arXiv:2305.02323v1 [cs.LG] 1 May 2023

面向多种能源来源异常检测的相关性驱动多层级多模态学习 *

Taehee Kim
数据科学研究生院首尔科技大学韩国首尔
cltkim@seoultech.ac.kr

Hyuk-Yoon Kwon
数据科学研究生院首尔科技大学韩国首尔
hyukyoon.kwon@seoultech.ac.kr

摘要

高级计量基础设施（AMI）已被广泛用作智能能源消耗测量系统。电力是 AMI 可采集的代表性能源；现有的大多数异常能源消耗检测研究都聚焦于单一能源，即电力。近年来，水、燃气和供热等其他能源也开始被积极采集。因此，有必要开发一种适用于多种能源的统一异常检测方法；然而，鲜有研究致力于解决这一问题。该问题的固有难点在于，异常通常没有标注。此外，现有研究对异常的定义仅依赖于单一能源。本文首先提出一种异常定义方法，不仅考虑单一能源，也考虑不同能源之间的相关性。随后，我们提出一种新的相关性驱动的多层多模态学习模型，用于检测多种能源中的异常。该模型的独特之处在于，根据能源之间相关性的强弱，以多个层级整合多种能源。此外，我们对所提出的模型进行了泛化，使其能够整合任意新增能源并进一步提升性能，同时考虑相关能源和非相关能源。通过在由三至五种能源组成的真实世界数据集上进行大量实验，我们证明，所提出的模型明显优于现有的多模态学习模型和近期的时间序列异常检测模型；我们还发现，随着整合的相关或非相关能源增多，模型性能会进一步提升。

关键词 多模态学习 · 多能源异常检测 · 基于相关性的异常定义 · 多种能源来源

1 引言

高级计量基础设施 (AMI) 是一种用于测量能源消耗的智能系统，可提供时变使用率、节电和需求响应等有用信息 [1, 2, 3, 4, 5, 6]。随着政府推行建立智能电网并通过提高能源效率来降低成本的政策，其重要性日益凸显 [3]。多项研究表明，检测异常能源消耗模式十分重要。Chou 等人 [4] 指出，通过发现能源消耗中的异常模式，可以减少建筑物运行与维护所需的能源消耗。Korba 等人 [5] 指出，检测异常能源消耗是进一步节能的核心。

电力曾经是 t　　通过高级计量基础设施采集的最具代表性的能源；现有的大多数研究都用于检测　　t
异常能源 con　　耗一直聚焦于一种特定能源，即电力。近年来，其他能源　　s

* 引用：作者。标题。页码..... DOI:000000/1111　1.

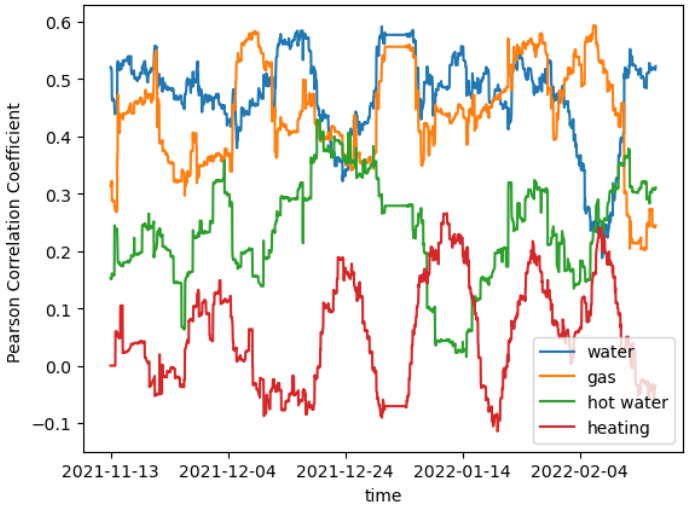

图1：电力与其他能源消耗之间的皮尔逊相关系数。

（例如水、燃气和供热）也已得到积极采集 [6]。因此，多能源系统（MES）也使人们开始关注多个能源来源（即电力、供热、制冷、燃料和燃气）在运营和规划阶段的能源消耗分析 [7]。然而，相关研究主要关注政策举措的成本与收益，对于多个能源来源的异常检测则鲜有探讨。因此，我们认为，开发一种适用于多个能源来源的统一异常检测方法具有重要意义。

然而，异常定义具有挑战性，因为异常通常没有标注，仅凭能源消耗也无法明确界定异常的标准 [8]。为弥补标注数据的缺乏，先前研究采用基于回归的方法 [8, 9, 10] 或现有的异常检测算法 [8, 11, 12] 来定义异常。本文提出一种新方法，不仅根据单种能源定义异常能源消耗，还依据不同能源之间的相关性进行定义。具体而言，我们注意到，某些观测值虽然可能被单种能源视为正常，但通过不同能源之间的相关性却能检测为异常。

图1展示了基于实验所用的真实世界数据集 5-ECK-2022，按周计算的电力与其他能源来源（即水、燃气、热水和供热）消耗量之间的相关性。这表明，家庭消耗的多种能源来源之间存在显著相关性。我们还注意到，能源来源之间的相关程度各不相同。具体而言，电力与水消耗量之间的平均皮尔逊相关系数为 0.4726，表明两者高度相关；而电力与供热消耗量之间的平均皮尔逊相关系数为 0.0539，表明两者并无相关性。基于这些观察结果，要检测异常消耗，需要考虑能源来源之间的相关性，而不是仅考虑单一能源来源。此外，还需要根据能源来源之间相关性的强弱，有区别地反映这些相关性。

图2展示了在一个真实世界的燃气和水能源消耗数据集上，采用两种不同方法定义的异常：1）根据二者之间的相关性定义的异常；2）根据以往研究中主要采用的方法，基于单一能源定义的异常 [8, 10]。在该图中，垂直和水平虚线分别表示依据每种单一能源划分正常和异常消耗的标准。我们需要关注图中由燃气和水消耗之间的相关性定义的红点异常，因为根据各自的能源来源，它们并不属于异常。将这些点视为异常是有意义的，因为相关能源之间消耗关系的不自然同样意味着异常模式。因此，我们提出了一种异常定义方法：在依据单一能源定义的异常基础上，进一步加入由能源来源之间的相关性所确定的异常，从而确保能源来源之间的相互关系。在本文中，我们提出了一种异常定义方法，利用 Cook距离 [13], 根据关系识别具有影响力的实例，从而基于多个能源之间的相关性定义异常。

我们提出了一种新的多模态学习模型，通过多个能源来源之间的相关性强度来检测异常。作为最简单的模型架构，我们考虑了三种常用于多能源场景的能源类型，并根据能源之间的相关性，采用不同的融合方法（即早期融合和晚期融合）将其设计为两层结构。具体而言，我们在第一层融合中，通过早期融合（即融合原始数据），整合相关性比另一种能源更弱的两种能源。

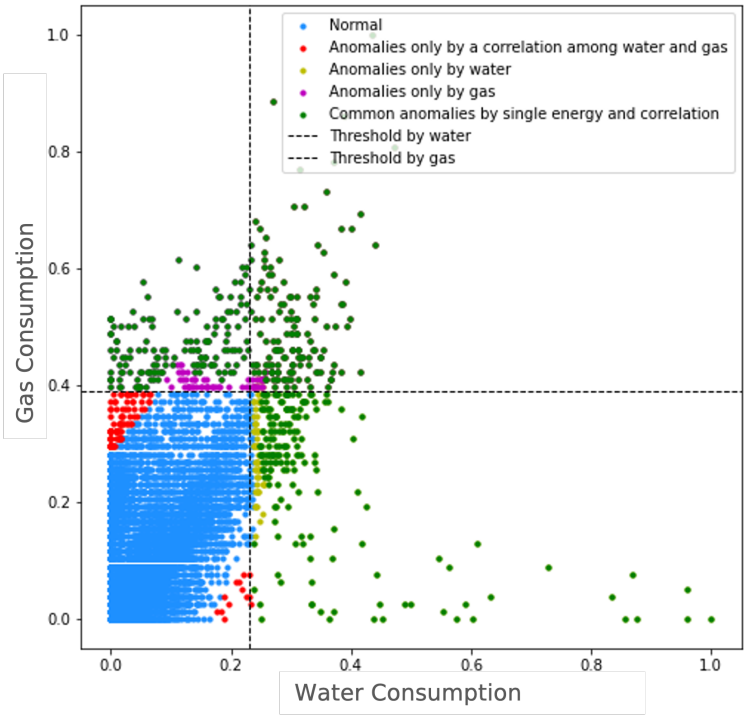

图2：由单一能源来源定义的异常分布，以及能源来源之间的相关性。

层，然后在第二级融合层中，通过晚期融合（即融合从原始数据中提取的特征）将融合结果与剩余的一种能源相结合。

此外，我们还提出了一种可扩展的模型架构，通过对彼此具有相关性的能源来源保持相关性驱动方法，实现向更多能源来源的有效扩展。基本上，我们将相关能源来源分为弱相关源和强相关源，并分别在第一层采用早期融合整合前者，在第二层采用晚期融合整合后者。具体而言，我们首先选择两个与其他能源来源相关性最低的能源来源进行早期融合。然后，从剩余的能源来源中，选择与前述两个能源来源相关性最弱的下一个能源来源。仅当该能源来源与早期融合所包含的两个能源来源的皮尔逊相关系数的平均值低于相关性阈值时，才将其纳入早期融合；对所有剩余能源来源重复这一过程。否则，将未被选入早期融合的其余能源来源通过晚期融合进行整合。

