arXiv:2301.01017v1 [cs.LG] 3 Jan 2023

资源受限系统与机队的全生命周期监测

Felipe Montana[1],Adam Hartwell[1],Will Jacobs[1],Visakan Kadirkamanathan[1],Andrew R Mills[1], 和 TomClark[2]

[1]谢菲尔德大学自动控制与系统工程系，英国[2]劳斯莱斯有限公司，英国

摘要

数字孪生（DT）是对物理系统的仿真，可提供信息，帮助人们做出能够创造经济、社会或商业价值的决策。物理系统的行为会随时间变化，因此，数字孪生必须持续利用物理系统的数据进行更新，以反映其不断变化的行为。对于资源受限系统而言，由于机载学习和机外数据传输等方面存在挑战，更新数字孪生并非易事。本文提出了一个面向系统健康监测的框架，用于更新资源受限系统的数据驱动型数字孪生。该方案包括：（1）在机载系统上运行轻量级数字孪生，以便对物理系统生成的数据进行优先级排序并精简传输；（2）在机外稳健地更新数字孪生并检测异常行为。本文采用一个生产用燃气涡轮发动机系统开展了两项案例研究，以展示该数字表示在真实世界中随时间变化的物理系统中的准确性。

1 引言

数字孪生（DT）是一项新兴技术，近年来因仿真、数据采集和数据通信的快速发展而受到关注，这些技术促成了物理空间和虚拟空间之间的交互 [1]。数字孪生是对竣工系统的仿真，例如车辆或工厂，能够准确呈现其对应的孪生体 [2]。与简单的模型或仿真不同，数字孪生是一个持续运行并不断演进的模型，贯穿其物理孪生体的生命周期 [3]。这是通过整合从系统传感器、环境、历史维护数据以及现有系统知识中收集的数据来实现的。此外，数字孪生还可以包含对物理系统的结构、功能、行为和控制的描述 [4]。数字孪生所提供的信息有助于制定影响物理资产的决策 [5]，并为利益相关者带来经济、社会或商业价值。

数字孪生范式应用于各种应用场景和行业，包括产品设计与工厂优化 [6], 飞机结构寿命预测 [7], 以及汽车制动系统监测 [8] 等。另一个例子是资产机队的管理与监测。在这种情况下，由于不同资产在使用、制造和材料属性方面存在差异，仅凭机队分布信息不足以评估各个系统 [9]。因此，定制化数字孪生有助于准确预测未来性能是否符合要求，并检测由新出现的故障引起的当前系统行为偏差。

物理系统的行为预计会随着时间推移而发生变化，这是由正常退化、机械

改造等因素造成的。其结果是，真实系统与其孪生体之间出现偏差。真实系统与其孪生体出现偏差的另一个原因，尤其是在数据驱动的数字孪生中，是系统在孪生体此前未见过的工况下运行。这两种情况都表明，有必要利用从物理系统获取的数据更新数字孪生，从而更准确地反映系统的当前状态。

对于预测性维护和监测等应用，数字孪生的更新主要包括更新模型参数。人们已提出多种参数更新方法，例如求解优化问题 [10] 或使用高斯过程回归 [11]。然而，尽管在实际应用中异常数据无处不在，人们却很少关注更新过程中的异常数据检测。在更新数字孪生之前，应先检测异常数据，再将其从更新数据集中移除。这对于防止数字孪生自我调整以表征新出现的故障至关重要，否则将无法检测异常行为 [12]。

更新模型的过程通常比模型的执行过程耗费多倍的计算资源。在许多实际工程系统中，用于执行这些更新的计算能力在“机载”环境中受到严重限制，例如在燃气涡轮发动机附近。对于在线学习而言，不仅直接连接资产的计算能力有限，计算存储容量也有限；数据传输能力低或传输成本高，也会限制可传输用于远程更新数字孪生的数据量。除了更新数字孪生所需的数据外，还必须收集可能包含异常系统行为的数据，以用于健康监测，例如识别物理系统中的故障。因此，面临的共同挑战是持续监测资产以检测行为中的不良变化，同时更新模型以反映行为中预期或正常的变化。图 1 展示了这些挑战。

为应对这些挑战，我们提出一种数据驱动的方法，为一组计算资源受限系统开发数字孪生。我们将数字孪生的应用范围限定在预测性

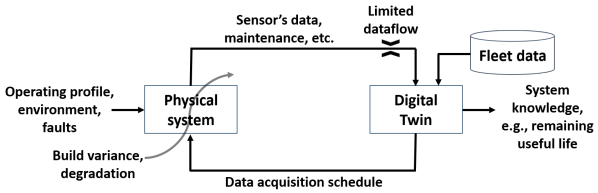


图 1：**数字孪生中的数据流**。数字孪生必须定期使用从物理系统记录的数据进行更新，以反映退化、构建方差等因素造成的变化。异常数据和数据采集方面的限制，是更新数字孪生时面临的一些挑战。数字孪生提供有关物理系统的知识，以及在不同条件下模拟该系统的手段。

