基于希尔伯特-施密特独立性准则的门控循环单元网络用于健康状态估计

Ziyue Huang、Lujuan Dang、Yuqing Xie、Wentao Ma，*IEEE* 会员 和陈八东，*IEEE* 高级会员

摘要—**健康状态（SOH）估算是确保电池安全、可靠运行的关键环节。由于不同循环的数据分布和序列长度各不相同等问题，现有的大多数方法都需要进行健康特征提取，这一过程既耗时又费力。门控循环单元（GRU）结构简单、性能优异，能够很好地解决这一问题，因此受到广泛关注。然而，网络中仍然存在冗余信息，影响健康状态估算的准确性。为解决这一问题，本文提出一种基于希尔伯特-施密特独立性准则的新型门控循环单元网络（GRU-HSIC）。首先，采用零掩码网络将每个循环中测得的不同长度电池数据转换为长度相同的序列，同时保留各循环原始数据规模的信息。其次，将源自信息瓶颈（IB）理论的希尔伯特-施密特独立性准则（HSIC）瓶颈扩展至GRU，以压缩隐藏层中的信息。为评估所提方法，我们在马里兰大学先进生命周期工程中心（CALCE）和NASA艾姆斯卓越预测中心的数据集上进行了实验。实验结果表明，我们的模型比其他循环模型具有更高的准确率。**

索引词—**信息瓶颈、健康状态、门控循环单元、希尔伯特-施密特独立性准则（HSIC）**。

I. 引言

T能源需求的不断增长给环境和能源资源都带来了巨大压力。因此，越来越多人开始考虑将可再生能源作为替代能源。锂离子电池具有能量密度高、功率性能良好、自放电率低等优点，因此已广泛应用于电动汽车（EV）、电动船舶和电动飞机中[1–3]。然而，其电化学特性会导致电池健康状态逐渐恶化，使功率和容量随时间推移而衰减 [4]。为确保电池使用安全可靠，研究人员开发了健康状态（SOH）估计技术[5]。目前，健康状态估计方法主要分为三类：实验或直接评估方法、自适应方法和数据驱动方法[6]。

本研究得到中国国家重点研发计划资助（项目编号：2021YFB2401904）。（通讯作者：陈八东。）

Ziyue Huang、Lujuan Dang、Yuqing Xie 和陈八东供职于人机混合增强智能国家重点实验室、国家视觉信息与应用工程研究中心以及西安交通大学人工智能与机器人研究所（中国西安，邮编 710049）（电子邮箱：zyhuang99@stu.xjtu.edu.cn；dan-glj@xjtu.edu.cn；felixxyq@stu.xjtu.edu.cn；chenbd@mail.xjtu.edu.cn；）。

Wentao Ma 任职于中国西安 710048 的西安理工大学电气工程学院（电子邮箱：mawt@xaut.edu.cn）

直接测量方法通过对充满电的电池进行完整放电，测得其容量或电阻。常见的直接测量方法包括库仑计数法 [7], 开路电压法[8], 和电化学阻抗谱法[9]。这些方法易于采集数据，计算效率高，但需要严格的测试条件，因此难以应用于实际场景。基于模型的方法将电池数据用于构建电化学模型（如戴维南电池模型 [10] 和RC模型 [11, 12]），以模拟电池的物理和化学性质。随后，使用偏微分方程（PDE）[13], 卡尔曼滤波器[14, 15], 及其他滤波方法估算健康状态。这些简单的电池模型与滤波方法相结合，能够更好地模拟电池的动态特性，并适用于更多场景。然而，这些方法的准确性取决于电化学模型的复杂度和精度，而且在不同运行条件下构建的模型不能相互通用。随着人工智能技术的发展，数据驱动方法近年来广受欢迎，其中包括支持向量机等机器学习方法 [16, 17],

高斯过程回归 [18], 随机森林 [19], 以及卷积神经网络 [20], IRBFNN [21], 长短期记忆网络 [22], 和门控循环单元 [23]等深度学习方法。数据驱动模型能够从数据中提取信息，且不依赖电化学模型，因此适用于不同类型的电池和运行条件。然而，大多数数据驱动方法都需要提取健康特征，因为电池数据的长度在每个循环中都会变化。这一步会提取健康特征，例如基于增量计算的健康特征、基于时间的健康特征、基于包络面积的健康特征，以及基于模型参数的健康特征 [1], , 这些特征反映了电池在不同循环之间的变化。尽管如此，这些方法往往会丢失大量信息，而且将健康特征提取与后续模型训练分开，会大幅增加工作量。

提出了一种基于滑动时间窗口的GRU网络来估计健康状态 [24], , 该方法无需预先从电池数据中提取健康特征。然而，该方法仅利用容量数据，忽略了电压、电流和温度等其他重要数据。相比之下，Fan等人 [25] 采用等间距重采样法，将电压、电流和温度数据输入GRU-CNN网络，从而有效利用了这些数据。此外，还提出了一种带有掩码网络的长短期记忆网络，用于处理作为输入的变长时间序列数据，从而消除了

对特定输入时间大小或长度的需求 [26, 27]。作为循环神经网络的变体，长短期记忆网络和门控循环单元凭借其循环连接，在处理时间序列任务方面表现出色，并解决了循环神经网络中出现的梯度爆炸和梯度消失问题。带有掩码网络的门控循环单元和长短期记忆网络能够从所有测量数据中学习，并以简单的流程和简洁的结构准确估计健康状态，无需提取健康特征。此外，门控循环单元的参数显著少于长短期记忆网络，但性能相当，效率更高 [28]。在某些情况下，门控循环单元从数据中学习的效果甚至优于长短期记忆网络 [29]。然而，在训练上述门控循环单元网络的过程中，所学信息可能存在冗余。为解决这一问题，Tishby [30], 最初提出的信息瓶颈（IB）理论为压缩信息提供了一种很有前景的方法。将信息瓶颈理论扩展到门控循环单元后，我们可以在保持结构简单的同时提升其性能。