此外，为了提高所提出模型的通用性，我们设计了一种模型架构，在第三级融合层中，将实际处理多个能源来源时可能出现的不相关能源与相关能源进行整合。其基本策略是，将不相关能源完全从针对相关能源的集成多模态学习模型中分离出来，并分别对每个不相关能源进行特征提取。随后，在第三级融合中，我们以监督方式将早期融合的结果、晚期融合的结果，以及从不相关能源中提取的特征进行拼接。在此，通过使用根据能源来源之间的相关性定义异常的数据集训练第三级融合层，我们完全区分了相关能源与不相关能源之间的权重贡献，这一点已通过SHAP值得到证实。

通过在三个包含不同类型多能源来源（即包含三至五种能源来源）的真实世界数据集上进行大量实验，我们证明了所提出模型的有效性。首先，我们将所提出的模型与现有多模态学习模型及近期的时间序列异常检测模型进行比较。对于由三种能源来源组成的数据集，即 AMPds2、3-ECK-2021 和 3-ECK-2022，其中所有能源来源彼此相关，我们的模型优于现有模型，F1 分数提升了 0.56%~26.85%。其次，对于由四种相关能源组成的数据集 4-ECK-2022，我们的模型仍保持对现有模型的性能优势。我们还通过展示相较于现有模型，平均 F1 分数的性能提升在 4-ECK-2022 上为 13.73~14.88%，而在 3-ECK-2022 上为 2.02~13.16%，验证了我们方法的可扩展性。最后，在整合了非相关能源的数据集上，我们的

模型使现有模型的平均 F1 分数提升了 3.25∼23.36%，而在仅排除非相关能源的同一数据集上，提升幅度为 2.67∼14.88%。
本文的主要贡献总结如下。

1. 我们提出了一种针对由多种能源构成的能源消耗的新型异常定义方法。具体而言，我们不仅考虑各个能源，还考虑它们与能源消耗之间的相关性。因此，即使每种能源单独来看都属正常，我们仍可通过考察相关能源之间的相互关系来定义异常能源消耗。2. 我们提出了一种新颖的多模态学习模型，用于检测涉及多种能源的能源消耗异常。该模型的突出特点是根据模型中各能源之间的相关性调整能源融合顺序，从而形成多层级架构。3. 所提出的模型能够灵活扩展，以整合更多任意能源。我们根据能源之间的相关性，制定了将各能源逐一整合到统一模型中的准则。我们证实，随着能源数量增加，模型的性能提升幅度也会增大。4. 对于不相关的能源，所提出的模型能够通过将它们分别纳入针对相关能源的统一多模态学习模型中进行处理，从而有效应对。随后，我们使用根据能源之间相关性定义的带标注数据集进行训练，以区分相关能源与不相关能源的权重贡献。得益于这一新颖特征，在相关能源的基础上加入不相关能源后，模型性能还能进一步提升。

本文其余部分安排如下。第2节介绍相关工作。第3节介绍由多种能源来源构成的真实世界能源消耗数据集。第4节介绍所提出模型的背景。第5节提出一种用于异常检测的新型多模态学习模型。第6节介绍性能评估。第7节总结全文。

2 相关工作

2.1 能源消耗异常

为解决数据集中缺乏经过标注的异常能源消耗的问题，一些先前研究基于能源消耗数据集定义了异常。Zhang等人 [9] 提出了一种基于电力消耗与温度之间关系的线性回归方法。Wang等人 [10] 利用燃气消耗与温度之间的马氏距离 [14] 识别异常。Cook距离 [13] 和拟合差异统计量（DFFITS） [15] 也被用于衡量基于杠杆值的异常分数。Weng等人 [8] 通过结合现有异常检测算法（即孤立森林和特征装袋）的结果来定义异常。

本文提出了一种通过能源之间的相关性而非仅根据单个来源来定义异常的方法。基于相关性的异常定义充分利用了能源之间的关系，这意味着我们可以利用相关能源之间的消耗模式来检测异常能源消耗。例如，在图1中，红点根据单个能源消耗被定义为正常，但根据基于相关性的能源消耗则被定义为异常。这类异常能够检测到重要的异常消耗模式，例如特定能源的泄漏或盗窃。

2.2 单一能源的异常检测

现有的大多数能源消耗异常检测方法主要针对电力 [2,3, 4, 5, 6, 16, 17]。Madhure 等人 [16]提出了一种基于卷积神经网络-长短期记忆网络的模型，Peng 等人 [17] 则采用K-均值聚类和局部离群因子来检测电力盗窃。针对其他能源来源（即水 [18, 19], 、燃气 [1, 20], 和供热 [21, 22]）的研究相对较少。Iyer 等人 [19] 检测了与废水再利用相关的潜在欺诈行为；Nadai 等人 [20] 识别了燃气浪费的原因；Park 等人 [22] 则检测了供热系统的故障。

2.3 多种能源来源的异常检测

目前仅有少量研究针对多种能源来源进行异常检测。Weng等人 [8] 提出了一种针对电力、水和燃气能源消耗的无监督异常检测方案。他们将长短期记忆网络自编码器（LSTM-AE） [11]应用于多种能源来源中的每一种，并将所提出的模型与现有的线性模型（即PCA和单类支持向量机）、基于邻近度的模型（即k近邻

）以及使用孤立森林和特征装袋的集成模型进行了比较。尽管他们考虑了几种能源来源，但每种来源都是独立处理的，并未考虑针对多种能源来源的统一异常检测。鉴于能源消耗与多种能源来源高度相关，对综合消耗进行多能源来源异常检测至关重要，因为这使我们能够检测出仅凭特定能源来源无法检测到的异常。

2.4 时间序列数据异常检测

能源消耗可视为一种时间序列数据。针对时间序列数据开展异常检测的研究已广泛进行。时间序列数据异常检测可分为三类：1）基于聚类的方法；2）基于机器学习的方法；3）基于神经网络的方法。基于聚类的方法采用了*k*均值 [23, 24] 和 DBSCAN [18, 24]；基于机器学习的方法使用了孤立森林 [8],*k*近邻 [25], 、单类支持向量机 [26, 27], 和局部离群因子 [17, 27]。近年来，基于神经网络的方法的表现优于现有的基于聚类或机器学习的方法 [8, 28]。Malhotra 等人 [11]提出了 LSTM-AE，以最小化训练过程中产生的重构误差。Li 等人 [12] 提出了一种基于图卷积和反卷积的自编码器，用于属性网络异常检测。Goodfellow 等人 [29] 通过对抗训练提升了时间序列数据的异常检测性能。Li 等人 [30] 提出了 MAD-GAN，该方法采用循环神经网络，即 LSTM-RNN，作为生成对抗网络的生成器和判别器。Audibert 等人 [31] 提出了 USAD，该方法在自编码器架构中训练对抗模型；结果表明，其性能优于包括自编码器、孤立森林、深度自编码高斯混合模型、OmniAnomaly 和 LSTM-VAE 在内的现有模型。

尽管多个能源来源属于多变量时间序列，但它们具有独特的属性：它们测量的是同一家庭的能源消耗，并且根据能源来源之间的关系呈现出独特的相关模式。因此，本文旨在设计一种定制模型，以突出多个能源来源之间相关性的差异。

2.5 多模态学习

多模态学习将具有不同特征的多种模态（例如图像、文本和传感器）整合到一个学习模型中 [32, 33]。它已广泛应用于各个领域，以提升单模态学习的性能。Nemati等人 [34] 展示了将两类文本特征（即字幕和歌曲歌词）与音乐视频的视听内容相结合，对视频检索效果的影响。Poria等人 [35] 提出了一种利用音频、视觉和文本模态特征进行情感分析的方法。Neverova等人 [36]利用深度、灰度视频、姿态信号和音频等多种模态进行手势检测。Park等人 [37] 提出了一种多模态学习模型，整合从视频、音频和文本中提取的各种特征，以提升电子竞技视频精彩片段检测的性能。Li等人 [38] 提出了一种多模态学习模型，整合新闻信息和股票基本面，通过解决二者的异质性来预测股价。Shin等人 [39] 提出了一种对比词嵌入模型：将整个词语语料库划分为正向和负向两部分，并通过多模态学习模型融合从中提取的特征，以提升基于深度学习的分类模型检测网络安全相关推文的性能。Wang等人 [40] 在多模态学习中利用从城市级到英里级的多种地理粒度，以提升房价预测效果。

3 数据集

为涵盖包含多种能源来源的各类能源消耗数据集，我们使用了三个真实世界数据集：1）AMPds2、2）4-ECK-2021（韩国四类能源消耗）和 3）5-ECK-2022（韩国五类能源消耗）。基于这些数据集，我们重构出更多数据集，使其仅包含相关能源，从而广泛比较各数据集的性能。当某个能源*ES* 与至少另一种能源的皮尔逊相关系数大于 $Th_{correlated}$ 时，我们将其定义为相关能源；当其与所有其他能源的皮尔逊相关系数均小于 $Th_{correlated}$ 时，则定义为非相关能源。本文采用 0.2 作为 $Th_{correlated}$，遵循先前研究 [41]。在数据集预处理过程中，我们始终对原始数据集进行转换，使测量频率统一为每小时一次，并根据相邻数据段之间的线性插值填补缺失值。随后，使用最小-最大缩放进行归一化。