维护和系统监测等领域。不过，该更新框架也适用于数字孪生的其他应用。对于呈现非线性动态行为的物理系统，我们使用深度神经网络进行建模，并以每个独立资产的数据训练该网络。与需要系统物理知识的基于模型的方法不同，数据驱动的数字孪生仅依靠数据，就能准确表征其物理孪生体。因此，我们的框架可用于表征各种复杂系统。为随时间更新数字孪生，我们会选取数字模型难以理解的数据片段（即模型预测置信度较低的数据），例如系统在新的、此前未见过的运行条件下生成的数据，并用这些数据更新模型。这种方法避免了传输额外信息量较低的数据所带来的高昂成本。除新颖数据外，我们还会在物理资产运行期间，收集最异常的数据，并依据数字孪生的预测误差判定异常程度。通过与机群数据集进行比较，系统会自动为这些数据添加标签，并将其提供给专家评估，以协助根因分析。为避免模型学习到新出现的故障，我们会从更新数据集中移除异常数据。

所提出方法的主要贡献包括：(1) 一种能够在受限系统中在线运行的轻量级数字孪生；(2) 一种基于数字孪生的数据优先级排序方法，

用于收集最相关的数据；以及 (3) 一种面向单个系统的稳健异常检测方法，能够利用机队信息。

所提出方法的两个关键特征是：选择适当的数据来更新数字模型，以及检测异常数据。本节余下部分将讨论这些主题。

1.1 数据选择

应定期使用物理系统生成的数据更新数字孪生，以使其保持最新，并能够识别异常行为。对于资源受限系统，无法在线进行此类更新；必须存储或传输数据，以便在计算能力更强的系统上更新数字孪生。多种因素会限制资源受限系统所能收集的数据量，例如数据传输成本、带宽有限、存储空间有限或能源容量有限。为解决这一问题，需要开发方法，选择针对目标任务信息丰富的高质量数据。

数据选择问题在主动学习领域中也存在。主动学习研究的是选择未标注数据进行标注，以用于模型训练的问题。其主要挑战在于如何选择信息量最大的 data，从而最大限度地提升模型性能。针对这一问题的研究提出了多种数据选择策略，例如模型分歧 [13], 预期模型变化最大化 [14] 和不确定性采样 [15]。在不确定性采样中，会选择类别分配或预测结果最不确定的样本。由于前两种方法对内存和计算资源的要求较高，因此不适用于资源受限系统。因此，本文提出的解决方案基于模型的不确定性选择数据片段，以更新数字孪生。

1.2 异常检测

异常，也称为离群点，是指数据中偏离某种既定正常性定义的模式。从宏观层面看，异常检测问题包括学习正常行为的区域或表征，并识别不属于该区域的数据。这项任务面临若干挑战，因此难以完成 [16]。首先，在许多情况下，异常与正常行为之间并没有明确的界定。其次，根据定义正常性所采用的方法，可能需要大量已标注数据，而这类数据往往难以收集且成本高昂。最后，当所分析的系统随时间发生变化（例如出现概念漂移）时，以往对正常性的定义可能不足以识别异常。视具体应用或领域而定，还可能面临其他挑战。

已有多种解决异常检测问题的方法 [17]。许多现有的异常检测方法都假设数据已存储，且有大量计算资源可用。然而，对于许多现实世界中的系统，例如数据无限增长的流式数据系统，或资源受限系统，这类方法无法运行 [18]。这些限制推动了用于在资源受限系统中检测异常的新方法的发展。已有研究提出了基于模型比较[19]和远程处理 [20]的高效设备端异常检测器。

异常检测也已在系统群组中得到研究，例如车辆队列。在这种场景下，虽然所有系统的行为都相似，但由于制造、使用和退化方面的差异，每个系统都有其独特性。若根据车队的平均行为学习单一正常性模型，由于各个系统之间存在差异，整体检测性能可能较差。另一种方法是为群组中的每个系统学习一种正常性表示。虽然采用这种方法可以检测异常，但考虑群组中所有系统的数据，有助于缓解异常数据和数据可用性问题。例如，某个特定系统中未知的运行条件，在考虑其他系统的数据时可能会被视为正常。

本文提出的解决方案结合了本地异常检测与集中式异常检测，以充分利用车队数据的优势，同时尽可能降低数据处理成本。在系统级，

数字模型用于识别每个系统中可能存在异常的数据片段。在群组级，能够访问群组历史数据的集中式系统用于改进各系统执行的异常检测。与其他现有方法不同，本文提出的方法无需收集或传输全部数据，即可更新单个模型并识别异常，从而有助于实际应用。

本文其余部分安排如下。第2节介绍本文要解决的问题，并引入两个案例研究。第3节详细阐述所提出的解决方案。最后，第4节和第5节分别给出结果和结论。

2 问题定义

本文聚焦于为一组资源受限系统开发一种数据驱动的数字孪生（DT）。具体而言，我们考虑具有以下特征的系统：系统无法执行计算负载较高的任务，例如运行全物理模型、更新数字模型或执行复杂异常检测方法；系统无法存储或传输所有待处理数据，以供资源更充足的系统处理。此外，数据无法持续传输至另一系统。

我们考虑复杂的非线性动态系统，这些系统会受到缓慢的正常内在退化、罕见但可接受的外部扰动，以及发生异常内在异常/故障的风险影响。鉴于这些特征，挑战在于构建一个框架，用于计算和更新数字孪生，使其能够在系统整个生命周期内准确模拟不断变化的物理系统。为了维护系统的数字表示，必须解决如何选择、管理和分析所收集数据的问题。