本文的主要贡献如下：

- 采用零掩码网络处理每个循环中长度各异的所有电池数据。我们的方法将健康特征提取与模型训练相结合。
- 我们提出了一种将信息瓶颈理论融入门控循环单元的新方法，从而增强门控循环单元捕获有用信息的能力。
- 我们的方法适用于恒定和随机充放电数据。我们使用来自马里兰大学 CALCE 和 NASA随机游走的数据集进行实验，以验证该方法的优越性能。

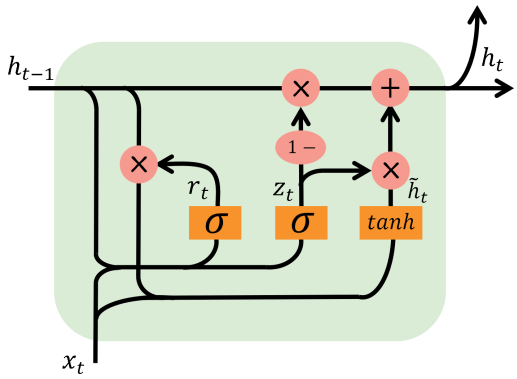


图 1：门控循环单元的内部结构

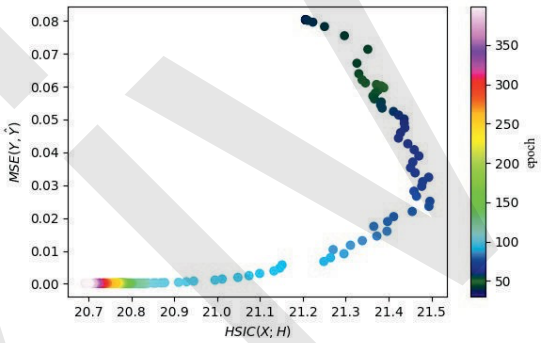


图 2：基于 CS 数据集的门控循环单元信息平面

II. Method

A. 健康状态的定义

在电池管理系统（BMS）中，SOH 是用于描述电池健康状态的指标，通常与电池的功率或最大容量有关。SOH 的定义如式（1）所示；在本研究中，目标是估计每个电池循环的最大容量。

$$SOH = \frac{C_{max}}{C_{nom}} \times 100\% \tag{1}$$

其中，C_{max} 表示电池在当前循环中的最大容量，而C_{new} 表示新电池的标称容量。

B. 门控循环单元网络

由于电池数据具有很强的时间特性，门控循环单元能够有效捕捉有助于估计健康状态的信息。门控循环单元的内部结构如图1所示。门控循环单元通过两个门控循环——重置门和更新门，来保留和丢弃信息。门控循环单元的内部计算如下：

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \tag{2}$$

$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \tag{3}$$

$$\tilde{h}_t = \tanh(W_h x_t + U_h(r_t \odot h_{t-1}) + b_h) \tag{4}$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \tag{5}$$

其中，x_t 表示时间t的输入，h_{t-1} 表示时间$t-1$的前一状态，r_t 和z_t 分别表示重置门和更新门的输出，$\tilde{h}_t$ 和h_t 分别表示时间t的候选隐藏状态和隐藏状态，$\odot$ 表示逐元素乘法，σ 表示 Sigmoid 函数，tanh 表示双曲正切函数，W_r、U_r、b_r、W_z、U_z、b_z、W_h、U_h、b_h 表示门控循环单元模型的参数。

然而，由于每个电池循环中的数值序列长度各不相同，在将数据输入深度学习方法之前，需要进行健康特征提取。但如果加入零掩码网络，GRU 就可以直接从每个循环中长度不同的电池数据进行学习。零掩码网络通过在短于最长序列的序列末尾补零，将输入序列转换为定长序列。随后，GRU 层会滤除序列末尾的所有零，同时保留每个循环长度的信息。

C. 信息瓶颈与希尔伯特-施密特独立性准则

信息瓶颈原理的目标是在保留T 关于输出 Y 的

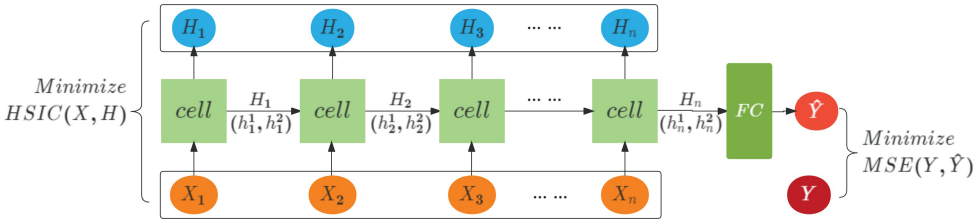


图 3：GRU-HSIC 结构

最大信息量的同时，获得输入<style id='3'>X </style>的最大压缩表示<style id='1'>T </style>。其数学表达式如式（6）所示。

$$L_{IB} = I(T;Y) - \beta I(X;T) \tag{6}$$

其中，$I(\cdot;\cdot)$ 表示互信息，$\beta > 0$ 是用于衡量这两个互信息的拉格朗日乘子。对于人工神经网络，T 可以表示其中一个中间层。由于人工神经网络中的输入X、隐藏层的信息H 和输出Y 显然构成一个马尔可夫链：$X \to H \to Y$。使用信息瓶颈解释深度神经网络 [31] 的工作机制已得到广泛认可。特别是，由于信息瓶颈的计算过程复杂得多，我们使用由信息瓶颈演化而来、计算更简便的希尔伯特-施密特独立性准则（HSIC）瓶颈 [32]，而非隐藏层与输入之间的互信息。HSIC 可以衡量两个随机变量之间的依赖关系。给定两个随机变量x 和y，以及两个映射函数 $\phi: X \to F$ 和 $\varphi: Y \to G$。HSIC [33–35] 的公式如下：

$$\begin{aligned} HSIC(X,Y) &= \|C_{XY}\|^2_{HS} \\ &= \|E[\phi(X)\varphi(Y)] - E[\phi(X)]E[\varphi(Y)]\|^2_{HS} \\ &= E[k(X,X')l(Y,Y')] + E[l(X,X')]E[l(Y,Y')] \\ &\quad - 2E[E[k(X,X')|X]E[l(Y,Y')|Y]] \end{aligned} \tag{7}$$