《**明年鉴**》 **公用电力数据集（AMPds2）**[2]：该数据集包含三种能源来源：1）电力。 r, 2) 燃气，和 3) 水，c 采集自加拿大的一个家庭。该数据集包含 1,051,200 条记录，观测间隔为 t

[2]https://doi.org/10.7910/DVN/FIE0S4

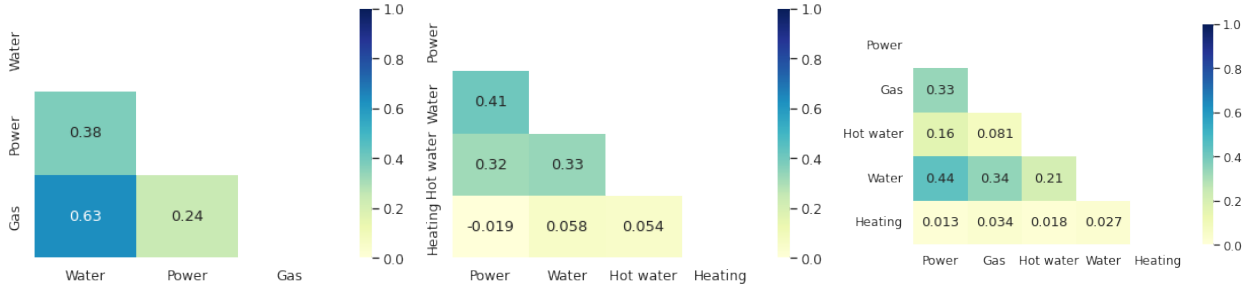

(a) AMPds2 (b) 4-ECK-2021 (c) 5-ECK-2022

图 3：多种能源之间的皮尔逊相关系数。

一分钟，时间跨度为 2012年4月至2014年3月。

韩国四类能源消耗（4-ECK-2021）[3]：该数据集包含四种能源来源：1）电力，2）水，3）热水和供热。该数据集共包含 47,117 条记录，记录时间范围为 2020年1月 至 2021年3月，观测间隔为 15 分钟。为仅包含相关能源，我们通过从 4-ECK-2021 中排除非相关能源供热，重新定义了 3-ECK-2021。

韩国五类能源消耗（5-ECK-2022）[4]：该数据集包含五种能源来源：1）电力，2）燃气，3）水，4）热水，以及5）供热。该数据集包含13,584条记录，记录时间跨度为2020年8月至2022年2月，采样间隔为一小时。我们通过从5-ECK-2022中排除不相关能源，重新定义了3-ECK-2022和4-ECK-2022。具体而言，将与其他能源来源相关性最弱的供热能源从5-ECK-2022中排除，并将其定义为4-ECK-2022；将供热和热水从5-ECK-2022中排除，并将其定义为3-ECK-2022。

图3展示了基于每个数据集的皮尔逊相关系数计算得到的不同能源来源之间的相关矩阵：图3a对应AMPds2；图3b对应4-ECK-2021；图3c对应5-ECK-2022。总体而言，各数据集之间呈现出一些共同特征，同时也表现出与具体数据集相关的差异。具体而言，在AMPds2中，水与其他能源来源的相关性最强；在4-ECK-2021和5-ECK-2022中，电力和水均与其他能源来源具有较强的相关性，而供热与其他能源来源的整体相关性相对较弱。

4 背景

4.1 多模态学习

图 4 展示了多模态学习模型的两种类别：1）早期融合和 2）晚期融合[33, 42]。早期融合在低层级拼接原始特征。随后，对整合后的特征应用特征提取器，最后再应用分类器。相比之下，在晚期融合中，会对每个特征分别应用特征提取器。然后整合其结果，并将这些嵌入结果输入最终分类器。根据融合策略，我们注意到它们在一个层级整合多个特征。本研究中，我们设计了一种多层级多模态学习模型，以差异化地体现相关性的优势。

4.2 多变量时间序列异常检测

本研究通过将基础异常检测模型用作特征融合中的基本特征提取器，设计了一种用于多模态学习的模型架构。我们指出，任何现有的异常检测模型都可以用作特征提取器。本节介绍两种具有代表性的无监督多变量时间序列异常检测模型：LSTM-AutoEncoder (LSTM-AE) [11]和无监督异常检测 (USAD) [31]，，本文采用它们作为特征提取器。LSTM-AE 常被用作检测多变量时间序列中异常的无监督学习方法。LSTM 用于有效处理序列数据，以反映长期时间依赖关系；自编码器则通过训练过程中产生的重构误差来检测异常。USAD 采用自编码器架构，并分两个阶段进行对抗训练

[3]https://doi.org/10 2 417632 68 4 49 . /m xz w t .
https://doi.org/10.17632/m68xz4w4t9.2

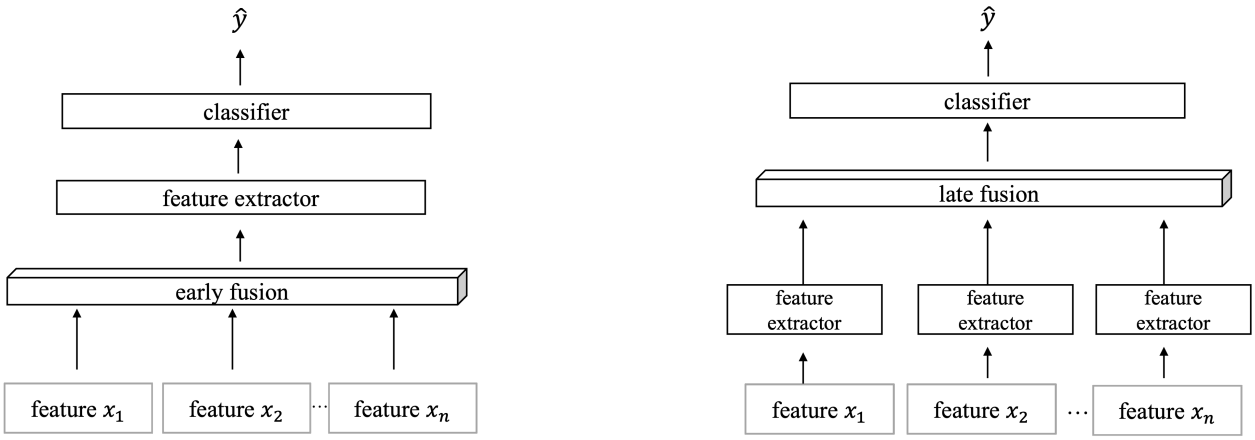

（a）早期融合　　（b）晚期融合

图 4：多模态学习的融合方法。

。USAD 由一个编码器和两个解码器组成，以充分利用自编码器和对抗训练的优势。第一阶段，模型经过训练以重现输入数据；第二阶段，模型经过训练，以区分真实数据与第一阶段生成的合成重构数据。通过这两个阶段的训练，即使异常与正常数据相似，模型也能有效检测出来。

5 提出的模型

5.1 异常能源消耗的定义

在本研究中，我们首先提出一种能源消耗异常定义方法，以解决能源消耗领域缺乏带标注数据集的问题，尤其是由多种能源来源组成的数据集。为此，我们在遵循现有基于单一能源的异常定义方法 [10, 8], 的基础上，通过考虑不同能源之间的相关性来扩充异常样本。具体而言，我们首先基于Z分数 [43], 对每种能源分别定义异常，并将超过平均能耗三倍的情况归类为异常。随后，我们根据不同能源之间的相关性定义异常，即使这些异常在单一能源中被视为正常。为了根据能源之间的相关性衡量某种能源相对于另一种能源的异常程度，我们采用Cook距离 [13], ，该方法同时考虑每个观测值的杠杆值和残差。对于非相关能源（例如，4-ECK-2021和5-ECK-2022中的供热），我们仅基于单一能源定义异常，而不采用基于相关性的异常。

Cook距离的定义如公式 1 所示，用于衡量在线性回归模型中包含实例 i 时的估计值 $\hat{}y_j$ 与不包含实例 i 时的估计值 $\hat{}y_{j(i)}$ 之间的差异。其中， p 表示系数的数量， MSE 表示均方误差。

$$D_i = \frac{\sum_{j=1}^{n} \hat{y}_j - \hat{y}_{j(i)}}{pMSE} \tag{1}$$

Cook距离使我们能够通过衡量每个实例对线性回归模型的影响程度来检查特征之间的关系。 D_i 的值较高意味着模型更有可能受到 i的扭曲。我们使用Cook距离的判定标准将正常数据和异常数据分类为 $\frac{4}{N-K-1}$，其中 N 是观测值数量， K 是预测变量数量，该标准已在先前研究 [44]中使用。

具体而言，假设我们有两个相关能源 CS_p 和 CS_q。我们可以考虑这种关系中的两个方向：1) 从 CS_p 到 CS_q 和 2) 从 CS_q 到 CS_p。因此，我们根据公式 (1) 为每个方向得到 D_i 。在此，我们将前者定义的异常记为 $A_{sp,\ sq}$，将后者定义的异常记为$A_{sq,\ sp}$。然后，将 CS_p 和 CS_q 之间基于相关性的异常定义为 $A_{sp,\ sq} \cup A_{sq,\ sp}$。最后，我们合并每对相关能源的所有基于相关性的异常。

