标是预测目标序列，同时最小化损失函数；本研究中，损失函数选用均方误差（MSE）[18]:

$$\mathcal{L}_{MSE}(\boldsymbol{y}, \hat{\boldsymbol{y}}) = \frac{1}{T_y} \sum_{t=1}^{T_y} \left(y^{<t>} - \hat{y}^{<t>}\right)^2 \tag{4}$$

在此情境下选择均方误差（MSE）是很自然的，因为它与欧几里得距离相似。事实上，均方误差可以直观地看作真实位置与预测位置之间的距离平方，再除以输出序列中的观测数量。

2.1. 序列到序列架构

在这项工作中，我们选择了序列到序列（Seq2Seq） [19] 架构来建模再入问题，因为它能够处理长度不同的输入序列和输出序列。如图所示 1 ，Seq2Seq架构由两个神经网络（编码器和解码器）以及上下文向量组成。编码器接收一个长度任意的序列作为输入，T_x，并生成一个固定长度的向量，称为上下文向量。该向量概括了输入序列中包含的信息。解码器的输出会被直接舍弃。在每个时间步，单元根据同一时间步的输入和前一时间步的隐藏状态生成隐藏状态 [20]:

$$\boldsymbol{h}_{Enc}^{<t>} = f(\boldsymbol{x}^{<t>}, \boldsymbol{h}_{Enc}^{<t-1>}, \boldsymbol{\theta}) \tag{5}$$

其中 $\boldsymbol{h}^{<t>}_{\text{编码器}}$ 表示编码器在时间步 t 的隐藏状态，$\boldsymbol{h}^{<t-1>}_{\text{编码器}}$ 表示前一时间步的隐藏状态，$\boldsymbol{x}^{<t>}$ 表示当前时间的输入向量， $\boldsymbol{\theta}$表示权重向量。函数 f 表示一个神经网络，可以是简单的循环神经网络

（循环神经网络） [21,22] 或更复杂的门控循环单元 [20,21,23] 或长短期记忆网络 [20,21]网络。在最后一个时间步 T_x，编码器的隐藏状态定义为上下文向量，如下所示：

$$\boldsymbol{c}_{context} = \boldsymbol{h}_{Enc}^{<T_x>} \tag{6}$$

解码器以编码器的最终状态 $\boldsymbol{h}^{<t'=0>Dec} = \boldsymbol{c}_{context}$ 初始化。解码器的目标是基于这个编码向量生成输出序列。在每个时间步$t' \in [1,T_y]$，给定隐藏状态和前一时间步$t'-1$的输出，解码器隐藏状态可定义如下 [20]:

$$\boldsymbol{h}_{Dec}^{<t'>} = g(\hat{y}^{<t'-1>}, \boldsymbol{h}_{Dec}^{<t'-1>}, \boldsymbol{\theta}') \tag{7}$$

其中，$g(\cdot)$ 同样可以是简单循环神经网络、门控循环单元或长短期记忆网络。随后，将解码器相应的输出传递给输出层，即可得到输出 $\hat{y}^{<t'>}$ 。请注意，时间$t' = Ty$ 的隐藏状态会被直接舍弃。

训练期间，解码器会接收自身前一隐藏状态以及真实输入，或前一时间步的预测输出，以依次生成新状态和输出。当仅向解码器提供“真实输入”时，这种训练方法称为教师强制 [21]。因此，在这种方法中，模型的预测输出会被我们的参考数据替代，而参考数据被视为真实值。然而，这种方法会导致训练阶段与推理阶段之间存在差异：推理阶段网络以开环方式运行，这可能会引入预测误差，因为网络无法从自身的错误中学习。为缓解这一问题，Bengio等人 [24] 提出了一种称为课程学习的方法。该方法根据训练周期，以一定概率随机选择前一真实输出或模型估计值。直观地说，在训练初期，模型尚未充分训练，可能会产生误差，因此应采用教师强制进行训练。相反，在训练后期，模型预计已训练充分，因此可以像推理时那样使用模型输出。具体而言，对于第j-th 个历元的每个批次中要预测的输出$y^{<t'>}$，通过抛硬币决定输入前一真实输出（其概率为 ϵ_j）还是模型估计值（其概率为$(1-\epsilon_j)$）。鉴于此处数据集规模相当小、训练轮次较多，概率设为训练周期的函数，而不是迭代次数 [24],:

$$\epsilon_j = k^j \tag{8}$$

其中 $k < 1$ 是一个常数，取决于收敛速度，也就是计划采样的衰减率。

训练过程中序列到序列模型的表示如图 1 所示，其中 $\boldsymbol{x}^{<t>}$表示输入序列的各个时间分量；$\hat{y}^{<t>}$ 表示预测输出；而 $y^{<t>}$ 表示真实值。

2.1.1. 门控循环单元

在本研究中，编码器和解码器均基于门控循环单元（GRU）[23], ，这是因为它们能够处理简单循环神经网络在长序列训练中所面临的梯度消失问题。它可以视为长短期记忆网络的简化版本，并且具有降低计算成本的优势，同时还能提供相当的性能 [25]。在每个时间步，GRU 计算：

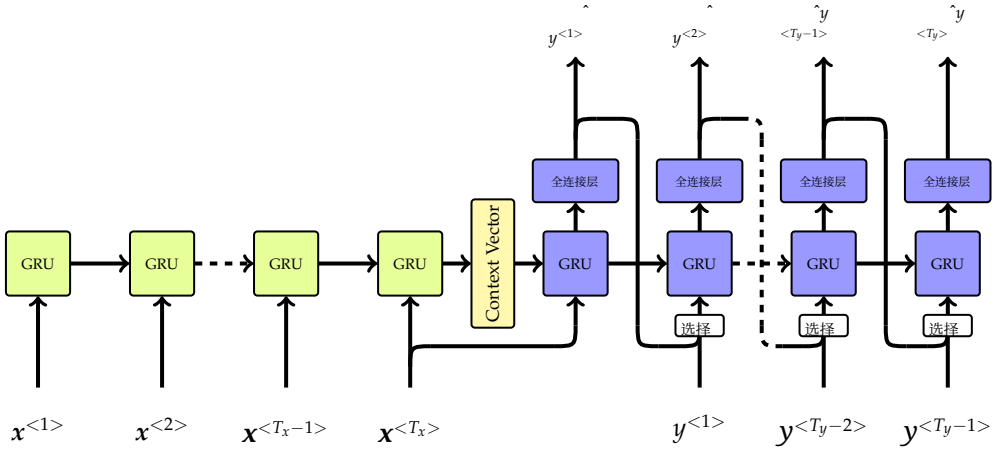


图 1. 训练期间 Seq2Seq架构的表示。

$$\mathbf{z}^{<t>} = \sigma\left(\mathbf{W}_z\mathbf{x}^{<t>} + \mathbf{V}_z\mathbf{c}^{<t-1>} + \mathbf{b}_z\right) \tag{9}$$

$$\mathbf{r}^{<t>} = \sigma\left(\mathbf{W}_r\mathbf{x}^{<t>} + \mathbf{V}_r\mathbf{c}^{<t-1>} + \mathbf{b}_r\right) \tag{10}$$

$$\tilde{\mathbf{c}}^{<t>} = \tanh\left(\mathbf{W}_c\mathbf{x}_t + \mathbf{V}_c\left(\mathbf{r}^{<t>} \odot \mathbf{c}^{<t-1>}\right) + \mathbf{b}_c\right) \tag{11}$$

$$\mathbf{c}^{<t>} = \left(1 - \mathbf{z}^{<t>}\right) \odot \tilde{\mathbf{c}}^{<t>} + \mathbf{z}^{<t>} \odot \mathbf{c}^{<t-1>} \tag{12}$$

其中，$\mathbf{W}_z$、$\mathbf{W}_r$、$\mathbf{W}_c \in \mathbb{R}^{k\times p}$ 表示输入权重矩阵；$\mathbf{V}_z$、$\mathbf{V}_r$、$\mathbf{V}_c \in \mathbb{R}^{k\times k}$ 表示隐藏状态权重；$\mathbf{b}_z$、$\mathbf{b}_r$、$\mathbf{b}_c \in \mathbb{R}^k$ 表示偏置向量；$\odot$ 表示逐元素乘积；σ（·）和 tanh（·）分别表示 Sigmoid 函数和双曲正切函数。变量 $\mathbf{z}^{<t>} \in \mathbb{R}^k$ 和 $\mathbf{r}^{<t>} \in \mathbb{R}^k$ 分别表示更新门和重置门，它们有助于解决梯度消失问题。它们的作用是控制需要从过去时间步传递下来的信息量。具体而言，更新门负责更新旧状态，通过控制新状态与过去状态之间的相似度来实现。重置门负责设定需要遗忘的信息量。因此，门的值通过 Sigmoid 函数限制在 0 到 1 之间。输出隐藏状态分两步计算。首先，根据公式（11）计算候选记忆单元 $\tilde{\mathbf{c}} \in \mathbb{R}^k$。其输入包括前一隐藏状态（与重置门相乘）以及当前输入。根据重置门各项的取值，可以确定两种极端情况。当其值接近 1 时，前一时间步的信息会像在简单循环神经网络中一样向前传递。相反，当其值接近 0 时，前一时间步的信息会被忽略。得到候选记忆单元后，即可根据公式（12）计算变量 $\mathbf{c} \in \mathbb{R}^k$，称为记忆单元。记忆单元以当前候选值和前一记忆单元为输入，并且仅受重置门控制。在这种情况下，当重置门各项接近 0 时，新的记忆单元会用候选值更新，这意味着前一时间步的信息会被丢弃。相反，当门的值接近 1 时，候选值会被直接丢弃，而记忆单元保持原有状态。最后，隐藏状态和 GRU 的输出可分别定义为：

$$h^{<t>} = c^{<t>}_{context} \tag{13}$$
$$\hat{o}^{<t>} = c^{<t>}_{context} \tag{14}$$