其中，X′ 和 Y′ 分别是 X 和 Y 的独立同分布副本。本文中的 k(X, X′) 和 l(Y, Y′) 为高斯核，并满足：k(x, x′) = ϕ(x − x′) 和 l(y, y′) = φ(y − y′)，其中 x、x′ 属于 R^p，y、y′ 属于 R^q。F 和 G 是再生核希尔伯特空间（RKHS），C_{XY} 是交叉协方差算子。给定从 P_{XY} 中抽取的样本 Z = $(X_1, Y_1), \ldots, (X_n, Y_n)$，其中 P_{XY} 是 X 和 Y 的联合测度。由于 k(X, X′) = k(X′, X)，且 l(Y, Y′) = l(Y′, Y)，我们将 k(X, X′)记为 k_X，将 l(Y, Y′)记为 l_Y。因此，通过计算式（8），可得到 HSIC 的如下形式：

$$HSIC(X,Y) = \frac{1}{(n-1)^2} tr(k_X W k_Y W) \tag{8}$$

where $W = I_n - \frac{1}{n}\begin{bmatrix} 1 & \cdots & 1 \\ \vdots & \ddots & \vdots \\ 1 & \cdots & 1 \end{bmatrix}$.

为观察门控循环单元训练过程中信息的变化，我们使用隐藏层与输入之间的希尔伯特-施密特独立性准则（HSIC），以及模型输出与真实值之间的均方误差（MSE），而非互信息。如图 2 所示，输入与隐藏层之间的 HSIC 起初增加，随后降低，这表明训练过程中存在冗余。考虑到应用信息瓶颈理论能够有效减少冗余，并提升门控循环单元的性能和效率，我们构建了一种带有 HSIC 瓶颈的新型门控循环单元模型，称为 GRU-HSIC。其结构如图 3 所示，损失函数见式（9）。

$$L_{GRU-HSIC} = MSE(Y, \hat{Y}) + \beta HSIC(X;H) \tag{9}$$

其中，Y 表示最大容量的真实值，$\hat{Y}$ 表示模型的估计值，X 表示输入，H 表示模型中隐藏层的信息，β 是拉格朗日乘子。

III. 实验

A. 数据集

本实验选取了三个数据集。其中两个来自马里兰大学先进生命周期工程中心（CALCE），[36], 另一个来自 NASA 艾姆斯卓越预测中心 [37, 38]。

分别从 CALCE 的 CS 和 CX2 数据集中选取了八个电池，即 CS2_35、CS2_36、CS2_37、CS2_38 以及 CX2_34、CX2_36、CX2_37、CX2_38。这些电池具有相同的正极材料 $LiCoO_2$，，采用相同的恒流-恒压（CC-CV）充电过程和恒流（CC）放电过程，但 CS 电池的额定容量为 1100 mAh，而 CX2 电池为 1350 mAh。

本文选取了来自 NASA 艾姆斯卓越预测中心的四个随机游走放电电池（RW13、RW14、RW15、RW16）。通过反复充电至 4.2V，再以 0.5A 至 5A 的随机电流放电至 3.2V，使这些电池持续运行。每经过 50 个循环，都会进行参考充放电循环，为电池健康状态提供基准。

本文采用的评估指标包括 均方误差、均方根误差、平均绝对误差、平均绝对百分比误差、对称平均绝对百分比误差 和相对误差，其定义见公式（10–15）。

$$MSE = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2 \tag{10}$$

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2} \tag{11}$$

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|y_i - \hat{y}_i| \tag{12}$$

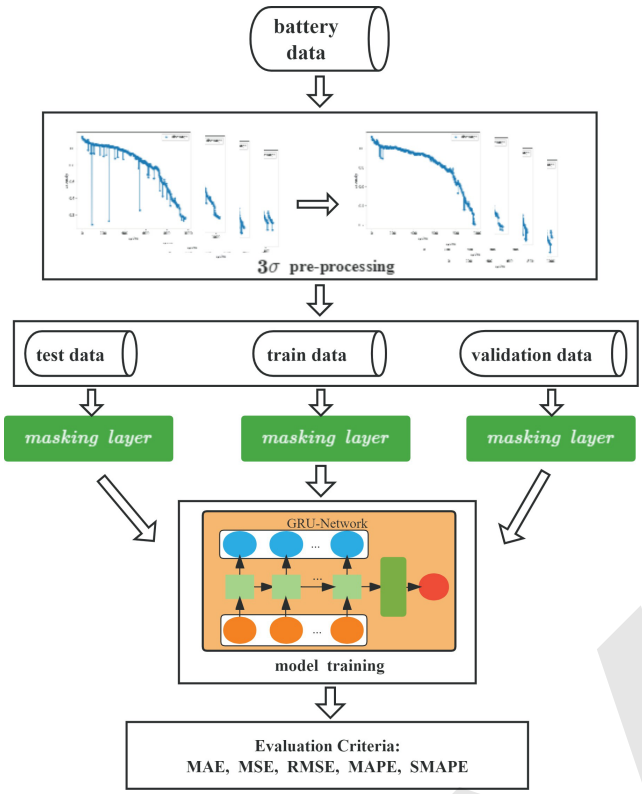


图 4：流程图

表 I：CS 数据集中的模型设置

模型	隐藏状态	网络层	seed	学习 rate	β	训练轮次
RNN	2	3	13	0.01	/	900
LSTM	2	3	13	0.01	/	900
GRU	2	3	13	0.005	/	900
GRU-HSIC	2	3	13	0.005	0.001	900