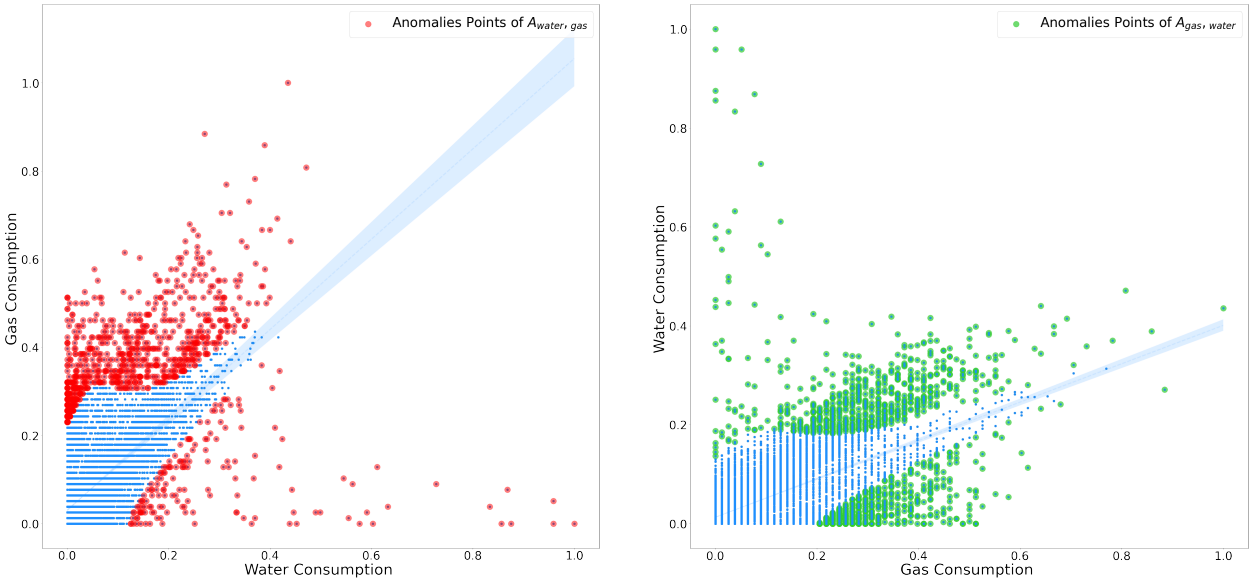

(a) CS_{gas} 对 CS_{water} 的线性回归　　(b) CS_{water} 对 CS_{gas}的线性回归

图5：基于相关性的异常定义。

表1：数据集中已定义异常的比例。

Type	数据集					
	3-ECK-2022	4-ECK-2022	5-ECK-2022	3-ECK-2021	4-ECK-2021	AMPds2
基于个体 (a)	7.40%	9.24%	11.40%	5.74%	8.93%	5.14%
基于相关性 (b)	10.13%	11.61%	11.61%	12.24%	12.24%	12.74%
(a) 和 (b) 的交集	7.40%	9.24%	9.31%	5.74%	6.03%	5.14%
(a) - (b)	0	0	2.09%	0	2.09%	0
(b) - (a)	2.73%	2.37%	2.31%	6.50%	6.21%	7.60%
最终比率	10.13%	11.61%	13.70%	12.24%	15.14%	12.74%

图5展示了通过燃气与水之间的相关性识别出的基于相关性的异常示例。在图5a中，我们将红圈标记的点定义为异常，$A_{water,gas}$，这些点通过 CS_{gas}关于 CS_{water}的线性回归模型发现，表明其中一些点仅在考虑 CS_{gas}时才会被视为正常数据。同样，在图5b中，我们定义$A_{gas,water}$，这些点通过 CS_{water} 关于 CS_{gas}的线性回归模型发现。

表1展示了通过我们的异常定义方法识别出的最终异常所占的比例。我们将各数据集中的异常比例均匀调整至约 10∼15%。我们注意到，异常主要通过相关性来定义，其中也包括由单个来源定义的异常，但仍有相当一部分异常只能通过相关性定义的异常来检测。

5.2 相关性驱动的多层多模态学习

本节提出一种相关性驱动的多层多模态学习模型。在第5.2.1节中，我们将三个能源彼此相关的情形作为最简单的情况进行探讨。随后，在第5.2.2节中，我们将其扩展到更多能源彼此相关的情形。最后，在第5.2.3节中，我们提出最终模型，将与其他能源不相关的能源也纳入其中。

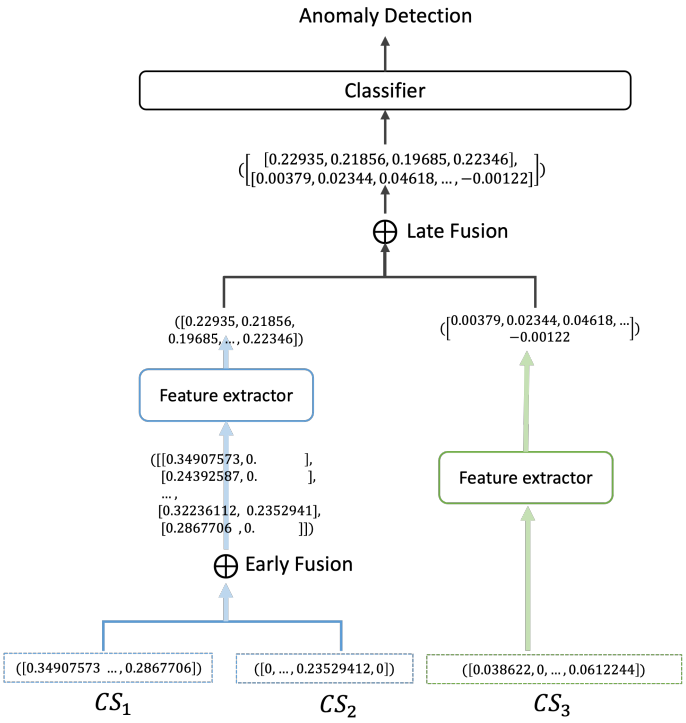

图 6：相关性驱动的双层多模态学习。

5.2.1 双层多模态学习模型

本节针对相关能源提出一种相关性驱动的多层多模态学习模型。在多模态学习中融合多种能源时，我们指出，如图3所示，多种能源之间的相关性存在显著差异。这促使我们根据相关性的差异对其进行差异化处理，这一做法受到以下事实的启发：多模态之间的相关性体现了融合它们所产生的效果 [42]。为此，我们设计了一种新颖的多模态学习模型，根据能源之间相关性的差异，以多层级方式融合这些能源。

图 6 展示了所提出模型的架构。作为最简单的情况，我们考虑三种能源来源，以说明所提出模型的主要特性。所提出模型的一个新颖之处在于，根据能源来源之间的相关性，将它们置于不同层级。随后，我们对各层级的能源来源应用融合方法（即早期融合或晚期融合）。在第一层级，主要策略是通过早期融合整合相关性最弱的两种能源，以最大限度地发挥整合效果。早期融合更适合融合特征各异的数据，因为它能够发现特征之间潜在的相关关系 [33, 42]。接着，在第二层级，我们通过晚期融合，将强相关能源的特征与早期融合的结果进行整合。因此，为了独立保留强相关能源，我们将其与弱相关能源分开处理，并分别提取特征表示。

基于深度学习的异常检测模型在逻辑上由两个部分组成：1）特征提取器，用于学习原始输入数据的表征；2）分类器，根据学习到的表征确定输入数据的最终类别（即正常或异常）。对于特征提取器，我们采用无监督时间序列表征学习，以无监督方式学习表征；对于分类器，我们以监督方式将学习到的表征应用于下游任务 [45, 46]。因此，我们在特征提取器中从多个能源来源提取丰富的表征，然后利用这些学习到的表征，通过使用特征提取器的输出训练分类器来进行异常检测。

5.2.2 两层模型的泛化

在本节中，我们将所提出的模型推广，以便整合更多能源来源。随着能源来源数量的增加，图 7 展示了我们所提模型的广义框架。我们将多模态学习形式化如下。根据各能源是否与其他能源相关，我们将相关能源定义为 $CS = \{CS_1, ..., CS_n\}$

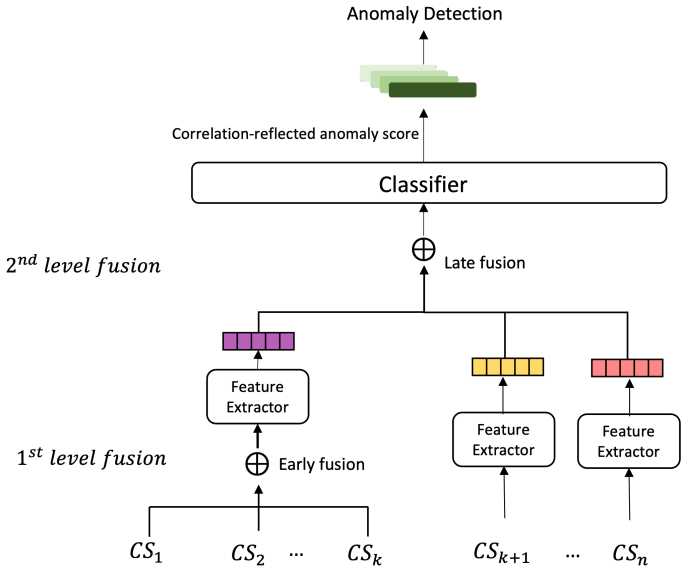

图 7：双层多模态学习的泛化。

。令 $P = \{1, 2, ..., p\}$ 和 $Q = \{p + 1, p + 2, ..., n\}$，其中 P 包含用于早期融合的能源，Q 包含用于晚期融合的能源。我们首先选出与其他能源的平均相关系数最弱的两个相关能源，并将其加入 P，作为用于早期融合的能源。然后，根据式 2，在 P 中找出与其他能源的皮尔逊相关系数平均值最小的能源。如果其按式 2 计算所得的值小于 $Th_{correlated}$，则将其加入 P。对其余能源重复此过程。最后，将所有不在 P 中的能源加入 Q。

$$\min_{k \in Q} \left\{ \frac{\sum_{r \in P} Corr(CS_k, CS_r)}{n - (p + 1)} \right\} \tag{2}$$