GRU 的计算流程图总结见图2。

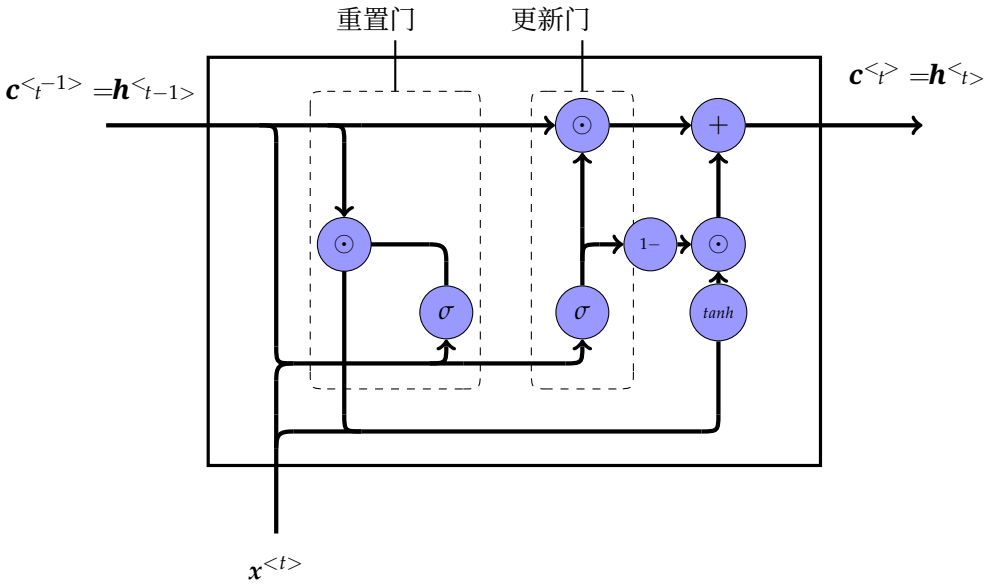


图 2. 门控循环单元架构的计算流程。

序列到序列模型基于 TensorFlow [26], 构建。TensorFlow 是由谷歌开发的广泛使用的机器学习和深度学习开源库。TensorFlow 使用自动微分自动计算模型权重对应的梯度，使模型训练变得简单直接。TensorFlow 的高级接口由 Keras [27], 提供。Keras 是一个*Python*库，可用于构建、训练和测试神经网络。

3. 数据预处理

用于训练和验证深度学习模型的原始数据取自 Space Track[1]。具体而言，研究考虑了 2000 年 1 月至 2021 年 10 月期间所有可获取跟踪与碰撞预测（TIP）数据的衰减目标。两行根数数据以轨道平均根数消息（OMM）的形式获取；获得原始两行根数数据后，需要对数据质量进行检查，并剔除可能的离群值。根据 [14], , 可通过关注平均运动和B^* 系数来查找离群值。剔除过程的主要步骤如下：

1. 通过设定时间阈值来识别是否存在两行根数修正，使先前的观测被视为不正确。常见的时间阈值为半个轨道周期。2. 识别连续两行根数之间较大的时间间隔，并据此将整个数据集划分为不同的窗口，以确保两行根数的一致性。3. 基于稳健线性回归技术和固定长度的滑动窗口，找出并筛除平均运动值不一致的单条两行根数。具体而言，将滑动窗口回归所得结果与 OMM 进行比较；若相对容差和绝对容差均超出阈值，则识别为异常值（滤波器的最优调优参数见 [14] 中的表 3 ）。

4. 使用统计方法识别并筛除偏心率和倾角中的潜在异常值。具体而言，在滑动窗口内计算均值，并从区间中心的轨道根数中减去该均值，从而得到一个差值时间序列。随后，使用另一个滑动窗口扫描上述差值序列，并计算平均绝对偏差。如果某个轨道根数与均值的差值超过给定阈值，则将其作为异常值移除（滤波器的最优调优参数见表4和表 5 中的[14]）。

5. 筛除 B^* 值为负的两行根数，因为这可能与未建模动力学或机动有关。

有关筛选器及其性能的完整说明，以及筛选器参数的最佳调优方法，请参阅 Lidtke 等人的研究。 [14]值得注意的是，这些筛选器可能无法识别某些离群值；不过，离群值的比例被认为足够小，不会影响数据的有效性。筛选后，使用 SGP4 传播器将两行根数中的平均根数转换为相应的瞬时变量 [10]。此外，还需考虑数据集的其他特征。具体而言，我们关注的是两行根数数据点数量充足且再入预测精度足够高的再入事件。两行根数数据点的最小数量是通过权衡筛除的两行根数数量与拟合过程的精度确定的（见第4.1节） [29]。此外，轨道的偏心率不应过高，因为此类轨道的再入机制会发生显著变化。筛选数据集时采用了以下标准：

- 最大再入不确定性：20 分钟。
- 初始两行根数的最大平均高度：200千米。
- 最终两行根数的最小平均高度：180 千米。
- 最大偏心率：0.1。
- 最少点数：4 个两行根数。

所述标准采用平均高度 h，其计算方式如下：

$$h = a - R_{\oplus}, \tag{15}$$

其中 a 为瞬时半长轴；$R_{\oplus}$ 为地球半径。经过这一剪枝和筛选流程后，得到一个包含 417 个天体的数据集，随后将其按 80% 用于训练、20% 用于验证的比例进行划分（见附录 A）。请注意，验证集中的对象应与训练集的特征相似。例如，训练集和验证集的 μ平均值 σ及 σ相对标准差 σ，以及 B^* 系数和偏心率应具有可比性（表 1）。

变量		训练集	验证集
偏心率 [-]	μ	$7.2842 \cdot 10^{-3}$	$5.8856 \cdot 10^{-3}$
	σ	$9.3963 \cdot 10^{-3}$	$7.1684 \cdot 10^{-3}$
B^* [1/地球半径]	μ	$6.3362 \cdot 10^{-4}$	$5.9503 \cdot 10^{-4}$
	σ	$5.4924 \cdot 10^{-4}$	$3.8341 \cdot 10^{-4}$

表 1. B^* 训练集和验证集的特征及偏心率。

此外，两组数据的再入时刻都相当均匀地分布在约2005年1月至2021年4月之间，因此不同天体经历了不同的太阳通量条件，也因此具有相近的阻力加速度值（图3）。最后需要指出的是，训练集和验证集中的大多数天体都具有以下特征

再入时刻的不确定性小于 2 分钟。

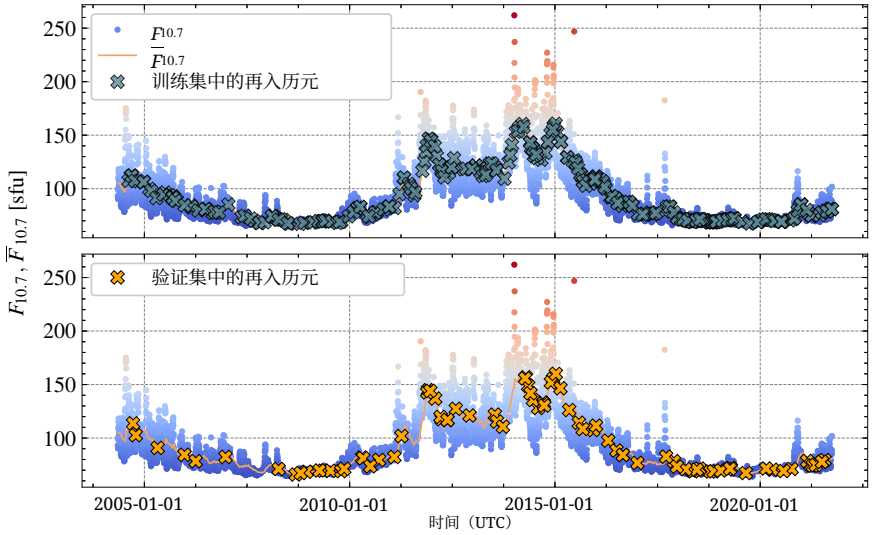


图3。 训练集（上）和验证集（下）中的再入时刻及太阳通量指数。

用于测试模型预测能力的对象选自 IADC 活动期间分析的天体，如表2所列。请注意，23853 和 19045 的再入时刻分别被手动调整为 16:25 协调世界时和 15:08 协调世界时 [7]。

北美防空司令部	Name	**再入时刻** [协调世界时]
23853	COSMOS 2332	2005-01-28T18:05*
26873	CORONAS F	2005年12月6日17:24
10973	COSMOS 1025	2007年3月10日12:56
31599	DELTA 2 R/B	2007年8月16日09:23
31928	EAS	2008年11月3日04:51
20813	闪电3-39	2009年7月8日22:42
11601	SL-3火箭体	2010年4月30日16:44
21701	UARS	2011年9月24日04:00
20638	伦琴卫星	2011年10月23日01:50
37872	福布斯-土壤号	2012年1月15日17:46
19045	宇宙1939号	2014-10-29T15:32*
40138	长征二号丁火箭体	2015-06-13T23:58
39000	长征二号丙火箭体	2016-06-27T19:04
38086	AVUM	2016-11-02T04:43
37820	天宫一号	2018-04-02T00:16

注：标有 * 的训练轮次根据 IADC活动 的指示进行了人工修改。**表2.** 由 TIP 得出的测试对象列表。

4. 特征工程

本节概述了如何筛选和预处理最重要的输入特征，以便使用机器学习模型预测再入时刻。然而，这并非一项简单的任务，因为有必要找到与

深度学习模型输出相关的输入变量。因此，必须从物理角度分析每个特征，以便将这些知识用于构建深度学习模型，使模型能够从每个输入变量中获益。这一过程通常称为特征工程。从这一角度来看，深度学习模型被视为物理模型：给定输入变量后，通过物理关系得到输出。与此不同，在机器学习中，模型被视为黑箱，能够根据真实值和输入特征自主学习输入输出关系。因此，可以基于对支配再入现象的物理原理的认识来选择和生成每个特征，而让深度学习模型负责学习物理问题中的不确定性。通过分析每个特征，可以揭示所考虑变量之间的关系，从而帮助我们更充分地判断所考虑的特征是否有利于深度学习模型 [28,29]。

此外，使用两行根数提供的原始数据，需要经过预处理和正则化，才能用于循环神经网络。事实上，两行根数数据的生成频率并不均匀，且因目标而异；此外，其精度不高，还可能存在异常值。在将数据输入循环神经网络之前，必须考虑所有这些因素。以下各节将分析本研究所考虑特征的作用，包括航天器平均高度、弹道系数、太阳指数以及 B^* 系数。

4.1. 平均高度

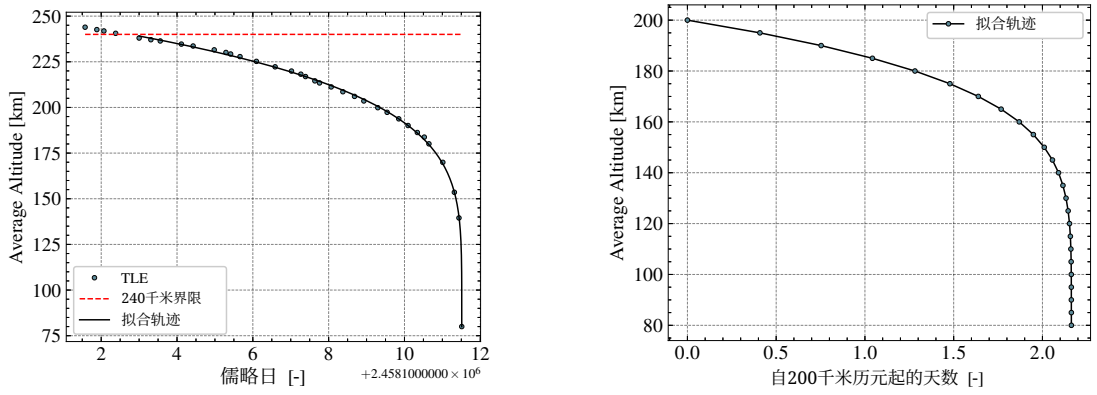
平均高度特征对于深度学习驱动的再入预测至关重要。事实上，它与用于训练循环神经网络的损失函数的定义有关，见式（4）。这意味着，平均高度剖面既作为深度学习模型的输入，也作为其输出：给定平均高度剖面的一部分作为输入，模型便会预测其余部分。平均高度剖面的预处理遵循 Jung 等人的研究[13]。具体而言，根据以下方程，对 240千米以下可用的两行根数进行拟合，以生成每条轨迹：

$$f(t) = a_1 + a_2\left(t_{ref} - t\right)^{\frac{1}{2}} + a_3\left(t_{ref} - t\right)^{\frac{1}{3}} + a_4\left(t_{ref} - t\right)^{\frac{1}{4}} \tag{16}$$