$$MAPE = \frac{100\%}{n}\sum_{i=1}^{n}\left|\frac{y_i - \hat{y_i}}{y_i}\right| \tag{13}$$

$$SMAPE = \frac{100\%}{n}\sum_{i=1}^{n}\frac{2\left|y_i - \hat{y_i}\right|}{(\left|y_i\right| + \left|\hat{y_i}\right|)} \tag{14}$$

$$relative\ errors = \left|y_i - \hat{y}_i\right| \tag{15}$$

实验在四块 NVIDIA 3090 GPU 上使用 Python 3.7.0 进行。

表 II：CS 数据集中的 MAE 分数比较

模型	平均 MAE	MAE 中的 CS2_35	MAE 中的 CS2_36	MAE 中的 CS2_37	MAE 中的 CS2_38
THF-RF	0.015229	0.008943	0.031082	0.009837	0.011056
THF-GPR	0.026747	0.023732	0.038745	0.021040	0.023472
RNN	0.071835	0.050642	0.081031	0.081577	0.074091
LSTM	0.024486	0.017969	0.025427	0.016974	0.037571
GRU	0.009695	0.010174	0.013220	0.009949	0.005437
GRU-HSIC	**0.004321**	**0.004553**	**0.006372**	**0.003656**	**0.002704**

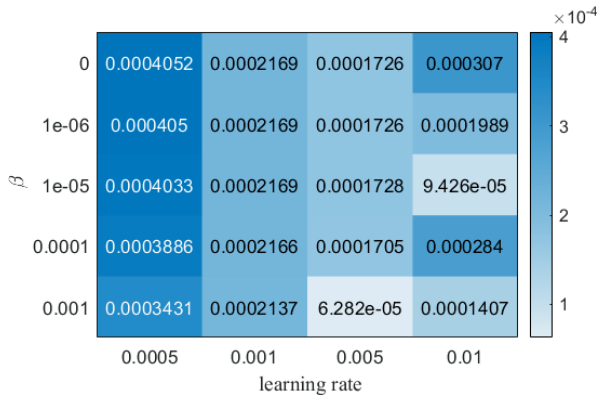


图 5：CS 数据集中 GRU 和 GRU-HSIC 的均方误差得分比较

表 III：CS 数据集中均方根误差得分比较

模型	平均均方根误差	RMSE 在 CS2_35	RMSE 在 CS2_36	RMSE 在 CS2_37	RMSE 在 CS2_38
THF-RF	0.053642	0.035144	0.119698	0.036704	0.023021
THF-GPR	0.053850	0.041323	0.064588	0.052288	0.057202
RNN	0.101645	0.068206	0.133452	0.102226	0.102698
LSTM	0.041674	0.023447	0.042906	0.020965	0.079379
GRU	0.012250	0.010843	0.020242	0.010098	0.007815
GRU-HSIC	**0.006982**	**0.005389**	**0.013404**	**0.005224**	**0.003911**

B. CS 数据集上的实验

对于 CS 数据集，模型的真实值通过对放电和充电电流数据进行积分得到。由于充电部分的异常值较多，实验中优先采用放电部分，以准确近似真实值。整个时间序列的电压、电流和电阻（V、I、R）用作模型输入，而每个循环经过异常值处理后的相应容量则用作标签。

在训练过程中，我们使用两块电池作为训练数据，一块电池作为验证数据，剩余的一块电池作为测试数据。例如，在电池 CS2_35 的实验中，电池 CS27 和 CS2_38 用作训练数据，电池 CS2_36 用作验证数据，剩余的电池 CS2_35 用作测试数据。对于循环神经网络、长短期记忆网络、门控循环单元，对于 GRU-HSIC，使用了所有电压、电流和电阻数据，导致循环网络的复杂度较高。为避免模型规模过大而难以应用，我们将重点放在架构简单的模型上。这四种模型的配置如表 I 所示，并从中选取四种模型的最佳结果。以 GRU 和 GRU-HSIC 为例，我们在图 5 中绘制了不同参数（学习率和 β）下的实验热力图；当学习率为 0.005、beta 为 0.0 和 0.001 时，参数取值最佳。此外，我们还采用基于经典基于时间的健康特征（THF）的随机森林（RF）模型和高斯过程回归（GPR）模型作为对比。

从表 II 和表 III 可以看出，电池的最佳 MAE 和 RMSE 均出现在 GRU-HSIC 中。从图 7 可以明显看出，

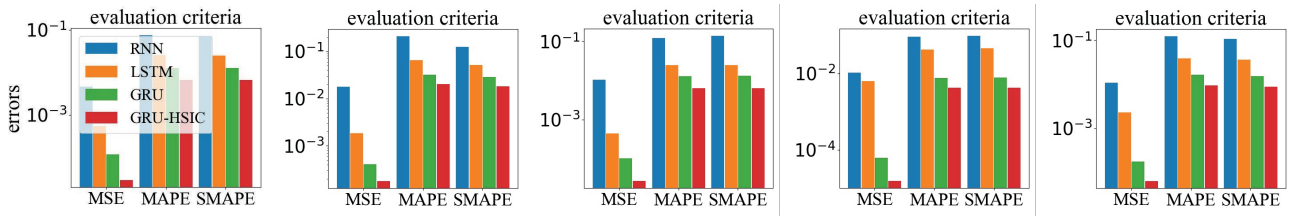


图 6：在 CS 数据集中的评估： （**a**）CS2_35， （**b**）CS2_36， （**c**）CS2_37， （**d**）CS2_38， （**e**）平均评估 .