2.1 案例研究

本文提出的解决方案通过两个真实数据案例研究进行了验证，这两个案例均使用来自航空航天燃气涡轮发动机的数据。以下介绍这两个案例研究：

异常检测。第一个案例研究考察了一台存在已知故障的在役燃气涡轮发动机。使用连续116次飞行期间记录的数据训练数字孪生，并测试其执行异常检测的能力。该数据集由 1 Hz 时间序列数据组成，包含12个通道，每个通道记录来自发动机上不同传感器的数据。在一次飞行中观察到了故障症状，见图2。该图显示，故障发生时，信号之间的关系出现了永久性变化。通过检测这一故障，展示了所提出的解决方案识别异常数据的能力。

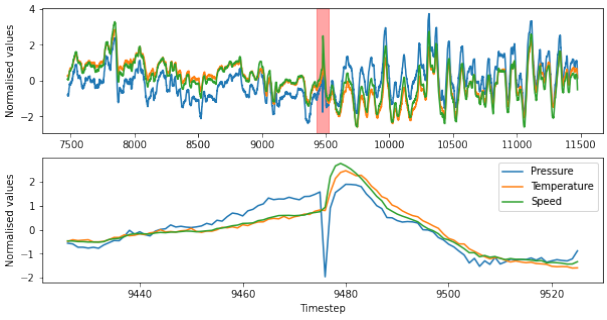


图2：**案例研究1，观察到的异常**。上图：飞行期间记录的归一化多变量时间序列数据。下图：压力信号中观察到的异常（在上图中突出显示）。

数字孪生更新。第二个案例研究展示了所提出的解决方案能够更新数字孪生，从而在物理系统的行为随时间变化时仍能准确模拟该系统。研究人员在数月期间，于试验台上对一台航空航天燃气涡轮发动机进行了多次运行，并记录了数据。在此期间，发动机出现了正常退化的迹象，并实施了多项维护措施，见图3。退化和维护使系统的动态行为随时间持续变化。与前一个案例研究一样，数据由 1 Hz 时间序列数据组成，但此处可用的数据通道超过 80 个。

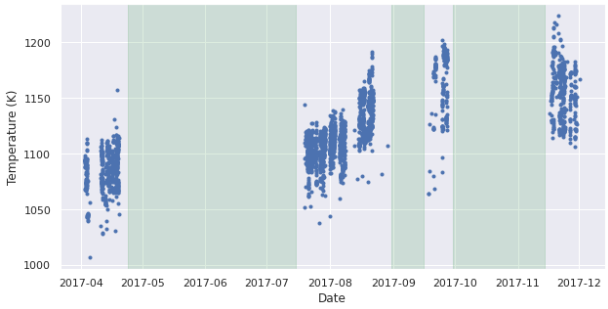


图3：**案例研究2，观测到的退化与维护**。在固定轴转速下记录的发动机温度均值。随着发动机逐渐退化，其效率会降低，要达到所需的轴转速就需要消耗更多能量。因此，在给定轴转速下，记录到的发动机温度会更高。高亮区域表示实施了重大维护操作的时段。

系统行为的永久性变化可视为异常。

我们提出一种闭环方法：从物理系统收集的选定数据会被发送至异常检测器，该检测器还可以访问群组数据。数据的选择依据模型的不确定性和数据异常情况。这使我们能够收集模型尚未充分理解的数据，例如来自新的运行条件的数据。随后，利用这些非异常但不确定的数据更新数字孪生（DT）。通过提升数字孪生在不同运行条件下预测行为的能力，数字孪生能够更准确地识别异常行为，下一节将对此作出说明。此外，访问群组数据使我们能够识别特定系统中由退化或此前未见的运行条件引起的行为；即使此类行为在群组层面属于正常行为，也可能被标记为异常。利用选定数据更新数字孪生，并访问群组数据，两者相结合可增强异常检测的鲁棒性。图4展示了所提方法的概览。

3 解决方案

数字孪生应在系统的整个生命周期内反映真实系统。通常，模型预测可能会因以下原因偏离观测数据：（1）退化：系统行为因预期的退化而发生变化；（2）未见过的运行条件：系统在此前未观测到的条件下运行；（3）系统故障：系统故障导致出现意外行为。要更新数字孪生，必须持续从物理系统收集数据。此外，为了避免数字孪生跟踪（学习）新出现的故障，必须对用于更新数字孪生的数据进行分析。这是在线学习面临的一项挑战，因为模型会根据数据流持续更新。在这种情况下，模型必须学习数据分布的变化，同时避免学习异常行为。已有研究提出了基于数据分布变化的解决方案 [21]。在这些方法中，如果模型预测在相当长一段时间内偏离观测数据，就会假设数据分布已经发生变化。然而，如第4节所述，具体取决于问题，

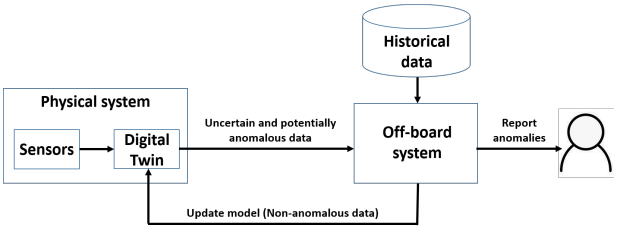


图 4：**所提出解决方案概述**。利用数字孪生，在物理系统上选择不确定且可能异常的数据。数据被发送至地面系统进行分析，并可访问该团队的历史数据。地面系统识别异常数据并呈现给用户，以便进一步分析。正常（非异常）数据用于更新数字孪生。