其中，t^{ref} 为再入时间，而a_1, a_2, a_3 和a_4, 是通过 Python 库 SciPy [30]提供的 Levenberg–Marquardt算法进行曲线拟合得到的参数。第一个系数a_1, 等于 80千米，这是提供 TIP消息时采用的参考高度 [7]。这一假设可避免拟合算法改变 TIP消息中的再入时刻，从而确保与两行根数数据保持一致。随后，将对应 200千米高度的历元设为初始历元，因此，从200千米起始高度到 80千米再入之间的时间跨度即为剩余时间。

由于每个物体的剩余时间各不相同，因此将剩余时间表示为平均高度的函数并进行插值会更加方便。为此，我们将所考虑的高度范围（200千米至80千米）细分为包含25个点的均匀网格。因此，每条轨迹均由一系列观测值表示 $\{x_i,\ t_i\}$，其中 $i = 1,\ 2,...25$，其中 x_i 表示平均高度，而t_i 表示相对历元。这样，深度学习模型只需以 t_i 作为输出即可。图 4 展示了对北美防空司令部 27392 号目标执行这一流程所得的结果。图中展示了训练集、验证集和测试集对应的轨迹

如图5所示。可以看出，剩余寿命介于0.5天至3天之间的轨迹较为集中。与此同时，剩余寿命超过6天的轨迹仅有3条，其中仅有两条用于训练。这一点很重要，因为该分布包含弹道系数信息，并且可直接关联到模型的预测能力。我们还注意到，在测试集中，最靠左的轨迹剩余时间约为14分钟，对应闪电3-39航天器。在这种情况下，该轨迹高度椭圆，不符合第3节中定义的筛选标准；不过，为了评估模型处理此类轨迹的能力，我们仍将其纳入测试集。



(a) **(b)**

图 4. 北美防空司令部编号为 27392 的目标再入轨迹拟合结果 (a) 和采样结果 (b) 示例。

在无法预先获知完整轨迹的实际情形中，可使用公式 (16)，并将 t^{ref} 设为最后一个可用两行根数对应的历元。不过，由此得到的曲线将与使用所有可用两行根数得到的曲线不同。因此，我们预计训练集和测试集的性能会存在一定差异。应对此进行进一步分析，因为预测轨迹可能会因所采用的流程及可用两行根数的数量而有所不同。不过，在两行根数数据点数量较多时，这种差异应会减小，例如，在 IADC 活动期间分析的目标就属于这种情况。

4.2. 弹道系数与 B^*

弹道系数 B 对低偏心率轨道的再入至关重要，因为其动力学主要受大气阻力摄动影响。根据公式 (17) 定义的弹道系数 [31], 通过航天器的形状、质量和阻力系数描述其与大气层之间的气动相互作用。

$$B = C_D \frac{A}{m} \tag{17}$$

然而，由于我们使用两行根数数据进行再入预测，因此采用类阻力系数B^*作为弹道系数的替代指标。事实上，B^* 是 SGP4 传播器中引入的系数，而该传播器又用于生成两行根数数据。B^* 的表达式如下 [10]:

$$B^* = \frac{1}{2} \frac{C_D A}{m} \rho_o R_\oplus \tag{18}$$

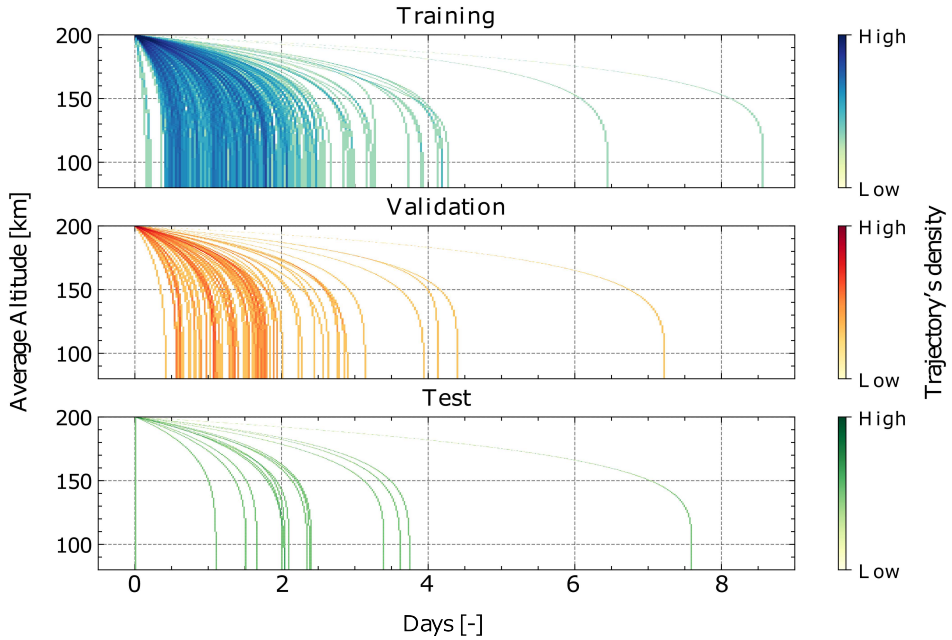


图5。使用拟合和采样程序为训练集（上）、验证集（中）和测试集（下）生成的轨迹。对于给定的再入时间，颜色越深表示轨迹越集中。

其中， ρ_0 是轨道近地点处的大气密度，假设为 2。461 $\times 10^{-5} \mathrm{kg/m^2}$/地球半径，其中地球半径 $= 6375$为 6378.135 km；$R_\oplus$ 表示地球半径，即 6378.135 km。通常，SGP4 公式中的 B^* 系数会吸收各种建模误差。尽管可以根据 B^*求得弹道系数，但二者并不相同。不过，在此情境下，我们假设 B^* 可作为 B 的替代指标，因为我们考虑的是轨道参数相似、会受到相似建模不确定性影响的物体。与平均高度类似，将 B^* 数据预处理后再输入循环神经网络至关重要。处理的第一步是定义一个固定大小的滑动窗口，以生成一系列平均值，其中每一项均为此前所有点的平均值。第二步是应用分段线性插值方案，在两个连续值之间保持前一个值不变。随后，在平均高度处理所确定的历元处对插值曲线进行采样。图6 展示了 NORAD 27392 的上述处理过程。

根据目前生成的特征，可以应用主成分分析，观察 B^*、以天为单位的剩余时间与平均高度之间是否存在预期关系。分析结果汇总于图 7。观察载荷图和第一主成分可见，与时间相关的特征具有较强的正载荷；与此同时，其他特征的载荷均为负。事实上，时间特征可视为剩余寿命的代称，因此随着 B^* 增加，由于阻力加速度增大，物体的寿命会缩短。此外，随着时间推移，高度与时间之间的关系表现为高度下降。

4.3 太阳指数

太阳指数，$F_{10.7}$，是描述太阳辐射强度的参数。它对于预测大气密度的变化非常重要 [10]。两行根数数据不包含大气密度；不过，B^* 也考虑了太阳指数的变化。为突出这种依赖关系，图8 展示了阻力类系数与

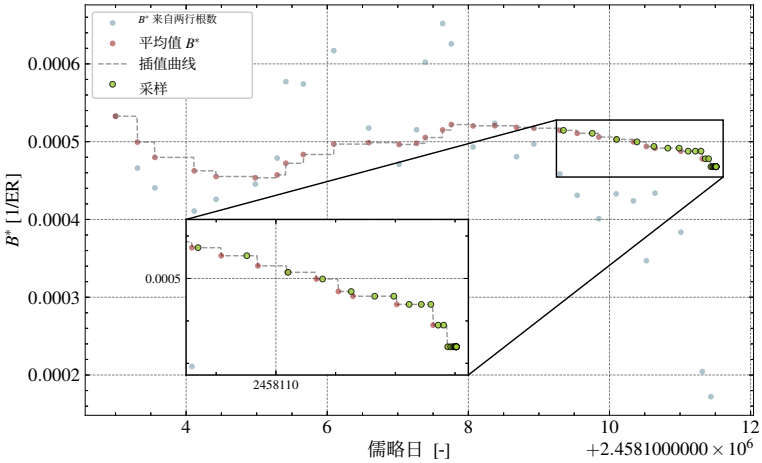


图 6. B^* 特征生成的预处理：采用移动窗口平均进行逐步线性插值。

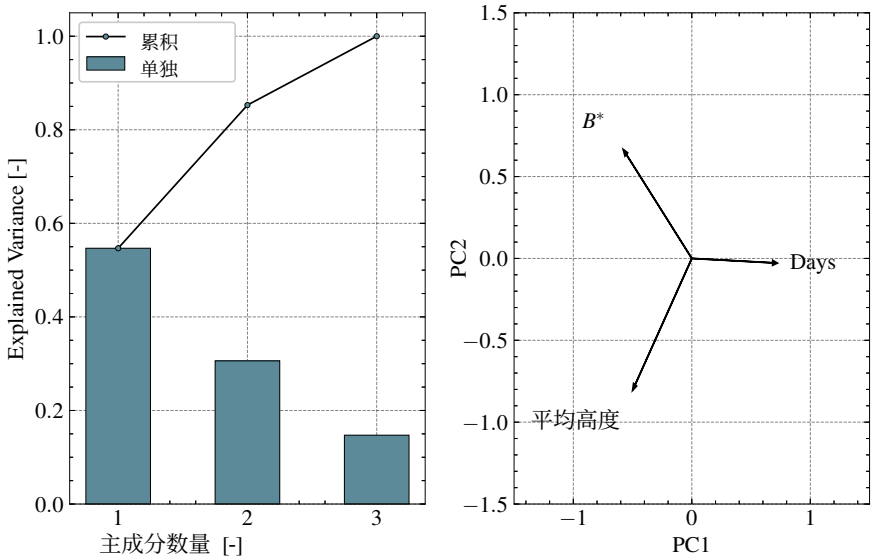


图 7. B^*、剩余时间和高度的方差图（左）与载荷图（右）。

不同天体的太阳指数最近 81 日平均值$F_{10.7}$ 的函数关系。可以观察到，随着$F_{10.7}$ 增大，B^* 呈非线性增长，表明这些变量之间存在关联。此外，B^*各组采用相同颜色，对应相同的$F10.7$ 值；与$F^2_{10}.7$相关的曲线拟合项也体现了这一点。因此，将$F_{10.7}$ 指数作为循环神经网络的一项特征，与面积质比一同输入。作出这一决定是因为模型必须处理B^* 相似但太阳指数截然不同的物体。从实现角度来看，研究发现，仅纳入预测起始历元对应的$F_{10.7}$ 指数时，循环神经网络的性能最佳。因此，将其纳入输入序列，并作为常数值重复输入。面积质比也采用相同的处理方式，保持固定。