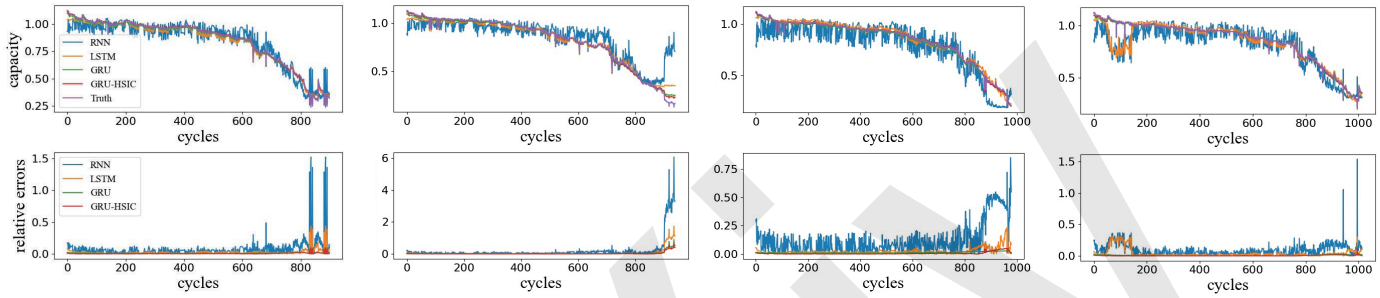


图 7：容 量及 CS 数据集中的相对误差： （**a**）CS2_35， （**b**）CS2_36， （**c**）CS2_37， （**d**）CS2_38。

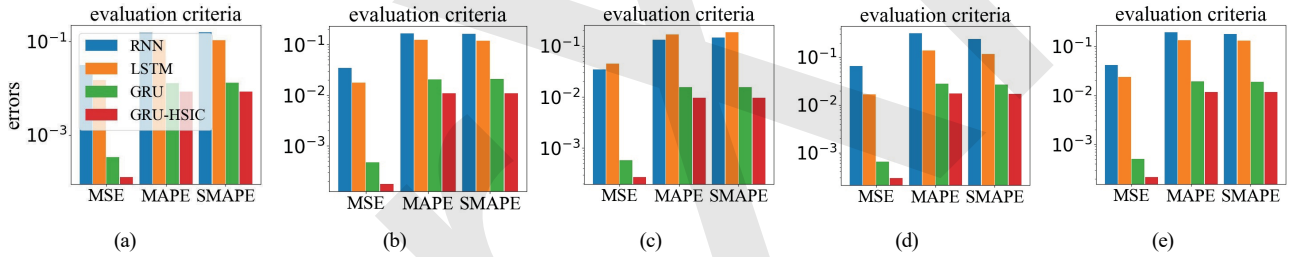


图 8：CX2 数据集中的评估： （**a**）CX2_34， （**b**）CX2_36， （**c**）CX2_37， （**d**）CX2_38， （**e**）平均评估。

在电池寿命的每个循环中，GRU-HSIC 的准确率都远高于 RNN 和 LSTM，且略高于 GRU。在四种电池寿命的最后几百个循环以及电池 CS2_38 的前 200 个循环中，RNN 和 LSTM 均出现了显著波动，但 GRU 和 GRU-HSIC 仍保持良好性能。GRU-HSIC 的误差基本在 0.015 以内波动。THF-RF 和 THF-GPR 的准确率与 LSTM 相近，但 THF-RF 的整体精度较低，且 THF-GPR 在这四种电池上的精度不稳定。与这两种采用基于时间的健康特征的方法相比，GRU 和 GRU-HSIC 的表现要好得多。这表明 GRU 和 GRU-HSIC 均具有良好的鲁棒性，并且能够很好地获得全局最优解。RNN 表现最差，可能是由于其循环单元结构过于简单。LSTM 表现不佳，可能是因为其在训练过程中保留了过多冗余信息。而 GRU 的简化结构能够筛除不需要的信息，加入 HSIC 瓶颈结构后，则进一步过滤隐藏层中的信息。从图 6 可以看出，GRU-HSIC 在所有五项评估指标（平均绝对误差、均方误差、均方根误差、平均绝对百分比误差、对称平均绝对百分比误差）均表现出显著优势。

表 IV：CX2 数据集中模型的设置

模型	隐藏状态	网络层	seed	学习 rate	β	训练轮次
RNN	2	1	11	0.01	/	900
LSTM	2	1	11	0.005	/	900
GRU	2	1	11	0.005	/	900
GRU-HSIC	2	1	11	0.005	0.001	900

表 V：CX2 数据集中的 MAE 分数对比

模型	平均 MAE	MAE 在 CX2_34	MAE 在 CX2_36	MAE 在 CX2_37	平均绝对误差（ CX2_38
THF-RF	0.028219	0.022766	0.012403	**0.007014**	0.070692
THF-GPR	0.023852	0.016552	0.015625	0.018064	0.045166
RNN	0.167329	0.153342	0.157970	0.155531	0.202474
LSTM	0.123287	0.102471	0.112975	0.189748	0.087954
GRU	0.017001	0.012931	0.018360	0.017600	0.019114
GRU-HSIC	**0.011033**	**0.008737**	**0.010892**	**0.011177**	**0.013325**