根据实际数据集，在 AMPds2 中，燃气和电力位于P，水位于Q；在 3-ECK-2021 中，热水和电力位于P，水位于Q；在 3-ECK-2022 中，燃气和电力位于P，水位于Q；在 4-ECK-2021 中，热水和电力位于P，水位于Q；在 4-ECK-2022 中，燃气和热水位于P，电力和水位于Q。同理，我们可以确定任何数据集中相关和不相关的能源来源及其顺序。

5.2.3 整合不相关能源来源的三级模型

我们进一步扩展双层多模态学习模型，以整合不相关的能源来源。在双层模型中，所有能源来源彼此相关，但相关强度不同。尽管大多数能源来源彼此相关，但其中一些并不相关，例如 5-ECK-2022 中的供热。在本研究中，我们设计了一种整合不相关能源来源的模型，如图 8 所示。我们将不相关的能源来源记为 $NS = \{NS_1, ..., NS_w\}$。例如，4-ECK-2021 和 5-ECK-2022 数据集中的供热属于不相关能源。

核心思想是在模型中区分不相关能源与相关能源。为实现这一目标，我们训练模型中的第三级层，使其学习相关能源与非相关能源的差异权重贡献，并将其称为基于相关性的权重贡献。我们注意到，相关能源与非相关能源之间的关键区别在于，前者会产生基于相关性的异常，而后者在标注中不会产生此类异常。为利用这一特性，我们使用标注以监督方式训练模型的第三级层，区分一组相关能源与一组非相关能源的权重贡献。因此，通过学习基于相关性的异常，相关能源将获得比非相关能源更大的权重贡献。

根据基于相关性的权重贡献，在我们的模型中，相关能源与非相关能源在第三级层中的重要性会在拼接后通过监督学习进行调整。我们通过测量相关能源与非相关能源之间的差异权重贡献来验证其影响。为此，我们测量每种能源的 SHAP值（Shapley加性解释） [47]

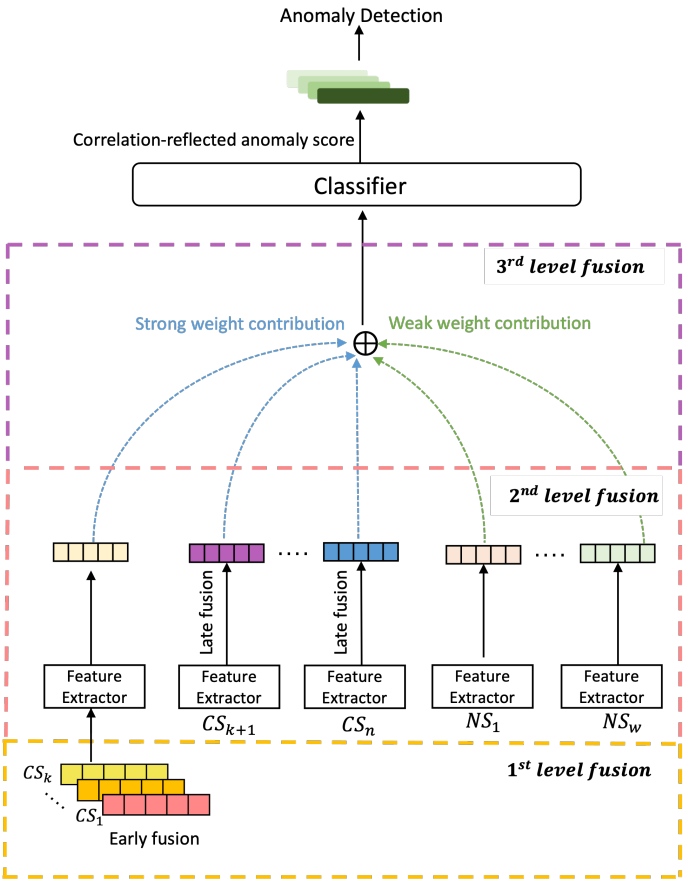

图8：整合不相关能源来源的三级模型。

以表示其对结果的权重贡献。这里，我们使用 5-ECK-2022 数据集，其中包括两种弱相关能源——燃气和热水、两种强相关源——电力和水，以及一种非相关能源——供热。

图9比较了所提出模型第三级中的能源来源的SHAP值（图9a），以及以下三种对比：1）将强相关能源来源替换为弱相关能源来源（图9b）；2）在早期融合中添加一种强相关能源来源（图9c）；3）将一种非相关能源视为相关性最低的能源（图9d）。我们注意到，正如预期，在所提出的模型中，各能源来源对结果的贡献顺序依次为强相关、弱相关和不相关；而在各对比中则并非如此。事实上，与这些对比相比，这些显著特点与所提出模型性能的大幅提升有关，具体将在第6.2.5节中讨论。

6 性能评估

6.1 实验环境与方法

通过大量实验，我们将提出的方法与现有模型进行了比较，包括：1）具有代表性的多模态学习模型，即早期融合和晚期融合 [33, 42], 2；2）近期的时间序列异常检测模型，即 USAD [31] 、LSTM-AE [11], 和 TAnoGAN [28]。如第5.2.1节所述，我们以无监督方式训练特征提取器，以有效学习正常数据的表示；并利用已训练特征提取器的输出以及标注，以监督方式训练分类器。在训练与评估方面，我们将整个数据集按 7:3 的比例划分为训练数据集和测试数据集。随后，我们仅使用训练数据集中的正常数据来训练特征提取器，而训练分类器时则同时使用训练数据集中的异常数据和正常数据。需要指出的是，我们可以采用任何现有的异常检测模型，作为多模态学习中的特征提取器和分类器。因此，我们重点比较所提模型与用于特征提取器的基线模型之间的相对性能。

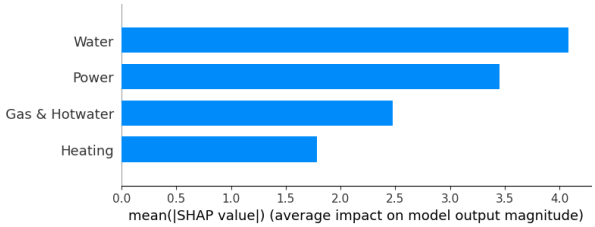

(a) 所提出的模型。

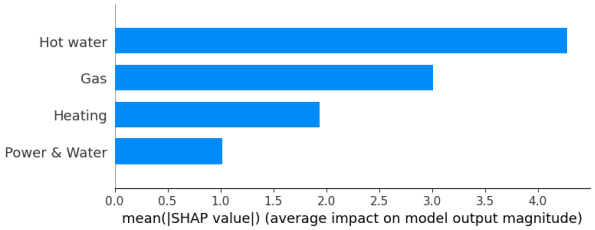

(b) 用弱相关能源替代强相关能源。

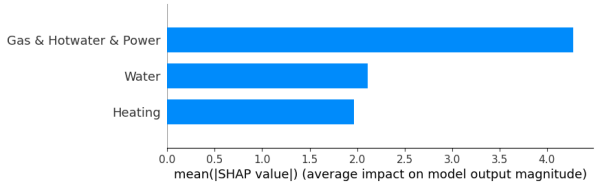

(c) 向早期融合中添加一种强相关能源。

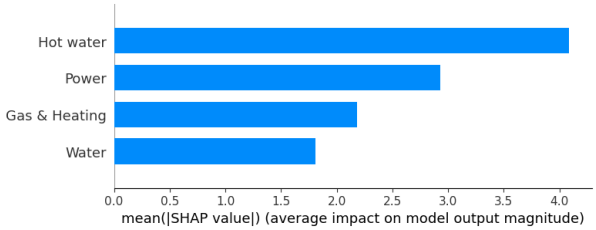

(d) 将一种非相关能源作为相关性最低的能源加以利用。

图9：所提出的模型与对比模型在5-ECK-2022上的权重贡献分析。

表 2：模型的通用超参数。

参数		数值
特征提取器	批量大小	1020
	训练轮数	100
	序列长度	12
	学习率	0.01
	优化器	Adam
分类器	估计器数量	400
	损失函数	对数损失
	提升类型	决策树

在实验中，我们采用 USAD [31], ——一种用于多变量时间序列无监督异常检测的先进模型——作为特征提取器，并将其替换为 LSTM-AE [11]，以表明我们的模型始终优于用作特征提取器的基线模型。为确保比较公平，我们在所有模型中均使用 LightGBM [48] 作为分类器。

表 2 展示了我们的模型和对比模型均一致采用的超参数。为确保与异常检测模型进行性能比较，我们遵循现有方法 [31]，在可行的异常阈值范围内评估每个模型的性能，从而找到使 F1 分数最高的最佳异常阈值。

在实验中，我们使用四种评估指标：(1) AUROC、(2) 宏平均 F1 分数（M-F1）、(3) 加权 F1 分数（W-F1）以及 (4) F1 分数。其中，我们使用 F1 分数作为代表性比较指标，用于比较不同实验中的性能提升幅度，因为它是最常用的指标。所有实验均在一台配备 NVIDIA RTX A4000 和 Intel(R) Xeon(R) Silver 4210R CPU @ 2.40GHz、内存为 32GB 的计算机上进行，运行环境为 Ubuntu 18.04。我们使用 Python（版本 3.8.11）和 PyTorch（版本 1.11.0）实现所提出的模型和对比模型。

6.2 实验结果

6.2.1 相关性驱动特征放置的影响

我们验证了这一新颖特性的有效性：该特性在多模态学习中根据特征之间的相关性对特征进行排列。在此，我们使用了 AMPds2，因为其中两种能源来源的相关性明显弱于其他能源来源。

表3：P　在多模态学习中验证相关性驱动的特征放置的性能比较　　g.