由于我们考虑的是资源受限系统，收集或传输所有数据并不可行。我们采用一种能够在物理系统上运行的轻量级数字孪生。该数字孪生能够识别并收集可能存在异常的

数据，以及尚未得到充分理解的数据，即预测不确定性较高的数据。后一类数据的一个例子是处于此前未见过的运行条件下的数据。本文将用于数据采集的车载数字孪生与软件的组合称为机载系统。机载系统采集的数据随后由集中式系统进行分析，该系统称为地面系统，可使用更多计算资源以及团队的历史数据。地面系统会判断机载系统返回的数据在群体层面上是否属于异常数据。随后可将这些数据提交给专家，以评估标签的准确性、开展根因分析并决定是否触发警报。未被识别为异常的数据将用于更新数字孪生。本节余下部分将介绍机载系统和地面系统。

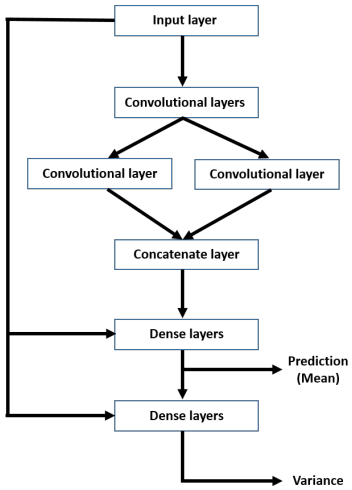


图 5：**网络架构概览**。卷积层用于从各个信号中提取特征。为以最低的计算开销提升性能，网络利用了跳跃连接。

3.1 机载系统

此处介绍用于对物理系统建模和进行数据选择的方法。由于系统的处理能力和存储能力有限，我们选择了专门设计的深度神经网络来对系统的行为建模。与其他计算开销较大的模型（例如全物理模型）相比，深度神经网络可以利用量化和剪枝等技术，高效地部署在资源有限的系统上[22]。下文将讨论该网络如何实现对不确定数据和潜在异常数据的筛选。我们专门设计了一种卷积神经网络（CNN），用于捕捉多输入非线性物理系统的动态行为。CNN 适用于此类应用，因为它能够压缩模型，使其在嵌入式系统上高效运行 [23]。该模型经过训练，可用一组精简的特征来表征物理系统的行为，从而加快运行时执行速度。

在每个采样时间 k，深度神经网络都会接收一个时间序列数据窗口 X（即系统传感器发出的信号）作为输入，并预测输出信号 y 的分布，该分布假设为高斯分布；

$$y(k) \sim \mathcal{N}\left(y(k)|f(X,\boldsymbol{\theta}),\sigma(X,\boldsymbol{\theta})\right) \qquad (1)$$

其中 $\boldsymbol{\theta}$ 为网络权重，

$$\begin{aligned} X &= [\mathbf{x}_1,\mathbf{x}_2,\ldots,\mathbf{x}_m] \in \mathcal{R}^{N\times m}, \\ \mathbf{x}_i &= [x_i(k-N),x_i(k-N+1),\ldots,x_i(k-1)]^T \in \mathcal{R}^{N\times 1} \end{aligned}$$

是一个向量，包含第 i 个输入数据流中先前的 N 个数据点，而 m 是输入数据中的通道数。

高斯分布由其均值 $\mu = f(X,\ \boldsymbol{\theta})$ 和方差 $\sigma = \sigma(X,\ \boldsymbol{\theta})$ 表征，这些参数取决于输入数据 X，并由深度神经网络同时估计，见图 5。模型权重 $\boldsymbol{\theta}$ 通过最小化以下负对数似然进行训练

$$\mathcal{L} = -\ln\left(\prod_{n=1}^{B}\mathcal{N}\left(y(n)|\mu(n),\sigma(n)\right)\right), \qquad (2)$$

使用基于随机梯度下降的算法，并在每次迭代时输入数据批次，批次大小为

批次大小 B。本文省略了神经网络架构、训练和实现的细节，感兴趣的读者可参阅[24]。

计算方差有两个目的：（1）识别模型不确定的数据；（2）计算标准化欧几里得距离，以识别异常数据。较大的预测方差（置信度较低）可能是因为输入数据的分布与训练时提供的输入数据不同。为了提高输入空间这类区域中的预测效果，进而提升数字孪生的鲁棒性，我们会收集最不确定预测附近窗口内的数据，交由地面系统分析。如果返回的数据片段相对于车队数据并非异常数据，就会按照第3.3节所述用于更新数字孪生。此项更新至关重要，可避免先前未见过的正常行为掩盖异常行为。

为识别可能的异常，使用均值和方差计算标准化欧几里得距离：

$$d(y(k),\mu(k)) = \sqrt{\frac{(y(k)-\mu(k))^2}{\sigma^2(k)}}. \tag{3}$$

直观而言，标准化欧几里得距离会对相对于预测标准差较大的预测误差施加更大的惩罚。这可以避免将未知条件下的正常数据标记为故障。与不确定数据类似，系统会收集以标准化欧几里得距离较大的点为中心的窗口。由于物理系统内存有限，运行期间会保留最N 不确定且异常的窗口。随后，这些窗口会在数据链路可用时发送至地面系统进行分析，从而避免必须在机载系统上对异常行为作出判断。请注意， N 的选择旨在存储尽可能多的数据。因此，它取决于系统的数据存储限制。