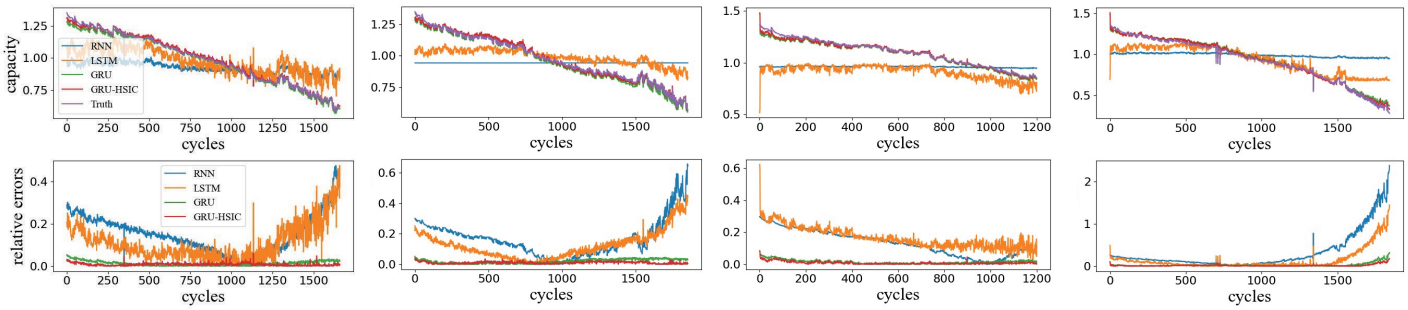


图 9：CX2 数据集中的容量和相对误差：（**a**）CX2_34，（**b**）CX2_36，（**c**）CX2_37，（**d**）CX2_38。

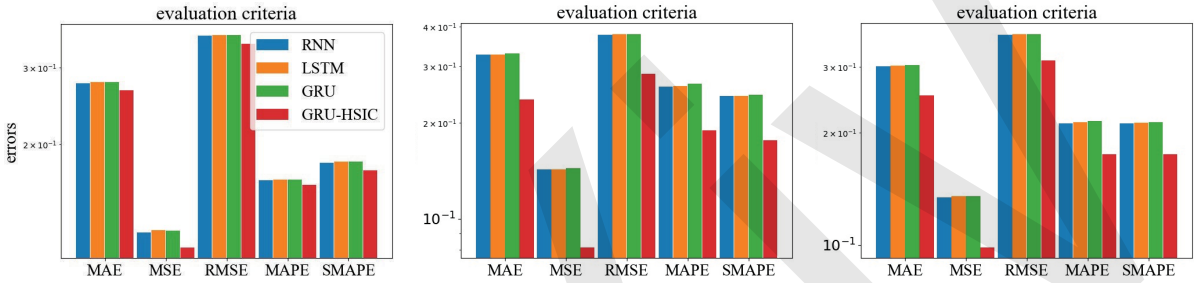


图 10：神经架构搜索中的评估 RW 数据集：（**a**）第一次实验，（**b**）第二次实验，（**c**）平均评估。

表 VI：CX2 数据集中的均方根误差得分比较

模型	平均均方根误差	RMSE 中 CX2_34	RMSE 中 CX2_36	RMSE 中 CX2_37	RMSE 中 CX2_38
THF-RF	0.066520	0.041006	0.033559	0.017917	0.173600
THF-GPR	0.048207	0.034264	0.037784	0.038850	0.081931
RNN	0.201727	0.178027	0.186825	0.186317	0.255737
LSTM	0.149096	0.122604	0.133215	0.211353	0.129210
GRU	0.022353	0.018316	0.021702	0.024103	0.025292
GRU-HSIC	**0.014502**	**0.011191**	**0.013266**	**0.016436**	**0.017113**

表 VII：NASA RW 数据集中的模型设置

模型	隐藏状态	网络层	seed	学习 rate	β	训练轮次
RNN	2	3	12	0.05	/	1000
LSTM	2	3	12	0.05	/	1000
GRU	2	3	12	0.05	/	1000
GRU-HSIC	2	3	12	0.05	2.0	1000

C. CX2 数据集实验

与放电部分相比，CX2 数据集中的充电部分也包含更多异常值，因此实验中更倾向于使用放电部分。CX2 数据集中的训练集和测试集与 CS 数据集中的相同。模型集合也与 CS 数据集中的相似，如表 IV 所示，我们为这些结构选择了最佳参数。最终结果见图 9、图 8、表 V 和表 VI。GRU-HSIC 中电池 CX2_34 - CX2_38 的 MAE 和 RMSE 最佳。THF-RF 和 THF-GPR 的性能优于 LSTM，但不如门控循环单元和 GRU-HSIC，其中 THF-RF 在电池 CX2_37 上的表现非常好，但在电池 CX2_38上的表现较差。从图 9 可以看出，尽管模型结构变得更简单，GRU-HSIC 在所有这些循环模型中仍保持了较高的准确性，相对误差也基本在 0.02 以内波动。然而，长短期记忆网络和循环神经网络模型的表现变得相当糟糕。与循环神经网络相比，长短期记忆网络的趋势更明显地贴合真实值，但其波动过大。与长短期记忆网络和循环神经网络相比，门控循环单元和 GRU-HSIC 在所有循环过程中表现都非常出色。此外，从图 8 可以看出，GRU-HSIC 在五项评估指标（平均绝对误差、均方误差、均方根误差、平均绝对百分比误差、对称平均绝对百分比误差）下也始终保持最佳性能

CX2数据集。经验证，结构更简单的 GRU-HSIC 也具有良好的性能。

D. NASA-RW 数据集实验

在 NASA RW 数据集中，每两个随机充电和放电实验之间都有两个标准充电和放电过程作为参考。用于估算健康状态的最大容量真值，是通过对每个区间内第二个放电过程的电流进行积分得到的。随机部分的电压、电流和温度（V、I、T）用作模型的输入。我们使用 NASA RW 数据集进行了两项实验。第一项实验使用 RW15 和 RW16 作为训练数据、RW13 作为测试数据、RW14 作为验证数据。第二项实验使用 RW13 和 RW16 作为训练数据、RW14 作为测试数据、RW15 作为验证数据。参数设置