融合		AMPds2			
第一级	第二级	AUROC	M-F1	W-F1	F1
水 &燃气	电力	0.8328	0.8340	0.8953	0.9350
电力与水	Gas	0.8419	0.8376	0.8967	0.9350
燃气与电力	水	**0.9064**	**0.8772**	**0.9194**	**0.9468**

表4：包含三种能源来源的数据集上的性能比较。

方法	AMPds2				3-ECK-2022				3-ECK-2021			
	AUROC	M-F1	W-F1	F1	AUROC	M-F1	W-F1	F1	AUROC	M-F1	W-F1	F1
USAD	0.9059	**0.9021**	0.9063	0.9213	0.8192	0.8147	0.8192	0.8407	**0.8882**	**0.8758**	0.8896	0.9148
LSTM-AE	0.7355	0.7476	0.7709	0.8544	0.5729	0.5686	0.5761	0.6114	0.7616	0.7918	0.8287	0.8967
TAnoGAN	0.7262	0.7804	0.8776	0.9384	0.7146	0.6647	0.7336	0.7929	0.8856	0.8275	0.8711	0.9081
AVG.	0.7892	0.8100	0.8516	0.9047	0.7022	0.6827	0.7096	0.7483	0.8451	0.8317	0.8631	0.9065
早期融合	0.8405	0.8435	0.9015	0.9392	0.8281	**0.8234**	0.8337	0.8639	0.6756	0.7101	0.8657	0.9319
晚期融合	0.8690	0.8569	0.9080	0.9412	**0.8287**	0.8189	0.8282	0.8555	0.7758	0.7667	0.8795	0.9275
AVG.	0.8548	0.8502	0.9048	0.8402	0.8284	0.8212	0.8310	0.8597	0.7257	0.7384	0.8726	0.9297
Ours	**0.9064**	0.8772	**0.9194**	**0.9468**	0.8204	0.8175	**0.8395**	**0.8799**	0.7788	0.8237	**0.9168**	**0.9564**

表3展示了使用相同的多层模型架构、但将特征放置在不同层级时的性能对比。我们注意到，所提出的模型始终优于对比模型。因此，在 AMPds2 中，当与其他能源来源相关性较弱的能源来源通过早期融合进行整合时，模型表现优于其他情况。

6.2.2 与三种相关能源来源的性能比较

为验证所提出的基于相关性的模型设计的有效性，我们首先在包含三种彼此均相关的能源来源的数据集上，对比我们的模型与对比模型的性能。表4展示了所提出的模型与五种对比模型的性能比较结果。鉴于性能表现会因评估指标而异，我们采用 F1 分数作为代表性指标来比较各模型的性能。总体而言，我们的模型在所有数据集上的表现通常都优于对比模型。具体来说，根据 F1 分数，我们的模型将现有多模态学习模型的性能提升了 0.56∼2.89%，将时间序列异常检测方法的性能提升了 0.84∼26.85%。值得注意的是，无论采用何种评估指标，随着后续实验结果中整合的能源来源增多，性能趋势都会变得更加清晰且一致，这体现了我们模型在结构上的优势。

6.2.3 相关的四种能源的性能比较

为验证所提出模型在多种能源来源上的可扩展性，我们使用了三种以上的能源来源，并将结果与此前在包含三种能源来源的数据集上得到的结果进行比较。本节重点研究相关能源，即 4-ECK-2022。表5展示了实验结果，用于比较我们的模型与对比模型的性能。结果表明，我们的模型显著优于对比模型。具体而言，根据 F1 分数，我们的模型较现有多模态学习模型提升了 12.48∼14.99%，较时间序列异常检测方法提升了 6.41∼25.32%。更重要的是，我们注意到，随着能源来源数量增加，我们的模型性能进一步提升，表明所提出模型的有效性和可扩展性。具体而言，根据 4-ECK-2022 上的平均 F1 分数，我们的方法较现有模型提升了 13.73∼14.88%；而在第 6.2.2 节中，3-ECK-2022 上的提升幅度为 2.02∼13.16%，其中 3-ECK-2022 是 4-ECK-2022 的一个子集。

表5：相关的四种能源数据集上的性能比较。

方法	4-ECK-2022			
	AUROC	M-F1	W-F1	F1
USAD [31]	0.8597	0.8199	0.8648	0.9031
LSTM-AE [11]	0.6443	0.6217	0.6567	0.7140
TAnoGAN [28]	0.7850	0.7588	0.7921	0.8382
AVG.	0.7630	0.7335	0.7712	0.8184
早期融合	0.7129	0.7205	0.7689	0.8424
晚期融合	0.4794	0.4272	0.6094	0.8173
AVG.	0.5962	0.5739	0.6892	0.8299
Ours	**0.9505**	**0.9464**	**0.9547**	**0.9672**

表6：包含不相关来源的数据集上的性能比较。

方法	4-ECK-2021				5-ECK-2022			
	AUROC	M-F1	W-F1	F1	AUROC	M-F1	W-F1	F1
USAD	**0.8845**	**0.8680**	0.8866	0.9146	0.7600	0.7112	0.7751	0.8295
LSTM-AE	0.6384	0.6491	0.7337	0.8636	0.5319	0.5213	0.6199	0.7143
TAnoGAN	0.7266	0.7584	0.8116	0.8932	0.6452	0.6101	0.6380	0.6837
AVG.	0.7498	0.7585	0.8106	0.8905	0.6457	0.6142	0.6777	0.7425
早期融合	0.7774	0.8127	0.8518	0.9118	0.5676	0.5799	0.8008	0.9092
晚期融合	0.8661	0.8456	0.9451	0.9686	0.8388	0.8515	0.9120	0.9476
AVG.	0.8218	0.8292	0.8985	0.9402	0.7032	0.7157	0.8564	0.9284
Ours	0.8016	0.8376	**0.9470**	**0.9727**	**0.9269**	**0.9274**	**0.9601**	**0.9761**

6.2.4 与不相关能源来源的性能比较

本节使用数据集（即 4-ECK-2021 和 5-ECK-2022）比较所提出模型与对比模型的性能，这些数据集均包含一种非相关能源。供热在这两个数据集中均为非相关能源，其余能源均为相关能源。表6展示了这些数据集上的性能比较结果。结果表明，根据 F1 分数，我们的模型较现有多模态学习模型提升了 0.41∼6.69%，较时间序列异常检测方法提升了 5.81∼29.24%。

通过比较各数据集上的性能，我们发现所提出的模型有两项关键优势。首先，与所有能源来源均相关的情况相比，我们的模型能够有效整合不相关能源来源，并进一步提升性能。具体而言，在

在数据集中加入不相关能源来源时，针对 4-ECK-2021 和 5-ECK-2022，模型的平均 F1 分数提高了 3.25∼23.36%；而在.....的情况下，模型提高了

2.67∼14.88%，适用于3-ECK-2021和4-ECK-2022；在这两种情况下，分别仅排除了4-ECK-2021和5-ECK-2022中的非相关能源。其次，我们验证了随着能源来源增加，所提出模型的可扩展性。具体而言，在由五种能源来源组成的5-ECK-2022数据集中，根据平均F1分数，我们的方法使对比模型的性能提升了4.77∼23.36%；而在由四种能源来源组成的4-ECK-2021中，性能提升了3.25∼8.22%。

表7：用于展示基于相关性的权重贡献影响的性能比较 n.