与第 4.1 节和4.2节类似，可以探索迄今生成的特征，以确定是否能发现预期的关系。为此，可对$F_{10.7}$ 指数、B^* 以及面积质比进行主成分分析。结果汇总于

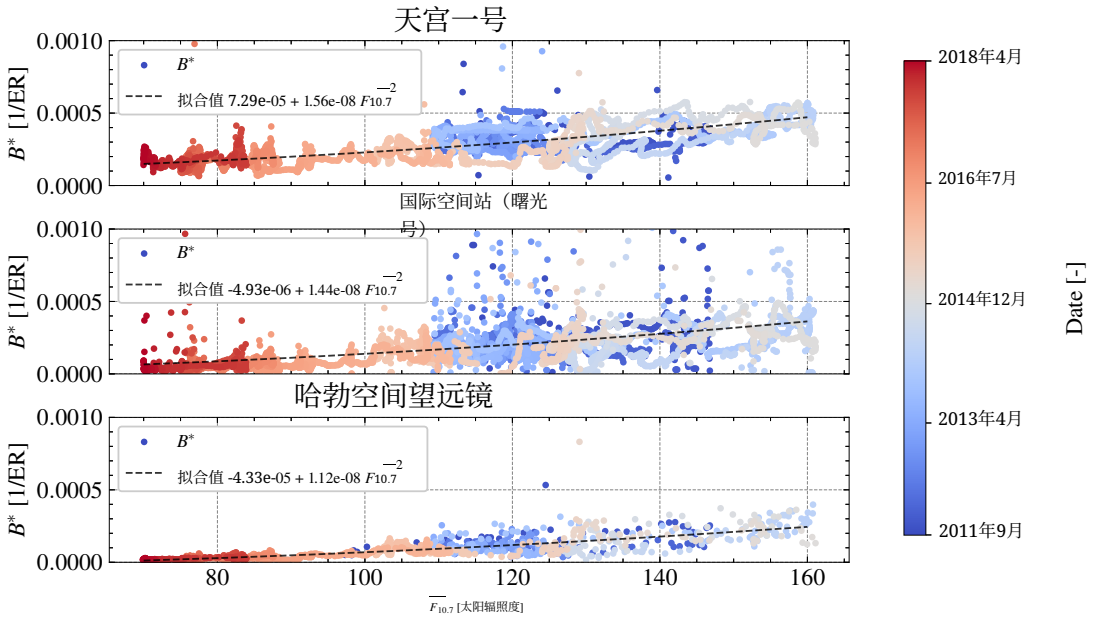


图8. B^* 天宫一号、国际空间站和哈勃空间望远镜的均值太阳指数函数。

图9。从载荷图可以看出，沿第一主成分方向，所有变量的载荷均为正。具体而言，A/m 与B^*之间的关系与类阻力系数的定义有关。正如图B^* 与太阳指数之间的关系与图8所讨论的相同，二者呈正相关。此外，面积质比与$F_{10.7}$ 之间的关系可通过B^*来解释。

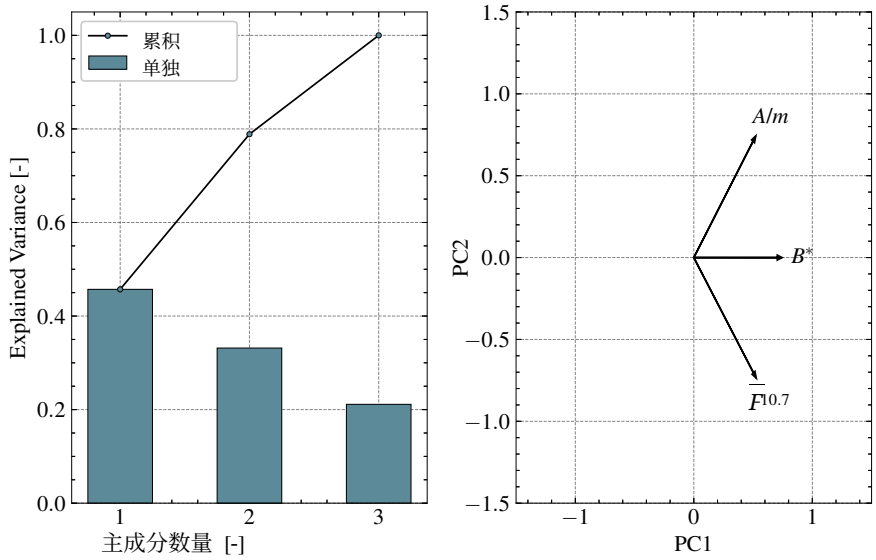


图9。太阳指数的主成分分析特征，B^* 和面积质比。

4.4. 数据正则化

目前生成的特征包括平均高度剖面、B^*、$F_{10.7}$ 和面积质比。由于其特性，太阳指数和时间相关特征根据 [18] 进行归一化：

$$\bar{\boldsymbol{x}} = \frac{\boldsymbol{x} - \min(\boldsymbol{x})}{\max(\boldsymbol{x}) - \min(\boldsymbol{x})} \tag{19}$$

其中 $\bar{\boldsymbol{x}}$ 表示归一化特征；$\boldsymbol{x}$ 表示相关的原始输入特征。

5. 结果

第2 节所述的序列到序列架构分别针对四个不同的案例进行训练，这些案例具有不同的起始高度，如表 3所示。通过这种方式，可以评估预测精度对起始高度的敏感性。

Case	T_x [-]	起始高度- [千米]	训练 训练轮次 [-]
A	5	180	2900
B	9	160	3000
C	13	140	1200
D	17	120	1200

表3. 训练案例的特征。

表 3中的每个案例都将整套两行根数分成两个独立部分：训练集和验证集。此外，两个集合的输入和输出长度均相同。因此，给定长度为 T_y 的输入序列，模型将训练以预测长度为 T_x 的输出序列；验证时也采用相同的策略。这意味着，损失 $\mathcal{L}_{MSE}^{Val}$ 和 $\mathcal{L}_{MSE}^{Train}$ 是根据与相同平均高度相关的值计算的。唯一的区别在于所分析的对象，这些对象在两个集合中各不相同。输入数据集在数学上表示为一个三阶张量，按照 TensorFlow 的记法，其维度为 [对象 $\times$ 时间 $\times$ 特征]。因此，根据问题定义，模型仅接收对象输入轨迹的一部分，以及所有相关的输入特征。时间维度的长度可根据需要，通过改变 T_x 的值来选择；该值与预测的起始高度相关。因此，表 3中的五种不同案例由不同的输入序列长度 T_x 加以区分。对于输出，模型必须预测平均轨迹高度的最后一部分，直至再入时刻。输入序列与输出序列长度之和为 $T_x + T_y = 25$。

5.1. 超参数优化

第 2 节所述的深度学习模型需要定义特定的超参数，这些变量是学习算法在优化和预测过程中所依赖的。一般而言，超参数可能因所研究的问题而异，因此有必要有依据地选择这些参数。通常通过优化超参数来最大化深度学习模型的性能。然而，超参数优化过程可能计算量很大，因此，本研究决定仅对表 3 中的案例 A 进行优化。事实上，该案例的输入序列最短，因此被认为是四个案例中最具挑战性的。优化方案采用*HyperOpt* [32] 模块（一种贝叶斯优化库），并结合异步连续减半（ASHA）算法 [33]，将随机搜索与提前停止表现不佳的超参数组合结合起来。使用 Python 软件包 *Ray Tune* [34]可以方便地组合并并行运行这些算法。本研究将部分超参数空间设为固定，并对其余部分进行优化。表 4列出了固定的超参数及其对应值。如式（4）所示，

损失函数为均方误差；所选优化器为 Adam [35], ，这是深度学习模型权重优化中常用的一种算法。它是一种一阶基于梯度的优化方法，基于一阶和二阶矩（即均值和方差）的自适应估计。如表 4 所述，一阶矩的衰减率 β_1 和二阶矩的衰减率 β_2 均已设定，同时还设置了 梯度裁剪范数参数；当梯度范数超过指定值时，该参数会强制对梯度重新缩放。

	参数	值 [-]
固定	Loss	均方误差
	优化器	Adam
	β_1	0.999
	β_2	0.999
	梯度裁剪范数	0.1

表4。 固定超参数。

其余优化的超参数总结于表5中，同时列出了相关的搜索空间和采样模式。与层相关的参数定义为编码器和解码器各自堆叠的 GRU 单元数。这意味着，如果层数为 2，模型将由 4 个单元组成，其中 2 个属于编码器，其余属于解码器。具体而言，编码器每一层的最终隐藏状态都会传递给解码器中对应的层。例如，解码器的第一个 GRU 单元以编码器第一个单元的隐藏状态作为初始状态。

超参数	**区间** [最小值，最大值]	**采样模式**[2]
学习率	$[1 \cdot 10^{-6}, 1 \cdot 10^{-1}]$	均匀对数
层数	[1, 3]	量化均匀分布
GRU 隐藏层大小	[16, 256]	量化均匀分布
批次大小	[8, 64]	量化均匀分布
衰减式计划采样	$[1 \cdot 10^{-1}, 9.9 \cdot 10^{-1}]$	均匀对数

表 5. 优化的超参数及其在*HyperOpt*中的相关搜索空间。

最后，还需要指定 ASHA算法的参数。表 6展示了上述参数及其选定值。具体而言，试验总数是指算法停止前尝试的超参数组合数量；缩减因子表示每轮运行后被淘汰的试验所占比例；宽限期则对应试验在减半前必须接受训练的训练轮次。选择这些值时，必须考虑硬件的计算资源和预期结果。表6列出了在结果与计算时间之间权衡后确定的最合适参数。需要注意的是，较短的宽限期可能会使 ASHA 偏向那些收敛较快、但性能并非最佳的方案。因此，通过实验发现，400 个训练轮次是较好的折中选择。此外，训练周期的最大值设为 2100，因为观察发现，最优值通常高于 2000。

[2] 它指的是用于选取超参数的特定分布。更多详情请参阅http://hyperopt.github.io/hyperopt/getting-started/search_spaces/ 。

输入	值
试验次数	100 [-]
缩减因子	4 [-]
宽限期	400 [历元]
最大训练轮数	2100 [历元]