如表 VII 所示。此外，这次我们比较了四种学习率相同的模型。由于难以从随机数据中提取健康特征，因此这里不使用基于健康特征的方法作为对比。最终结果如图 10 所示，在全部五项评估指标（平均绝对误差、均方误差、均方根误差、平均绝对百分比误差、对称平均绝对百分比误差）上，GRU-HSIC 的表现都远优于其他三种模型。我们还发现，循环神经网络、长短期记忆网络和门控循环单元的表现同样不佳，这可能是因为使用完全随机分布的数据集训练网络具有挑战性。然而，GRU-HSIC 表现良好，这可能归功于 HSIC 瓶颈的压缩能力，使其能够从随机数据中提取关键且有用的信息。

IV. 结论onclusion

本文提出了一种基于希尔伯特-施密特独立性准则的新型门控循环单元网络（GRU-HSIC），用于健康状态估算。该方法将健康特征提取与模型训练结合起来，简化了健康状态估算的步骤。信息获取不受人为感知的影响，从而降低了信息遗漏的可能性，并尽量减少人工主观操作。本文将基于信息瓶颈理论发展的 HSIC 瓶颈扩展至门控循环单元，用于估算健康状态。所有电池数据都可以通过零掩码网络直接输入模型，而 HSIC 瓶颈有助于优化模型训练过程。在不同恒流及随机充放电数据集上的验证结果表明，GRU-HSIC 模型优于基于时间的数据驱动模型，以及无需进行健康特征提取的循环神经网络、长短期记忆网络和门控循环单元模型。此外，在 NASA RW 数据集上的实验表明，GRU-HSIC 不仅适用于实验室中的常规数据，也能有效处理具有异质分布的数据。

References

[1] X. Shu、S. Shen、J. Shen、Y. Zhang、G. Li、Z. Chen 和 Y. Liu，“基于机器学习的锂离子电池健康状态预测：进展与展望”，*iScience*，第 24 卷，第 11 期，文章编号 103265，2021年。[2] E. Vanem、C. B. Salucci、A. Bakdi 和 Ø. Å. sheim Alnes，“数据驱动的健康状态建模——现状综述及其在船舶电池系统中的应用思考”，*Journal of Energy Storage*，第 43 卷，文章编号 103158，2021年。[3] Z. Deng、X. Lin、J. Cai 和 X. Hu，“结合退化模式识别与迁移学习的电池健康状态估计”，*Journal of Power Sources*，第 525 卷，231027，2022年，第 。[4] J. Tian、R. Xiong、W. Shen 和 F. Sun，“锂离子电池电极老化估计与开路电压重构”，《能源存储材料》，第 37 卷，第 283–295 页，2021年。[5] Y. Li、K. Liu、A. M. Foley、A. Zülke、M. Berecibar、E. Nanini-Maury、J. Van Mierlo 和 H. E. Hoster，“数据驱动的健康状态估计与寿命预测锂离子电池：综述，”可再生与可持续能源评论，第113卷，第109254页，2019年。[6] M. H. Lipu、M. Hannan、A. Hussain、M. Hoque、P. J. Ker、M. M. Saad和A. Ayob，《电动汽车用锂离子电池健康状态与剩余使用寿命估算方法综述：挑战与建议》，*Journal of cleaner production*，第205卷，第115–133页，2018年。[7] K. S. Ng、C.-S. Moo、Y.-P. Chen和Y.-C. Hsieh，《用于估算锂离子电池荷电状态和健康状态的改进库仑计数法》，*Applied energy*，第86卷，第9期，第1506–1511页，2009年。[8] Y. Cui、P. Zuo、C. Du、Y. Gao、J. Yang、X. Cheng、Y. Ma和G. Yin，《基于实时阻抗与开路电压参数辨识方法的锂离子电池健康状态诊断模型》，*Energy*，第144卷，第647–656页，2018年。[9] Y. Fu、J. Xu、M. Shi和X. Mei，《一种基于快速阻抗计算的电池健康状态估算方法》，*IEEE*工业电子学汇刊，第69卷，第7期，第7019–7028页，2021年。[10] P. A. Topan、M. N. Ramadan、G. Fathoni、A. I. Cahyadi和O. Wahyunggoro，《通过卡尔曼滤波器估算锂聚合物电池的荷电状态（soc）和健康状态（soh）》，载于*2016*年第二届科学与技术—计算机国际会议（*ICST*）。IEEE，2016年，第93–96页。[11] L. Fang、J. Li和B. Peng，《基于DEKF方法的锂离子电池荷电状态与健康状态在线估算及误差分析》，*Energy Procedia*，第158卷，第3008–3013页，2019年。[12] M. Gholizadeh和A. Yazdizadeh，《用于估算锂离子电池荷电状态与健康状态的系统化混合自适应观测器与扩展卡尔曼滤波器方法》，*IET Electrical Systems in Transportation*，第10卷，第2期，第135–143页，2020年。[13] S. J. Moura、N. A. Chaturvedi和M. Krstic´，《先进电池管理系统的偏微分方程估计技术——第二部分：健康状态辨识》，载于*2012*年美国控制会议（*ACC*）。IEEE，2012年，第566–571页。[14] X. Li、Z. Huang、J. Tian和Y. Tian，《基于物理模型和自适应容积卡尔曼滤波器的耐电池老化荷电状态估算》，*Energy*，第220卷，第119767页，2021年。[15] W. Yan、B. Zhang、G. Zhao、S. Tang、G. Niu和X. Wang，《采用基于勒贝格采样的扩展卡尔曼滤波器的电池管理系统》，*IEEE*工业电子学汇刊，第66卷，第4期，第3227–3236页，2018年。[16] X. Feng、C. Weng、X. He、X. Han、L. Lu、D. Ren和M. Ouyang，《基于支持向量机和部分充电区段的锂离子电池健康状态在线估算》，*IEEE Transactions on Vehicular Technology*，第68卷，第9期，第8583–8592页，2019年。[17] J. Meng、L. Cai、G. Luo、D.-I. Stroe和R. Teodor-escu，《结合短时电流脉冲测试与支持向量机的锂离子电池健康状态估算》，*Microelectronics Reliability*，第88卷，第1216–1220页，2018年。