模型	5-ECK-2022			
	AUROC	M-F1	W-F1	F1
案例1	0.8074	0.8359	0.8659	0.9149
案例2	0.8717	0.7066	0.8336	0.8959
案例3	0.8644	0.8605	0.8957	0.9300
Ours	**0.9269**	**0.9274**	**0.9601**	**0.9761**

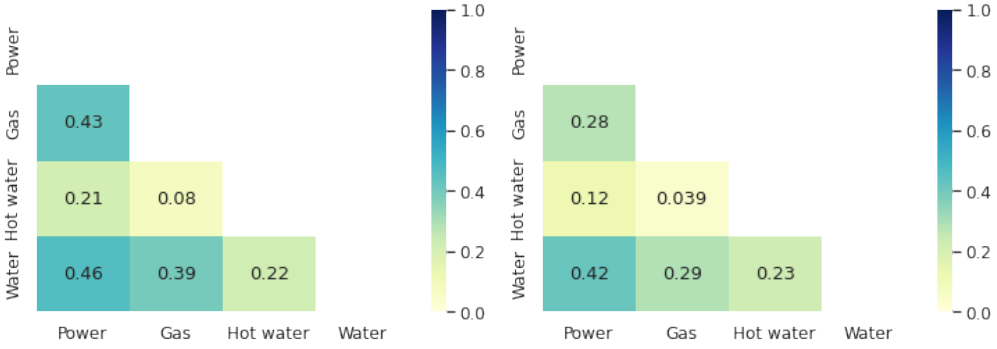

(a) 冬季 (b) 夏季

图 10：季节性数据的皮尔逊相关系数。

6.2.5 基于相关性的权重贡献的影响

我们研究了基于相关性的权重贡献在5-ECK-2022数据集上的有效性。我们按照第5.2.3节所述的相同方式设计了三个对比模型。表7展示了性能评估结果。我们提出的模型明显优于所有对比模型，表明该模型能够有效处理包括不相关的来源在内的多种能源来源，展现出其优势。

6.2.6 季节性数据集上的性能比较

在本节中，我们考虑季节性变化来衡量所提出模型的性能。我们注意到，能源来源之间的相关性会随季节而变化。如图10所示，冬季热水和燃气与电力的相关性高于夏季。这是因为冬季人们倾向于待在家中使用热水和燃气。

表 8 展示了 4-ECK-2022 季节性数据集上的性能。由于能源来源之间的相关性随季节变化，我们的模型根据相关性，反映出将能源来源整合到模型中的顺序。具体而言，在冬季，我们的模型首先通过早期融合整合燃气和热水，随后通过晚期融合纳入水和电力。相比之下，在夏季，模型先通过早期融合整合燃气和热水，再通过晚期融合整合电力和水。结果表明，在冬季和夏季数据集上，我们提出的模型始终优于所有对比模型，展现了模型的优越性。

为验证模型中融合策略的有效性，我们在 4-ECK-2022 上采用相同架构，通过改变融合策略进行实验。首先，对于基于全年数据相关性标注的数据集，我们构建了两个采用不同融合策略的模型，其相关性分别基于：1）所有季节的数据；2）冬季数据。这里，前者是所提出的模型，后者是对比模型。其次，对于基于冬季数据相关性标注的数据集，我们构建了两个采用不同融合策略的模型，其相关性分别基于：1）所有季节的数据；2）冬季数据。这里，后者是所提出的模型，前者是对比模型。表9展示了实验结果，清楚表明所提出的模型在两种情况下均优于对比模型。这证实了所提出的融合策略在多模态学习模型中的有效性。

(a) 冬季

方法	4-ECK-2022			
	AUROC	M-F1	W-F1	F1
USAD	0.7561	0.7276	0.7647	0.8149
LSTM-AE	0.6412	0.6130	0.6569	0.7174
TAnoGAN	0.7102	0.6775	0.7170	0.7705
早期融合	0.7079	0.7130	0.8008	0.8740
晚期融合	0.8993	0.8831	0.9023	0.9282
Ours	**0.9388**	**0.9366**	**0.9553**	**0.9709**

(b) 夏季

方法	4-ECK-2022			
	AUROC	M-F1	W-F1	F1
USAD	0.8656	0.8275	0.8711	0.9081
LSTM-AE	0.7085	0.6587	0.7283	0.7882
TAnoGAN	0.6962	0.7146	0.8088	0.8873
早期融合	0.7975	0.7859	0.8212	0.8689
晚期融合	0.8984	0.8819	0.9012	0.9273
Ours	**0.9187**	**0.8889**	**0.9056**	**0.9281**

表 8：季节性数据集上的性能比较。

表 9：不同融合策略在季节性数据集上的性能比较 .

标签标准	基于相关性融合策略	4-ECK-2022			
		AUROC	M-F1	W-F1	F1
所有季节 (4-ECK-2021)	冬季	0.9346	0.9329	0.9528	0.9693
	所有季节（拟议）	**0.9388**	**0.9366**	**0.9553**	**0.9709**
冬季 (4-ECK-2021)	所有季节	0.9135	0.9161	0.9346	0.9557
	冬季（本文提出）	**0.9505**	**0.9545**	**0.9464**	**0.9547**

表10：所提出模型在不同特征提取器上的性能。

模型	4-ECK-2022			
	AUROC	M-F1	W-F1	F1
USAD	0.8597	0.8199	0.8648	0.9031
提出的模型（USAD）	**0.9505**	**0.9464**	**0.9547**	**0.9672**
LSTM-AE	0.6443	0.6217	0.6567	0.7140
提出的模型（LSTM-AE）	**0.7547**	**0.7799**	**0.8182**	**0.8867**

6.2.7 特征提取器的变化

本节中，我们用 LSTM-AE 替换 USAD 作为特征提取器，以展示所提出模型的结构优势不受所用特征提取器模型的影响。 [11] 本实验使用了 4-ECK-2022。表10显示，与 USAD 的情况类似，基于 LSTM-AE 的模型显著优于 LSTM-AE，从而证实了我们模型的结构优势。

7 结论

本文提出了一种新的多模态学习模型，以有效整合多个能源来源。具体而言，我们根据能源来源之间相关性的强弱，提出了一种有效策略，将能源来源分层放置，并采用不同的融合方法（即早期融合和晚期融合）。主要策略是在模型的第一层中通过早期融合整合弱相关能源，然后在第二层中将强相关能源与早期融合的结果进行整合。我们还将所提出的方案推广至双层多模态学习模型，以涵盖更多能源来源。为此，我们将所提出的模型扩展为不仅整合相关能源，还整合不相关能源

并构建了三级多模态学习模型。在三级层中，我们通过使用根据相关性定义的带标注数据集，以监督方式训练该层，从而区分相关能源与不相关能源的权重贡献。通过在三个真实世界数据集上进行实验，我们清楚地展示了根据相关性在多层模型中放置能源来源的有效性。结果表明，我们提出的模型显著优于对比模型。特别是，我们还证明，随着相关与不相关能源来源数量的增加，所提出模型的性能会进一步提升。

本文中，由于能源消耗数据集缺少标注，我们无法使用真实异常数据集，因此提出了一种新方法，根据能源来源之间的相关性来定义异常能源消耗，其中包括异常。由此，我们能够定义一种考虑能源来源之间相关性的异常消耗，而这种异常无法仅通过单个能源的能源消耗发现。所提出模型的突出特点是，其融合策略可以推广到包括能源来源在内的任何类型的数据，因为模型不仅纳入相关来源，也纳入不相关的来源。因此，作为进一步研究，我们计划通过考察多个特征之间的差异相关性，将这一思路拓展到涉及多个特征的其他领域问题。

致谢

本研究得到韩国政府（科学技术信息通信部）资助的韩国国家研究基金会（NRF）项目（编号：2022R1F1A1067008）以及韩国国家研究基金会（NRF）资助的基础科学研究项目（教育部资助，编号：2019R1A6A1A03032119）的支持。

参考文献

[1] Xiaodu Yang、Xiuwen Yi、Shun Chen、Sijie Ruan、Junbo Zhang、Yu Zheng 和 Tianrui Li。你如何使用，就是什么样的人：在不同餐馆用户中识别燃气盗窃嫌疑人。载于第*29*届*ACM*信息与知识管理国际会议论文集，第2885–2892页，2020年。[2] Assia Maamar 和 Khelifa Benahmed。用于高级计量基础设施能源盗窃检测的机器学习技术。载于*2018*年国际软件工程与信息管理会议论文集，第57–62页，2018年。[3] Yassine Himeur、Khalida Ghanem、Abdullah Alsalemi、Faycal Bensaali 和 Abbes Amira。基于人工智能的建筑物能源消耗异常检测：综述、当前趋势与新视角。《应用能源》，287:116601，2021年。[4] Jui-Sheng Chou 和 Abdi Suryadinata Telaga。异常电力消耗的实时检测。《可再生与可持续能源评论》，33:400–411，2014年。[5] Abdelaziz Amara Korba、Nouredine Tamani、Yacine Ghamri-Doudane 等。用于检测智能电网高级计量基础设施中电力过载网络攻击的基于异常的框架。《计算机与安全》，96:101896，2020年。[6] Wongchai Anupong、R Azhagumurugan、Kishan Bhushan Sahay、Dharmesh Dhabliya、Ravi Kumar 和 D Vijendra Babu。面向高级计量基础设施智能电表高精度性能及智能电网新技术的研究。《可持续计算：信息学与系统》，35:100690，2022年。[7] Pierluigi Mancarella。多能源系统：概念与评估模型概述。《能源》，65:1–17，2014年。[8] Yu Weng、Ning Zhang 和 Chunlei Xia。基于多智能体的智慧校园能源消耗异常无监督检测。*IEEE Access*，7:2169–2178，2018年。[9] Yi Zhang、Weiwei Chen 和 Jason Black。用户侧能源消耗数据中的异常检测。载于*2011*年*IEEE*电力与能源学会全体会议，第1–8页。IEEE，2011年。[10] Hantao Wang、Chenghong Gu、Xin Zhang、Furong Li 和 Lihong Gu。识别本地能源系统中环境温度与燃气消耗之间的相关性。《中国电机工程学会电力与能源系统学报》，4(4):479–486，2018年。[11] Pankaj Malhotra、Anusha Ramakrishnan、Gaurangi Anand、Lovekesh Vig、Puneet Agarwal 和 Gautam Shroff。用于多传感器异常检测的基于长短期记忆网络的编码器—解码器。*arXiv*预印本 *arXiv:1607.00148*，2016年。[12] Yuening Li、Xiao Huang、Jundong Li、Mengnan Du 和 Na Zou。SpecAE：属性网络异常检测的谱自编码器。载于第*28*届*ACM*信息与知识管理国际会议论文集，第2233–2236页，2019年。