3.2 地面系统

地面系统的目标是收集机载系统返回的数据，以更新数字模型并识别异常。机载系统与地面系统之间有两个关键区别：（1）可使用更多计算资源；（2）可访问单个资产及整个群组的历史数据。更多的计算资源意味着地面系统能够运行计算需求更高的异常检测程序。此外，与机载系统不同，地面系统的运行时间并不关键；机载系统会持续接收数据，并且必须在线分析这些数据。通过访问群组的历史数据，可以提升异常检测的鲁棒性，使地面系统能够识别出对特定系统而言异常、但对整个群组而言并不异常的数据。

地面系统所用方法的选择很大程度上取决于具体问题。因此，我们仅概述案例研究中采用的方法。

如第2节所述，案例研究中分析的数据是多变量时间序列。特征是从所有历史数据的时间序列中提取的。具体而言，使用核主成分分析 [25] 获得的反映信号之间相关性的特征，以及从单个时间序列中提取的统计特征的组合。可根据地面系统长期收集的异常数据所提供的知识，设计并更新这些统计特征。提取这些特征的计算开销很大，因此无法在机载系统上运行此类方法。这些特征用于训练单类支持向量机（SVM）。SVM 的训练方式可以是：将机载系统未学习到的罕见正常事件（因而被标记为可能的异常）分类为非异常数据。

3.3 数字孪生更新

当物理系统因退化等因素而改变其行为时，应更新数字孪生以描述新的行为。为展示系统行为变化所产生的影响，请看图6所示的示例。该示例展示了

同一台发动机在数月期间多次运行时，预测信号的均方预测误差。预测由一个模型生成，该模型使用图中所示初始日期之前进行的发动机运行数据训练。如第2节所述，发动机在每段较长的停机期间都会进行维护。因此，每次维护事件都会改变发动机的动态特性，导致当前模型无法预测发动机行为。

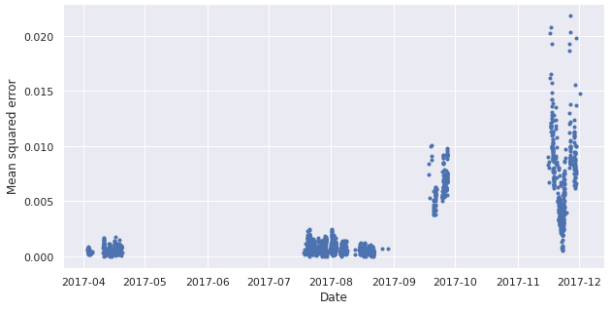


图 6：系统大修和退化导致预测误差增加。

上面的例子表明，必须使用最近收集的数据更新数字孪生。换言之，必须使用一个相对较小的数据集来更新深度神经网络，而最初用于训练模型的数据集则要大得多。迁移学习通过微调 [26]解决了这一问题。使用小数据集更新预训练模型时，主要面临两个问题：过拟合和灾难性遗忘 [27], ，即模型在使用新信息训练时，可能会忘记先前学到的知识。参数正则化方法已被用于缓解这一问题。通过限制网络的学习能力，可以减少过拟合问题。从形式上说，这些方法最小化如下形式的损失函数：

$$\tilde{\mathcal{L}} = \mathcal{L} + \sum_j \Omega_j \|\theta_j - \theta_j^*\|_2^2, \tag{4}$$

其中， $\mathcal{L}$ 是原始损失函数，此处由（2）给出； θ_j 是第 j 个网络权重，θ_j^* 是预训练网络的第 j 个权重，而 Ω 是一个超参数，用于控制正则化强度。最常见的正则化类型之一是 L^2正则化，它会迫使所有参数趋近于零，即 $\theta_j^* = 0 \ \forall \ j$。其他方法则保留原始网络的参数值，即 θ^*，并根据各个权重对先前知识 [28]的重要性，计算其正则化强度。

当从机载系统接收到新数据时，考虑了两种不同的正则化器来更新模型： L^2 和 L^2-SP [29]。多个任务的结果表明，与更复杂且计算开销更大的方法相比，这些正则化器具有竞争力 [30]。 L^2-SP正则化器对所有参数施加相同的惩罚因子，即 Ω $_j = \alpha \ \forall \ j$ 和 $\alpha \in \mathbb{R}$。因此，所有权重都被限制在接近预训练网络权重的范围内。与使用 L^2 正则化器更新的模型相比，使用 L^2-SP正则化器更新的模型预计能够在学习新信息的同时，记住先前见过的行为。

4 结果

本节展示所提出的解决方案对物理系统进行建模、识别异常数据并更新数字模型的能力。

4.1 异常检测

在第2节介绍的第一个案例研究中，展示了检测异常数据的能力。数据集被划分为训练集和测试集。已知包含故障症状的数据被放入测试集。神经网络训练完成后，使用测试数据集测试网络预测发动机行为和识别异常的能力。机载系统运行于 ARM Cortex-A7 微处理器上（该处理器用于生产监控系统）。将测试集中的时间序列输入神经网络，以预测目标信号的值。在每个时间步计算标准化欧几里得距离或得分，以识别最异常的数据。