表 6. ASHA 的输入参数。

图 10 展示了验证损失随各超参数值变化的情况。可以观察到，较低损失对应的曲线大致分布在较小的批次大小（20 到 40）以及隐藏状态大小（尤其是 50 到 150）范围内。此外，这些分布还体现了各参数的重要性。具体而言，可以通过观察参数值变化所导致的损失幅度变化来判断参数的重要性。也就是说，即使输入参数只有微小变化，也可能导致损失发生显著变化。例如，查看平行坐标图中的学习率，可以看到红色曲线和蓝色曲线之间的差异：较低的学习率会导致较高的验证损失。相比之下，0.002 到 0.0075 之间的值似乎能带来更好的性能。相反，计划采样机制的衰减率对验证损失的影响似乎微乎其微。事实上，无法确定能够带来更好性能的取值范围。这是因为式（8）中的衰减率对收敛并无显著影响：优化器所选的所有取值都会使选择真实值或模型输出的阈值迅速降低，从而迫使模型从其预测输出中学习。因此，这可能表明，当模型需要处理自身误差时，其表现会更好；这种情况比训练更接近推理。

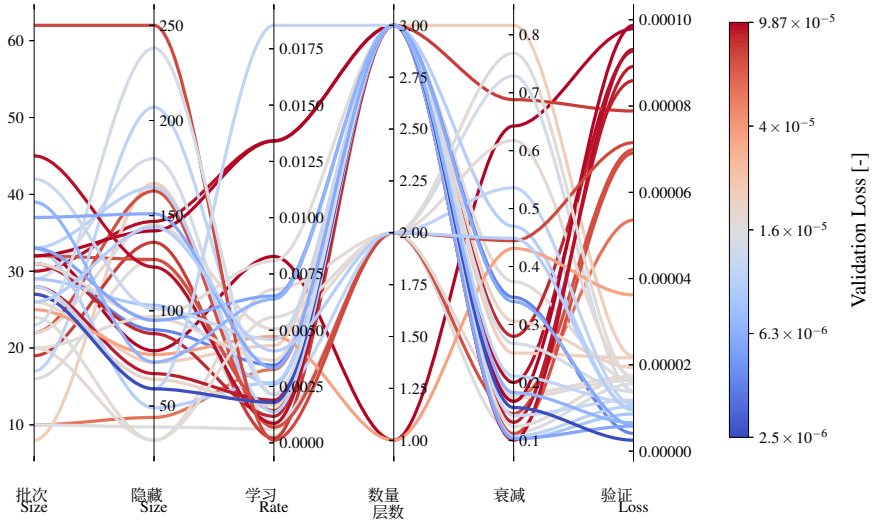


图 10. 将选定的超参数组合表示为平行线，这些线经过与每次试验所关联超参数对应的顶点，每种颜色对应一个验证损失值。

最后，超参数的优化值见表 7。

5.2. 数据集特征描述

为了分析并理解模型的性能，必须根据测试对象相对于训练集的物理属性对其进行划分。我们定义了两

	参数	值 [-]
优化的	学习率	0.001795
	层数	3
	GRU 隐藏层大小	59
	批次大小	27
	衰减式计划采样	0.15665

表 7. 优化的超参数。

类对象，如表3 （附录A.3.1）所示，其中测试集中的对象与训练集中的对象具有相似的特征。具体而言，如图11所示，这两类对象根据B^* 系数类别 *1*对象（红色标签）的中位数B^*系数位于训练集分布的第 0.25 和第 0.75 分位数之间，而B^* 系数的中位数则位于此范围之外。因此，鉴于类别2对象（黑色标签）*中 的重要性，预计深度学习模型在其分布与训练集相似的对象上表现更好。

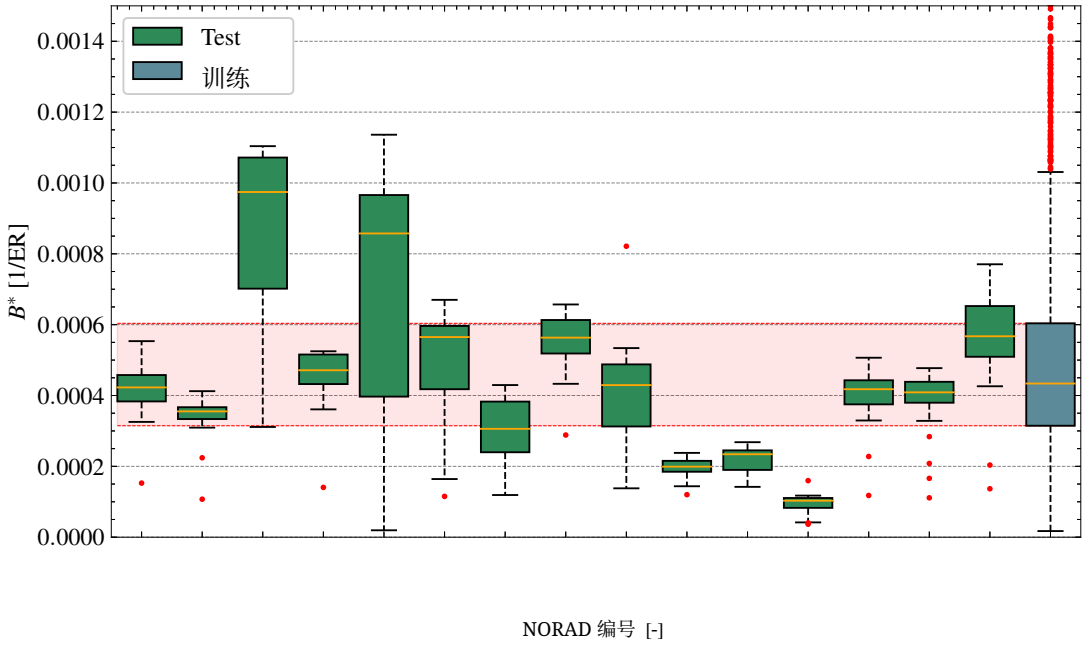


图 11。 B^* 训练集和测试集中天体的分布，其中红色的 NORAD 编号表示与训练集具有相似B^* 分布的测试天体（类别 1）。

为了分析和了解模型的性能，必须根据测试对象相对于训练集的物理属性对其进行划分。因此，图11展示了对象的B^* 分布情况，其中根据北美防空司令部编号的不同颜色，可以识别出两类天体。另一个需要分析的参数是偏心率，其在训练集和测试集中的分布如图12所示。可以看出，与所有其他对象相比，20813 是一个异常值。事实上，其偏心率中位数约为 0.7，表明它处于高度椭圆轨道，其再入性质也有所不同。不过，我们

决定保留该对象，以进一步测试所开发的深度学习模型的能力和局限性。

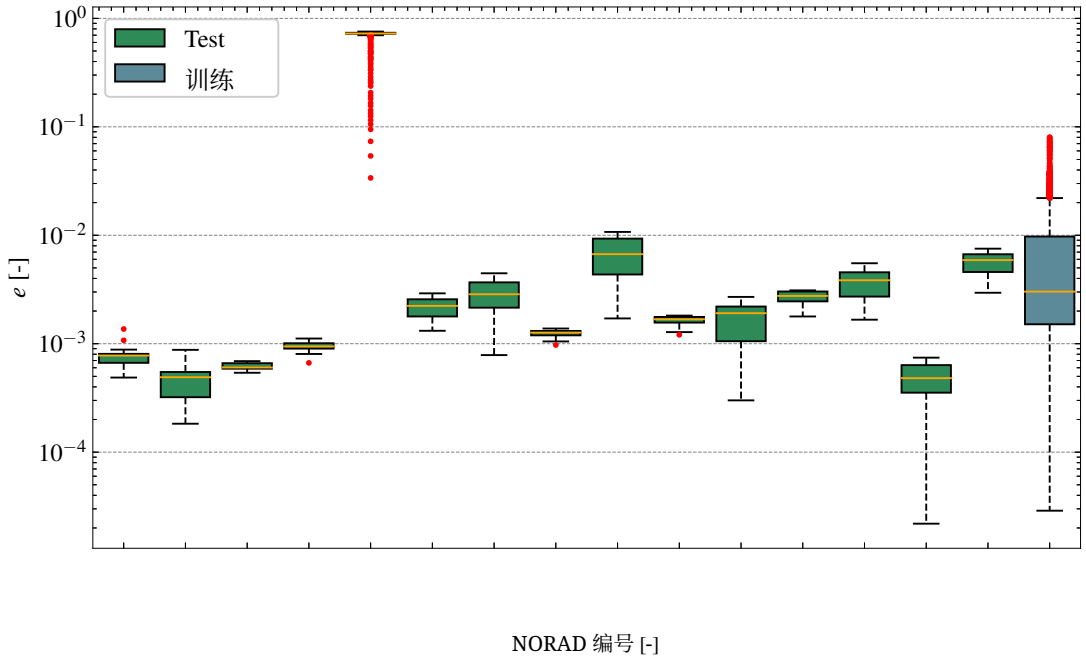


图12. 训练集和测试集中对象的偏心率分布。

为描述性能并比较结果，将绝对误差 ϵ_{abs} 和相对误差 ϵ_{rel} 分别定义为：

$$\epsilon_{abs} = |t_{Predicted} - t_{Actual}| \tag{20}$$

$$\epsilon_{rel} = \frac{|t_{Predicted} - t_{Actual}|}{t_{Actual} - t_{Initial}} \times 100 \tag{21}$$

w其中 $t_{Predicted}$ 是预测的再入时刻；t_{Actual} 是评估得到的再入时刻 .