[13] R Dennis Cook。线性回归中强影响观测值的检测。Technometrics，19(1):15–18，1977年。[14] Genichi Taguchi、Yuin Wu 和 Subir Chodhury。马氏田口系统。麦格劳-希尔专业出版公司，2000年。[15] David A Belsley、Edwin Kuh 和 Roy E Welsch。回归诊断：识别强影响数据与共线性来源。约翰·威立父子公司，2005年。[16] Rutuja Umesh Madhure、Radha Raman 和 Sandeep Kumar Singh。基于卷积神经网络-长短期记忆网络的高级计量基础设施窃电检测器。载于2020年第11届国际计算、通信与网络技术会议（ICCCNT），第1–6页。IEEE，2020年。[17] Yanlin Peng、Yining Yang、Yuejie Xu、Yang Xue、Runan Song、Jinping Kang 和 Haisen Zhao。基于聚类和局部离群因子的高级计量基础设施窃电检测。IEEE Access，9:107250–107259，2021年。[18] Zhang Yu、Hua Xufeng、Sun Xueliang、Xue Yangyang 和 Tian Yunchen。基于密度聚类的水产养殖水体异常检测研究。载于2021年第7届国际计算与人工智能会议，第227–232页，2021年。[19] Sreerag Iyer、Snehal Thakur、Mihirraj Dixit、Rajneesh Katkam、Ashish Agrawal 和 Faruk Kazi。基于区块链和异常检测的废水再利用监管监测系统。载于2019年第10届国际计算、通信与网络技术会议（ICCCNT），第1–7页。IEEE，2019年。[20] Marco De Nadai 和 Maarten Van Someren。通过差分自回归移动平均模型和人工神经网络预测进行燃气消耗短期异常检测。载于2015年IEEE环境、能源与结构监测系统研讨会（EESMS）论文集，第250–255页。IEEE，2015年。[21] Mikel Lumbreras、Koldobika Martin-Escudero、Gonzalo Diarce、Roberto Garay-Martinez 和 Ruben Mulero。与区域供热网络相连的建筑物中供热能源需求模式识别的无监督聚类。载于2021年第6届智能与可持续技术国际会议（SpliTech），第1–5页。IEEE，2021年。[22] Sungwoo Park、Jihoon Moon 和 Eenjun Hwang。基于Shapley加性解释的区域供热可解释异常检测。载于2020年国际数据挖掘研讨会（ICDMW），第762–765页。IEEE，2020年。[23] Istvan Kiss、Béla Genge、Piroska Haller 和 Gheorghe Sebestyén。工业控制系统中基于数据聚类的异常检测。载于2014年IEEE第10届智能计算机通信与处理国际会议（ICCP），第275–281页。IEEE，2014年。[24] Mete Çelik、Filiz Dada,ser-Çelik 和 Ahmet ,Sakir Dokuz。使用DBSCAN算法检测温度数据中的异常。载于2011年智能系统与应用创新国际研讨会，第91–95页。IEEE，2011年。[25] Yingfu Huang 和 Qiurong Zhang。基于KNN与LOF组合算法的船舶异常行为识别。载于AIP会议论文集，第2073卷，第020090页。AIP Publishing LLC，2019年。[26] Chen Tao、Tianhao Li 和 Jiapeng Huang。用于新颖性与离群点检测的单类支持向量机核函数选择。载于2020年第2届机器学习、大数据与商业智能国际会议（MLBDBI），第116–120页。IEEE，2020年。[27] Efrem Heri Budiarto、Adhistya Erna Permanasari 和 Silmi Fauziati。使用k均值、局部离群因子和单类支持向量机进行无监督异常检测。载于2019年第5届科学与技术国际会议（ICST），第1卷，第1–5页。IEEE，2019年。[28] Md Abul Bashar 和 Richi Nayak。TAnoGAN：使用生成对抗网络进行时间序列异常检测。载于2020年IEEE计算智能研讨会系列（SSCI），第1778–1785页。IEEE，2020年。[29] Ian Goodfellow、Jean Pouget-Abadie、Mehdi Mirza、Bing Xu、David Warde-Farley、Sherjil Ozair、Aaron Courville 和 Yoshua Bengio。生成对抗网络。《ACM通讯》，63(11):139–144，2020年。[30] Dan Li、Dacheng Chen、Baihong Jin、Lei Shi、Jonathan Goh 和 See-Kiong Ng。MAD-GAN：利用生成对抗网络进行多变量时间序列异常检测。载于国际人工神经网络会议，第703–716页。施普林格，2019年。[31] Julien Audibert、Pietro Michiardi、Frédéric Guyard、Sébastien Marti 和 Maria A Zuluaga。USAD：多变量时间序列无监督异常检测。载于第26届ACM SIGKDD知识发现与数据挖掘国际会议论文集，第3395–3404页，2020年。[32] Chuanbo Hu、Minglei Yin、Bin Liu、Xin Li 和 Yanfang Ye。Instagram上的非法毒品贩运事件检测：一种深度多模态多标签学习方法。载于第30届ACM信息与知识管理国际会议论文集，第3838–3846页，2021年。

[33] Tadas Baltrušaitis、Chaitanya Ahuja 和 Louis-Philippe Morency。多模态机器学习：综述与分类学。*IEEE*模式分析与机器智能汇刊，41(2):423–443，2018。[34] Shahla Nemati 和 Ahmad Reza Naghsh-Nilchi。利用证据理论融合文本、音频和视觉模态，实现情感音乐视频检索。载于*2017*年第*3*届国际模式识别与图像分析会议（*IPRIA*），第222–228页。IEEE，2017。[35] Soujanya Poria、Erik Cambria、Newton Howard、Guang-Bin Huang 和 Amir Hussain。融合音频、视觉和文本线索，从多模态内容中进行情感分析。神经计算，174:50–59，2016。[36] Natalia Neverova、Christian Wolf、Graham Taylor 和 Florian Nebout。ModDrop：自适应多模态手势识别。*IEEE*模式分析与机器智能汇刊，38(8):1692–1706，2015。[37] Gang-Min Park、Hye-In Hyun 和 Hyuk-Yoon Kwon。基于视频、音频和聊天特征融合的多模态学习模型，用于检测电子竞技精彩片段。应用软计算，2022。[38] Qing Li、Jinghua Tan、Jun Wang 和 Hsinchun Chen。利用在线新闻进行股票预测的多模态事件驱动LSTM模型。*IEEE*知识与数据工程汇刊，33(10):3323–3337，2021。[39] Han-Sub Shin、Hyuk-Yoon Kwon 和 Seung-Jin Ryu。基于对比式词嵌入的新型文本分类模型，用于检测Twitter中的网络安全情报。电子学，9(9):1527，2020。[40] Pengkun Wang、Chuancai Ge、Zhengyang Zhou、Xu Wang、Yuantao Li 和 Yang Wang。用于子区域房价预测的联合门控协同注意力多模态网络。*IEEE*知识与数据工程汇刊，第1–1页，2021。[41] Haldun Akoglu。相关系数指南。《土耳其急诊医学杂志》，18(3):91–93，2018。[42] Pradeep K Atrey、M Anwar Hossain、Abdulmotaleb El Saddik 和 Mohan S Kankanhalli。多媒体分析中的多模态融合：综述。《多媒体系统》，16(6):345–379，2010。[43] Stanton A Glantz 和 Bryan K Slinker。应用回归与方差分析入门，第654卷。麦格劳-希尔公司，纽约，2001。[44] Richard M Heiberger、Richard M Heiberger 和 Burt Holland Burt Holland。统计分析与数据展示：一门包含*R*语言示例的中级课程。施普林格，2015。[45] Ling Yang 和 Shenda Hong。通过迭代双线性时间-频谱融合进行无监督时间序列表征学习。载于国际机器学习会议，第25038–25054页。PMLR，2022。[46] Emadeldeen Eldele、Mohamed Ragab、Zhenghua Chen、Min Wu、Chee Keong Kwoh、Xiaoli Li 和 Cuntai Guan。通过时间和上下文对比进行时间序列表征学习。*arXiv*预印本 *arXiv:2106.14112*，2021。[47] Scott M Lundberg 和 Su-In Lee。解释模型预测的统一方法。神经信息处理系统进展，30，2017。[48] Guolin Ke、Qi Meng、Thomas Finley、Taifeng Wang、Wei Chen、Weidong Ma、Qiwei Ye 和 Tie-Yan Liu。LightGBM：一种高效的梯度提升决策树。神经信息处理系统进展，30，2017。