图 7 显示了数据集中包含已知故障的一段数据的预测结果和评分。可以看到，故障发生后，发动机的行为发生变化，因此模型无法预测新的行为。这导致故障发生后评分较高。

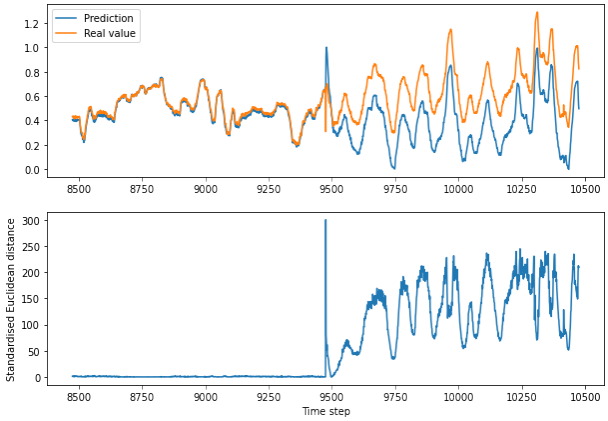


图 7：上：目标信号（压力）的实际值和预测值。时间步 9476 发生故障，导致系统行为发生变化。下：标准化欧几里得距离。标准化欧几里得距离用于选出最异常的数据。

从测试集的每条时间序列中，收集最异常且最不确定的窗口。机载系统返回的数据量受传输带宽限制。为尽可能多地收集数据，机载系统不使用阈值来筛选异常数据，而是采用排序系统，根据标准化欧几里得距离优先处理最异常的数据。在该案例研究中，每次飞行收集了排名前 100 的异常且不确定窗口。随后，地面系统对数据进行分析，以剔除非异常数据。由于数据可用性有限，地面系统的异常检测器使用从一台发动机长期收集的历史数据进行训练。此类历史数据可能包含当前数字孪生尚未充分学习的罕见行为。因此，地面系统能够识别被机载系统标记为异常的正常数据片段。需要注意的是，尽管研究中只考虑了一台发动机，但所提出的方法旨在使用一组系统或整个机队的数据。在机载系统于前 14 次飞行中收集的 1400 个已分析窗口中，地面系统识别出 10 个异常窗口，其中包括已知异常。这表明所提出的解决方案能够减轻用户的工作负担。随后对其余被检测为异常的窗口进行了进一步分析。该分析将一台发动机记录的数据与其姊妹发动机（飞行中使用的另一台发动机）记录的数据进行比较。两台发动机记录的数据之间存在较大的残差，表明其中一台发动机的行为异常。在 10 个被标记的窗口中，有 5 个窗口（包括已知异常）呈现出较大的发动机间残差。这证实了已知的异常行为，并表明可能还存在此前未发现的异常。

上面的示例展示了对预测信号中真实异常的检测。为说明如何检测车载神经网络输入中的异常，我们将不同规模的异常合成注入输入数据中，见图 8。上图展示了随着异常规模增大，预测误差（即预测值与真实值之差）的分布。正如预期，异常规模增大将导致预测误差增大。中间的图展示了标准化欧几里得距离的累积分布。该图表明，对于给定的通信容量，返回的异常所对应的平均误差将会增大。

最后一张图展示了未知输入对预测置信度的影响。随着输入变得越发异常，预测置信度会降低。这种置信度降低会对先前未知输入造成的预测误差施加惩罚。然而，正如第一个案例研究的结果所示，对于足够大的异常输入，这种惩罚并不会妨碍检测异常。

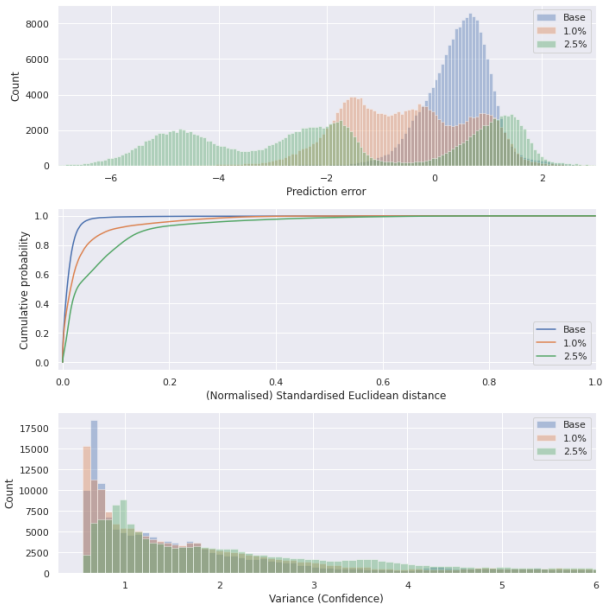


图 8：深度神经网络输入中不同幅度的异常（占输入范围的百分比）所产生的影响。上：预测误差直方图。中：归一化标准化欧几里得距离的累积分布。下：预测方差直方图。随着输入空间中的噪声水平增加，网络的置信度会降低，即方差会增大。

4.2 数字孪生更新

这里展示使用从物理系统收集的数据更新数字模型的结果。这对应于第2节中介绍的第二个案例研究。此外，我们根据预测准确率以及记忆先前行为的能力，对第3.3节中介绍的正则化方法进行了比较。

采用迭代更新策略来更新数字孪生。使用4月17日之前各次运行的全部数据训练初始模型，并用该模型从随后10次运行（训练数据之后）中筛选异常数据。收集到的数据用于更新数字孪生。模型更新后，对接下来的10次运行数据进行处理和收集，再次用于更新数字孪生。重复此过程，直至处理完所有运行数据。初始模型和更新后模型的预测误差如图9所示。初始模型的误差在2017年9月之后显著增加，这是由于对发动机进行了维护。结果表明，通过更新数字孪生，即使系统发生变化，也能够预测物理系统的行为。