5.3 测试

从第一类物体开始，表8 展示了表3中定义的所有不同起始高度对应的预测误差。总体而言，可以看出，该模型能够成功预测输出轨迹，进而预测再入时刻。例如，39000 的绝对误差小于 2 分钟，而此时距离再入约有 24 小时。此外，对于所有预测，该误差始终保持在约 3 分钟以内。这种表现与各物体的B^* 分布和训练集的分布相似有关。事实上，值得注意的是，最大绝对误差为 14 分钟，对应于 40138。此外，观察均方误差可见，所有相对误差都介于 10^{-5} 和 10^{-7}之间，这表明B^* 的相似性带来了出色的表现。值得注意的是，比较不同案例可发现，均方误差的降低并不一定对应较小的绝对误差，例如 11601 和 39000。这表明，选择不同的损失函数也可能获得更好的结果。

关于第二类中的物体，所有天体的误差均列于表 9。总体而言，与上一类物体相比，模型的性能较差，

Case	指标	北美防空司令部								
		10973	**11601**	**20638**	**21701**	**26873**	**31599**	**38086**	**39000**	**40138**
案例 A	ε_{abs} **[小时]**	0.0129	0.0012	0.0593	0.0287	0.0381	0.0835	0.0856	0.0263	0.2225
	ε_{rel} **[%]**	0.0582	0.0051	0.2930	0.1262	0.1800	0.5004	0.3469	0.1093	1.2464
	均方误差 [天^2]	4.4482e-6	1.1707e-6	1.0218e-5	1.0236e-5	1.7067e-6	5.2804e-6	2.1809e-5	1.0643e-6	1.9246e-5
情况 B	ε_{abs} **[小时]**	0.0915	0.0411	0.0417	0.0021	0.0376	0.0640	0.0187	0.0191	0.0191
	ε_{rel} **[%]**	0.9903	0.4878	0.6032	0.0265	0.4828	1.0072	0.2198	0.2134	0.2952
	均方误差 [天^2]	7.0168e-6	1.8629e-6	2.6473e-6	4.4563e-6	2.6635e-7	1.2836e-6	1.1987e-6	1.7427e-6	1.8259e-6
情况 C	ε_{abs} **[小时]**	0.0934	0.0043	0.0125	0.0268	0.0610	0.1025	0.0368	0.0065	0.0198
	ε_{rel} **[%]**	2.8694	0.1839	0.7061	1.3862	2.8083	5.6717	1.7670	0.2461	1.1732
	均方误差 [天^2]	1.8350e-5	2.1482e-6	9.5146e-7	4.1151e-6	1.5597e-6	5.9912e-6	4.7233e-6	1.5328e-6	6.7500e-7
情况 D	ε_{abs} **[小时]**	0.0670	0.0560	0.0244	0.0340	0.0581	0.0271	0.0580	0.0420	0.0093
	ε_{rel} **[%]**	8.1350	14.1151	9.1041	13.5330	15.8149	8.8874	20.3210	8.3022	3.7092
	均方误差 [天^2]	6.4009e-6	3.1455e-6	1.3601e-6	1.3073e-6	2.2189e-6	1.0388e-6	2.2950e-6	2.1382e-6	1.5021e-6

表 8. 类别 1 中对象的结果。

这是因为具有与训练集相似的 B^*分布的天体数量较少。37872 的情况清楚地说明了这一点，它在任何集合中都找不到与之对应的 B^* 分布。因此，输出的均方误差最高，这是因为模型倾向于高估所有相对历元。不过可以证明，输出轨迹相当准确地遵循了轨道高度的变化形状。此外，20813 的相对误差最高，均方误差也同样显著。这表明模型无法预测输出轨迹，并且完全错过了所有预测历元。事实上，查看图 11可见，20813 的 B^* 值分布范围很大，其最大值与 19045 的相近。然而，在所有案例中，模型对 19045 的输出曲线拟合得相当好，最大相对误差约为 18 分钟，均方误差介于 10^{-5} 和 10^{-7} [天^2]之间。然而，物体20813 的偏心率也较大（见图 12），这说明了深度学习模型在预测其再入时遇到困难，也表明正如预期的那样，对于非近圆形轨道，偏心率的影响不可忽视。

5.3.1. 轨道预测 - 案例 A

本节将详细展示案例 A 的结果。具体而言，我们展示训练损失和验证损失的变化，以及所开发的深度学习模型对测试集中的选定对象进行轨迹预测的结果。对于测试案例，已纳入两类对象（附录A.3.1）。图 13 展示了总计 2900 个训练周期内训练损失和验证损失随训练周期的变化。我们可以看到，验证损失的收敛速率远低于训练损失；尽管如此，最终损失低于 1×10^{-5}，而此前的观察表明，这一损失水平能够产生准确的结果。

图 14 展示了测试集中类别 1 的选定对象的轨迹预测。黑色曲线表示输入平均高度（输入序列的前 5 个元素，T_x），红线表示预测序列，蓝色轨迹表示真实输出（根据两行根数数据得到）。

总体而言，可以看出该模型能够出色地预测再入时刻。由于预测结果与真实轨迹相当吻合，因此模型能够成功估计每个目标的输出轨迹。事实上，正如表8所示，38086对应的均方误差最高；然而，再入时刻的相对误差很小。因此，即使均方误差看起来相对较高，绝对误差和相对误差

Case	指标	北美防空司令部					
		19045	**20813**	**23853**	**31928**	**37820**	**37872**
案例 A	ε_{abs} [小时]	0.2994	1.2758	0.3083	0.6206	0.5829	1.3427
	ε_{rel} [%]	2.5476	964.0562	0.8570	1.7715	1.6664	1.6942
	均方误差 [天^2]	6.1088e-5	1.1331e-3	9.9711e-5	3.6330e-4	3.2982e-4	1.0313e-2
情况 B	ε_{abs} [小时]	0.0355	0.7159	0.0273	0.0854	0.0894	2.5015
	ε_{rel} [%]	0.8068	1309.4202	0.2152	0.7246	0.7297	9.3210
	均方误差 [天^2]	1.7582e-6	2.6453e-4	3.2465e-6	7.4105e-6	5.7928e-6	1.2797e-2
情况 C	ε_{abs} [小时]	0.0029	0.2194	0.0033	0.0080	0.0222	1.9536
	ε_{rel} [%]	0.2301	2254.3293	0.1022	0.2579	0.6580	31.1668
	均方误差 [天^2]	1.1096e-7	6.2342e-5	6.7083e-6	1.6303e-5	1.5640e-5	1.1795e-2
情况 D	ε_{abs} [小时]	0.0805	0.0098	0.1186	0.0847	0.0788	2.9645
	ε_{rel} [%]	35.9520	2532.4688	26.520	16.8331	13.4101	373.4046
	均方误差 [天^2]	9.3967e-6	2.5700e-5	2.4415e-5	2.3780e-5	1.9272e-5	1.5264e-2

表9. 类别2中物体的结果。

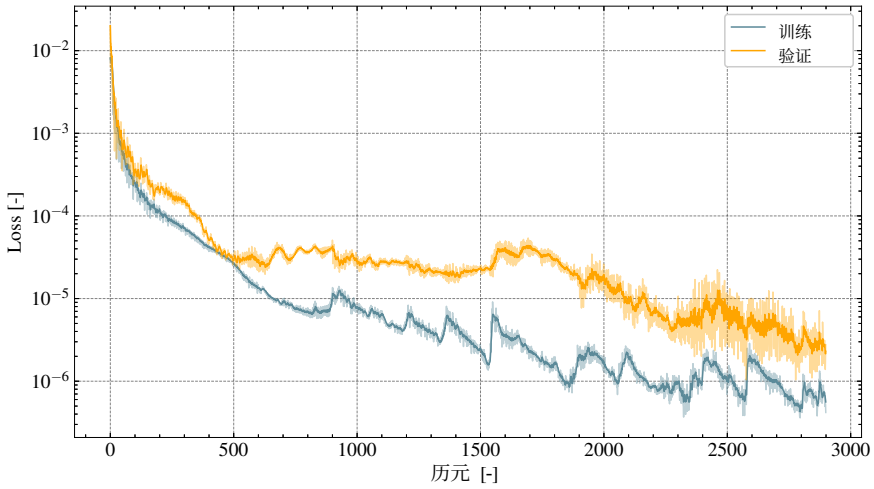
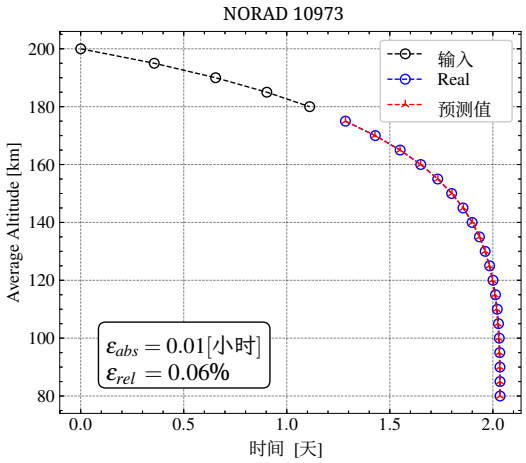


图13. 案例 A 中训练和验证损失曲线的表示，其中每条曲线均以其指数加权平均值（彩色）和原始值（阴影）表示。

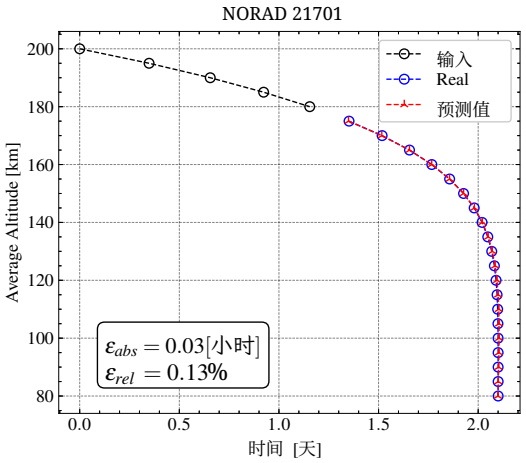
再入时刻的绝对误差和相对误差都很小。此外，除40138外，绝对误差均低于约13分钟；40138的误差为13.35分钟。这可以用40138的B* 分布较训练集更高来解释。此外，考察目标40138和10973可知，模型似乎正确掌握了太阳指数与类阻力系数之间的关系。

关于 B^* 分布与训练集（类别2）不同的物体，结果汇总于图 15 和图 16。

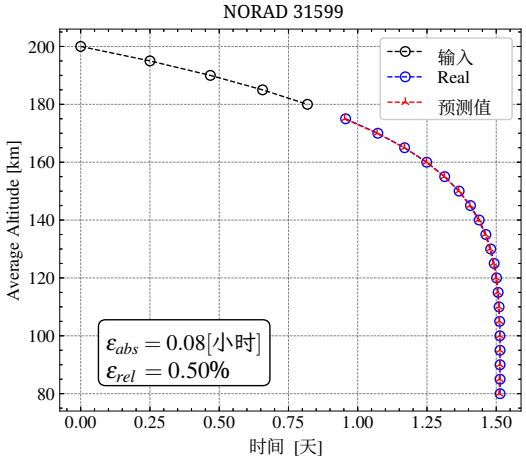
总体而言，可以观察到，与前一个案例相比，所有误差都更大。这与具有类似于训练的B^*分布的物体数量较少有关，因此模型的表现不够准确。不过，在 7 个案例中的 4 个案例里，绝对误差小于约 40 分钟。因此，可以得出结论，在此案例中，模型能够较好地近似真实输出。然而，