[18] H. Huang、J. Meng、Y. Wang、F. Feng、L. Cai、J. Peng和T. Liu，《基于局部库仑计数曲线的全面优化锂离子电池健康状态估算器》，*Applied Energy*，第322卷，119469，2022年，第。[19] K. Liu、X. Hu、H. Zhou、L. Tong、W. D. Widanage和J. Marco，《基于随机森林分类的锂离子电池制造特征分析与建模》，*IEEE/ASME*机电学汇刊，第26卷，第6期，第2944–2955页，2021年。[20] G. Lee、D. Kwon和C. Lee，《一种具有物理可解释性的锂离子电池健康状态估算卷积神经网络模型》，*Mechanical Systems and Signal Processing*，第188卷，第110004页，2023年。[21] J. Wu、L. Fang、G. Dong和M. Lin，《基于改进径向基函数神经网络的锂离子电池健康状态估算》，*Energy*，第262卷，第125380页，2023年。[22] H. Sun、J. Sun、K. Zhao、L. Wang和K. Wang，《数据驱动的ICA-Bi-LSTM组合锂电池健康状态估算》，*Mathematical Problems in Engineering*，第2022卷，第1–8页，2022年。[23] H. Sun、D. Yang、J. Du、P. Li和K. Wang，《基于数据驱动算法的锂离子电池健康状态预测》*Energy Reports*，第8卷，第442–449页，2022年。[24] L. Ungurean、M. V. Micea和G. Cârstoiu，《基于门控循环单元神经网络的锂离子电池健康状态在线预测方法》，*International journal of energy research*，第44卷，第8期，第6767–6777页，2020年。[25] Y. Fan、F. Xiao、C. Li、G. Yang和X. Tang，《一种用于锂离子电池健康状态估算的新型深度学习框架》，*Journal of Energy Storage*，第32卷，第101741页，2020年。[26] J. Hong、Z. Wang、W. Chen、L. Wang、P. Lin和C. Qu，《考虑可变驾驶工况的真实世界电动汽车电池系统健康状态在线精准估算》，*Journal of Cleaner Production*，第294卷，第125814页，2021年。[27] W. Li、N. Sengupta、P. Dechent、D. Howey、A. An- naswamy和D. U. Sauer，《基于深度长短期记忆网络的锂离子电池容量在线估算》，*Journal of power sources*，第482卷，第228863页，2021年。[28] Y.-X. Wang、Z. Chen和W. Zhang，《采用改进的基于GRU的迁移学习，为小目标样本集估算锂离子电池荷电状态》，*Energy*，第244卷，第123178页，2022年。[29] J. Chung、C. Gulcehre、K. Cho和Y. Bengio，《门控循环神经网络在序列建模中的实证评估》，*arXiv*预印本*arXiv:1412 3555*，2014.[30] N. Tishby、F. C. Pereira和W. Bialek，《信息瓶颈方法》，*arXiv*预印本*physics/0004057*，2000年。[31] N. Tishby和N. Zaslavsky，《深度学习与信息瓶颈原理》，载于*2015*年*IEEE*信息论研讨会（*ITW*）。IEEE，2015年，第1–5页。[32] W.-D. K. Ma、J. Lewis 和 W. B. Kleijn，“HSIC 瓶颈：无需反向传播的深度学习”，载于*AAAI* 人工智能会议论文集，第 34 卷，第 04 期，2020年，页码 5085–5092。[33] A. Gretton、O. Bousquet、A. Smola 和 B. Schölkopf，“利用希尔伯特-施密特范数度量统计依赖”，载于算法学习理论：第 *16* 届国际会议，*ALT 2005*，*2005* 年 *11* 月 *8* 日至 *16* 日 2005年，63–77新加坡，*10* 月。会议论文集。施普林格，页码 –。[34] A. Meynaoui、M. Albert、B. Laurent 和 A. Marrel，“基于 HSIC 度量的自适应独立性检验”，2019年。[35] Y. He、D. Yan、W. Xie、Y. Zhang、Q. He 和 Y. Yang，“利用多方面希尔伯特-施密特独立性准则优化图神经网络”，*IEEE* 神经网络与学习系统汇刊，2022年。[36] B. Bole、C. Kulkarni 和 M. Daigle，“随机化电池使用数据集，NASA 艾姆斯预测数据存储库。NASA 艾姆斯研究中心，莫菲特机场，加利福尼亚州”，2014年。[37] W. He、N. Williard、M. Osterman 和 M. Pecht，“基于邓普斯特–谢弗理论和贝叶斯蒙特卡罗方法的锂离子电池预测”，*Journal of Power Sources*，第 196 卷，10 321，2011年 23，10 ,314，第 – 页。[38] Y. Xing、E. W. Ma、K.-L. Tsui 和 M. Pecht，“用于预测锂离子电池剩余有用性能的集成模型”，*Microelectronics Reliability*，第 53 卷，第 6 期，页码 811–820，2013年。