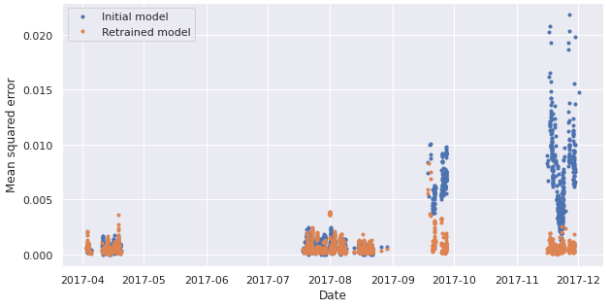


图 9：初始模型和迭代重新训练模型所作预测的均方误差。

为说明对物理系统的错误模拟会如何影响异常识别，我们在随机选取的运行数据中注入了合成异常（长度和幅度固定的尖峰，其幅度基于信号的局部标准差）。这些运行数据分为两组：9 月维护事件之前和之后。如图 9 所示，当数字孪生未更新时，无法准确预测系统行为。因此，异常检测的表现预计会较差，结果也证实了这一点。数字孪生未更新时，维护事件之前检测到 22 个合成异常，之后仅检测到 1 个。相比之下，更新数字孪生后，大修之前和之后分别检测到 28 个和 23 个异常。结果表明，定期更新数字孪生能提高检测到的异常数量。正如预期，在维护事件之后的数据中，改进更为明显。

以上结果表明，当

模型定期更新时，可以准确预测发动机行为。不过，这些结果并未说明模型在遗忘先前行为方面受到何种影响。为观察这一影响，从每次发动机运行中提取了两个不同的机动工况或运行剖面，分别标记为 A 和 B，见图 10（上）。首先使用机动工况 A 训练模型，并假设没有机动工况 B 的数据可用。随后，按照上述流程，使用机动工况 B 的数据对模型进行迭代再训练。采用了三种不同的方法对模型进行再训练： L^2 正则化、$L^2 - SP$ 正则化，以及一种扩充训练数据方法，其中包含机动工况 A 的历史数据。图 10（下）展示了模型再训练后对机动工况 A 的预测。不同方法对机动工况 B 的预测差异并不显著，因此未予展示。

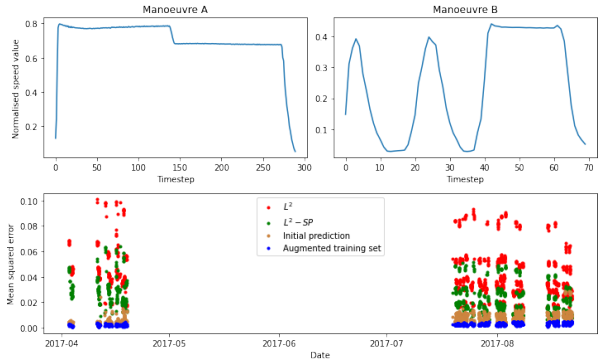


图 10：上图：代表发动机不同运行行为的机动工况。下图：采用不同训练方法，使用机动工况 B 对模型重新训练后，对机动工况 A 的预测。

正如预期，结果表明，使用 L^2 正则化器更新模型后，模型会忘记如何预测操作 A。使用 $L^2 - SP$ 正则化器时，遗忘现象显著减少。在重新训练期间加入操作 A 的数据，可提高模型记住操作 A 的能力。虽然在上述玩具示例中，这种方法并不构成挑战，但当必须从大量历史发动机行为数据中挑选数据时，就会带来新的挑战，因为这些数据可能无法代表系统当前的行为。

5 结论

数字孪生广泛应用于物理系统的管理、优化和决策支持。为准确表征对应的物理系统，数字孪生必须定期利用从物理系统采集的数据进行更新，以便识别物理系统中的异常行为。对于资源受限的系统而言，这可能是一项重大挑战。此外，并非所有采集到的数据都适合用于更新数字孪生，例如，与新出现的故障相关的异常必须谨慎处理，尤其是在本文选定的系统健康监测应用中。本文提出了一种新颖的两阶段框架，用于使数据驱动数字孪生与其对应的物理系统保持同步。该方案支持资产实时监测，并利用无故障车队数据筛选高质量数据，以便远程更新数字孪生。燃气涡轮发动机案例研究的结果表明，该方案能够在发动机的整个生命周期内准确模拟其行为。为进一步降低更新所需的计算和数据要求，值得探索的未来研究方向包括制定模型更新时机的（最优）判据，以及在机器学习更新过程中引入基于物理的约束。

参考文献

[1]F. Tao、H. Zhang、A. Liu 和 A. Y.C. Nee。《工业中的数字孪生：最新进展》。*IEEE*工业信息学汇刊，15(4):2405–2415，2018年。

[2]E. Glaessgen 和 D. Stargel。《面向未来美国国家航空航天局和美国空军车辆的数字孪生范式》。载于 *AIAA/ASME/ASCE/AHS/ASC* 结构、结构动力学与材料会议论文集，第118页，2012年。

[3] B. R. Barricelli、E. Casiraghi 和 D. Fogli。关于数字孪生的综述：定义、特征、应用与设计启示。*IEEE Access*，7:167653–167671，2019年。[4] J. Leng、D. Wang、W. Shen、X. Li、Q. Liu 和 X. Chen。基于数字孪生的工业4.0智能制造系统设计：综述。*Journal of Manufacturing Systems*，60:119–137，2021年。[5] The DTHub。http://https://digitaltwinhub.co.uk