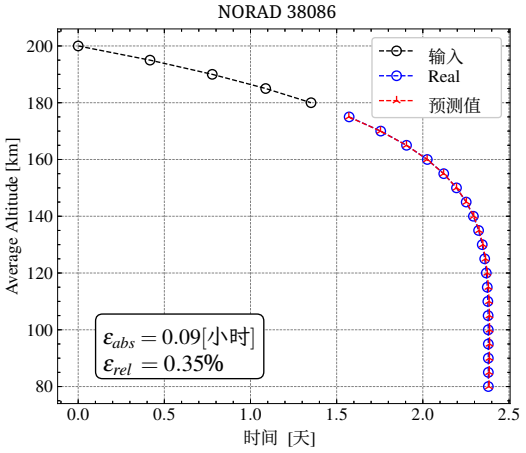
(a)NORAD 10973



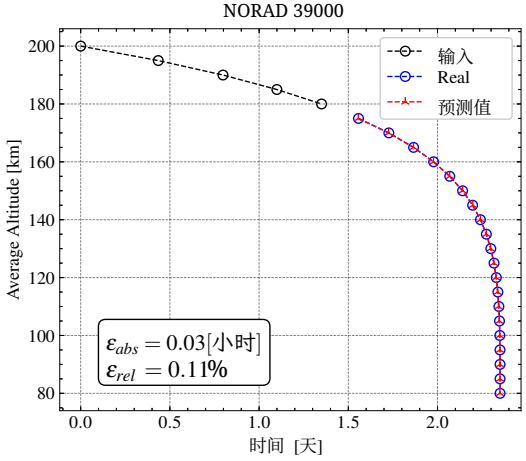
(b)NORAD 21701



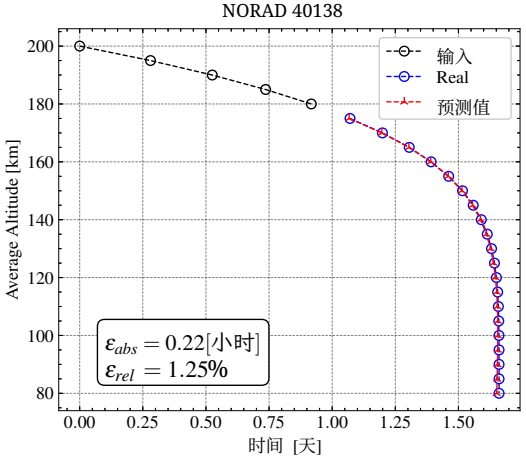
(c)NORAD 31599



(d)NORAD 38086



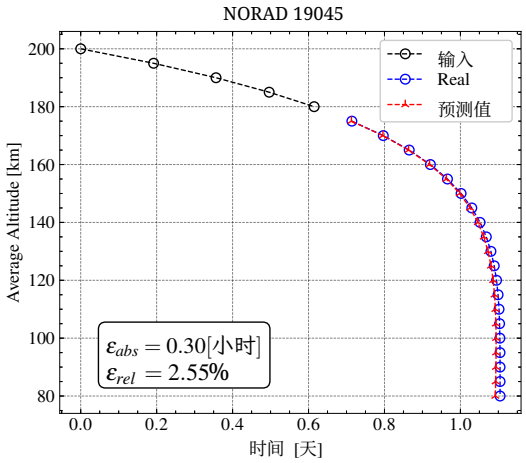
(e)NORAD 39000



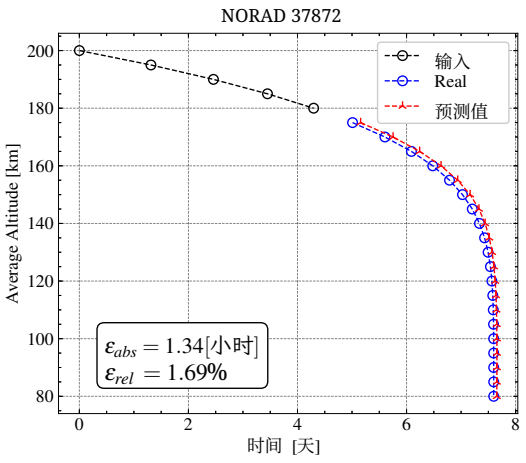
(f)NORAD 40138

图14。从180 千米高度开始的类别 1 中选定对象的预测。

物体20813在误差方面是个例外，如图17所示，其输出轨迹完全失真。

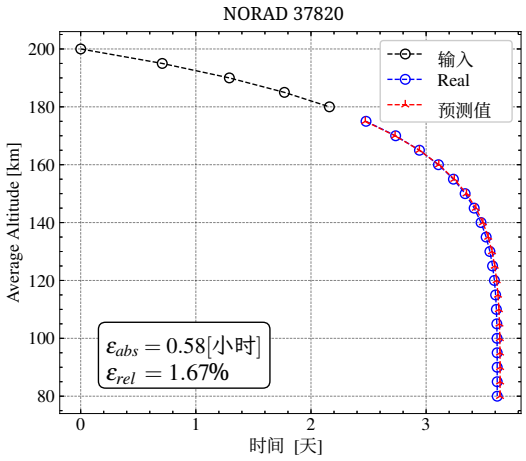


(a)NORAD 19045。

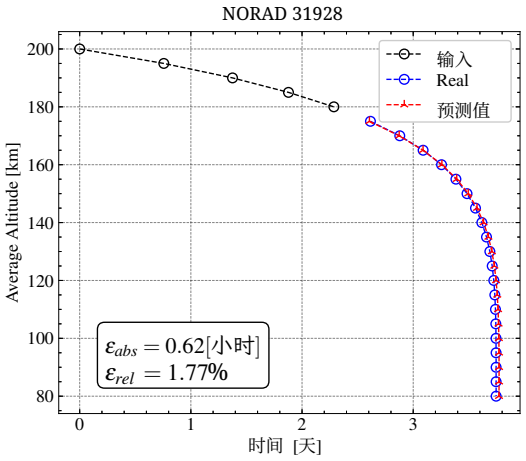


(b)NORAD 37872。

图 15。 从 180 千米高度对 19045 和 37872 进行的预测。



(a)NORAD 37820。



(b)NORAD 31928。

图16. 从180 千米高度对37820和31928的预测。

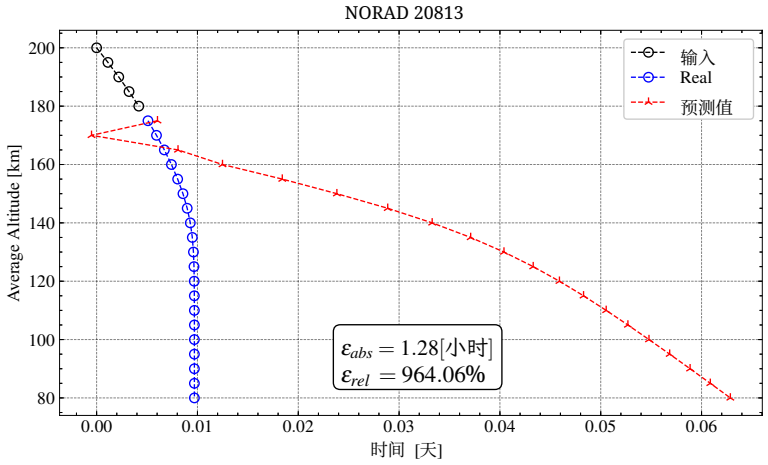


图17. 从180 千米高度对NORAD 20813的预测。

通过查看图 11，可以看出，B^* 的分布具有较大的取值范围。不过，其四分位距小于 19045；模型在后者上的表现已得到验证，输出能够准确跟随真实值。因此，类阻力系数似乎并非导致性能不佳的直接因素。事实上，20813 的偏心率较高，如图 12所示。这使得再入性质有所不同，而模型由于未接受相关训练，无法习得这方面的知识。因此，预测能力不仅与 B^* 有关，也与偏心率有关。

6. 结论与讨论

本文介绍了一种深度学习模型的开发，该模型基于序列到序列架构的一种变体，并采用课程学习，根据两行根数数据预测低地球轨道中非受控物体的再入。为此，我们提出了从物理方法转向数据驱动方法的范式转变。基于对再入现象的物理认知，我们在平均高度剖面之外引入了额外特征，以期更好地表征和预测再入时刻。我们确定了另外两个关键特征：类阻力系数 B^*和太阳指数 $F_{10.7}$。类阻力系数至关重要，因为它将再入时间与物体和大气层之间的相互作用联系起来。在本研究中，我们提出了一种方法，通过逐步移动窗口插值方案将此类参数作为特征引入深度学习模型。太阳指数对再入预测同样重要，因为它会影响大气层密度，进而影响再入时间。在分析这一参数时，我们发现需要引入一个额外特征，以便将太阳指数与物体的物理属性联系起来。因此，我们也将面积质比作为一项特征加入模型。通过研究深度学习模型对这些特征的响应，我们确定了将其引入模型的可行方法。我们开发的深度学习模型已在 IADC活动期间研究的一组物体上进行了测试。与 Jung 等人 [13], 的研究一致，我们观察到 B^* 分布对模型性能有显著影响。然而，物体20813表现不佳（图 17）表明，偏心率也有重要影响。因此，未来的研究可以纳入对高偏心轨道的处理。此外，我们发现，所选损失函数（均方误差）的降低并不一定意味着再入预测准确度更高。因此，未来的研究还可以探究不同损失函数对深度学习模型输出的影响。总体而言，分析结果表明，使用机器学习进行再入预测前景良好；但正如预期，模型的预测能力很大程度上取决于训练数据的质量和数量。因此，为了拓展这种数据驱动方法的能力，扩大训练数据集规模至关重要；此外，还可考虑两行根数以外的数据来源，以提高这类数据的质量。

作者贡献： 概念构思：Mirko Trisolini、Francesco Salmaso、Camilla Colombo；方法学：Francesco Salmaso、Mirko Trisolini；软件：Francesco Salmaso；验证：Francesco Salmaso；形式分析：Francesco Salmaso；调查研究：Francesco Salmaso；论文初稿撰写：Mirko Trisolini、Francesco Salmaso；论文审阅与编辑：Mirko Trisolini、Camilla Colombo；可视化：Francesco Salmaso；监督：Mirko Trisolini、Camilla Colombo；经费获取：Camilla Colombo。所有作者均已阅读并同意发表该论文。

资助： 本论文所述研究获得了欧洲研究委员会（ERC）通过欧盟地平线2020研究与创新计划提供的资助，资助项目为 COMPASSproject（资助协议编号 679086）。

利益冲突： 作者声明不存在利益冲突。

缩略语

本文使用了以下缩略语:

TLE 两行根数 TIP 跟踪与撞击预测 PCA 主成分分析
Seq2Seq 序列到序列 TPE 树结构帕岑估计器 ASHA 异步
连续减半算法 ANN 人工神经网络 RNN 循环神经网络
GRU 门控循环单元 MSE 均方误差 OMM 轨道均值要素
消息

附录 A

附录 *A.1* 训练集的 *NORAD* 编号22277,33594, 38223, 43538, 49130,38976, 43033,37727, 12389,28883, 45942, 45729, 33440, 40459, 28824,45601, 39573, 41813, 25431,29504, 25577,26481, 12072,40714, 40700, 33448, 41640, 43703, 40120, 43586, 1377, 37346, 28701, 44500, 36604, 39262, 28642, 38349, 28842, 33387, 40085, 28827, 39561,24968, 28400, 49045, 28822,34670, 24840,38048, 25288,33592, 48853, 34906, 28486, 28424, 29480, 41478, 39259, 39683, 25274, 27451, 39147, 28641, 25291, 3835, 46930, 39507, 27375, 24837, 31602, 10861, 46390, 25285, 28655, 40949, 40452, 41313, 38075, 8063, 41628, 28504, 12071, 43705, 43475,25173, 22781, 24872, 40589,42718, 39145,40897, 43007,29058, 33507, 40096, 28896, 40728, 44210,28625, 32267, 37674, 37397,39033, 37874,39566, 28777,25064, 11745, 34872, 40957, 43243, 25342,44228, 32007, 39409, 32377,42701, 44070,36835, 41865,46397, 36096, 27372, 39178, 26897, 42734,29247, 39116, 33456, 43166,32261, 40745,25647, 27474,23769, 40421, 39560, 40430, 40740, 25275,35642, 41821, 27450, 31596,26874, 49065,44551, 41819,44385, 27374, 48804, 32485, 40723, 40453,25290, 41100, 32269, 39193,24945, 37883,37821, 43532,29053, 40314, 39580, 41559, 28933, 40668,40945, 32270, 46614, 43494,27642, 28823,28362, 41480,43757, 14207, 29157, 39571, 33054, 41776,28425, 40363, 28878, 37197,29109, 41909,28519, 38848,39503, 32757, 37172, 12054, 34603, 21694,42723, 43863, 33435, 45112,25468, 39527,40127, 45596,28099, 11474, 29667, 40702, 38462, 10582, 38074, 11849, 14694, 27392, 43691, 44372, 36130, 21931, 38249, 25276, 39623, 25040, 25106, 32477,30778, 29080, 42757, 41486,39519, 32262,37860, 27841,43090, 31394, 28867, 44844, 43239, 32002,39126, 44707, 35694, 41596,37680, 41769,25171, 23020,39514, 29229, 29263, 42731, 38862, 32751,29253, 47619, 44438, 32059,25287, 39393,20299, 27700,43212, 35818, 39031, 38037, 35867, 29403,41574, 28363, 33457, 44206,24794, 37255,44834, 41777,40727, 27550, 28907, 37217, 35947, 37942, 29653, 43667, 39569, 39513, 25777, 7338, 39062, 35011, 36362, 41125, 37634, 42703, 43244, 29394,40898, 40126, 43637, 44826,39220, 42972,25263, 41027,39171, 24839, 45604, 36506, 27706, 24905,41487, 37758, 43027, 46669,28403, 25530,41572, 44799,29386, 39180, 39149, 41597, 47255, 28130, 29246, 39386, 37878, 47348, 42730, 41387, 41178, 35941, 38672, 24966

附录 *A.2* 验证集的北美防空司令部编号

41868, 45177, 29488, 39682, 60, 32386, 38336, 33332, 38550, 24792, 48160, 36522, 32284, 39649, 35949, 43064, 41636, 28191, 40247, 6212, 25346, 37362, 11671, 28643, 44317, 42938, 24904, 43129, 11332, 28445, 27475, 41107, 40393, 44505, 40313, 36512, 48866, 36087, 37873, 37729, 42716, 39363, 48870,44111, 40359, 13402, 39187,33273, 47782,26405, 37856,28506, 41455, 39408, 39493, 41475, 39137,24869, 34840, 42733, 41629,48275, 23757,46463, 40361,40619, 28997, 42702, 42800, 28942, 44075, 36749, 32713, 33449, 38076, 37876, 41449, 28774, 31798, 41483, 45938, 39532, 37383, 40886

附录 *A.3* 测试集的北美防空司令部编号

20813、19045、11601、10973、40138、38086、23853、21701、37872、39000、20638、31928、37820、26873、31599

附录 A.3.1 类别 1 和类别2中的测试集细分

表 A1 展示了测试集对象的北美防空司令部编号，这些对象被细分为类别 1 和类别2。类别 1 包含中位数 B^* 位于训练集 B^* 分布四分位距范围内的对象，而类别 2 中的对象其中位数 B^* 则在此区间之外。

类别	北美防空司令部编号								
1	10973	11601	20638	21701	26873	31599	38086	39000	40138
2	19045	20813	23853	31928	37820	37872			

表 A1. 测试集中的天体按B^* 分布进行细分。

参考文献

1. 欧空局空间碎片办公室。欧空局《2021年年度空间环境报告》。2. Alby, F.; Alwes, D.; Anselmo, L.; Baccini, H.; Bonnal, C.; Crowther, R.; Flury, W.; Jehn, R.; Klinkrad, H.; Portelli, C.; 等。《欧洲空间碎片安全与减缓标准》。《太空研究进展》2004, 34, 1260–1263。https://doi.org/10.1016/j.asr.2003.08.043。3. 美国国家航空航天局。《限制轨道碎片流程》，NASA-STD-8719.14B, 2019。4. Space-Track。www.space-track.org。5. Pardini, C.; Anselmo, L. 失控卫星再入预测：研究结果与挑战。载于第6届国际空间安全促进会会议“安全不是一种选择”论文集；，2013。6. Pardini, C.; Anselmo, L. 太阳活动水平较高时用于卫星再入预测的大气密度模型性能评估。《日本航空航天学会学报》2003, 46, 42–46。https://doi.org/10.2322/tjsass.46.42。7. Pardini, C.; Anselmo, L. 评估影响人造空间物体非受控再入的风险与不确定性。《空间安全工程杂志》2018, 5, 46–62。https://doi.org/10.1016/j.jsse.2018.01.003。8. Braun, V.; Flegel, S.; Gelhaus, J.; Kebschull, C.; Moeckel, M.; Wiedemann, C.; Sánchez-Ortiz, N.; Krag, H.; Vörsmann, P. 太阳通量建模对卫星寿命预测的影响。载于第63届国际宇航大会论文集；，2012。9. Vallado, D.A.; Finkleman, D. 卫星阻力与大气密度建模的批判性评估。《航天学报》2014, 95, 141–165。https://doi.org/10.1016/j.actaastro.2013.10.005。10. Vallado, D. 《轨道力学基础与应用》，第2版；施普林格多德雷赫特，2001。11. Anselmo, L.; Pardini, C. 再入轨迹与风险评估的计算方法。《太空研究进展》2005, 35, 1343–1352。https://doi.org/10.1016/j.asr.2005.04.089。12. Frey, S.; Colombo, C.; Lemmens, S. 扩展King-Hele轨道收缩方法，以实现非圆轨道的精确半解析传播。《太空研究进展》2019, 64, 1–17。https://doi.org/https://doi.org/10.1016/j.asr.2019.03.016。13. Jung, O.; Seong, J.; Jung, Y.; Bang, H. 用于预测失控空间物体再入轨迹的循环神经网络模型。《太空研究进展》2021, 68, 2515–2529。https://doi.org/10.1016/j.asr.2021.04.041。14. Lidtke, A.A.; Gondelach, D.J.; Armellin, R. 优化两行根数集筛选，以提高地球同步转移轨道物体的再入预测准确率。《太空研究进展》2019, 63, 1289–1317。https://doi.org/10.1016/j.asr.2018.10.018。15. Flohrer, T.; Krag, H.; Klinkrad, H. 美国空间监视网目录中两行根数轨道误差的评估与分类。载于2008年先进毛伊岛光学与空间监视技术（AMOS）会议论文集。16. Levit, C.; Marshall, W. 使用两行根数改进轨道预测。《太空研究进展》2011, 47, 1107–1115。https://doi.org/10.1016/j.asr.2010.10.017。17. Aida, S.; Kirschner, M. SGP4轨道信息转换为密切根数的精度评估。载于第6届欧洲空间碎片会议论文集；，2013。18. Raschka, S. Python机器学习，第3版；Packt Publishing Ltd，2019。19. Sutskever, I.; Vinyals, O.; Le, Q.V. 《基于神经网络的序列到序列学习》。载于第27届神经信息处理系统国际会议论文集——第2卷；麻省理工学院出版社：美国马萨诸塞州剑桥，2014；第3104–3112页。

20. Zhang, A.; Lipton, Z.C.; Li, M.; Smola, A.J. 动手学深度学习，2021。arXiv:2106.11342。21. Goodfellow, I.; Bengio, Y.; Courville, A. 深度学习；麻省理工学院出版社，2016。22. Elman, J.L. 在时间中发现结构。认知科学 **1990**，*14*，179–211。https://doi.org/10.1207/s15516709cog1402_1。23. Cho, K.; van Merriënboer, B.; Gulcehre, C.; Bahdanau, D.; Bougares, F.; Schwenk, H.; Bengio, Y. 使用RNN编码器–解码器学习用于统计机器翻译的短语表示。载于2014年自然语言处理实证方法会议（EMNLP）论文集；计算语言学协会：卡塔尔多哈，2014；第1724–1734页。https://doi.org/10.3115/v1/D14-1179。24. Bengio, S.; Vinyals, O.; Jaitly, N.; Shazeer, N. 使用循环神经网络进行序列预测的计划采样。神经信息处理系统进展**2015**，*28*。25. Chung, J.; Gulcehre, C.; Cho, K.; Bengio, Y. 门控循环神经网络在序列建模中的实证评估，2014。arXiv:1412.3555。26. Abadi, M.; Agarwal, A.; Barham, P.; Brevdo, E.; Chen, Z.; Citro, C.; Corrado, G.S.; Davis, A.; Dean, J.; Devin, M.; 等。TensorFlow：异构系统上的大规模机器学习，2015。软件可从tensorflow.org获取。27. Chollet, F. 使用*Python*进行深度学习；西蒙与舒斯特，2021。28. Dong, G.; Liu, H. 面向机器学习与数据分析的特征工程；CRC出版社，2018。29. Salmaso, F. 用于空间物体非受控再入预测的机器学习模型与特征工程。博士论文，米兰理工大学，2022。30. Virtanen, P.; Gommers, R.; Oliphant, T.E.; Haberland, M.; Reddy, T.; Cournapeau, D.; Burovski, E.; Peterson, P.; Weckesser, W.; Bright, J.; 等。SciPy 1.0：Python科学计算的基础算法。《自然·方法》**2020**，*17*，261–272。https://doi.org/10.1038/s41592-019-0686-2。31. Curtis, H.D.面向工程学生的轨道力学，第3版；巴特沃思-海涅曼，2014。32. Bergstra, J.; Yamins, D.; Cox, D. 将模型搜索发展为一门科学：面向视觉架构的数百维超参数优化。载于第30届国际机器学习大会论文集；，2013；第28卷，第115–123页。33. Li, L.; Jamieson, K.; Rostamizadeh, A.; Gonina, E.; Hardt, M.; Recht, B.; Talwalkar, A. 大规模并行超参数调优系统，2020。arXiv:1810.05934。34. Liaw, R.; Liang, E.; Nishihara, R.; Moritz, P.; Gonzalez, J.E.; Stoica, I. Tune：用于分布式模型选择与训练的研究平台。*arXiv*预印本 *arXiv:1807.05118* **2018**。35. Kingma, D.P.; Ba, J. Adam：一种随机优化方法。*arXiv*预印本 *arXiv:1412.6980* **2014**。