访问日期：2021-06-15。[6] Q. Qi 和 F. Tao。数字孪生与大数据助力智能制造和工业4.0：360度比较。*IEEE Access*，6:3585– 3593，2018。[7] E. J. Tuegel、A. R. Ingraffea、T. G. Eason 和 S. M. Spottswood。利用数字孪生重新设计飞机结构寿命预测。国际航空航天工程期刊，2011，2011。[8]R. Magargle、L. Johnson、P. Mandloi、P. Davoudabadi、O. Kesarkar、S. Krishnaswamy、J. Batteh 和 A. Pitchaikani。用于汽车制动系统模型驱动健康监测和预测性维护的基于仿真的数字孪生。载于*International Modelica Conference* 会议论文集，第35–46页。Link¨oping University Electronic Press，2017。[9] C. Li、S. Mahadevan、Y. Ling、S. Choze 和 L. Wang。用于飞机机翼健康监测数字孪生的动态贝叶斯网络。*AIAA Journal*，55(3):930–941，2017。

[10] J. Wang、L. Ye、R. X. Gao、C. Li 和 L. Zhang。《智能制造中旋转机械故障诊断的数字孪生》。《国际生产研究》，57(12):3920–3934，2019年。

[11] S. Chakraborty 和 S. Adhikari。《基于机器学习的动力系统数字孪生》具有多个时间尺度。*Computers & Struc-tures*，243:106410，2021。[12]O. Fink、Q. Wang、M. Svensen、P. Dersin、W. Lee 和 M. Ducoffe。深度学习在预测与健康管理应用中的潜力、挑战与未来方向。*Engineering Applications of Intelligence*，92:103678，2020。[13] R. Burbidge、J. J. Rowland 和 R. D. King。基于委员会查询的回归主动学习。载于*Proc. of IDEAL*，第209–218页。Springer，2007。[14] W. Cai、Y. Zhang 和 J. Zhou。最大化回归主动学习中的预期模型变化。载于*Proc. of ICDM*，第51–60页。IEEE，2013。[15] Y. Yang、Z. Ma、F. Nie、X. Chang 和 A. G. Hauptmann。通过不确定性采样与多样性最大化实现多类别主动学习。*InternationalJournalofComputer Vision*，113(2):113–127，2015。[16]V. Chandola、A. Banerjee 和 V. Kumar。异常检测：综述。*ACM computingsurveys (CSUR)*，41(3):1–58，2009。[17] M. A.F. Pimentel、D. A. Clifton、L. Clifton 和 L. Tarassenko。新颖性检测综述。*Signal Processing*，99:215–249，2014。[18] S. Rajasegarar、C. Leckie 和 M. Palaniswami。无线传感器网络中的异常检测。*IEEEWireless Communications*，15(4):34–40，2008。[19]M. B. Attia、C. Talhi、A. Hamou-Lhadj、B. Khosravifar、V. Turpaud 和 M. Cou- ture。资源受限系统的设备端异常检测。载于*Proc. of ACM/SIGAPP*，第548–554页，2015。[20]P. Amontamavut、Y. Nakagawa 和 E. Hayakawa。面向嵌入式系统的分离式 Linux 进程日志记录机制。载于*Proc.of RTCSA*，第411–414页。IEEE，2012年。

[21] S. Saurav、P. Malhotra、V. TV、N. Gugulothu、L. Vig、P. Agarwal 和 G. Shroff。使用循环神经网络结合概念漂移适应进行在线异常检测。载于*Proc. of theACM India JointInternationalConference onData Scienceand Managementof Data*，第78–87页，2018年。[22] B. Reddy、Y. Kim、S. Yun、C. Seo 和 J. Jang。利用深度神经网络模型压缩实现面向嵌入式系统的实时驾驶员疲劳检测。载于*Proc. of CVPR*，第121–128页，2017年。[23] V. Sze、Y. Chen、T. Yang 和 J. S. Emer。深度神经网络的高效处理：教程与综述。*Proceedings of the IEEE*，105(12):2295–2329，2017年。[24] Adam Hartwell、Felipe Montana、Will Jacobs、Visakan Kadirkamanathan、Andrew R Mills 和 Tom Clark。利用卷积神经网络进行飞行中新颖性检测。*arXiv preprintarXiv:2112.03765*，2021年。[25] K. Yang 和 C. Shahabi。用于多变量时间序列核主成分分析的基于PCA的核。载于*Proc.of ICDM*，2005年。[26] J. Yosinski、J. Clune、Y. Bengio 和 H. Lipson。深度神经网络中的特征具有多强的可迁移性？载于*Advances in neural information pro-cessing systems*，第3320–3328页，2014年。[27] M. McCloskey 和 N. J. Cohen。连接主义网络中的灾难性干扰：序列学习问题。载于*Psychology oflearning and motivation*，第24卷，第109–165页。爱思唯尔，1989年。[28]J. Kirkpatrick、R. Pascanu、N. Rabinowitz、J. Veness、G. Desjardins、A. A. Rusu、K. Milan、J. Quan、T. Ramalho、A. Grabska-Barwinska 等。克服神经网络中的灾难性遗忘。*Proc. of the national academy ofsciences*，114(13):3521–3526，2017年。[29] H. Daum´e III。令人沮丧地简单的领域适应。*arXiv preprint arXiv:0907.1815*，2009年。[30]X. Li、Y. Grandvalet 和 F. Davoine。用于卷积网络迁移学习的显式归纳偏置。*arXiv* 预印本 *arXiv:1802.01483*，2018。